

Dinamička neuronska mreža u regulaciji stupnja istrošenosti reznog alata

Rajaković, Marko

Undergraduate thesis / Završni rad

2014

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:219692>

Rights / Prava: [In copyright/Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-07-27**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Marko Rajaković

Zagreb, 2014.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentor:

Doc. dr. sc. Danko Brezak

Student:

Marko Rajaković

Zagreb, 2014.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem svima koji su na ikoji način doprinijeli mom obrazovanju i pisanju ovog rada.

Marko Rajaković



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite

Povjerenstvo za završne ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu	
Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

ZAVRŠNI ZADATAK

Student:

Marko Rajaković

Mat. br.: 0035168531

Naslov rada na
hrvatskom jeziku:

**Dinamička neuronska mreža u regulaciji stupnja istrošenosti reznog
alata**

Naslov rada na
engleskom jeziku:

Application of recurrent neural network in the tool wear control

Opis zadatka:

Kvalitetan nadzor i regulacija stupnja istrošenosti reznih alata predstavljaju najvažnije komponente u razvoju inteligentnih alatnih strojeva s neposrednim utjecajem na sigurnost, kvalitetu i produktivnost obradnog procesa. I dok je u posljednjih 30-ak godina učinjen znakoviti napor na području nadzora trošenja, razvoj algoritama adaptivnog upravljanja prema kriteriju istrošenosti praktički je tek na početku zbog nepostojanja preciznijih i robusnijih estimatora trošenja. Stoga je cilj ovog rada analizirati primjenu dinamičke neuronske mreže u filtriranju odziva estimatora stupnja istrošenosti, a u cilju smanjenja estimacijske pogreške i time postizanja kvalitetnijeg odziva regulacijskog kruga.

U radu je potrebno:

- Izraditi programsku podršku za troslojnu dinamičku neuronsku mrežu učenu primjenom EBP algoritma, koja u strukturi skrivenog sloja ima dinamičke neurone 2. reda.
- Proširiti model skrivenog sloja s dinamičkim neuronima višeg reda.
- Generirati odzive mreže primjenom nekoliko testova koji obuhvaćaju različite dinamike trošenja reznih alata.
- Usporediti dobivene rezultate i izvesti zaključke rada.

Zadatak zadan:

11. studenog 2013.

Rok predaje rada:

1. rok: 21. veljače 2014.
2. rok: 12. rujna 2014.

Predvideni datumi obrane:

1. rok: 3., 4. i 5. ožujka 2014.
2. rok: 22., 23. i 24. rujna 2014.

Zadatak zadao:

Doc(dr.sc.) Danko Brezak

Predsjednik Povjerenstva:

Prof. dr. sc. Zoran Kunica

SADRŽAJ

SADRŽAJ.....	I
POPIS SLIKA	II
POPIS TABLICA.....	III
POPIS OZNAKA	IV
SAŽETAK.....	VI
SUMMARY	VII
1. UVOD	1
2. NEURONSKE MREŽE	2
2.1. Biološki i umjetni neuron	3
2.2. Umjetne neuronske mreže	4
3. DINAMIČKE NEURONSKE MREŽE	5
4. MODEL DINAMIČKE NEURONSKE MREŽE.....	6
4.1. Učenje dinamičke neuronske mreže	8
4.1.1. Unaprijedna faza učenja dinamičke mreže	9
4.1.1.1. Skriveni sloj	9
4.1.1.2. Izlazni sloj.....	9
4.1.2. Povratna faza učenja dinamičke neuronske mreže	9
4.1.2.1. Promjena težina izlaznog sloja	10
4.1.2.2. Promjena parametara učenja sakrivenog sloja.....	10
4.1.2.3. Promjena parametara učenja ulaznog sloja.....	14
4.2. Ocjena uspješnosti algoritma učenja	16
4.3. Testiranje mreže	16
5. ZAKLJUČAK	24
PRILOZI.....	26

POPIS SLIKA

Slika 1. Regulacijski model stupnja istrošenosti alata [1].....	1
Slika 2. Pojednostavljena struktura biološkog neurona	3
Slika 3. Struktura umjetnog neurona [3]	4
Slika 4. Model dinamičkog neurona [3]	5
Slika 5. Sigmoidalna aktivacijska funkcija skrivenog sloja neuronske mreže.....	6
Slika 6. Model dinamičke neuronske mreže [3].....	7
Slika 7. Postupak učenja dinamičke mreže [3].....	8
Slika 8. NRMS učenja.....	17
Slika 9. Odaziv mreže na datoteku učenja	18
Slika 10. Odaziv mreže na test	19
Slika 11. Datoteka učenja.....	20
Slika 12. Odaziv mreže na test 7 s pretreniranim parametrima (gore) i mreže s najboljim rezultatima (dolje)	23

POPIS TABLICA

Tablica 1. Razlike između digitalnog računala i ljudskog mozga.....	2
Tablica 2. Usporedba obrade podataka kod konvencionalnog računala i neuronske mreže.....	3
Tablica 3. Postavke testirane mreže	17
Tablica 4. Parametri testova	19
Tablica 5. Testirane mreže s tri ulazna neurona	20
Tablica 6. Testirane mreže s pet ulaznih neurona	21
Tablica 7. Testirane mreže s sedam ulaznih neurona	21
Tablica 8. Rezultati testova nakon 10000 koraka učenja (pretrenirana mreža) i 101 koraka (najbolji odziv)	22

POPIS OZNAKA

$A(z)$	nazivnik impulsne prijenosne funkcije dinamičkog neurona
$B(z)$	brojnik impulsne prijenosne funkcije dinamičkog neurona
$D_{a_{tj}}$	parametar promjene a_t koeficijenta j-og dinamičkog neurona
$D_{b_{tj}}$	parametar promjene b_t koeficijenta j-og dinamičkog neurona
$D_{v_{ji}}$	parametar promjene težina između ulaznog i skrivenog sloja
O_k	k-ti izlaz neuronske mreže
Z_i	i-ti ulaz neuronske mreže
a_{tj}	t-ti koeficijent nazivnika prijenosne funkcije dinamičkog člana j-og dinamičkog neurona
b_{tj}	t-ti koeficijent brojnika prijenosne funkcije dinamičkog člana j-og dinamičkog neurona
d_k	željena vrijednost k-og izlaza neuronske mreže
u_j	vrijednost j-og ulaza neurona
v_{ji}	težinski koeficijent između j-og neurona skrivenog sloja i i-tog neurona ulaznog lsoja
w_j	težinski koeficijent j-og ulaza neurona
w_{kj}	težinski koeficijent veze između k-og neurona izlaznog sloja i j-tog neurona skrivenog sloja
\tilde{y}	izlaz dinamičkog člana dinamičkog neurona
\bar{y}	ulaz aktivacijske funkcije dinamičkog neurona
$\tilde{y}(n - t)$	izlaz dinamičkog člana dinamičkog neurona u $(n - t)$ koraku
y_j	vrijednost izlaza j-og neurona skrivenog sloja
$z^{-i}[net(n)]$	operator linearnog pomaka
σ_{d_n}	standardna devijacija željenih vrijednosti izlaza mreže
Δ	iznos promjene težina u jednom koraku
∇E	gradijent pogreške
$BIAS$	neuron bez ulaza s konstantnom izlaznom vrijednosti jednakom 1
E	funcija cilja (suma kvadrata pogrešaka)
I	broj neurona ulaznog sloja mreže
J	broj neurona skrivenog sloja mreže
K	broj neurona izlaznog sloja mreže
MS	srednja kvadratna pogreška
$NRMS$	normalizirani korijen srednje kvadratne pogreške – mjera točnosti
RMS	korijen srednje kvadratne pogreške
net_{Hj}	vrijednost funkcije sume j-og neurona skrivenog sloja
$net_{Hj}(n - t)$	vrijednost funkcije sume j-og neurona skrivenog sloja u $(n - t)$ koraku
net_{Ok}	vrijednost funkcije sume k-og neurona izlaznog sloja

net	vrijednost funkcije sume
rf	red filtra dinamičkog sloja neuronske mreže
x	vektor ulaznih vrijednosti (značajki) uzoraka skupa za učenje
y	vektor izlaza neurona
α	vrijednost momentuma
γ	aktivacijska funkcija neurona
γ'	derivacija aktivacijske funkcije neurona
η	koeficijent brzine učenja

SAŽETAK

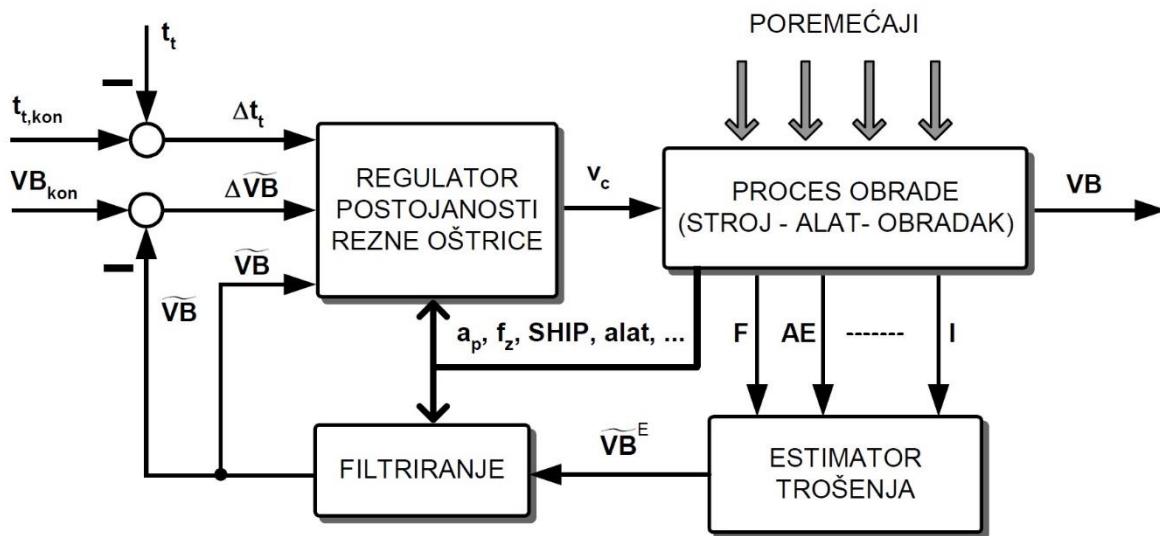
U ovom završnom radu opisana je struktura i način funkcioniranja umjetnih neuronskih mreža, te njihova povezanost s biološkim neuronskim mrežama. Zatim je opisan dinamički neuron i struktura dinamičke neuronske mreže. Neuronska mreža u strukturi skrivenog sloja ima dinamičke neurone drugog, četvrtog ili šestog reda, a učena je metodom povratnog rasprostiranja pogreške (eng. error back-propagation). Radi ubrzanja učenja u mrežu je dodan momentum prvog reda. Kasnije se funkcionalnost mreže testira na proporcionalnom članu prvog reda i mreža se testira u svrhu filtriranja odaziva estimatora trošenja reznih alata.

SUMMARY

This paper describes the structure and the operating principle of artificial neural networks, as well as their link to biological neural networks. The structures of a basic dynamic neuron and a dynamic network are defined. The network's hidden layer contains either second, fourth or sixth order dynamic neurons. The network is trained via the error backpropagation method and the training speed is increased with the use of a first order momentum. The network's functionality is tested using a first order proportional controller and later for the purpose of filtering the response of a cutting tool wear estimator.

