

NOVI POSTUPCI PREDVIĐANJA ZA POTREBE ODRŽIVOG RAZVOJA

Jelena Milojković, Vančo Litovski
Elektronski fakultet u Nišu

Sadržaj – U ovom radu svojstvo veštačkih neuronskih mreža da generalizuju primenjeno je na interpolaciju i ekstrapolaciju. Pokazano je da je vrlo lako postići dobru interpolaciju, za razliku od ekstrapolacije, za koju je potrebno uložiti dodatne napore. Predložena je struktura veštačkih neuronskih mreža kao i set podataka za obuku iste, kojima se prevazilazi dati problem i omogućava predviđanje na kratke vremenske periode. Postupak je primenjen na predviđanje količina zastarelih računara.

1. UVOD

Tema održivog razvoja je jedna od najaktuelnijih danas. Mada se dugo smatralo da elektronika nije povezana sa uzročnicima problema održivog razvoja već da je bezuslovni pokretač društvenog razvoja, poslednjih godina suočavamo se sa nekim novim aspektima interakcije elektronike i prirodne okoline. Naime, vrlo velike količine proizvedenih elektronskih uređaja dolaze na kraj svog životnog veka i njihova obrada postaje ozbiljan društveni problem. Pri tome treba da se ima u vidu da jednostavno odlaganje elektronskog otpada na deponije nije dozvoljeno zbog hemijskog sastava materijala. Spaljivanje nekih od delova elektronskog otpada takođe je pod znakom pitanja s obzirom na otrovne gasove koji se razvijaju.


Na osnovu svega ovoga reciklaža elektronskog otpada postaje vitalna aktivnost za prevazilaženje problema koji nastaju na kraju životnog veka elektronske opreme. Reciklažni kapaciteti, naravno, predstavljaju kompleksne i skupe industrijske instalacije koje moraju da zadovoljavaju i specijalne norme pri transportu i rukovanju materijalima. Da bi one bile ekonomski održive, pre izgradnje, u fazi planiranja, neophodno je predvideti količine očekivanih materijala koji će biti obrađeni. Metodama predviđanja posvećen je ovaj rad.

U radu koji smo nedavno objavili [1], a koji se odnosi na modelovanje digitalno-analogne sprege u kolima sa mešovitim signalima dobili smo ubedljive rezultate koji potvrđuju da neuronske mreže mogu uspešno da ekstrapoliraju. Sada, mi tvrdimo da su veštačke neuronske mreže, budući univerzalni aproksimatori [2], [3], odlično sredstvo za postizanje dva cilja: obuhvatanje svojstava prirodne pojave koju trenutno razmatramo (interpolacija) i predviđanje njenog ponašanja u budućem vremenu (ekstrapolacija).

Rad je organizovan na sledeći način. Najpre ćemo se upoznati u kratkim crtama, sa neuronskim mrežama koje će biti upotrebljene za predviđanje tokom ovog rada. Zatim će biti prikazan primer primene neuronskih mreža za interpolaciju i ekstrapolaciju. Biće korišćeni podaci o količinama elektronskog otpada od računara za SAD. Objašnjenje osnovne ideje koja je ovde po prvi put prikazana kao i njena primena biće data u odeljku 3.

2. NEURONSKE MREŽE I PREDVIĐANJE

Na Sl. 1 je prikazana neuronska mreža koju ćemo koristiti za predviđanje. Ona ima samo jedan skriveni sloj, a to je dovoljno za ovakvu vrstu zadatka [4]. Strelicama je označen prenosni signal između neurona i to: oznake i , h i o , na ovoj slici, označavaju ulazni sloj, skriveni sloj, i izlazni sloj, respektivno. Vrednost pridružena strelici izražava činjenicu da je izlazni signal neurona iz prethodnog sloja pomnožen konstantom, (koja se ovde naziva težina i ima oznaku $w(i,j)$), pre nego što pobudi neuron u sledećem sloju. Tako, za set težina koje povezuju ulazni i skriveni sloj imamo: $i=1,2,\dots,n_h, j=1,2,\dots, n_o$.



Sl. 1. Potpuno povezana neuronska mreža sa jednim skrivenim slojem

Drugi parametar neurona koji utiče na obuku neuronske mreže je prag, koji se obeležava kao $\theta_{x,i}$, pri čemu se x odnosi na skriveni ili izlazni neuron, zavisno o kom sloju se radi. Neuroni iz ulaznog sloja su u stvari samo razvodnici signala, dok se oni iz skrivenog sloja aktiviraju sigmoidnom funkcijom.

