

# Razvoj neuronskih modela za istovremeno direktno i indirektno praćenje habanja reznih alata

Obrad Spaić, Radislav Brđanin, Budimirka Marinović

Univerzitet u Istočnom Sarajevu

Fakultet za proizvodnju i menadžment Trebinje

Trebinje

[obradspaic59@gmail.com](mailto:obradspaic59@gmail.com), [radislavbrdjanin@gmail.com](mailto:radislavbrdjanin@gmail.com), [buda.koprivica@gmail.com](mailto:buda.koprivica@gmail.com)

**Sadržaj** — Vještačke neuronske mreže imaju mogućnost da na osnovu poznatih eksperimentalnih rezultata nauče i generalizuju prirodu različitih fenomena, što im daje mogućnost primjene u modeliranju i predviđanju izabrane funkcije cilja posmatranih pojava i procesa. Modeli zasnovani na vještačkim neuronskim mrežama predstavljaju osnovu za inteligentno upravljanje različitim performansama tehničkih sistema. Poseban kvalitet neuronskim mrežama daje mogućnost istovremenog praćenja više funkcija cilja u zavisnosti od cilja istraživanja i želje istraživača. Tako je u ovom radu razvijen neuronski model za istovremeno direktno i indirektno praćenje habanja reznih alata, odnosno neuronski model za istovremeno praćenje širine pojasa habanja, aksijalne sile bušenja i obrtnog momenta kao najvjernijih nosioca informacija o fenomenu habanja.

**Ključne riječi** - Neuronske mreže; širina pojasa habanja; obrtni moment; aksijalna sila bušenja.

## I. UVOD

Veliki broj poslovnih sistema posjeduje neophodne informacije u cilju boljeg poslovanja, ali zbog neposjedovanja adekvatnog alata za njihovu primjenu one postaju samo trošak i dodatno usporavaju sistem upravljanja. U savremenom poslovanju vještačka inteligencija nudi novu dimenziju u konceptu sistema upravljanja, automatizacije i unapređenja poslovanja poslovnim procesima, pa samim tim i procesima u obradi rezanjem.

Vještačka inteligencija predstavlja softver koji donosi odluke zasnovane na prikupljenom iskustvu i informacijama, korišćenjem funkcija učenja, adaptacije, rezonovanja i samokorekcije [1]. Međutim, uvođenjem vještačke inteligencije u poslovne sisteme problemi se ne rješavaju primjenom jedne tehnike na jedinstven način, već su u primjeni različite tehnike, kao što su ekspertni sistemi, fazi logika, vještačke neuronske mreže i genetski algoritmi.

U inženjerstvu se vještačke neuronske mreže, engl. artificial neural network (ANN) primjenjuju za modeliranje različitih pojava i parametara. Tako su Šimunović, Šarić i Lujčić [2] izradili studiju o primjeni neuronskih mreža u procjenjivanju kvaliteta obrađivane površine, odnosno posmatran je uticaj obrađivanog materijala, alata, dubine rezanja, koraka i brzine rezanja na hrapavost obrađivane površine na predmetu „razvodnik uređaja za ronjenje“. Bajić, Lela, i Živković [3] su istraživali uticaj parametara obrade na

hrapavost obrađene površine pri čeonom glodanju. Spaić, Krivokapić i Soković [4] su uspostavili model za opisivanje funkcije habanja reznih alata zasnovan na familiji ANN.

U zavisnosti od cilja istraživanja i želje istraživača ANN moguće je istovremeno pratiti više funkcija cilja (izlaznih parametara) u zavisnosti od većeg broja ulaznih parametara, što im daje poseban značaj pri primjeni u inženjerstvu. U ovom radu se primjenom ANN istovremeno predviđa širina pojasa habanja, aksijalna sila i obrtni moment, kao najvjerniji nosioci informacija o fenomenu habanja, u zavisnosti od koraka i dužine bušenja.