1. UVOD

Automatska strojna obrada u mnogim proizvodnim industrijama postaje neophodna zbog rastućeg zahtjeva smanjenja troškova proizvodnje. Veliki materijalni i vremenski gubici, nastali radi istrošenosti reznih alata, mogu se izbjegći automatskom detekcijom trošenja alata. Ovime se smanjuje se rizik pucanja alata, a samim time i oštećenje obratka ili alatnog stroja. Preciznim predviđanjem trošenja, podešavanjem položaja te zamjenom istrošenih alata osigurava se zadovoljavajuća kvaliteta obrade. I dok je u posljednjih 30-ak godina učinjen znakovit napor na području nadzora trošenja, razvoj algoritama adaptivnog upravljanja prema kriteriju istrošenosti praktički je tek na početku zbog nepostojanja preciznijih i robusnijih estimatora trošenja. Stoga je cilj ovog rada analizirati primjenu dinamičke neuronske mreže u filtriranju odaziva estimatora stupnja istrošenosti, u cilju smanjenja estimacijske pogreške i time postizanje kvalitetnijeg odaziva regulacijskog kruga [Slika 1].



Slika 1. Regulacijski model stupnja istrošenosti alata [1]

2. NEURONSKE MREŽE

Digitalna računala svakodnevno obrađuju ogromnu količinu podataka, zapravo sva automatizirana obrada obrađuje se računalom. No to je i dalje tek malen dio podataka naspram onih koji se iz sekunde u sekundu obrađuju u mozgovima živih bića.

Kako ljudski mozak sadrži maksimum inteligencije koju danas poznajemo. Čovjek pokazuje kreativnost koja se očituje u sposobnosti izbora ispravnih hipoteza, stjecanje iskustava i vođenja tih iskustava na temelju logičkih pravila. Čovjek je osim toga sposoban učiti koristeći se različitim strategijama. Učenje je jedan od najbitnijih aspekta umjetne inteligencije koji sustavu omogućava da obavlja promjene nad samim sobom. Stoga je opravdano smatrati da sustav koji uspješno oponaša rad ljudskog mozga bi isto tako bio intelligentan. Danas znamo da se ljudski mozak sastoji od velikog broja neurona koji pri obradi različitih vrsta informacija rade paralelno. Dok konvencionalna računala rade sekvencijalno (von Neumannova arhitektura).

Tablica 1. Razlike između digitalnog računala i ljudskog mozga

atribut	mozak	računalo
tip elementa za procesuiranje	neuron (100 različitih vrsta)	bistabil
brzina prijenosa	2 ms ciklus	ns ciklus
broj procesora	oko 10^{11}	10 ili manje
broj veza među procesorima	$10^3 - 10^4$	10 ili manje
način rada	serijski, paralelno	serijski
signali	analogni	digitalni
informacije	ispravne i neispravne	ispravne
pogreške	ne fatalne	fatalne
redundancija	stotine novih stanica	eventualno rezervni sustav

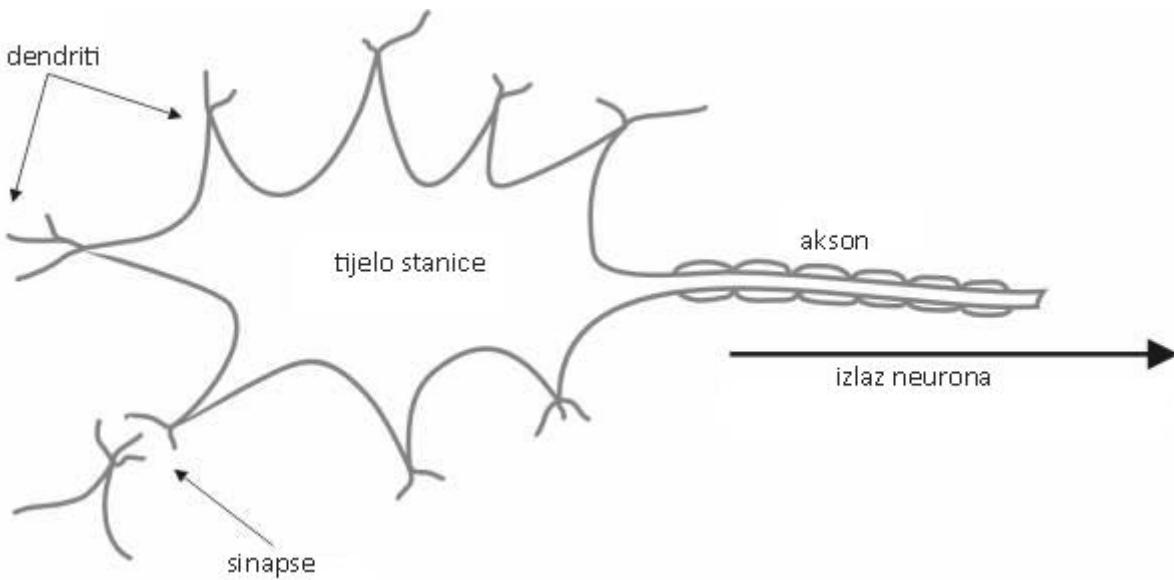
Ipak možemo se koristiti i konvencionalnim računalima pri implementaciji umjetne neuronske mreže, odbacujući pri tome formalizam rješavanja problema putem algoritama, odnosno manipulacije simbola po definiranim pravilima. Na taj se način nalazimo u hibridnom području u kojem sekvencijalni stroj tek imitira neuronsku mrežu kao visoko paralelnu arhitekturu.

Tablica 2. Usporedba obrade podataka kod konvencionalnog računala i neuronske mreže

von Neumann	neuronska mreža
Računalu se unaprijed detaljno mora opisati algoritam u točnom slijedu koraka (program)	Neuronska mreža uči samostalno ili s učiteljem
Podaci moraju biti precizni, nejasni podaci ne obrađuju se adekvatno	Podaci ne moraju biti precizni (gotovo uvijek su neprecizni)
Arhitektura je osjetljiva kod uništenja nekoliko memorijskih ćelija računalo ne funkcioniра	Obrada i rezultat ne mora puno ovisiti o pojedinačnom elementu mreže
Postoji eksplicitna veza između varijabli, brojeva, zapisa u bazi i sklopoljja računala preko pokazivača na memoriju	Pohranjeno znanje je implicitno, ali ga je teško interpretirati

2.1. Biološki i umjetni neuron

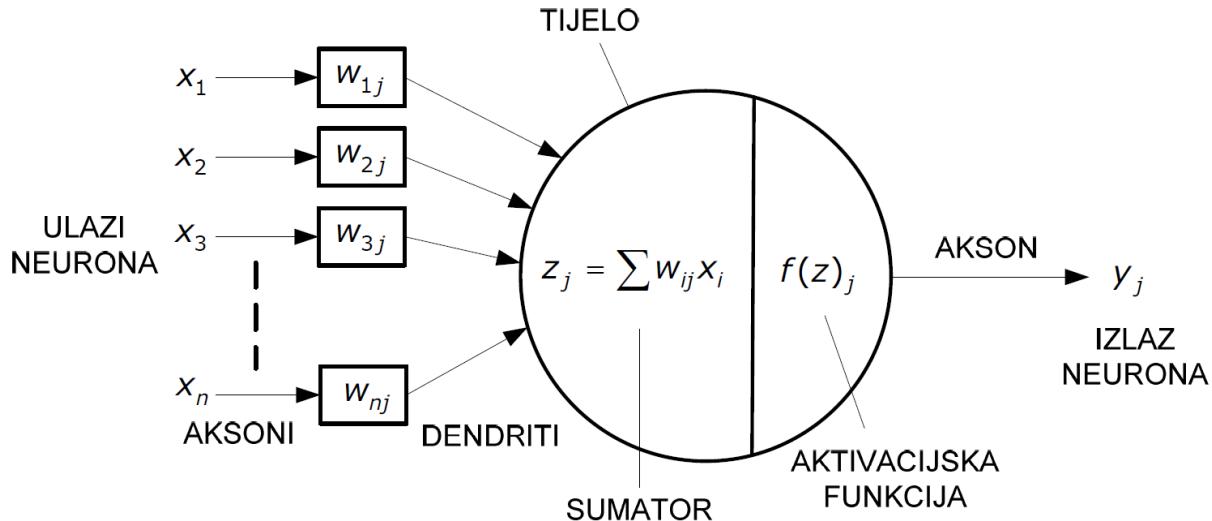
Četiri su osnovna djela neurona: tijelo stanice, skup dendrita, akson. prikazuje građu pojednostavljenog biološkog neurona [Slika 2].



Slika 2. Pojednostavljena struktura biološkog neurona

Tijelo stanice sadrži informaciju predstavljenu električnim potencijalom između unutrašnjeg i vanjskog dijela stanice (oko $-70mV$ u neutralnom stanju). Na sinapsama, spojnom sredstvu dvaju neurona kojim su pokriveni dendriti, primaju se informacije od drugih

neurona u obliku post-sinaptičkog potencijala koji utječe na potencijal stanice povećavajući (hiperpolarizacija) ili smanjivajući ga (depolarizacija). U tijelu stanice sumiraju se sinaptički potencijali tisuća susjednih neurona. Ako ukupan napon pređe određeni prag, neuron postane aktiviran i generira akcijski potencijal u trajanju od $\sim 1ms$. Kada se informacija akcijskim potencijalom prenese do završnih članaka, oni ovisno o veličini potencijala proizvode i otpuštaju kemikalije (neurotransmitere). To se zatim ponavlja u dalnjim neuronima [2].



Slika 3. Struktura umjetnog neurona [3]

Umjetni neuron [Slika 3] je dizajniran s idejom da oponaša biološki. Tijelo neurona zamjenjuje se sa sumatorom, ulogu dendrita preuzimaju ulazi u sumator, uzlaz iz sumatora je akson, a ulogu praga osjetljivosti obavlja aktivacijska funkcija. Ulogu sinaptičkih veza biološkog neurona s njegovom okolinom, preuzimaju težinski faktori kod umjetnog neurona.

2.2. Umjetne neuronske mreže

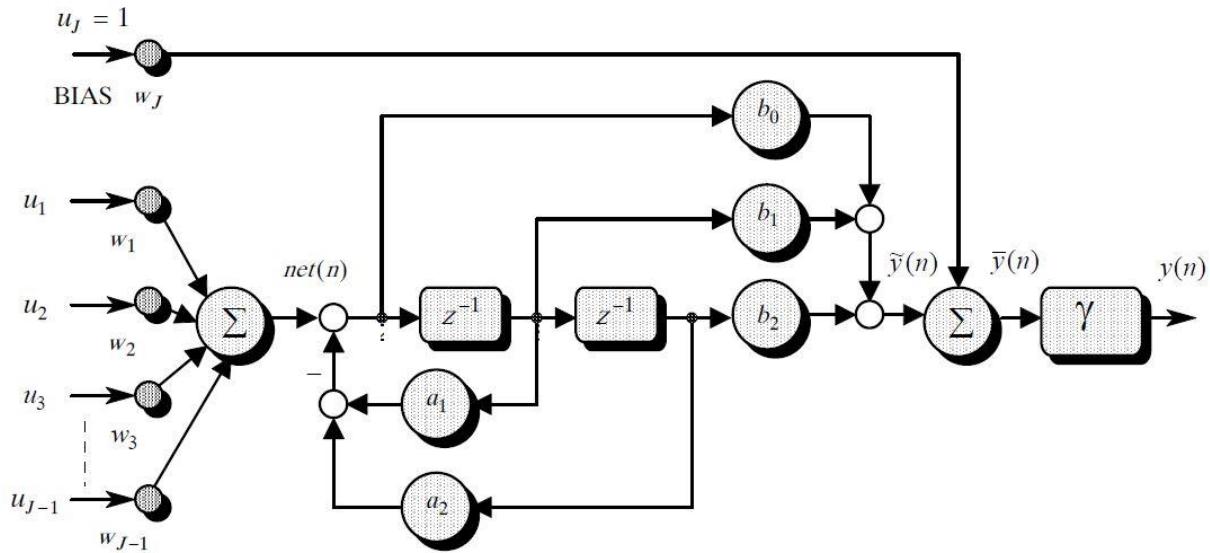
Kao što se ljudski mozak sastoji od bioloških neurona, tako se umjetna neuronska mreža sastoji od umjetnih neurona. Neuronske mreže su sastavljene od paralelnih slojeva neurona, pri čemu su jednoslojne mreže sastavljene samo od ulaznog i izlaznog sloja. Višeslojne mreže dodatno imaju skrivene slojeve koji se nalaze između ulaznog i izlaznog sloja i nisu direktno povezani s okolinom. S obzirom na smjer putovanja signala, mreže se dijele na unaprijedne (eng. feedforward neural networks) ili na povratne (eng. feedback ili recurrent neural networks).