Kada govorimo o algoritmu za učenje mreže, iskorišćena je jedna verzija algoritma najbržeg spusta [5]. Inicijalizacija problema je rešena u skladu sa [6]. Broj skrivenih neurona, n_h , predstavlja glavni problem. Da bi to uspešno odredili, primenjujemo postupak opisan u [1] koji je zasnovan na postupcima opisanim u [4], [7], [8] i [9].

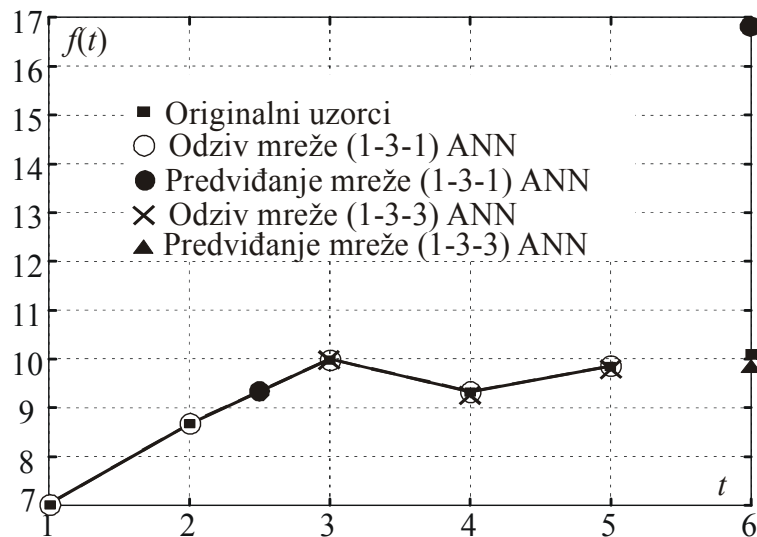
Pre nego što detaljnije izložimo kako se neuronske mreže mogu iskoristiti za predviđanje, razmotrićemo svojstvo generalizacije neuronskih mreža koje ćemo indirektno iskoristiti za naš metod. Neuronske mreže su bile intenzivno korišćene za aproksimaciju funkcija [10]. Način na koji se to uopštavanje prihvata, međutim, pomalo navodi na pogrešna očekivanja.

Uopštavanje se opisuje kao sposobnost da mreža prepozna, to jest, da tačno klasifikuje uzorke koje nikada ranije nije bila u mogućnosti da susretne. U stvari, predviđanje je u samoj prirodi neuroskih mreža. Ali, da li uopštavanje odnosno generalizacija, znači i tačno predviđanje?

Tabela 1. Podaci koji se koriste za obuku neuronske mreže

t	1	2	3	4	5
$f(t)$	7.03	8.67	10.0	9.33	9.85

Problem ćemo ilustrirati na primeru rezultata koji je prikazan na Sl. 2. Ovde je prikazan i set podataka za obuku koji je na slici predstavljen kao crni kvadratić. Brojčane vrednosti su date u Tabeli 1. koja je uzeta iz [11], gde su količine zastarelih računara računane tokom vremena. t predstavlja godinu umanjenu sa 1990, dok $f(t)$ predstavlja broj zastarelih računara godišnje, u SAD, izražen u milionima.



Sl. 2. Ilustracija rezultata koji su dobijeni obukom neuronske mreže. Interval za učenje je bio (1,5)


Tabela 2. Težine i pragovi za 1-3-1 ANN

j	$w_i(1,j)$	$\theta_{h,j}$	$w_o(j,1)$	$\theta_{o,1}$
1	7.42688	-4.96847	-4.46035	-3.07126
2	1.16715	1.93692	4.15149	
3	4.89878	-4.03203	7.12565	

Za aproksimaciju je iskorišćen jednostavni model neuronske mreže, sa jednim ulaznim, tri skrivena, i jednim izlaznim neuronom. Tu ćemo mrežu nazvati 1-3-1 ANN (Artificial Neural Network). Tabela 2. sadrži vrednosti za konstante: težine i pragove za 1-3-1 ANN koji su dobijeni posle obučavanja mreže.

Rezultat koji je dobijen posle obuke je prikazan na Sl. 2. kružićima.