## II. VJEŠTAČKE NEURONSKE MREŽE

Razvojem ANN došlo se do velikog napretka na području vještačke inteligencije, jer se mogu rješavati problemi iz oblasti prepoznavanja, predviđanja, optimizacije, asocijativne memorije i kontrole.

ANN predstavljaju specifično uređenje elemenata obrade (neurona) povezanih međusobno i sa okolinom, tako da grade funkcionalnu cjelinu. Neuronu su raspoređeni u slojeve i povezani tako da izlaz svakog neurona predstavlja ulaz u jedan ili više drugih neurona. Slojevi u koje su grupisani neuroni mogu biti: ulazni, skriveni i izlazni. Ulazni sloj prima informacije ili ulazne podatke iz okoline i prenosi signale neuronima u sljedećem sloju (skrivenom). Neuronu u skrivenom sloju obrađuju primljene signale i informacije koje smataju važnim upućuju neuronima u sljedećem sloju. Konačni rezultati obrade se dobijaju od neurona izlaznog sloja, koji predstavlja izlaz mreže.

Prema smjeru prostiranja informacija ANN, mogu biti jednosmjerne (nepovratne) i dvosmjerne (povratne), a prema intenzitetu pobuđujuće ili smirujuće.

Uspješnost aplikacije ANN leži u dobroj konfiguraciji i pravilnom treniranju. Proces kreiranja neuronske mreže se sastoji od četiri faze:

- Raspoređivanje neurona u slojeve,
- Određivanje tipa veze između neurona,
- Određivanje načina na koji neuroni primaju ulaze i proizvode izlaze i
- Određivanje pravila učenja.

Značajna karakteristika neuronskih mreža je njihova sposobnost da uče obrazce koji su skriveni u ulaznim podacima i čine uopštenje tih obrazaca.

#### A. Učenje neuronskih mreža

Kod neuronskih mreža postoje dva načina učenja: učenje uz nadzor i učenje bez nadzora. Učenje uz nadzor zahtjeva vanjskog „učitelja“ koji posmatra mijenjanje parametara neuronske mreže (učenje). Kod ovoga načina učenja mreži se, iz skupa ulaznih podataka, zadaje jedan par ulaz izlaz, aktivira se mreža i računa izlaz. Dobijeni rezultat se upoređuje sa željenim, pa ukoliko su identični (ili zadovoljavajuće blizu) korekcija težinskih koeficijenata se ne vrši. U suprotnom slučaju vrši se korekcija težinskih koeficijenata, kako bi se u sljedećoj iteraciji greška svela na najmanju moguću mjeru. Postupak se ponavlja sa narednim parovima ulaz izlaz, sve dok se u potpunosti ne iscrpi skup podataka za treniranje. Nakon procesa učenja slijedi proces testiranja, koji se izvodi s novim skupom ulaza koji nije bio sadržan u ulaznom skupu procesa učenja. Testiranjem mreža daje izlaze koji se upoređuju sa željenim izlazima, pri čemu se ne mijenjaju parametri (težine) mreže. Veličina greške u procesu testiranja služi za ocjenu generalizacijskih svojstava mreže, odnosno sposobnosti mreže da daje zadovoljavajuće izlaze za skup ulaza kojim nije bila učena.

Kod obučavanja bez nadzora izlazni sloj se obučava da odgovori različitim grupama modela koje postoje u ulaznim podacima bez učitelja. U ovom slučaju se mreža sama organizuje, pa se mreže učene ovom metodom nazivaju samoorganizirajuće mreže. Na ulaz mreže dovodi se skup ulaznih varijabli, a mreža se sama organizuje podešavanjem svojih parametara (težina) po definisanom algoritmu. Budući da željeni izlaz mreže nije specificiran za vrijeme učenja mreže, rezultat učenja nije predvidiv. Nakon učenja provodi se postupak testiranja. Mreža organizovana na ovaj način najčešće se koristi za prepoznavanje uzoraka.