Prema načinu učenja dijelimo ih na: mreže koje uče po uzorku i mreže koje uče po skupu podataka. Mreže mogu učiti s učiteljem (nadgledano učenje) ili bez učitelja (nenadgledano učenje).

Prema zavisnosti o vremenskim parametrima, neuronske mreže dijelimo na: staticke i dinamičke.

3. DINAMIČKE NEURONSKE MREŽE

Osnovna ideja koncepta dinamičkog neurona je dodavanje dinamike ispred aktivacijske funkcije, tako da aktivnost neurona bude u funkciji stanja neurona [3]. Ugradnja modela ARMA – filtera (Auto Regressive Moving Average) ispred aktivacijske funkcije neurona [Slika 4] omogućuje djelovanje dinamičkog neurona na osnovu ulaznih signala ($u_j, u_j(n-1), u_j(n-2)$) i prethodno dobivenih vrijednosti izlazne veličine dinamičkog člana dinamičkog neurona ($\tilde{y}(n-1), \tilde{y}(n-2)$).



Slika 4. Model dinamičkog neurona [3]

Oznake (n) , $(n-1)$, $(n-2)$, $(n+1)$ nam govore o vrijednosti promatrane varijable u promatranom koraku (n) , pa je tako $(n-1)$ u prethodnom koraku, $(n-2)$ dva koraka prije tekućeg i $(n+1)$ za slijedeći korak [3].

Ulaz u dinamički član je $net(n)$ te rezultira:

$$net(n) = \sum_{j=1}^{J-1} w_j u_j . \quad (1)$$

Izlaz iz dinamičkog člana [Slika 4] s dva pola i dvije nule dobiva se korištenjem vremenskih pomaka signala ulaza i izlaza:

$$G(z) = \frac{B(z)}{A(z)} = \frac{\tilde{y}(z)}{net(z)} = \frac{b_0 + b_1 z^{-1} + b_2 z^{-2}}{1 + a_1 z^{-1} + a_2 z^{-2}} \quad (2)$$

Izvedeno iz impulsne prijenosne funkcije (2), prema slici 4:

$$\tilde{y}(z) = b_0 net(z) + b_1 net(z)z^{-1} + b_2 net(z)z^{-2} - a_1 \tilde{y}(z)z^{-1} - a_2 \tilde{y}(z)z^{-2} , \quad (3)$$

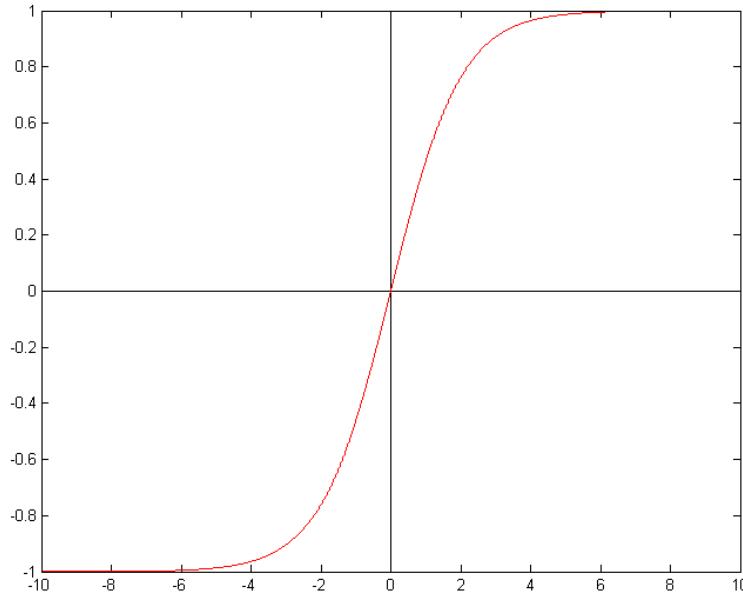
odnosno:

$$\begin{aligned} \tilde{y}(n) = & b_0 net(n) + b_1 net(n-1) + b_2 net(n-2) - a_1 \tilde{y}(n-1) \\ & - a_2 \tilde{y}(n-2) . \end{aligned} \quad (4)$$

Prema slici 4 izlaz dinamičkog neurona zbraja se s Bias neuronom:

$$\bar{y}(n) = \tilde{y}(n) + w_j. \quad (5)$$

Dalje rezultate odrađuje aktivacijska funkcija za koju smo odabrali da je sigmoidalna funkcija [Slika 5]:



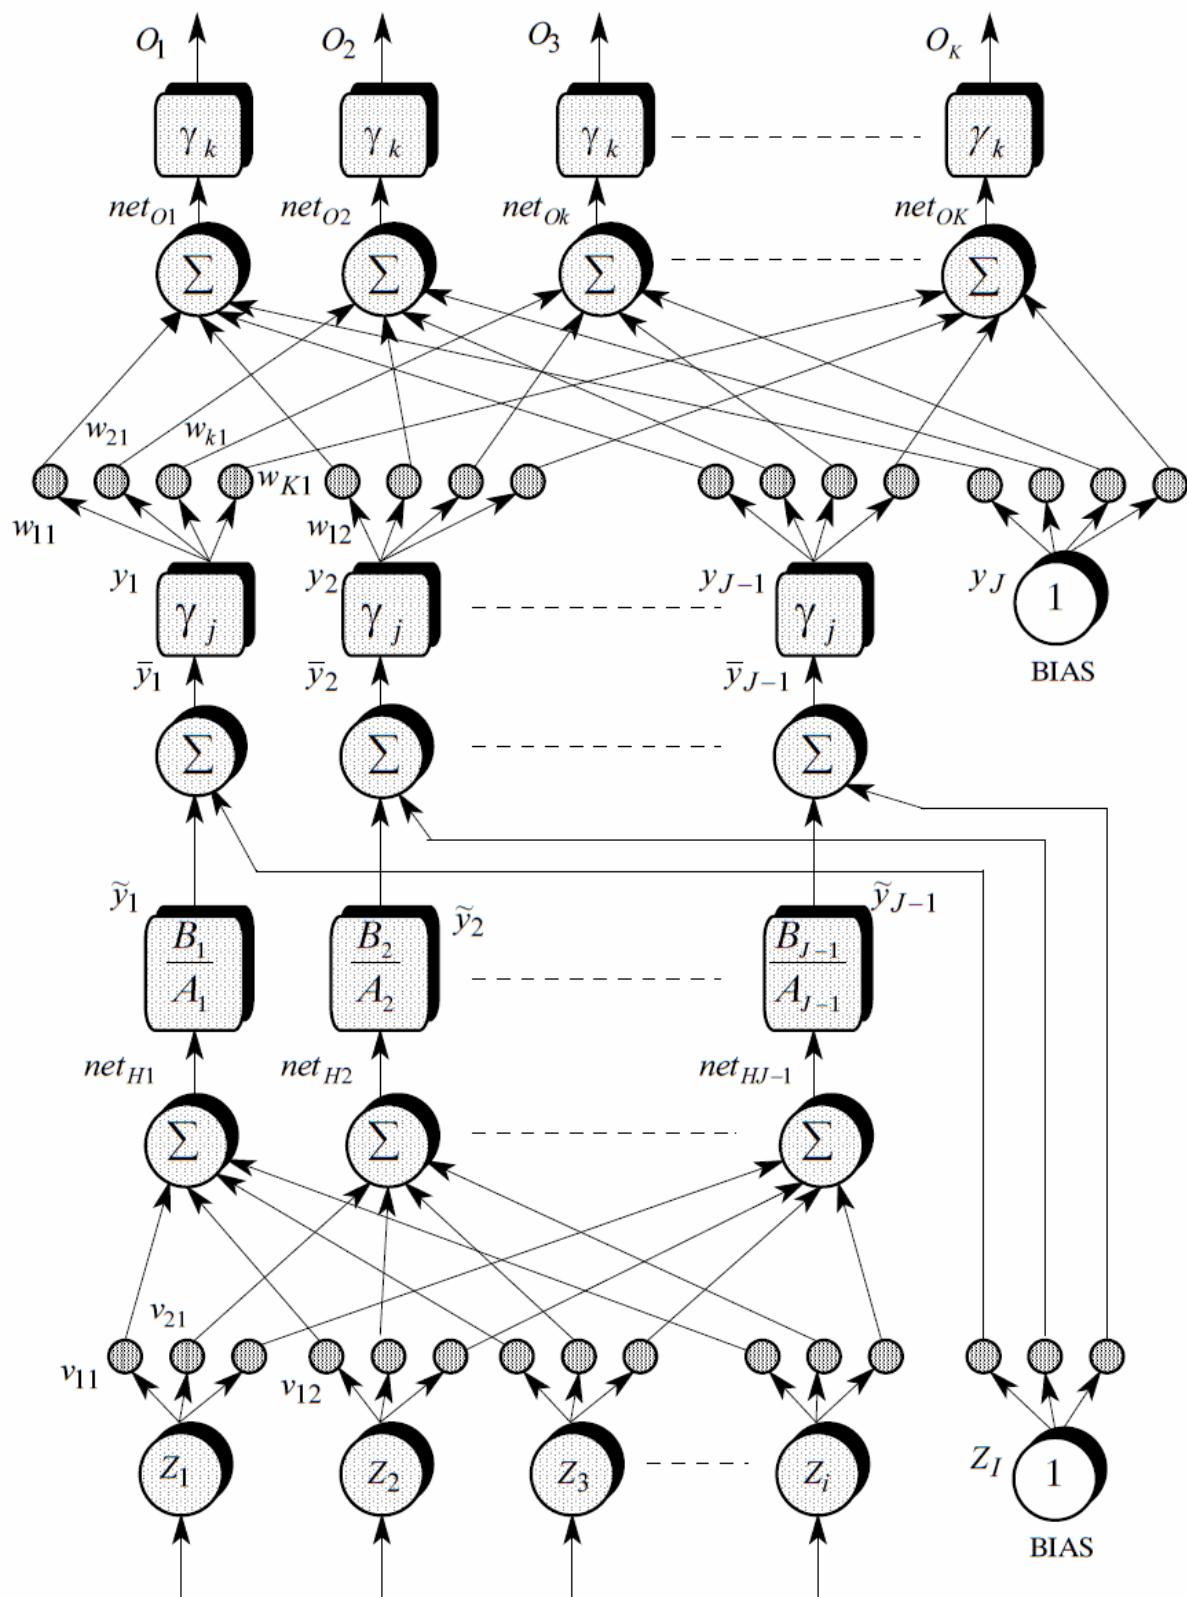
Slika 5. Sigmoidalna aktivacijska funkcija skrivenog sloja neuronske mreže

$$y(n) = \gamma(\bar{y}(n)) = \frac{2}{1 + e^{-\bar{y}(n)}} - 1. \quad (6)$$

4. MODEL DINAMIČKE NEURONSKE MREŽE

Za dobivanje strukture neuronske mreže, potrebno je organizirati neurone u slojeve. Slojevi su međusobno povezani težinskim koeficijentima. U sklopu ovog rada koristit će se troslojna neuronska mreža. Ulazni i izlazni sloj će biti u izravnoj interakciji s okolinom, dok će sakriveni sloj između njih biti između njih odvojen od okoline. Ulaz i izlazni sloj će u ovom slučaju biti isti kao i kod višeslojne statičke neuronske mreže, a skriveni sloj će se tvoriti od dinamičkog neurona koji je prikazan na slici 4. Na slici 6 s B_j je označen brojnik, a s A_j ($j = 1, \dots, J - 1$) nazivnik impulsne prijenosne funkcije (2). Bias je jedini neuron koji nije dinamički u skrivenom sloju.