Postignuto učenje mreže je bilo odlično. Da bi proverili svojstvo generalizacije, uvodimo dva nova (dosad neviđena) ulaza u neuronsku mrežu 1-3-1 ANN. Prvi je za $t=2.5$ i kao što vidimo (na slici je predstavljen kao crni kružić), generalizacija (interpolacija, predviđanje) je izvanredno. Takva generalizacija se može očekivati za bilo koji ulazni signal koji bi pripadao pomenutom intervalu (1-5). Takođe, to se može postići i nekom drugom aproksimativnom metodom, polinomnom, na primer. Ali, kod takve metode bi svako ekstrapoliranje bilo neuspešno. To se može videti za ulaznu vrednost $t=6$ gde nije postignuta generalizacija (ekstrapolacija, predviđanje) van aproksimativnog intervala. Isto se može očekivati i za druge aproksimacione metode.



Sl. 3. Mreža koja predviđa jedan interval u budućnosti i ponavlja sadašnji i raniji odziv

U daljem tekstu pokušaćemo da razjasnimo problem koji je nastao i izvršimo ekstrapolaciju koristeći pravilno strukturiranu neuronsku mrežu i odgovarajuću organizaciju podataka za obuku.

3. METOD I NJEGOVA IMPLEMENTACIJA

Konstrukcija odgovarajuće strukture neuronske mreže za rešavanje problema nelinearnih modela je opsežno proučena u literaturi [12], [13]. Ono što je nama važno je da se izvrši predviđanje, a ne generalizacija, tako da predložimo novu strukturu neuronske mreže i reorganizaciju podataka za obuku (ovi podaci su već prikazani u Tabeli 1.). Nova struktura je data na Sl. 3.

Kao što se može videti, iskorišćen je samo jedan ulazni signal. On predstavlja sadašnji trenutak (godina). Nametnuta su tri snopa izlaznih signala: snop signala koji predstavljaju prošlost, snop koji predstavlja sadašnjost (samo jedan signal) i snop signala koji predstavljaju budućnost. Radi pogodnosti na Sl. 3 grupe (snopovi) signala iz prošlosti i iz budućnosti su pred-

stavljene samo sa po jednim izlaznim priključkom. Set podataka za obuku je organizovan na novi način i prikazan u Tabeli 3.

Tabela 3. Prilagođeni set signala za obuku 1-2-3 ANN

t	2	3	4
$f(t)_{\text{prošlost}}$	7.03	8.67	10.0
$f(t)_{\text{sadašnjost}}$	8.67	10.0	9.33
$f(t)_{\text{budućnost}}$	10.0	9.33	9.85

Zapravo, tri vrednosti iz već postojećeg seta za obuku prikazanog u Tabeli 1. su predstavljene kao izlaz koji se uči: prošlost, sadašnjost i budućnost. To se ponavlja za svaki sukcesivni ulazni signal iz datog intervala. Težine i pragovi dobijeni posle obuke mreže su dati u Tabeli 4. Dva neurona u skrivenom sloju su bila dovoljna za aproksimaciju. Sada smo dobili novu mrežu koju smo nazvali 1-2-3 ANN.

Tabela 4. Težine i pragovi za 1-2-3 ANN

i	$w_i(1, i)$	$\theta_{h,i}$	$w_o(1, i)$	$w_o(2, i)$	$\theta_{o,i}$
1	3.83212	-1.39827	-0.170301	2.35469	-0.726043
2	2.59071	-0.413988	-2.78201	4.18158	-0.245994
3			1.68659	-2.47095	1.64923

Tabela 5. Odgovori neuronskih mreža

t	1	2	2.5	3	4	5	6
tip							
1-3-1 ANN	7.03	8.67	9.46	10.0	9.33	9.85	16.9
1-2-3 ANN				10.0	9.33	9.85	9.81

Glavni cilj restrukturiranja topologije neuronske mreže i ulaznih podataka je bio stvaranje tri funkcije koje zapravo aproksimiraju isto preslikavanje ali su samo pomerene u vremenu. Pretpostavljalo se da će se unutrašnje međuzavisnosti, koje određuju prirodu preslikavanja, na ovaj način mnogo bolje obuhvatiti i omogućiti veći uticaj podataka iz prošlog i sadašnjeg trenutka na predviđanje.

