

GRAFIČKA INTERPOLACIJA JEDNOSLOJNIH I VISESLOJNIH NEURONSKIH MREŽA U MATRIČNOM LABORATORIJU

Pregledni članak

Mr.sci.Elvir Čajić, email: ecaajic86@gmail.com

Finra Tuzla, Elektrotehnička škola Tuzla

Damir Bajrić, profesor matematika i informatike, email: damir.bajric@gmail.com

OS“Vukovije“Vukovije, Kalesija

Sažetak: Ljudski mozak računa na posve različit način od konvencionalnih digitalnih računara. Neuroni su pet-šest redova veličine sporiji od digitalne logike. Postoje ljudske prirodne i umjetne neuronske mreže. Umjetne mreže su veoma slične ljudskom mozgu. U radu će biti prezentovani modeli neurona, matematički model i načini prikazivanja modela kroz simulaciju u programskom paketu Matlab. Matlab je programski paket –matrični laboratorij visokog nivoa koji sadrži skup alata koji omogućavaju korisniku da jednostavno i efikasno riješe određene probleme. Uzmajući u obzir mogućnosti Matlba mislimo da je idealno rješenje za interpolaciju umjetnih neuronskih mreža te načinima implementacije algoritama za učenje istih. Simulacijom smo došli do zaključka da je mreža sa dva sloja bolji izbor od one sa jednim. U radu takođe bit će predstavljena dva tipa neuronskih mreža pomoću funkcija ADALINE i NANR(linearna i nelinearna neuronska mreža). Različiti broj iteracija kod nelinearnih mreža dovest će nas do poboljšanja topologije mreže tj do poboljšanja izlaza iz neuronske mreže.

Ključne riječi: Neuron, neuronske mreže, matematički model, Matlab, simulacija

GRAPHIC INTERPOLATION OF SINGLE-LAYER AND MULTILAY NEURAL NETWORKS IN THE MATRIX LABORATORY

Abstract: Human brain counts in a completely different way from conventional digital computers. Neurons are five to six rows of size slower than digital logic. There are human natural and artificial neural networks. The artificial nets are very similar to the human brain. The model of neurons, the mathematical model and the simulation models in the Matlab program will be presented. Matlab is a suite of high-level math labs that contain a set of tools that enable the user to easily and efficiently solve certain problems. Taking into account Matlab's capabilities, we think it is an ideal solution for the implementation of artificial neural networks and the ways of implementing algorithms for learning them. By simulation, we came to the conclusion that the two-layer network is a better choice than the one with one. In the paper, two types of neural networks will be presented using ADALINE and NANR (linear and nonlinear nonlinear networks). Different number of iterations in nonlinear networks will lead to improvement of network topology up to improving output from the neural network.

Keywords: Neuron, Neural Networks, Mathematical Model, Matlab, Simulation.

1. UVOD

Akson, sinapsa i neuron osnovni su pojmovi za opis funkcionalnog načina rada bioloških neuronskih mreža. Akson je produženje živčane stanice mozga koji prenosi električne impulse nastale u tijelu stanice. Akson se putem sinapse spaja na dendrite drugih neurona i žlijezda. Sinapsa je mali razmak između završetka jednog neurona i dendrita ili tijela drugog neurona na kojoj se signal prenosi električnim putem. Neuron šalje električni impuls kroz akson kada je

doveden u stanje dovoljne pobude koje se postiže njegovim trenutnim stanjem, te uticajem signala drugih neurona preko njegovih dendrita ili tijela. Signali mogu biti smirujući ili pobudni. Sa aspekta matematike takvi signali su suprotnog predznaka. Prema procjeni mozak čovjeka ima preko 100 milijardi neurona koji su veoma složene strukture. Neuroni u mozgu komuniciraju preko neuronskih vlakana koje grade preko 100 trilijuna veza. Uprava ta mreža neurona je odgovorna za funkcije koje čovjek može da obavlja kao što su: učenje, razmišljanje, emocija, spoznaja, kao i izvođenje senzoričke i motorike autonomnih funkcija. Umjetni neuroni oponašaju osnovne funkcije bioloških neurona. Sa aspekta umjetnih neurona veoma značajnu ulogu igra perceptron. Perceptron je umjetni neuron koji se aktivira putem binarne funkcije definisan je matematičkim izrazom. Izlaz iz ovog neurona može poprimiti brojno stanje 0 neaktivan i 1 aktivan. U radu ćemo uz pomoć Matlaba prikazati način povezivanja od nekoliko destina do nekoliko stotina hiljada neurona. Kreirat ćemo neuronsku mrežu uz pomoć binarne aritmetike te prikazati simulaciju u Matlabu. Postavit ćemo matematički model neuronske mreže te opisati izlaz iz mreže uz pomoć povratne i nepovratne sprege neuronskih funkcija. Kreiranje algoritma za opisivanje rada neuronskih mreža bit će polazna osnova ovog rada. Dva su osnovna načina prikazivanja rada neuronskih mreža Hintov algoritam i grafički dijagram. Matlab kao laboratorijski alat ima mogućnost ugradnje sopstvenih funkcija i odličan izbor funkcija za grafičko sučelje što nas je navelo da se odlučimo za grafički prikaz simulacije rada neuronskih mreža.