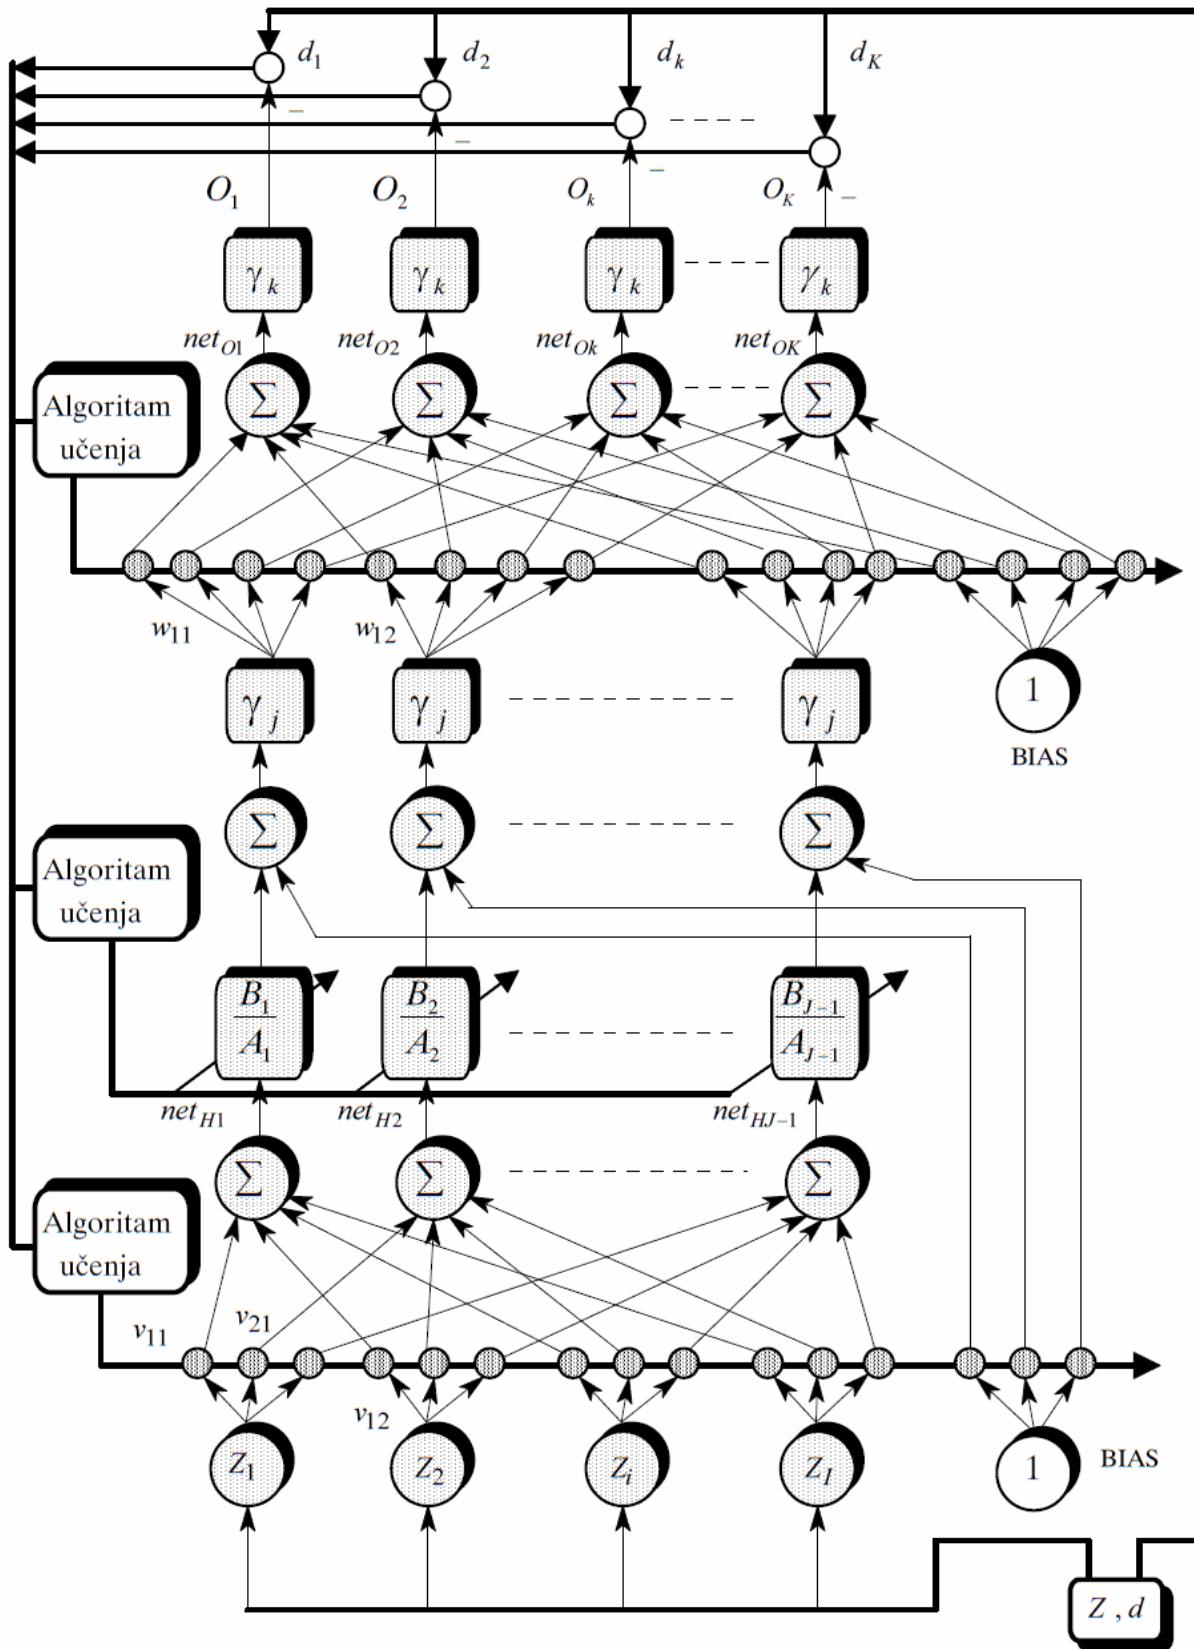
Ulazi neurona ulaznog sloja (Z_i) ujedno su i ulazi u mrežu, prema slici 6 vidi se da je ulazni sloj sa skrivenim slojem povezan preko veličina v_{ji} . Slojevi mreže su u potpunosti umreženi, što znači da je svaki neuron promatranog sloja vezan sa svakim neuronom prethodnog sloja. Izuzetak su jedino i uvijek neuroni označeni s bias, neuroni konstantne izlazne vrijednosti jednake jedinici. Izlazni sloj označen s O_k povezan je sa skrivenim slojem neurona težinskim koeficijentima označenima s w_{kj} [3].



Slika 6. Model dinamičke neuronske mreže [3]

4.1. Učenje dinamičke neuronske mreže

Postupak učenja neuronske mreže predstavlja podešavanje težinskih koeficijenata ulaznog i izlaznog sloja i veličine koeficijenata a i b koji se vide na slici 4 dinamičkih komponenata neurona.



Slika 7. Postupak učenja dinamičke mreže [3]

Promjena težina i koeficijenata dinamičkih članova odvija se za svaki par ulazno-izlaznih vrijednosti.

4.1.1. Unaprijedna faza učenja dinamičke mreže

Uzimaju se vrijednosti ulaza mreže \mathbf{Z} i izračunavaju se izlazi mreže \mathbf{O} , a vrijednosti $\mathbf{V}, \mathbf{A}, \mathbf{B}, \mathbf{W}$ su slučajno generirani brojevi.

4.1.1.1. Skriveni sloj

Prema slici 6 net_{H_j} ima oblik:

$$net_{H_j} = \sum_{i=1}^{I-1} v_{ji} Z_i, \quad j = 1, 2, \dots, J-1, i = 1, 2, \dots, I-1 . \quad (7)$$

Izlaz iz dinamičkih članova $\tilde{y}(n)$:

$$\begin{aligned} \tilde{y}(n) = & b_{0j}(n)net_{H_j}(n) + b_{1j}(n)net_{H_j}(n-1) + b_{2j}(n)net_{H_j}(n-2) \\ & - a_{1j}\tilde{y}(n-1) - a_{2j}\tilde{y}(n-2) . \end{aligned} \quad (8)$$

Nakon sume \bar{y}_j po slici 6:

$$\bar{y}_j(n) = \tilde{y}_j(n) + v_{jI}(n)Z_I . \quad (9)$$

Kako je bias $Z_I = 1$:

$$\bar{y}_j(n) = \tilde{y}_j(n) + v_{jI}(n) . \quad (10)$$

Izlaz iz sigmoidalne aktivacijske funkcije y_j :

$$y_j(n) = \frac{2}{1 + e^{-\bar{y}_j(n)}} - 1, \quad j = 1, 2, \dots, J-1 , \quad (11)$$

a za bias je $y_J = 1$.

4.1.1.2. Izlazni sloj

Suma aktivacijske funkcije računa se preko:

$$net_{O_k}(n) = \sum_{j=1}^J y_j(n) w_{kj}(n) . \quad (12)$$

Primjenom linearne aktivacijske funkcije u izlaznom sloju dobiva se:

$$O_k(n) = net_{O_k}(n), \quad k = 1, 2, \dots, K , \quad (13)$$

gdje je K broj izlaza mreže.

4.1.2. Povratna faza učenja dinamičke neuronske mreže

Druga faza u učenju neuronske mreže je povratna faza [Slika 7]. Na osnovu ostvarenog izlaza mreže i željenog izlaza mreže izračunava se pogreška. Na temelju pogreške vrši se

korekcija vrijednosti težinskih koeficijenata između slojeva mreže. Postupak se odradi za svaki ulazno-izlazni par podataka i ponavlja se sve dok mreža ne postigne zadenu točnost.

4.1.2.1. Promjena težina izlaznog sloja

Promjena izlaznih parametara učenja prema slici 7 se odvija na slijedeći način:

$$\mathbf{w}_{kj}(n+1) = \mathbf{w}_{kj}(n) - \eta \nabla E(n) - \alpha \Delta \mathbf{w}_{kj}(n-1) . \quad (14)$$

Gradijent pogreške za \mathbf{w}_{kj} izračunava se prema:

$$\nabla E(n) = \frac{\partial E(n)}{\partial \mathbf{w}_{kj}} = \frac{\partial E(n)}{\partial O_k} \frac{\partial O_k}{\partial net_{ok}} \frac{\partial net_{ok}}{\partial \mathbf{w}_{kj}} . \quad (15)$$

Računanje pojedinih članova:

$$\frac{\partial E(n)}{\partial O_k} = -(d_k - O_k) , \quad (16)$$

$$\frac{\partial O_k}{\partial net_{ok}} = \gamma_k = 1 , \quad (17)$$

$$\frac{\partial net_{ok}}{\partial \mathbf{w}_{kj}} = y_j . \quad (18)$$

Uvrštavanjem izraza (16), (17) i (18) u izraz (15) dobiva se gradijent pogreške:

$$\nabla E(n) = -(d_k - O_k)y_j . \quad (19)$$

Uvrštavanjem izraza (19) u izraz (14) dobivamo konačan oblik algoritma, za promjenu težina izlaznog sloja, pri čemu je η koeficijent brzine učenja, a α vrijednost momentuma:

$$\mathbf{w}_{kj}(n+1) = \mathbf{w}_{kj}(n) + \eta(d_k - O_k)y_j - \alpha \Delta \mathbf{w}_{kj}(n-1) . \quad (20)$$