#### B. Normiranje podataka za vještačku neuronsku mrežu

Oblik u kojem su ulazni podaci predstavljeni ulaznim neuronima ANN ima vrlo važan uticaj na uspješnost učenja i sposobnost generalizacije neuronske mreže.

Ulazne i izlazne varijable mogu biti kvantitativne i kvalitativne. Kvantitativne varijable poprimaju određene broječne vrijednosti, a kvalitativne ukazuju na vrstu ili skupinu u koju podaci spadaju po određenim značajnostima. Postupak prilagođavanja ulaznih i/ili izlaznih podataka neuronskoj mreži se naziva normiranje podataka. Podaci se najčešće transformišu tako da sve ulazne i/ili izlazne vrijednosti budu unutar intervala [-1, 1] ili [0,1].

Ukoliko se za aktivacijsku funkciju neurona u izlaznom sloju neuronske mreže odabere neka od monotono rastućih funkcija sa zasićenjem, izlazne je podatke neophodno normirati unutar područja vrijednosti koje ta funkcija poprira. Nelinearna unipolarna sigmoidna aktivacijska funkcija sama normira vrijednosti ulaza u skup [0,1], a bipolarna aktivacijska funkcija u skup [-1,1]. Stoga, da bi se u fazi učenja neuronske mreže mogle ispravno izračunati razlike između izračunatih

izlaza mreže i željenih izlaza neophodno je izlaze normirati u skup vrijednosti koje poprimaju izračunati izlazi mreže.

#### C. Ulazne funkcije

Ulazni signali u neuron (iz okruženja ili drugih neurona) pomnoženi, sa odgovarajućim težinskim koeficijentima i korigovani stanjem neurona, odnosno pragom osjetljivosti (ako postoji) sumirani u sumatoru predstavljaju ulaznu funkciju neurona, koja se naziva i „simulacijska“ funkcija. Opšti oblik ulazne funkcije prikazan je jednačinom (1) [5]:

$$n(t) = \sum_{i=1}^n w_i(t) \cdot x_i(t) - w_{n+1} \quad (1),$$

gdje je:  $w_i(t)$  - vektor težinskih koeficijenata,  $X_i(t)$  - vektor ulaznih signala, a  $w_{n+1}$  - prag osjetljivosti neurona.

#### D. Transfer funkcija

Ulazna funkcija neurona se propušta kroz transfer (aktivacionu) funkciju neurona i ta vrijednost predstavlja izlaz iz neurona, koji se šalje drugim neuronima s kojima je neuron povezan. Najčešće su to neuroni u narednom sloju. Kao aktivacione funkcije koriste se: linearna funkcija, linearna odskočna funkcija, u dijelovima linearna funkcija, signum funkcija, sigmoidna funkcija, logaritamska sigmoidna funkcija, tangens-sigmoidna funkcija itd. Jedna od najčešće korištenih je tangens-sigmoidna funkcija, koja se koristi i u ovom radu. Ova funkcija je definisana izrazom:

$$a = \tan \operatorname{sgn}(n) = \frac{2}{(1 + e^{-2n})} - 1 \quad (2).$$


Grafik funkcije je kontinuirano monoton, a vrijednosti funkcije se kreću u intervalu [-1,1].

### III. NEURONSKE MREŽE SA BACKPROPAGATION ALGORITMOM UČENJA

Algoritam učenja Back-Propagation (širenje greške unatrag) bio je presudan za široku komercijalnu upotrebu ove metodologije, te je neuronske mreže učinio široko upotrebljavanom i popularnom metodom u različitim područjima. U osnovi, ovaj algoritam propagira input kroz mrežu od ulaznog do izlaznog sloja, a zatim određuje grešku i tu grešku propagira unazad sve do ulaznog sloja ugrađujući je u formulu za učenje. Standardni algoritam mreže „širenje greške unatrag“ uključuje optimizaciju greške koristeći deterministički algoritam gradijentnog opadanja. Glavni nedostatak ovog algoritma je problem čestog pronalaženja lokalnog umjesto globalnog minimuma greške. Zbog toga novija istraživanja uključuju njegovo unapređivanje drugim metodama.