Topologiju neuronske mreže činit će tri funkcije naseg algoritma, sinusna, sigomidna i Gaussova funkcija kroz linearni i nelinearni dinamički sistem. Linearni i nelinearni sistem ponašanja neuronskih mreža opisat ćemo diferencijalnim jednačinama prvog reda.

Kako su parcijelne diferencijalne jednačine prvog reda pretežno linearne diferencijalne jednačine čija se grafička interpolacija predstavlja pomoću linearnih funkcija u našem slučaju to je funkcija ADALINE, koja je sastavni dio matričnog laboratorija, mogućnost pravljenja grešaka u tim algoritmima je veoma mala.

Kada su pak u pitanju diferencijalne jednačine višeg reda ili nelinearne diferencijalne jednačine (dinamički sistemi), one su definisane za određena područja u kojima je moguće pronaći njihova rješenja. Uzmajući u obzir ograničenja i postavljanje diferencijalnih jednačina i njihovih parametara u navedenim područjima omogućava se ispravka signala tj, može doći do poboljšanja izlaza iz neuronskih mreža. Na kraju simulacija, moguća su određena odstupanja a kako je riječ o stohastičkim ili slučajnim procesima ograničili smo broj iteracija od 0-1000. To znači da će ponekad za poboljšanje rada neuronske mreže biti potrebno nekoliko stotina iteracija kako bih proces bio poboljšan. U našem radu mi smo poboljšanje dobili nakon 680 iteracije.

2. NEURONSKE MREŽE

Metoda umjetne inteligencije čija se struktura pravi prema ljudskom mozgu nazivamo neuronskim mrežama. Neuronske mreže pripadaju simboličkim metodama umjetne inteligencije zajedno sa genetičkim algoritmima i Fuzzy logikom. Postoji biološki pristup neuronskim mrežama i jako mnogo istraživanja na ovu temu, međutim ovaj rad je usmejen na simulaciju neuronske mreže putem računarskog softvera Matlab. Neuronske mreže mogu da

se tretiraju kao mreže za učenje, kao mreže za tehnološke sisteme za složenu obradu informacija.¹⁹⁷

Razlozi zašto neuronske mreže bolje funkcionišu nego statističke metode u radu sa složenim problemima leži u tome da mogućnosti neuronskih mreža su veće u pogledu analiziranja podataka sa smetnjama, te imaju mogućnost rješavanja problema koji nemaju jednostrano rješenje, te mogućnost učenja na podacima iz prošlosti. Zbog takvih uspjeha i prednosti neuronske mreže su pokazale uspjeh u predviđanjima različitih serija podataka koji imaju visok stepen variranja i fluktuacije. Od nedostataka za neuronske mreže možemo izdvojiti nedostatak testova statističkog značaja modela neuronskih mreža i procijenjenih parametara.¹⁹⁸

2.1. Osobine neuronskih mreža

Neuronska mreža sa matematičkog stajališta se može definisati kao nelinearna aproksimacija funkcija više varijabli. Obrada signala u neuronu se vrši matematičkim zapisom:

$$u = \sum \theta x$$

Ulazna funkcija koju neuronska mreža uči opisana je parovima ulaz-izlaz. Tokom procesa treniranja neuronska mreža mijenja stanje vrijednosti neurona težine i pragova, čime se postiže bolja aproksimacija i generalizacija ulazne funkcije.

Izlaz iz svakog neurona je definisan funkcijom:

$$y = \varphi(u - \theta)$$

Postoji nekoliko metoda za treniranje neuronskih mreža. U ovom radu predstaviti ćemo simulaciju za različitih broj uzoraka i metoda povratne i nepovratne sprege.