To je, po našem mišljenju, postignuto. Naime, izlazni signal $f(t)$ budućnost neuronske mreže 1-2-3 ANN, koji je dobijen posle obuke, može takođe videti na Sl. 2. obeležen sa crnim trouglicem. Jedno je sada sigurno, 1-2-3 ANN ne samo da dobro aproksimira (interpolira), već i odlično predviđa.

U Tabeli 5. su dati izlazni signali koji su se dobili posle obuke (to su signali iz obe mreže: i 1-2-3 ANN i 1-3-1 ANN). Treba primetiti da je 1-2-3 ANN dat samo izlazni signal $f(t)$ budućnost. Vrednost koju je trebalo predvideti je $f(6)=10.1$.

4. ZAKLJUČAK

Predložena je jedna struktura neuronskih mreža za predviđanje, kao i odgovarajući podaci za obuku mreže. Postupak je primenjen na predviđanju količina zastarele elektronske opreme od računara pri čemu su korišćeni podaci iz američkih izvora. Preliminarni rezultati koji su dobijeni su vrlo ohrabrujući.

LITERATURA

- [1] Litovski, V. B., Andrejević, M., Petković, P., Damper, R., "ANN Application to Modelling of the D/A and A/D Interface for Mixed-Mode Behavioural Simulation", Journal of Circuits, Systems and Computers, Vol. 13, No. 1, February 2004, pp. 181-192.
- [2] Scarselli, F., and Tsoi, A.C., "Universal approximation using feed-forward neural networks: A survey of some existing methods and some new results", Neural Networks, (Elsevier), Vol. 11, No. 1, 1998, pp. 15-37.
- [3] Hornik, K., Stinchcombe, M., and White, H., "Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks", Neural Networks, (Pergamon Press), Vol. 3, 1990, pp. 551-560.
- [4] Masters, T., "Practical Neural Network Recipes in C++", Academic Press, San Diego, 1993.
- [5] Zografski, Z., "A novel machine learning algorithm and its use in modeling and simulation of dynamical systems", Proceedings of 5th Annual European Computer Conference, COMPEURO'91, Bologna, Italy 1991, pp. 860-864.

- [6] Denoeux, T., and Lengelle, R., "Initializing back propagation networks with prototypes", Neural Networks (Pergamon Press), Vol. 6, 1993, pp. 351-363.
- [7] Huang, G.-B., and Babri, H. A., "Upper bound on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation function", IEEE Trans. on Neural networks, Vol. 9, No. 1, January 1998, pp. 224-228.
- [8] Baum, E.B., and Haussler, D., "What size net gives valid generalization", Neural Computing, Vol. 1, 1989, pp. 151-160.
- [9] Murata, N., Yoshizawa, S., Amari, S., "Network information criterion – Determining the number of hidden units for an artificial neural network model", IEEE Trans. on Neural networks, Vol. 5, No. 6, November 1994, pp. 865-872.
- [10] Rivals, I., and Personnaz, L., "Neural-network construction and selection in nonlinear modeling", IEEE Trans. on Neural networks, Vol. 14, No. 4, July 2003, pp. 804-819.
- [11] Matthews, H. S., McMichael, F. C., Hendrickson, C. T., Hart, D. J., "Disposition and End-of-Life Options for Personal Computers", Green Design Initiative Technical Report #97-10, Carnegie Mellon University, July 7, 1997
www.ce.cmu.edu/GreenDesign/comprec/NEWREPORT.PDF
- [12] Wang, Z., Di Massimo, C., Tham, M. T., and Julian Morris, A., "A procedure for determining the topology of multilayer feedforward neural networks", Neural Networks (Pergamon Press), Vol. 7, 1994, pp. 291-300.
- [13] Sietsma, J., and Dow, R.J.F., "Creating artificial neural networks that generalize", Neural Networks (Pergamon Press), Vol. 4, 1991, pp. 67-79.

Abstract – The generalization property of the artificial neural networks (ANNs) is considered and interpolation and extrapolation distinguished. It is shown that while good interpolation is easy achieved, a special effort is necessary in order to get extrapolation. Training set organization and ANN's structure is proposed that overcomes the problem and enables short term prediction. The method is implemented to prediction of quantities of obsolete computers.

NEW METHODS OF PREDICTION FOR SUSTAINABLE DEVELOPMENT

Jelena Milojković, Vančo Litovski