Algoritam učenja „širenje greške unatrag“ je univerzalni algoritam primjenjiv na probleme kod kojih je potrebno predvidjeti vrijednost jedne ili više izlaznih varijabli, a moguće ga je koristiti i za probleme klasifikacije, gdje se ulazni vektor raspoređuje u jednu od klasa zadanih na izlazu, Ovaj algoritam se ne preporučuje za upotrebu na nestacionarnim podacima ili za slučajevne kada podaci u sebi

skrivaju više, u osnovi različitih, problema. Rješenje za takve probleme može se pronaći u upotrebi više neuronskih mreža



Slika 1. Back-Propagation algoritam učenja

od kojih će svaka rješavati pojedini problem zasebno, ili u izboru nekog drugog algoritma.

Algoritam učenja „širenje greške unatrag“ prikazana je na Sl. 1, pri čemu je zbog jasnoće prikazan samo jedan skriveni sloj.

Tok podataka kroz mrežu može se ukratko opisati u nekoliko koraka:

- od ulaznog sloja prema skrivenom sloju: ulazni sloj učitava podatke iz ulaznog vektora  $X$ , i šalje ih u prvi skriveni sloj,
- u skrivenom sloju: jedinice u skrivenom sloju primaju ulaz i prenose ga u naredni skriveni ili u izlazni sloj koristeći prenosnu funkciju,
- kako informacije putuju kroz mrežu, računaju se sumirani ulazi i izlazi za svaku jedinicu obrade,
- u izlaznom sloju: za svaku jedinicu obrade, računa se skalirana lokalna greška koja se upotrebljava u određivanju povećanja ili smanjenja težina,
- propagiranje unazad od izlaznog sloja do skrivenih slojeva: skalirana lokalna greška, te povećanje ili smanjenje težina računa se za svaki sloj unazad, počevši od sloja neposredno ispod izlaznog sve do prvog skrivenog sloja, i težine se podešavaju. [5], [6].

#### IV. PRIMJENA VJEŠTAČKIH NEURONSKIH MREŽA ZA ISTOVREMENO DIREKTNO I INDIKRETNNO PRAĆENJE HABANJA REZNIH ALATA

Postojanost, kao osnovni faktor kvaliteta svih reznih alata, u najvećoj mjeri zavisi od karaktera, intenziteta i brzine habanja reznih elemenata, tako da praćenje habanja reznih elemenata alata daje najvjerniju sliku o stanju alata u realnom vremenu. Sistemi za mjerenje parametara habanja alata mogu se svrstati u dvije grupe mjernih sistema: vanprocesne i procesne.

Sušтина vanprocesnih mjernih sistema sastoji se u tome što se mogu koristiti tek nakon prekida procesa rezanja i skidanja reznog alata sa obradnog sistema, off-line.

Za mjerenje habanja alata pomoću procesnih senzora koristi se više metoda među kojima su najznačajnije direktne i indirektnе. U direktne metode spadaju tehnike mjerenja pomoću kojih se direktno, odnosno neposredno mjeri habanje u toku odvijanja procesa obrade. Kod indirektnih metoda mjerenje habanja se vrši tokom rezanja i to mjerenjem različitih parametara procesa vezanih za habanje alata (sile rezanja, obrtni moment, vibracije, temperatura ...).