Primjena neuronskih mreža ima široku oblast istraživanja u slijedećim područjima: određivanje eksploziva na aerodromima, određivanje problema rada avio-motora, obrada signala, prepoznavanje govora, pretvaranje texta u govor, finansije, marketing i poslovanje.

Najvažnije osobine neuronskih mreža su: paralelna obrada informacija, redundantnost, učenje i adaptacija, viševarijabilni sistemi, univerzalni aproksimator.

3. MATEMATIČKI MODEL NEURONSKE MREŽE

Ulazne signale označavamo sa $x_1, x_2, \dots, x_n$.

Težine označavamo sa $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$.

Ulazni signali su Booleovi izlazi iz područja $\{0,1\}$. Matematička funkcija opsteg modela neuronskih mreža opisana je sa funkcijom [net] izrazom:

¹⁹⁷ Li, E.Y. (1994), *Artificial Neural Networks and Their Business Applications*, Information & Management, vol. 27, pp. 303-313

¹⁹⁸ Refenes, A.N., Zapranis, A., Francis, G. (1997), *Stock Performance Modeling Using Neural Networks: A Comparative Study with Regression Models*, Neural Networks, vol. 7, No. 2, pp. 375-388.

$$net = \varepsilon_1 x_1 + \varepsilon_2 x_2 + \dots + \varepsilon_n x_n - \theta$$

Često se odgovorno uzima da je vrijednost $\theta = -\varepsilon_0$ uz dodavanje ulaznog signala x_0 i fiksiranom vrijednosti 1 (aktivno stanje) pa se navedeni izlaz pise u obliku:

$$net = \varepsilon_0 x_0 + \varepsilon_1 x_1 + \varepsilon_2 x_2 + \dots + \varepsilon_n x_n = \sum_{i=0}^n \varepsilon_i x_i.$$

Prenosna funkcija data je sa :

$$y = f(\sum_{i=0}^n \varepsilon_i x_i) = f(net)$$

Ulazni sloj ili skriveni sloj naše simulacije u Matlabu predstavljat će sinusna funkcija $f = \sin(net)$, dok će izlazni sloj biti opisan bipolarnom sigmodinom funkcijom tkzv. logističkom funkcijom

$$y = \frac{2}{1 + e^{-net}} - 1.$$

Izlazna funkcija u tom slučaju za neurosnu mrežu data je sa : $y = \sin(net)$.

Funkcija sume net neurona dobija prvi indeks pripadnog sloja, te drugi indeks pripadnog sloja prema svakom neuronu izlaznog sloja, a računa se prema formuli :

$netA = \sum_{j=0}^L \varepsilon_{ij} y_j$. $i=1,2,\dots,K$, gdje je K broj neurona izlaznog sloja, tj. broj izlaza mreže. U našim simulacijama broj izlaza iz mreže biti će u rasponu od 10-40.

Modeli neurona imaju tri osnovne osobine i to skupove sinapsi tj. ulaza od kojih svako ima svoju jačinu, sumator za sabiranje otežanih ulaza i nelinearnu aktivacijsku funkciju (sinusna, logistička ili Gaussova funkcija na intervalu [0,1]).

Prikaza matematičkim modela neuronske mreže bit će pomoću orjentisanih grafika slično grafiku toka signala. Imat ćemo dvije vrste grana sinaptičke i aktivacijske grane.

Arhitektura ili topologija mreže određivat će načine na koji su neuroni međusobno povezani. Postoje 4 vrste mreža jednoslojne, višeslojne, mreže sa povratnim vezama i lejstvičaste mreže.

Uspjeh ili neuspjeh neuronske mreže kao i njena korist, tumači se pomoću dobijene greške na uzorku za validaciju. Najčešća greška koja se koristi prilikom preračunavanja neuronskih mreža jeste kroijen iz srednje kvadrane greške (root mean square error=:

$$\sigma = \sqrt{\frac{\sum_{i=1}^{n-1} (T_i - A_i)^2}{n}}$$

gdje je T_i - izračunati izlaz mreža, O_i željeni stvarni izlaz za slučajeve i i n broj slučajeva u uzorku neuronske mreže.