4.1.2.2. Promjena parametara učenja sakrivenog sloja

Nakon promjene vrijednosti koeficijenata izlaznog sloja \mathbf{w}_{kj} , slijedi promjena parametara skrivenog sloja. Radi lakšeg prikaza definiran je linearni operator vremenskog pomaka:

$$z^{-t}[net(n)] = net(n-t) . \quad (21)$$

Parametri A i B dobiju se preko:

$$[\tilde{y}(n)] = \frac{B(z)}{A(z)} [net_H(n)] , \quad (22)$$

$$A(z)[\tilde{y}(z)] = \tilde{y}(n) + a_1\tilde{y}(n-1) + a_2\tilde{y}(n-2) , \quad (23)$$

$$B(z)[net_H(n)] = b_0net_H(n) + b_1net_H(n-1) + b_2net_H(n-2) . \quad (24)$$

Promjena parametara učenja odvija se prema:

$$b_{0j}(n+1) = b_{0j}(n) - \eta \nabla E \left(b_{0j}(n) \right) - \alpha \Delta b_{0j}(n-1) , \quad (25)$$

$$\nabla E(n) = \frac{\partial E(n)}{\partial b_{0j}} = \frac{\partial E(n)}{\partial y_j} \frac{\partial y_j}{\partial \bar{y}_j} \frac{\partial \bar{y}_j}{\partial \tilde{y}_j} \frac{\partial \tilde{y}_j}{\partial b_{0j}} . \quad (26)$$

Promjena prve parcijalne derivacije $\frac{\partial E(n)}{\partial y_j}$ izračunava se preko:

$$\begin{aligned} \frac{\partial E(n)}{\partial y_j} &= \frac{\partial E(n)}{\partial O_1} \frac{\partial O_1}{\partial net_{01}} \frac{\partial net_{01}}{\partial y_1} \\ &+ \frac{\partial E(n)}{\partial O_2} \frac{\partial O_2}{\partial net_{02}} \frac{\partial net_{02}}{\partial y_2} + \dots \\ &+ \frac{\partial E(n)}{\partial O_K} \frac{\partial O_K}{\partial net_{OK}} \frac{\partial net_{OK}}{\partial y_j} , \end{aligned} \quad (27)$$

pri tome su:

$$\frac{\partial E(n)}{\partial O_k} = -(d_k - O_k) , \quad k = 1, 2, \dots, K , \quad (28)$$

$$\frac{\partial O_k}{\partial net_{0k}} = 1 , \quad k = 1, 2, \dots, K , \quad (29)$$

$$\frac{\partial net_{0k}}{\partial y_j} = \mathbf{w}_{kj} , \quad k = 1, 2, \dots, K . \quad (30)$$

Uvrštavanjem izraza (28), (29), (30) u izraz (27) dobiva se izraz prve parcijalne derivacije u izrazu (26):

$$\frac{\partial E(n)}{\partial y_j} = - \sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} . \quad (31)$$

Drugi parcijalni razlomak u izrazu (26) dobije se preko:

$$\frac{\partial y_j}{\partial \bar{y}_j} = \gamma'_j = \frac{1}{2} (1 - y_j^2) . \quad (32)$$

Treći parcijalni razlomak u izrazu (26) prema izrazu (10) daje:

$$\frac{\partial \bar{y}_j}{\partial \tilde{y}_j} = 1 . \quad (33)$$

Primjenom linearog operatora vremenskog pomaka (21), a red filtera se označi s rf izvodi se:

$$\frac{\partial [\tilde{y}(n)]}{\partial b_{tj}} = [D_{b_{tj}}(n)] = \frac{z^{-t}}{A(z)} [net_{Hj}(n)] , \quad t = 0, 1, 2, \dots, rf . \quad (34)$$

Odnosno kako bi dobili $D_{b_{0j}}$:

$$\begin{aligned} D_{b_{0j}}(n) &= \frac{z^{-0}}{A(z)} [net_{Hj}(n)] , \\ [D_{b_{0j}}(n)] A(z) &= z^{-0} [net_{Hj}(n)] , \\ [D_{b_{0j}}(n)] (1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_{rf} z^{-rf}) &= z^{-0} [net_{Hj}(n)], \\ t = 0 , \end{aligned} \tag{35}$$

$$D_{b_{0j}}(n) + a_1 D_{b_{0j}}(n-1) + a_2 D_{b_{0j}}(n-2) + \dots + a_{rf} D_{b_{0j}}(n-rf)$$

$$= net_{Hj}(n) ,$$

$$D_{b_{0j}}(n) = net_{Hj}(n) - a_1 D_{b_{0j}}(n-1) - a_2 D_{b_{0j}}(n-2) - \dots$$

$$- a_{rf} D_{b_{0j}}(n-rf) .$$

Uvrštavanjem izraza (31), (32), (33), (35) u izraz (26):

$$\nabla E(n) = -\frac{1}{2}(1 - y_j^2) D_{b_{0j}}(n) \sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} . \tag{36}$$

Uvrštavanjem izraza (36) u izraz (25):

$$\begin{aligned} b_{0j}(n+1) &= b_{0j}(n) + \frac{1}{2}\eta(1 - y_j^2) D_{b_{0j}}(n) \left(\sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} \right) \\ &\quad - \alpha \Delta b_{0j}(n-1) . \end{aligned} \tag{37}$$

Konačan izraz za promjenu parametara učenja b_{tj} glasi:

$$\begin{aligned} b_{tj}(n+1) &= b_{tj}(n) + \frac{1}{2}\eta(1 - y_j^2) D_{b_{tj}}(n) \left(\sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} \right) \\ &\quad - \alpha \Delta b_{tj}(n-1) . \end{aligned} \tag{38}$$

U skrivenom sloju osim parametara B treba mijenjati i parametre a_{tj} i promjena se odvija prema:

$$a_{1j}(n+1) = a_{1j}(n) - \eta \nabla E(a_{1j}(n)) - \alpha \Delta a_{1j}(n-1) , \tag{39}$$

$$\nabla E(n) = \frac{\partial E(n)}{\partial a_{1j}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \bar{y}_j} \frac{\partial \bar{y}_j}{\partial \tilde{y}_j} \frac{\partial \tilde{y}_j}{\partial a_{1j}} , \tag{40}$$

Kao i kod računanja b_{tj} i kod a_{tj} prva tri parcijalna razlomka se računaju na isti način:

$$\frac{\partial E(n)}{\partial y_j} = - \sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} , \quad (41)$$

$$\frac{\partial y_j}{\partial \bar{y}_j} = \gamma'_j = \frac{1}{2} (1 - y_j^2) , \quad (42)$$

$$\frac{\partial \bar{y}_j}{\partial \tilde{y}_j} = 1 . \quad (43)$$

Posljednji parcijalni razlomak je nešto komplikiraniji, ali i dalje sličan kao kod b_{tj} :

$$\frac{\partial [\tilde{y}(n)]}{\partial a_{tj}} = [D_{a_{tj}}(n)] = -\frac{z^{-t}}{A(z)} [\tilde{y}_j(n)] , \quad t = 1, 2, \dots, rf . \quad (44)$$

Oblik izведен za $D_{a_{1j}}$:

$$\begin{aligned} D_{a_{1j}}(n) &= -\frac{z^{-1}}{A(z)} [\tilde{y}(n)] , \\ [D_{a_{1j}}(n)] A(z) &= -z^{-1} [\tilde{y}_j(n)] , \\ [D_{a_{1j}}(n)] (1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_{rf} z^{-rf}) &= -z^{-1} [\tilde{y}_j(n)] , \quad t = 1 , \\ D_{a_{1j}}(n) + a_1 D_{a_{1j}}(n-1) + a_2 D_{a_{1j}}(n-2) + \dots + a_{rf} D_{a_{1j}}(n-rf) \\ &= -\tilde{y}_j(n-1) , \\ D_{a_{1j}}(n) &= -\tilde{y}_j(n-1) - a_1 D_{a_{1j}}(n-1) - a_2 D_{a_{1j}}(n-2) - \dots \\ &\quad - a_{rf} D_{a_{1j}}(n-rf) . \end{aligned} \quad (45)$$

Uvrštavanjem izraza (41), (42), (43), (45) u izraz (40):

$$\nabla E(n) = -\frac{1}{2} (1 - y_j^2) D_{a_{1j}}(n) \sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} . \quad (46)$$

Uvrštavanjem (39) u (46):

$$\begin{aligned} a_{1j}(n+1) &= a_{1j}(n) + \frac{1}{2} (1 - y_j^2) D_{a_{1j}}(n) \left(\sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} \right) \\ &\quad - \alpha \Delta a_{1j}(n-1) . \end{aligned} \quad (47)$$

Konačan izraz za promjenu parametara učenja a_{tj} glasi:

$$a_{tj}(n+1) = a_{tj}(n) + \frac{1}{2} (1 - y_j^2) D_{a_{tj}}(n) \left(\sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} \right) - \alpha \Delta a_{tj}(n-1) . \quad (48)$$

4.1.2.3. Promjena parametara učenja ulaznog sloja

Nakon promjene parametara dinamičkog djela neurona skrivenog sloja na redu su promjene težinskih koeficijenata veza između skrivenog i izlaznog sloja neurona \mathbf{v}_{ji} [3].

$$\mathbf{v}_{ji}(n+1) = \mathbf{v}_{ji}(n) - \eta \nabla E(n) - \alpha \Delta \mathbf{v}_{ji}(n-1) . \quad (49)$$

Gradijent pogreške za \mathbf{v}_{ji} izračunava se prema:

$$\nabla E(n) = \frac{\partial E(n)}{\partial \mathbf{v}_{ji}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \bar{y}_j} \frac{\partial \bar{y}_j}{\partial \tilde{y}_j} \frac{\partial \tilde{y}_j}{\partial \mathbf{v}_{ji}} . \quad (50)$$

Promjena prve parcijalne derivacije $\frac{\partial E(n)}{\partial y_j}$ izračunava se preko:

$$\begin{aligned} \frac{\partial E(n)}{\partial y_j} &= \frac{\partial E(n)}{\partial O_1} \frac{\partial O_1}{\partial net_{o1}} \frac{\partial net_{o1}}{\partial y_1} \\ &+ \frac{\partial E(n)}{\partial O_2} \frac{\partial O_2}{\partial net_{o2}} \frac{\partial net_{o2}}{\partial y_2} + \dots \\ &+ \frac{\partial E(n)}{\partial O_K} \frac{\partial O_K}{\partial net_{oK}} \frac{\partial net_{oK}}{\partial y_j} . \end{aligned} \quad (51)$$

Pri tome su:

$$\frac{\partial E(n)}{\partial O_k} = -(d_k - O_k), \quad k = 1, 2, \dots, K , \quad (52)$$

$$\frac{\partial O_k}{\partial net_{ok}} = 1, \quad k = 1, 2, \dots, K , \quad (53)$$

$$\frac{\partial net_{ok}}{\partial y_j} = \mathbf{w}_{kj}, \quad k = 1, 2, \dots, K . \quad (54)$$

Uvrštavanjem izraza (52), (53), (54) u izraz (51) dobiva se izraz prve parcijalne derivacije u izrazu (50):

$$\frac{\partial E(n)}{\partial y_j} = - \sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} . \quad (55)$$

Drugi parcijalni razlomak u izrazu (50) dobiva se preko:

$$\frac{\partial y_j}{\partial \bar{y}_j} = \gamma'_j = \frac{1}{2}(1 - y_j^2) . \quad (56)$$