Osnovu za razvoj senzorske tehnike u indirektnim metodama mjerenja habanja alata čini skup raznovrsnih signala koji potiču iz jedinica obradnog sistema, a koji su funkcionalno povezani sa parametrima habanja alata određenim korelacionim vezama. Ovi signali predstavljaju nosioce informacija o veličini i brzini habanja elemenata reznog klina. Dakle, na ovaj način se dobijaju informacije o veličini habanja mjerenjem karakteristika procesa rezanja koje se relativno lakše mjere u odnosu na direktno mjerenje parametara habanja [7]. Njihova najznačajnija karakteristika vezana je za mogućnost praćenja istrošenosti u realnom vremenu uz kontinuirani ili „on-line“ režim nadzora, čime se osiguravaju potrebni uslovi inteligentnog vođenja obradnog procesa. Zbog toga su, danas, indirektni mjerni sistemi najčešći izbor u konstrukciji i razvoju automatizovanih sistema nadzora habanja reznih alata.

Zbog sve veće primjene indirektnih metoda mjerenja habanja reznih alata u ovom radu je, na osnovu eksperimentalnih rezultata, predstavljen model zasnovan na ANN za istovremeno direktno praćenje habanja i aksijalne sile i obrtnog momenta kao najvjernijih informacija o fenomenu habanja reznih alata (indirektno praćenje fenomena habanja).


#### A. Uslovi izvođenja eksperimenta

Eksperiment je izveden pri bušenju slijepе rupe dubine  $l=3d$  u epruветama od hrom-molibdenovog legiranog alatnog čelika za poboljšanje Č.4732, termički obrađenim na tvrdoću 43–45 HRC, zavojnim burgijama (ZB) DIN 338, Ø6.0, od brzoreznog čelika sa 8% Co proizvedenog konvencionalnom metalurgijom (S2-9-1-8), naoštrenim krstasto (KO).

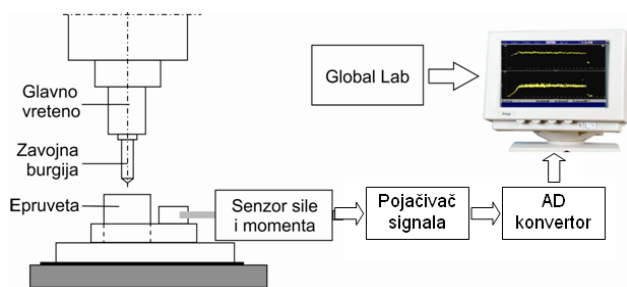
Ispitivanje je izvedeno pri brzini rezanja  $v=9,42$  m/min i koracima  $s=0.027$  mm/o i  $s=0.107$  mm/o. Za hlađenje i podmazivanje upotrebljavan je 8%-tni rastvor teolina H/VR, količine 1 l/min.

Kao kriterij habanja izabrana je srednja vrijednost širine pojasa habanja ledne površine oba glavna sječiva, ilustrovano na sl. 2, čije su vrijednosti mjerene optičkim uređajem GÜHRING PG 100.

TIP 9271A, integrisanim sa univerzalnom glodalicom i povezanim sa softverom Global Lab za akviziciju podataka,



Slika 2. Habanje zavojne burgije



Slika 3. Šema akvizicije podataka pri izvođenju eksperimenta

ilustrovano na sl. 3, u istim mjernim tačkama u kojima je mjerena i širina pojasa habanja lednih površina.

Prvo mjerenje izvedeno je oštrim ZB, a posljednje pri dužini bušenja pri kojoj je srednja vrijednost širine pojasa habanja iznosila  $B_{d_{max}}=0.25$  mm ( $\approx 0.04$  D).

Maksimalna srednja vrijednost širine pojasa habanja ledne površine oba sječiva  $B_{d_{max}}=0.25$  mm ( $\approx 0.04$  D) je unaprijed definisana kao kriterij zatupljenja.

Ostala mjerenja izvršena su pri dužinama bušenja pri kojima se srednja širina pojasa habanja nalazila u intervalu:  $0 < B_d < B_{d_{max}}$ .

Rezultati mjerenja prikazani su u tabelama 1 i 2.