Dinamiku učenja neuronskih mreža jednostavnog linearnog dinamičkog člana prvog reda P1 treba pokazati generalizacijski osobine unaprijeđenih neuronskih mreža te uporediti učenje i testiranje naučenih neuronskih mreža sa različitim aktivacijskim funkcijama učenja.

Dinamika P1 člana opisuje se diferencijalnom jednačinom prvog reda :

$$Ax(t) + x(t)'' = K_p u(t).$$

gdje je A vremenska konstanta a K_p –konstanta pojačanja sistema.

Nelinearni haotični sistem opisan je pomoću Glass-Mackeyeveve nelinearne diferencijalne funkcije koja je data sa jednačinom :

$$\dot{x} = \frac{ax(t - \tau)}{1 + x^{10}(t - \tau)} - bx(t)$$

Gdje su: a i b parametri sistema a t je oznaka vremena. Parametri a i b bit ce odabrani proizvoljno u pogramskom paketu Matlab, a τ –je interval.

4. INTERPOLACIJA NEURONSKIH MREŽA U MATLABU


Programski paket Matlab predstavlja matrični laboratorij čije interaktivno okruženje korisniku omogućava numeričko i matrično računanje, vizualizaciju i programiranje dobijenih rezultata. Radi lakše implementacije algoritma učenja potrebno je matematički zapis neurOnskih mreža pretvoriti u matrični zapis. Funkcija net u matričnom zapisu ima oblik:

$$net_{A_j} = \sum_{i=1}^M a_{ji} * B_i$$


$$net_A = A * B^T$$

Gdje je A matrica težinskih koeficjenata skrivenog sloja dimenzija $[J-1*I]$, a B- matrica dimezija ulaza $[N*M]$, dok je matrica net_A dimnzija $[J*N]$, N-broj uzoraka ulaznog skipa podataka. Važno je prilikom formiranja matrica A i b u njih uključiti bias.


Za početak u nastavku slika 1 prikazuje grafički sistem prikaza neurona za mrežu od N=10 uzoraka:



Slika 1. Broj uzroaka neurona N=10.




Slika 2. Broj uzroaka neurona N=100.




Slika 3. Broj uzoraka neurona 1000.

Funkcije normalne raspodjele i gustine neurona pokretanjem simulacijskog paketa Matlab za uzorak od 10- 40 klasa aktivacijske funkcije net dato je sa :



Slika 4. Normalna raspodjela neurona za K=10 frekvencija



Slika 5. Normalna raspodjela i gustina simulacija za K=40 frekvencija.

Najjednostavnija aktivacijska funkcija za opsi i simulaciju u Matlabu jeste funkcija ADALINE za opisivanje umjetne neuronske mreže. Izlaz iz takve funkcije jednak je težinskoj sumi njegovih ulaza $f(\text{net}) = \text{net}$. Slika 6.

```
% define segments of time vector

dt = 0.02; % time step [seconds]

t1 = 0 : dt : 5; % first time vector [seconds]

t2 = 5+dt : dt : 8; % second time vector [seconds]

t = [t1 t2]; % complete time vector [seconds]

% define signal

y = [sin(5.1*pi*t1) .4*sin(4.3*pi*t2)];

% plot signal

plot(t,y,'-')

xlabel('Time [sec]');

ylabel('Target Signal');

grid on

ylim([-1.1 1.1])

p = con2seq(y);

inputDelays = 1:50; % delayed inputs to be used

learning_rate = 0.25; % learning rate

% define ADALINE

net = linearlayer(inputDelays,learning_rate);

[net,Y,E] = adapt(net,p,p);

% view network structure


view(net)

% check final network parameters


disp('Weights and bias of the ADALINE after adaptation')

net.IW{0};

net.b{1};
```



Slika 7. Linearna adaptivna mreža net= net linear view



Slika 8. Adaptivna linearna mreža greške i produktivnost mreže.


Nelinearne neuronske mreže u sistemu Matlab opisane su sa Mackey- Glass serijama neuronske mreže.

Matematički zapis :


$$\dot{y} = \frac{bx(t - \tau)}{1 + x^{10}(t - \tau)} - cx(t)$$

Unos paametara :


N=700, Nu=300, b=0.1;c=0.2; $\tau = 17$; korak 0.2 To=1s, 1-100 epoha.