Treći parcijalni razlomak u izrazu (26) prema izrazu (10) daje:

$$\frac{\partial \bar{y}_j}{\partial \tilde{y}_j} = 1 . \quad (57)$$

Posljednji, četvrti razlomak primjenom vremenskog operatora (21) ima slijedeći oblik:

$$\frac{\partial[\tilde{y}(n)]}{\partial \boldsymbol{v}_{ji}} = [D_{\boldsymbol{v}_{ji}}(n)] = \frac{B(z)}{A(z)} [Z_i(n)] , \quad (58)$$

odnosno kako bi dobili $D_{\boldsymbol{v}_{ji}}$:

$$\begin{aligned} D_{\boldsymbol{v}_{ji}}(n) &= \frac{b_0 + b_1 z^{-1} + b_2 z^{-2} + \cdots + b_{rf} z^{-rf}}{1 + a_1 z^{-1} + a_2 z^{-2} + \cdots + a_{rf} z^{-rf}} [Z_i(n)] , \\ [D_{\boldsymbol{v}_{ji}}(n)] (1 + a_1 z^{-1} + a_2 z^{-2} + \cdots + a_{rf} z^{-rf}) &= (b_0 + b_1 z^{-1} + b_2 z^{-2} + \cdots + b_{rf} z^{-rf}) [Z_i(n)] , \\ D_{\boldsymbol{v}_{ji}}(n) + a_1 D_{\boldsymbol{v}_{ji}}(n-1) + a_2 D_{\boldsymbol{v}_{ji}}(n-2) + \cdots + a_{rf} D_{\boldsymbol{v}_{ji}}(n-rf) &= b_0 Z_i(n) + b_1 Z_i(n-1) + \cdots + b_{rf} Z_i(n-rf) , \\ D_{\boldsymbol{v}_{ji}}(n) &= b_0 Z_i(n) + b_1 Z_i(n-1) + \cdots + b_{rf} Z_i(n-rf) - a_1 D_{\boldsymbol{v}_{ji}}(n-1) \\ &\quad - a_2 D_{\boldsymbol{v}_{ji}}(n-2) - \cdots - a_{rf} D_{\boldsymbol{v}_{ji}}(n-rf) . \end{aligned} \quad (59)$$

Uvrštavanjem (55), (56), (57), (58) u izraz (50) dobiva se:

$$\nabla E(n) = -\frac{1}{2}(1 - y_j^2) D_{\boldsymbol{v}_{ji}}(n) \left(\sum_{k=1}^K (d_k - O_k) \boldsymbol{w}_{kj} \right) , \quad (60)$$

$$\begin{aligned} \boldsymbol{v}_{ji}(n+1) &= \boldsymbol{v}_{ji}(n) + \frac{1}{2}\eta(1 - y_j^2) D_{\boldsymbol{v}_{ji}}(n) \left(\sum_{k=1}^K (d_k - O_k) \boldsymbol{w}_{kj} \right) \\ &\quad - \alpha \Delta \boldsymbol{v}_{ji}(n-1) . \end{aligned} \quad (61)$$

I još jedine težine koje nam ostaju za mijenjanje su težine pridružene bias neuronu ulaznog sloja:

$$\boldsymbol{v}_{jl}(n+1) = \boldsymbol{v}_{jl}(n) - \eta \nabla E(n) - \alpha \Delta \boldsymbol{v}_{jl}(n-1) . \quad (62)$$

Gradijent pogreške za v_{jl} izračunava se prema:

$$\nabla E(n) = \frac{\partial E(n)}{\partial \boldsymbol{v}_{jl}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \bar{y}_j} \frac{\partial \bar{y}_j}{\partial \boldsymbol{v}_{jl}} . \quad (63)$$

Prvi parcijalni razlomak se računa prema izrazu (55), drugi prema izrazu (56), a treći je jednak:

$$\frac{\partial \bar{y}_j}{\partial v_{jl}} = Z_l = 1 . \quad (64)$$

Uvrštavanjem izraza (55), (56), (64) u izraz (63) dobiva se:

$$\nabla E(n) = -\frac{1}{2}(1 - y_j^2) \left(\sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} \right) . \quad (65)$$

I uvrštavanjem (65) u (62) dobivamo konačan algoritam za promjenu bias težina:

$$\mathbf{v}_{jl}(n+1) = \mathbf{v}_{jl}(n) + \frac{1}{2}(1 - y_j^2) \left(\sum_{k=1}^K (d_k - O_k) \mathbf{w}_{kj} \right) - \alpha \Delta \mathbf{v}_{jl}(n-1) . \quad (66)$$

4.2. Ocjena uspješnosti algoritma učenja

Za procjenu točnosti (uspješnosti) algoritma učenja u rješavanju postavljenog zadatka potrebno je definirati tzv. mjeru (indeks) točnosti. Pomoću mjere točnosti za tipske zadatke učenja moguće je uspoređivati primjenjivani algoritam s ostalim algoritmima učenja. Danas su najčešće u uporabi slijedeće tri mjerne točnosti algoritma učenja [3]:

1. Srednja kvadratna pogreška (Mean Square error):

$$MS = \frac{\sum_{n=1}^N (d_n - O_n)^2}{N} , \quad (67)$$

2. Korijen srednje kvadratne pogreške (Root Mean Square error):

$$RMS = \sqrt{MS} = \sqrt{\frac{\sum_{n=1}^N (d_n - O_n)^2}{N}} , \quad (68)$$

3. Normalizirani korijen srednje kvadratne pogreške (Normalized Root Mean Square error):

$$NRMS = \frac{RMS}{\sigma_{d_n}} = \frac{\sqrt{\frac{\sum_{n=1}^N (d_n - O_n)^2}{N}}}{\sigma_{d_n}} , \quad (69)$$

$$\sigma_{d_n} = \sqrt{\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^2} , \quad (70)$$

$$\bar{d} = \frac{1}{N} \sum_{n=1}^N d_n . \quad (71)$$

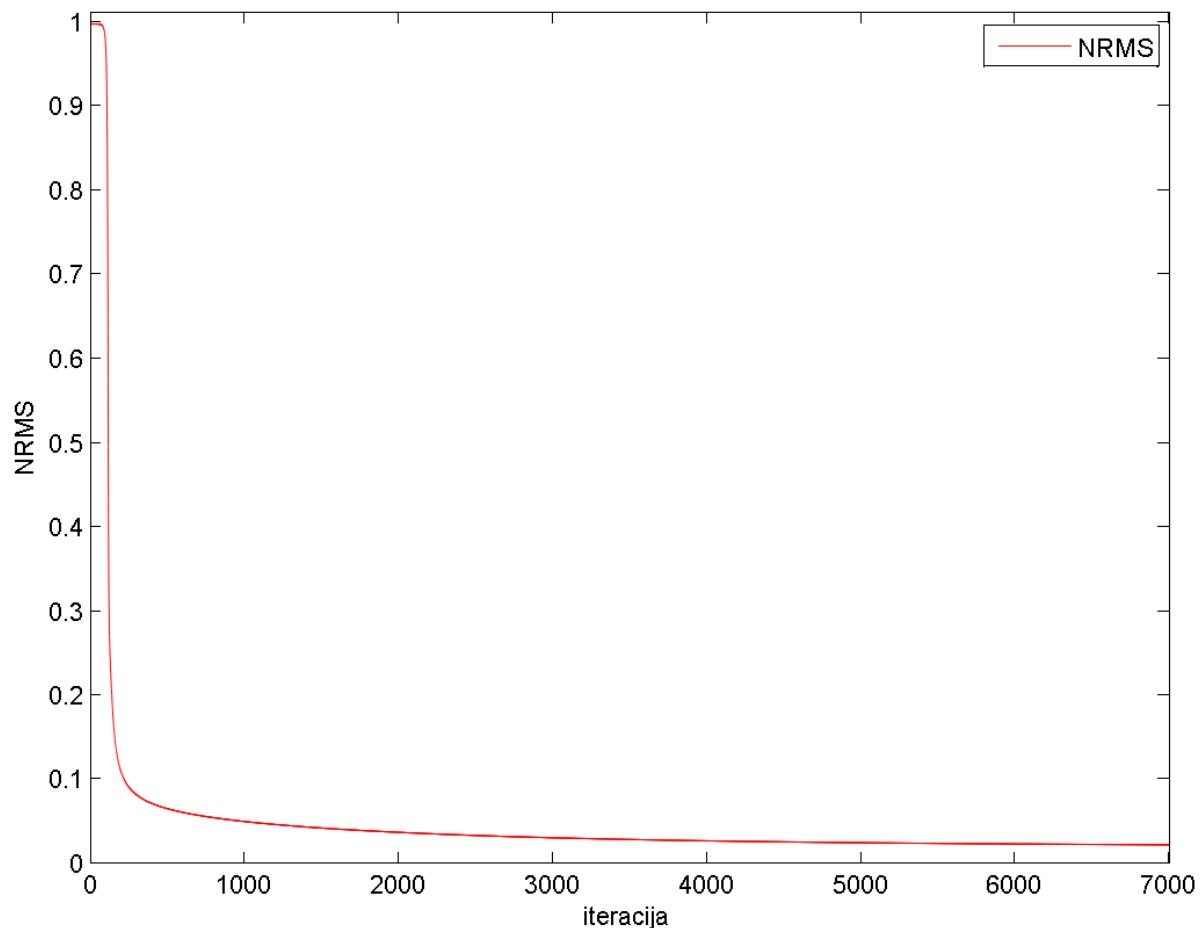
4.3. Testiranje mreže

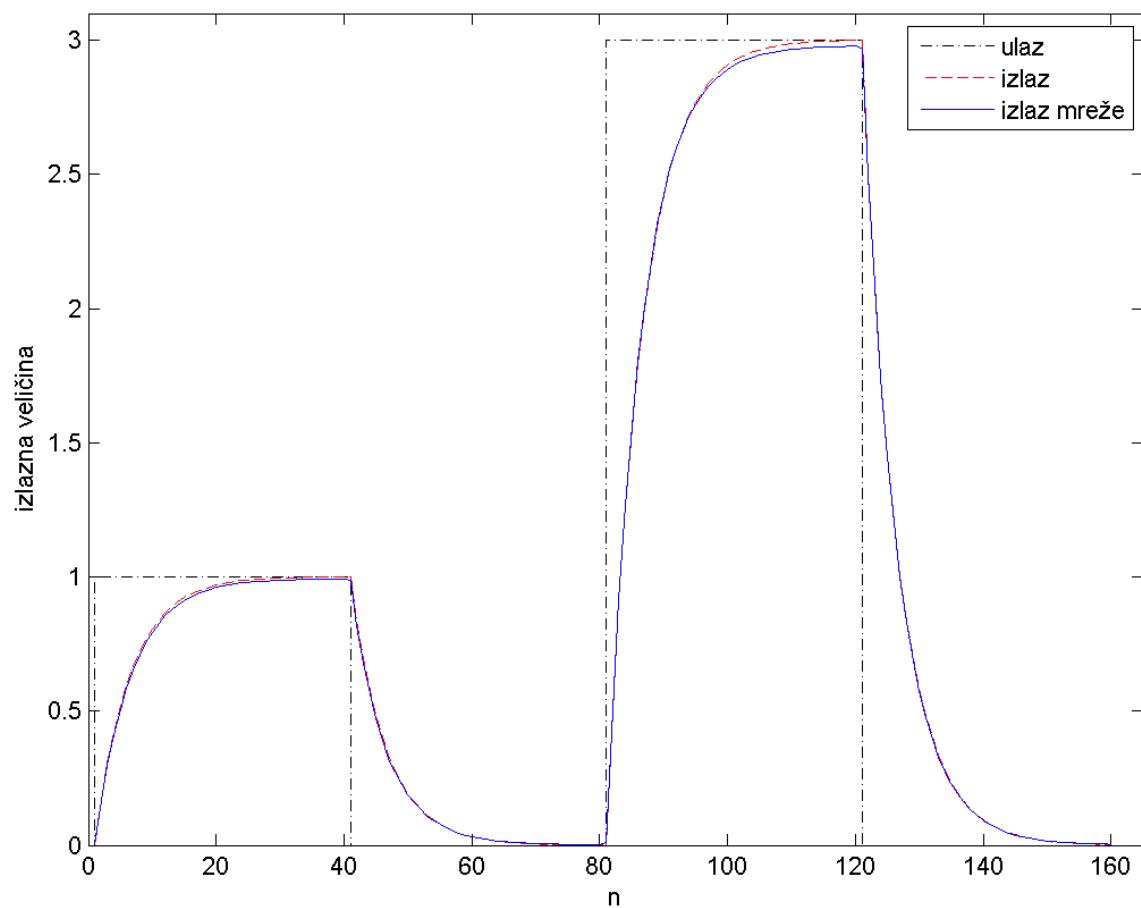
Za testiranje mreže korišten je odaziv proporcionalnog član prvog reda. Korišteno je 160 točaka koje predstavljaju skup ulaznih i izlaznih podataka učenja.