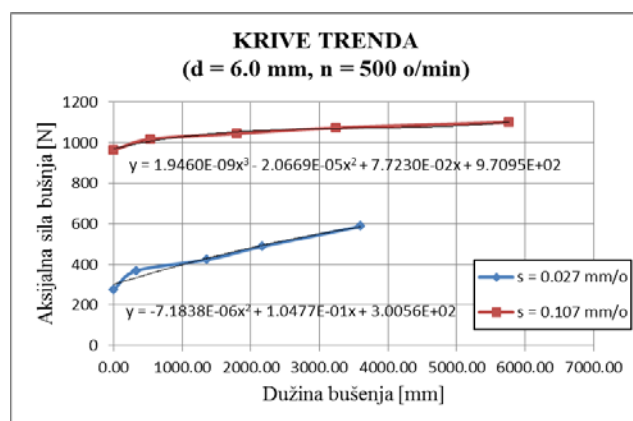
TABELA I. REZULTATI MJERENJA AKSIJALNE SILE I OBRTOG MOMENTA

Red. br.	s = 0.027 mm/o			s = 0.107 mm/o		
	Dužina bušenja [mm]	Aksijalna sila bušenja [kN]	Obrtni moment [Nm]	Dužina bušenja [mm]	Aksijalna sila bušenja [kN]	Obrtni moment [Nm]
1.	0	275.7	64.4	0	965	184
2.	324	367.8	66.95	540	1018.2	188.5
3.	1363.32	423.6	69.5	1800	1046	225.4
4.	2168.64	488.7	81.25	3240	1073.8	253.9
5.	3603.6	587.4	105.2	5760	1101.6	282.3

TABELA II. REZULTATI MJERENJA ŠIRINE POJASA HABANJA

Red. br.	s = 0.027 mm/o		s = 0.107 mm/o	
	Dužina bušenja [mm]	Širina pojasa habanja [mm]	Dužina bušenja [mm]	Širina pojasa habanja [mm]
1.	0	0	0	0
2.	324	0.0975	540	0.0725
3.	1363.32	0.135	1800	0.11
4.	2168.64	0.175	3240	0.125
5.	2343.6	0.18	4320	0.155
6.	3063.6	0.195	5040	0.18
7.	3603.6	0.24	5760	0.24

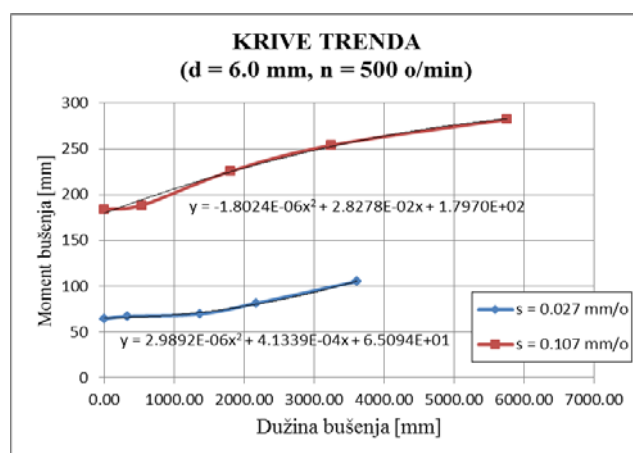
Na osnovu rezultata mjerenja definisane su krive zavisnosti, odnosno uspostavljene su korelacione veze, između širine pojasa habanja, aksijalne sile bušenja i obrtnog momenta od uticajnih parametara. Za definisane krive zavisnosti, primjenom softvera Microsoft Excel 2007,




Slika 4. Zavisnost aksijalne sile bušenja od dužine bušenja

definisane su krive trenda, kao i polinomne jednačine koje opisuju te krive. Na Sl. 4, 5 i 6 prikazane su krive zavisnosti aksijalne sile bušenja, obrtnog momenta i širine pojasa habanja u zavisnosti od koraka i dužine bušenja, kao i polinomne jednačine koje opisuju te krive.

Definisanjem polinomnih jednačina krivih trenda obezbjeđen je dovoljan broj podataka za treniranje ANN.