Slika 9. Nanr mreža




Slika 10. Povratna sprega Nanr mreže




Slika 11. Izlaz iz Nanr mreže




Slika 12. Interpolacija nanr mreže




Slika 13. Best Validation Performance




Slika 14.Gradient




Slika 15.Error Histogram



Slika 16. Training and test nanr



Slika 17. Response of Output Element 1 for Time-Series 1



Slika 18. Autocorelation of Error 1

5. ZAKLJUČAK

Ovaj rad prikazao je načine simulacije neuronskih mreža linearnih i nelinearnih u programskom paketu Matlab. Prikazan je opšti pojam neurona, načini njihovog međusobnog povezivanja, te način simulacije i vizualizacije kako linearnih statičnih mreža tako i nelinearnih dinamičkih mreža. Za opis problema ovog rada koristili smo se matematičkim modelom i diferencijalnim jednačinama.

Nakon toga diferencijalne jednačine smo morali pretvoriti u matrični zapis radi lakšeg poduzimanja određenih mjera prilikom testiranja.

Prilikom testiranja mreža koristene su dvije vrste aktivacijskih funkcija sinusna i logistička funkcija. Na izlazu iz nelinearne dinamičke mreže koristeći se topologijom povratne sprege, regresione analize ispravili smo grešku mreže kako bi ona bila evidentno validna i spremna za krositenje. Dio simulacija počeo je od 1- 1000 iteracija u 1-100 epoha.

Za primjer haotičnog dinamičkog sistema uzet je Glass-Meckeyev nelinearni haotični sistem. Nakon snimanja u matričnom laboratoriju Matlab definisana je datoteka sa podacima za testiranje neuronske mreže. Može se zaključiti da je za rješavanje problema učenja i testiranja neuronskih mreža, mreža sa dva skrivena sloja puno bolji izbor od mreže sa jednim slojem. Sinusna aktivacijska funkcija je pokazala mnogo bolje rezultate za testiranje mreže od logističke ili sigmoidalne funkcije. Podešavanjem parametara koeficijenata moguće je postići i bolje rezultate.

6. LITERATURA

- [1] Li, E.Y. (1994), *Artificial Neural Networks and Their Business Applications*, Information & Management, vol. 27, pp. 303-313
- [2] Refenes, A.N., Zapranić, A., Francis, G. (1997), *Stock Performance Modeling Using Neural Networks: A Comparative Study with Regression Models*, Neural Networks, vol. 7, No. 2, pp. 375-388.
- [3] W. James, *The Principles of Psychology*, 1890.
- [4] Modelovanje i simulacije, numeričke metode A. Tokić, 2010, Numeričke metode matematike. Fet Tuzla
- [5] Inženjerska matematika, Radoslav Galić, Osijek 1998, Inženjerska matematika Fet Osijek.

- [6] W. McCulloch and W. Pitts, *A logical calculus of the ideas immanent in nervous activity*, Bulletin of Mathematical Biophysics 5, pp. 115-133, 1943. M. Brown, C. J. Harris, *Neurofuzzy adaptive modelling and control*, Prentice Hall, 1994.
- [7] J. S. Jang, C. T. Sun, E. Mizutani, *Neuro-Fuzzy and Soft Computing: Acomputational approach to learning and machine intelligence*, Prentice-Hall, Upper Saddle River, NJ 07458, 1997.
- [8] S. J. Russel, P. Norvig, *Artificial Intelligence - A Modern Approach*, Prentice Hall, Englewood Cliffs, New Jersey, 1995.
- [9] G. Chakraborty, “Genetic Algorithm Approaches to Solve Various Steiner Tree Problems“, *Steiner Trees in Industries*, Kluwer Academic, pp. 71-100, 2001.
- [10] C. T. Lin, G. Lee, *Neural Fuzzy Systems: A Neural-Fuzzy Synergism to Intelligent Systems*, Prentice-Hall Inc., NJ, 1996.
- [11] M. Dorigo, G. Di Caro, “Ant colony optimization: a new meta-heuristic”, Proceedings of the 1999 Congress on Evolutionary Computation, 1999. Vol. 2, Washington, DC, USA.
- [12] W.S. McCulloch, W. Pitts, “A logical calculus of the ideas immanent innervousactivity”, *Bulletin of mathematical biophysics* 5, pp. 115-133, 1943
- [13] G. F. Luger, *Artificial Intelligence-Structures and Strategies for Complex Problem Solving*, Addison-Wesley, 2005.
- [14] P. Simpson, *Artificial neural system*, Pergamon, Elmsford, NY, 1990.
- [15] S. Haykin, *Neural networks - a*