Tablica 3. Postavke testirane mreže

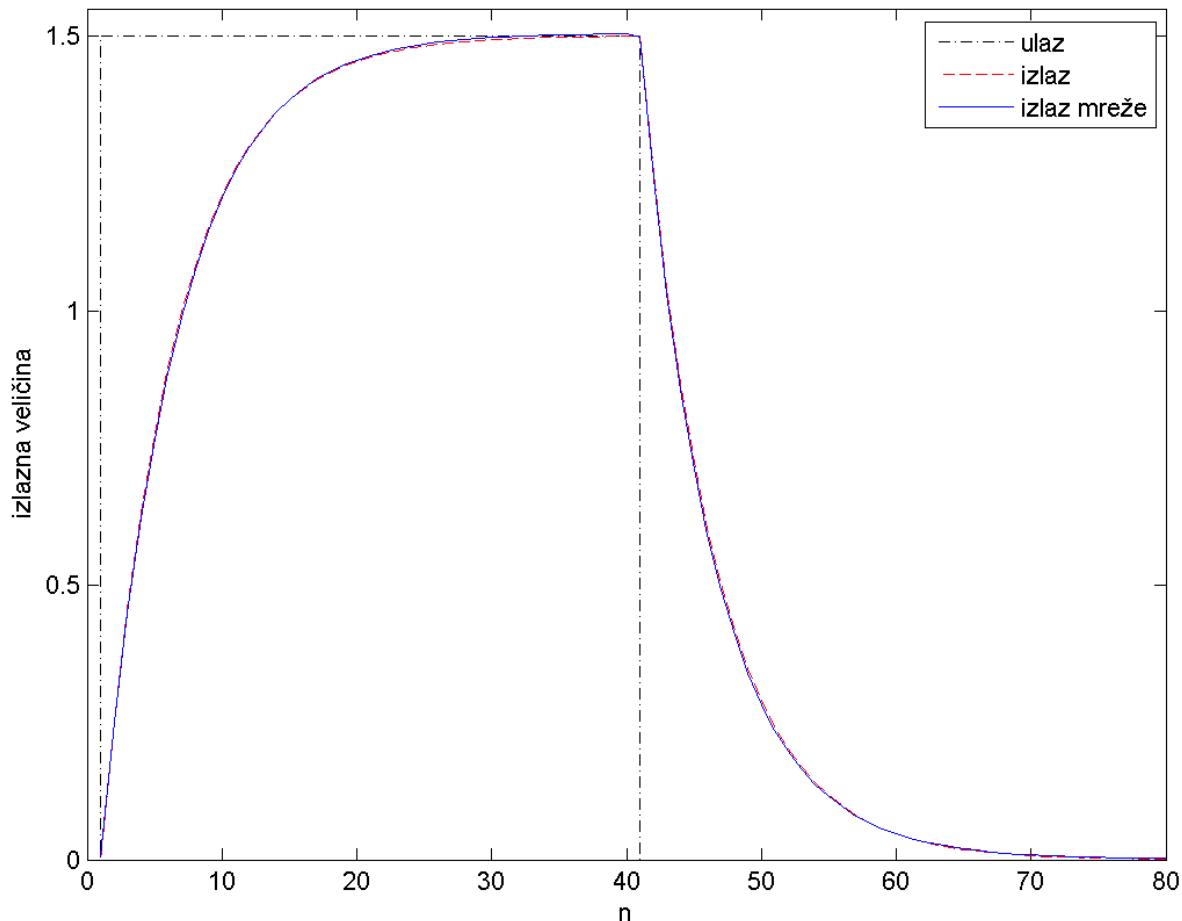
Struktura neuronske mreže:	1-1-1
Red filtera:	2
Faktor učenja η :	0,01
Momentum α :	0,8
Broj iteracija:	40000

Učenje je izvršeno u 40000 iteracija, ali se NRMS stabilizira već nakon 5000 iteracija [Slika 8].

**Slika 8. NRMS učenja**



Slika 9. Odaziv mreže na datoteku učenja

**Slika 10. Odaziv mreže na test**

Nakon što je utvrđeno da mreža radi ispravno, mogu se generirati odazivi u svrhu filtriranja estimatora alatnog stroja.

Mreža je testirana sa sedam testova vezanih uz dubinu rezanja $a_p = 2,5\text{mm}$, posmak alata $f = 0,35\text{mm/okr}$, različite brzine rezanja $125 - 265\text{m/min}$ i uz različite poremećaje obradnog procesa (u ovom slučaju tokarenja). Parametar koji se filtrira je širina trošenja stražnje površine alata VB.

Tablica 4. Parametri testova

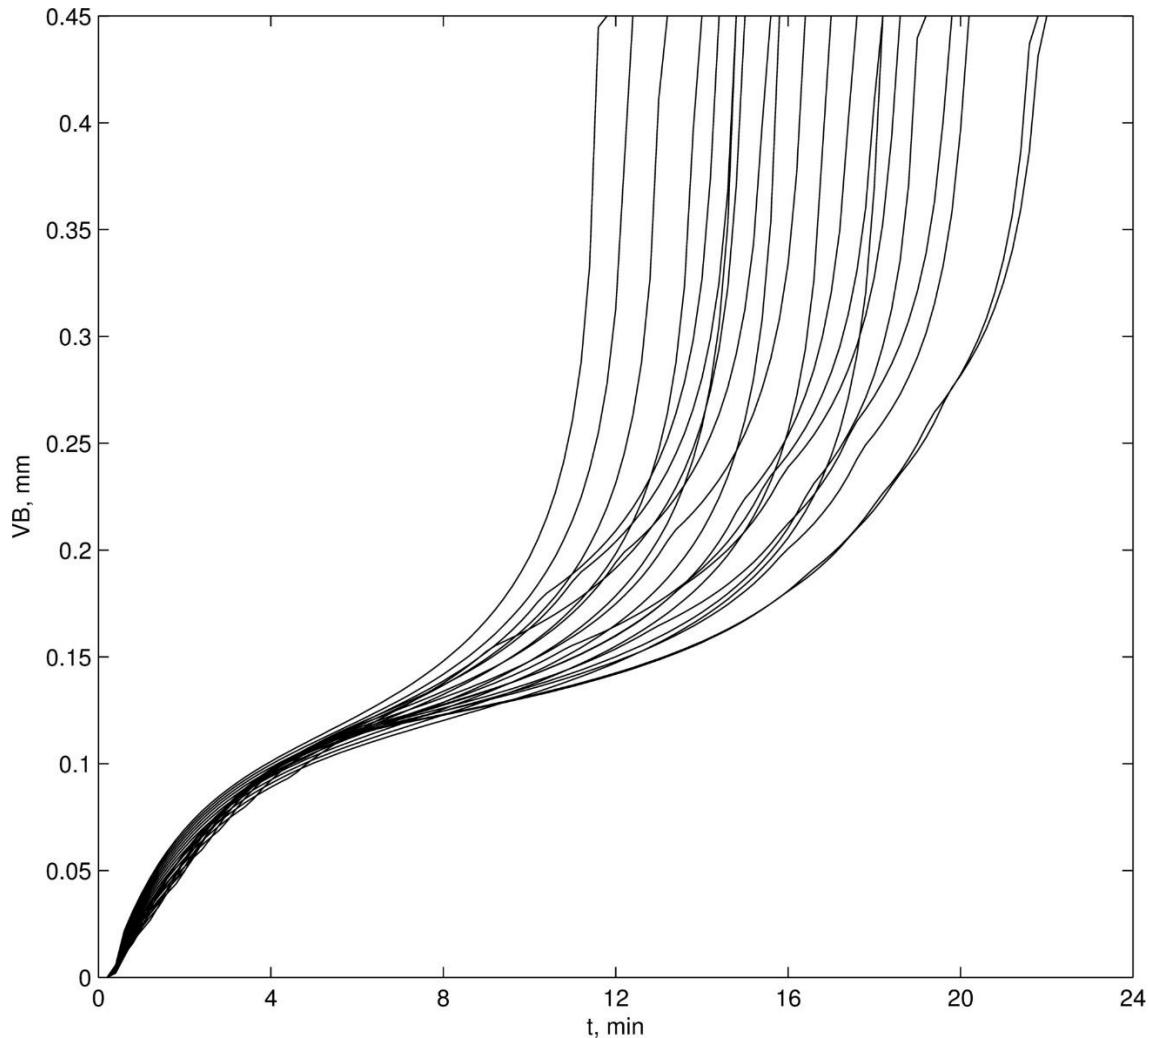
Test	Brzina rezanja, v_c (m/min)	Impulsni poremećaj (naglo trošenje), δ_i^I	Varijabilni poremećaj, δ_i^V	Trenutak/Period djelovanja poremećaja, (min)
test 1	125	-	-	
test 2	155	0,1	-	u 10. min
test 3	185	0,5	-	u 15. min
test 4	205	-	0,3	od 7.-15. min
test 5	225	-	0,6	od 7.-15. min
test 6	245	-	-0,3	od 7.-15. min
test 7	265	-	-0,6	od 7.-15. min

Učenje je izvršeno tako da je mreži dan šumovit ulaz (izlaz iz estimatora) i željeni odaziv, ukupno je učeno 27 mreža i to:

- a) Broj ulaznih neurona: 3, 5, 7

- b) Broj neurona skrivenog sloja: 2, 5, 8
 c) Red filtera: 2, 4, 6

I sve njihove kombinacije. Sve mreže su učene s faktorom učenja $\eta = 0,01$, momentumom $\alpha = 0$, i s 10000 iteracija učenja.



Slika 11. Datoteka učenja

Slikom 11 prikazani su svi primjeri kojima je učena mreža, s tim da su radi simulacije realnih uvjeta ulazi zašumljeni s estimacijskom pogreškom $0,05mm$.

Tablica 5. Testirane mreže s tri ulazna neurona

Broj ulaznih neurona:	3	3	3	3	3	3	3	3	3
Broj skrivenih neurona:	2	2	2	5	5	5	8	8	8
Red filtera:	2	4	6	2	4	6	2	4	6
NRMS:	0.1261	0.1394	0.1238	0.1290	0.1279	0.1082	0.1261	0.1207	0.1200
NRMS test 1:	0.1686	0.1867	0.1758	0.1714	0.1663	0.1969	0.1684	0.1519	0.1925
NRMS test 2:	0.1374	0.1528	0.1450	0.1389	0.1347	0.1776	0.1368	0.1277	0.1713
NRMS test 3:	0.1723	0.1975	0.1721	0.1768	0.1729	0.1722	0.1731	0.1606	0.1828

NRMS test 4:	0.1329	0.1461	0.1437	0.1329	0.1326	0.1854	0.1324	0.1310	0.1804
NRMS test 5:	0.1403	0.1583	0.1563	0.1415	0.1383	0.1823	0.1399	0.1269	0.1823
NRMS test 6:	0.1773	0.2091	0.2140	0.1746	0.1763	0.2564	0.1769	0.1719	0.2557
NRMS test 7:	0.2543	0.3246	0.3257	0.2493	0.2640	0.3425	0.2541	0.2398	0.3495
NRMS prosjek testova:	0.1690	0.1964	0.1904	0.1693	0.1693	0.2162	0.1688	0.1586	0.2164