Slika 5. Zavisnost obrtnog momenta bušenja od dužine bušenja



Slika 6. Zavisnost širine pojasa habanja od dužine bušenja

**B. Modeliranje aksijalne sile rezanja, obrtnog momenta i širine pojasa habanja**

ANN se uspješno koriste za rješavanje problema vezanih za linearnu i nelinearnu zavisnost procesa, pri čemu uspješnost aplikacija ANN leži u činjenici da su mreže na pravi način konfigurisane i pravilno trenirane. Na taj način omogućavaju dobru aproksimaciju mjerenih vrijednosti.

Treniranje ANN sa algoritmom učenja Back-Propagation, iz softverskog paketa MATLAB 7.12, izvedeno je sa dva ulazna parametra i to: dužinom bušenja i korakom, i širinom pojasa habanja, aksijalnom silom bušenja i obrtnim momentom kao izlaznim parametrima.


Prilikom treniranja ANN sa Back-Propagation algoritmom učenja najbolje rezultate je postigla ANN, arhitekture prikazane na na sl. 7.

Parametri izabrane ANN prikazani su u tabeli 3.

Kriterijum za zaustavljanje procesa treniranja mreže zasniva se na unaprijed definisanoj grešci. Za definisanje greške koriste se apsolutna postotna greška i srednja apsolutna postotna greška. Model se trenira sa vlastitim podešavanjem treniranja do postizanja definisane tačnosti (greške).

Rezultati treniranja prikazani su na Sl. 8, sa koje se vidi da je mreža konvergirala u 22 epohe. Na dijagramu crvena linija prikazuje grešku testiranja, plava treniranja, a zelena grešku validacije.

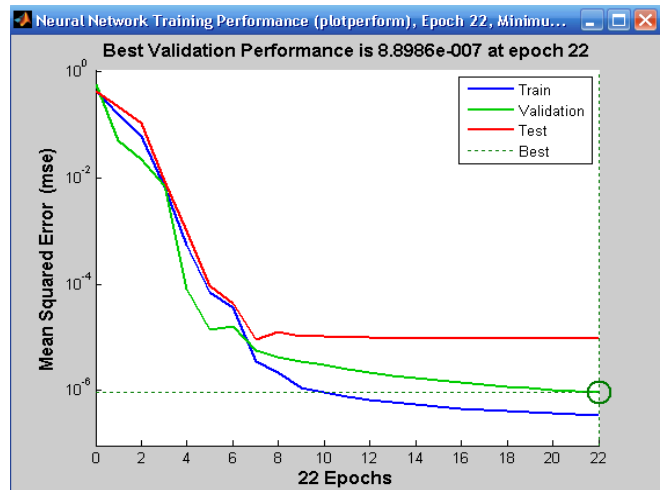
Greška treniranja u odnosu eksperimentalne rezultate kreće se u intervalu [-0.01126; -1.99E-05] za habanje, [0.004054; -2.52E-06] za obrtni moment i [0.001886; -1.19E-06] za aksijalnu silu bušenja.



Slika 7. Arhitektura ANN

TABELA III. PARAMETRI FORMIRANE ANN

Parametar mreže		Usvojeno obilježje ANN
Trening funkcija		TRAINLM
Funkcija učenja		LEARNGDM
Funkcija performansi n/m		MSE
Broj slojeva		2
Broj neurona	I sloj (skriveni)	10
	II sloj (izlazni)	3
Transfer funkcija	I sloj	TANSIG
	II sloj	PURRELIN
Broj epoha		1000




Slika 8. Rezultati treniranja ANN


Simuliranje obučene ANN izvedeno je sa standardnim vrijednostima koraka iz intervala [0.027 - 0.107 mm/o], odnosno koracima: 0.033, 0.042, 0.053, 0.067 i 0.084 mm/o, za sve vrijednosti dužine bušenja iz intervala [0 - 2000 mm]. Rezultati simuliranja prikazani su dijagramima na sl. 9 - 11.