Tablica 6. Testirane mreže s pet ulaznih neurona

Broj ulaznih neurona:	5	5	5	5	5	5	5	5	5
Broj skrivenih neurona:	2	2	2	5	5	5	8	8	8
Red filtera:	2	4	6	2	4	6	2	4	6
NRMS:	0.1307	0.1332	0.13313	0.2189	0.2143	0.1327	0.1496	0.2005	0.1884
NRMS test 1:	0.1672	0.1784	0.19224	0.6037	0.6634	0.2844	0.2038	0.6077	0.5131
NRMS test 2:	0.1346	0.1445	0.16126	0.6150	0.6745	0.2764	0.1775	0.6160	0.5179
NRMS test 3:	0.1779	0.1892	0.19238	0.5569	0.5926	0.2535	0.2238	0.5442	0.4657
NRMS test 4:	0.1347	0.1386	0.15648	0.6684	0.7345	0.2982	0.1685	0.6699	0.5632
NRMS test 5:	0.1423	0.1477	0.16821	0.6768	0.7376	0.2926	0.1709	0.6729	0.5658
NRMS test 6:	0.1731	0.1862	0.21721	0.8909	0.9799	0.3972	0.2118	0.8938	0.7563
NRMS test 7:	0.2702	0.2855	0.32431	1.0884	1.1866	0.4962	0.3045	1.0839	0.9213
NRMS prosjek testova:	0.1714	0.1814	0.2017	0.7286	0.7956	0.3283	0.2087	0.7269	0.6147

Tablica 7. Testirane mreže s sedam ulaznih neurona

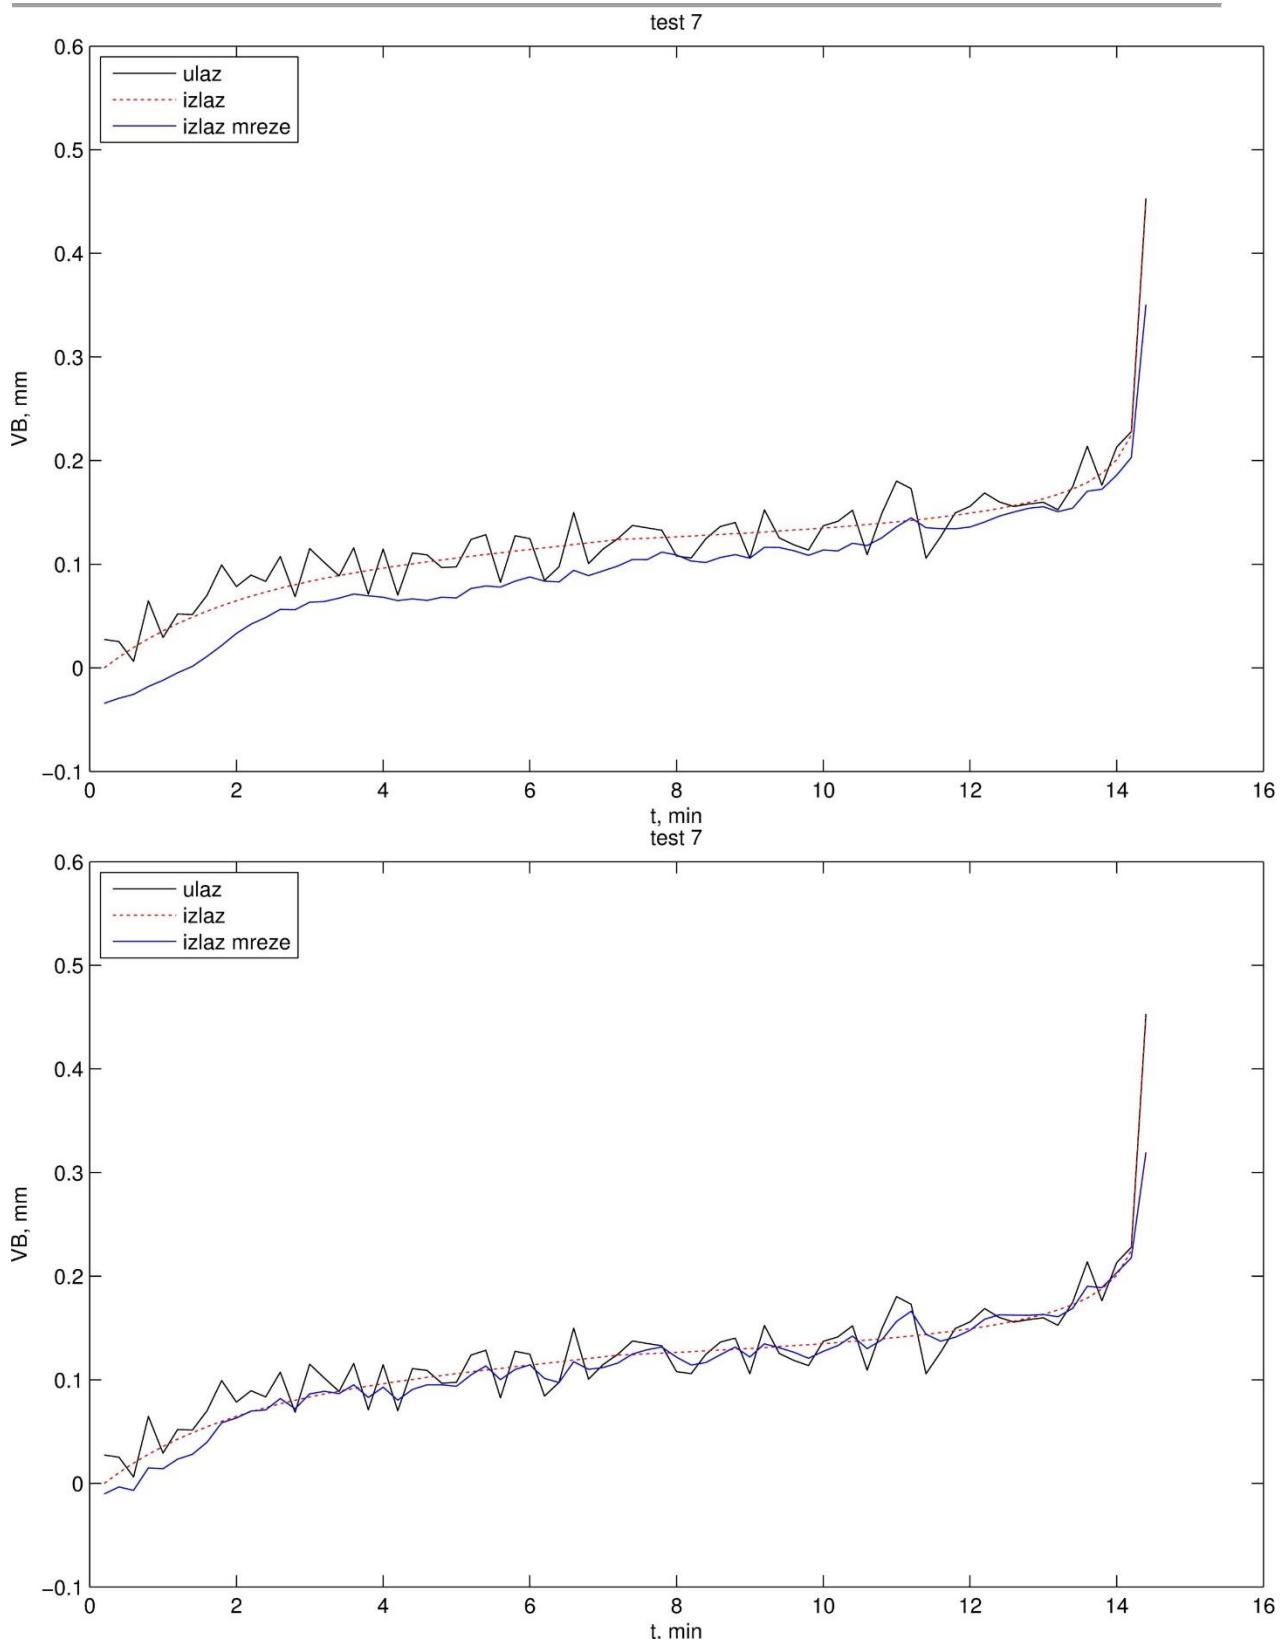
Broj ulaznih neurona:	7	7	7	7	7	7	7	7	7
Broj skrivenih neurona:	2	2	2	5	5	5	8	8	8
Red filtera:	2	4	6	2	4	6	2	4	6
NRMS:	0.1287	0.13295	0.1445	0.1237	0.2583	0.1239	0.2141	0.2397	0.1387
NRMS test 1:	0.1823	0.18479	0.2005	0.1716	0.8000	0.2570	0.6287	0.7262	0.2462
NRMS test 2:	0.1475	0.1491	0.1685	0.1382	0.8178	0.2412	0.6394	0.7411	0.2322
NRMS test 3:	0.1866	0.19314	0.2073	0.1746	0.7226	0.2248	0.5724	0.6564	0.2359
NRMS test 4:	0.1379	0.1403	0.1610	0.1325	0.8909	0.2530	0.6967	0.8076	0.2428
NRMS test 5:	0.1487	0.15135	0.1773	0.1435	0.8987	0.2490	0.7027	0.8142	0.2426

NRMS test 6:	0.1791	0.1825	0.2444	0.1762	1.1874	0.3577	0.9251	1.0769	0.3374
NRMS test 7:	0.2622	0.2769	0.3597	0.2622	1.4392	0.4499	1.1234	1.3050	0.4281
NRMS prosjek testova:	0.1777	0.1826	0.2169	0.1713	0.9652	0.2904	0.7555	0.8753	0.2808

Iz prikazanih rezultata se može zaključiti da sve strukture dinamičke mreže daju najlošije rezultate za test 7. Za mrežu 5-5-1 (red filtera 6) napravljen je dodatan test u kojem se nakon svake iteracija učenja posebno izvrši unaprijedna faza testa 7, ako je NRMS testa manji od prethodnog, zapamte se svi parametri učenja za tu iteraciju. Tako je u ovom slučaju najbolja vrijednost bila za vrijeme 101. iteracije učenja [Slika 12].

Tablica 8. Rezultati testova nakon 10000 koraka učenja (pretrenirana mreža) i 101 koraka (najbolji odziv)

Broj iteracija:	10000	101
Broj ulaznih neurona:	5	5
Broj skrivenih neurona:	5	5
Red filtera:	6	6
NRMS:	0.1327	0.1606
NRMS test 1:	0.2844	0.1910
NRMS test 2:	0.2764	0.1760
NRMS test 3:	0.2535	0.1527
NRMS test 4:	0.2982	0.1514
NRMS test 5:	0.2926	0.1343
NRMS test 6:	0.3972	0.2226
NRMS test 7:	0.4962	0.3138
NRMS prosjek testova:	0.3283	0.1917



Slika 12. Odaziv mreže na test 7 s pretreniranim parametrima (gore) i mreže s najboljim rezultatima (dolje)

U prilogu se nalaze najbolji odazivi mreža za svaku kombinaciju ulaznih neurona.

5. ZAKLJUČAK

U ovom radu prikazan je izvod i primjena jednostavne dinamičke neuronske mreže učene povratnim rasprostiranjem greške. Mreža je izrađena u svrhu filtriranja odaziva estimatora stupnja istrošenosti, kako bi se smanjila estimacijska pogreška stupnja istrošenosti stražnje površine alata i time postigla kvalitetnija obrada odvajanjem čestica.

Što se tiče filtriranja signala estimatora, kod mreža koje su dale bolje odazive može se vidjeti da je odaziv mreže bliže željenoj vrijednosti nego bez filtriranja mreže. Kod mreža s lošijim rezultatima, uglavnom dolazi do problema pretreniranosti mreže nakon 10000 iteracija, kao što je prikazano na mreži 5-5-1 (red filtera 6), koja daje gotovo duplo bolje rezultate nakon samo 101 iteracije učenja, nego nakon 10000 iteracija. Promjenom i testiranjem drugih aktivacijskih funkcija bi moglo rezultirati boljim odazivom za ovaj specifičan problem.

LITERATURA

- [1] D. Brezak: Razvoj hibridnog estimatora trošenja alata i metoda vođenja alatnog stroja, doktorski rad, Fakultet strojarstva i brodogradnje, Zagreb, 2007.
- [2] B. Bašić, M. Čupić, J. Šnajder: Umjetne neuronske mreže, Fakultet elektrotehnike i računarstva, Zagreb, 2008.
- [3] B. Novaković, D. Majetić & M. Široki: Umjetne neuronske mreže, Fakultet strojarstva i brodogradnje, Zagreb, 1998.

PRILOZI

DNM: 3–8–1 Red Filtera: 4