Na Sl. 9 je prikazana zavisnost obrtnog momenta, a na Sl. 10 zavisnost aksijalne sile bušenja od koraka i dužine bušenja, pri čemu su vrijednosti pri koraku od 0.027 i 0.107 mm/o dobijene eksperimentom (sa kojim je trenirana ANN), a pri koracima 0.033, 0.042, 0.053, 0.067 i 0.084 simuliranjem obučene ANN.

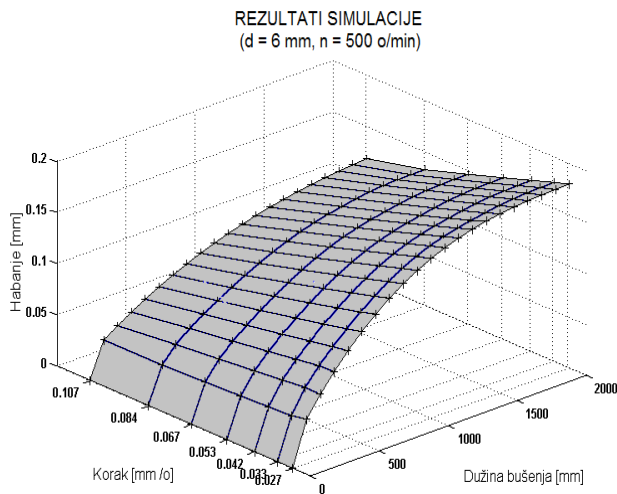
Na Sl. 11 je prikazana zavisnost širine pojasa habanja od koraka i dužine bušenja, pri čemu su vrijednosti pri koraku od 0.027 i 0.107 mm/o dobijene eksperimentom (sa kojim je trenirana ANN), a pri koracima 0.033, 0.042, 0.053, 0.067 i 0.084 simuliranjem obučene ANN.



Slika 9. Uticaj dužine bušenja i koraka na obrtni moment za n=500mm/o i d=6mm



Slika 10. Uticaj dužine bušenja i koraka na aksijalnu silu bušenja za n=500mm/o i d=6mm



Slika 11. Uticaj dužine bušenja i koraka na aksijalnu silu bušenja za n=500mm/o i d=6mm

Iz navedenih dijagrama se vidi da su izlazne vrijednosti širine pojasa habanja, aksijalne sile i obrtnog momenta dobijene simuliranjem jedne obučne ANN logično raspoređene između eksperimentalnih vrijednosti, što potvrđuje činjenicu da se ANN mogu uspješno koristiti za istovremeno modeliranje pojava sa više funkcija cilja (izlaznih parametara) u zavisnosti od istih ulaznih parametara.

#### ZAKLJUČAK

Vrijednosti širine pojasa habanja, aksijalne sile bušenja i obrtnog momenta dobijene simuliranjem, razvijenog neuronskog modela, standardnim koracima iz dijapazona obuhvaćenog eksperimentom i dužinom bušenja do

zatupljenja, logično su raspoređene između vrijednosti dobijenih eksperimentom, što ukazuje da se:

- vještačkim neuronskim mrežama izabrani procesi ili pojave mogu modelirati sa više funkcija cilja (izlaza) za iste uticajne parametre,
- razvijeni neuronski model može koristiti za direktno i/ili indirektno modeliranje procesa habanja, odnosno za modeliranje širine pojasa habanja i/ili aksijalne sile bušenja i/ili obrtnog momenta, kao najvjernijih nosioca informacija o fenomenu habanja.
- vještačke neuronske mogu uspješno koristiti u modeliranju pojava u obradnim procesima.

#### LITERATURA

- [1] B. Kuzmanović, Stankovski "Inteligentna podrška i eda tehnologija u osiguranju", INFOTEH-Jahorina, Vol. 4, Ref. E-II-2, p. 272-276, March 2005.
- [2] G. Šimunović, T. Šarić, R. Lujčić, "Primjena neuronskih mreža u procjenjivanju kvalitete obradivane površine", Technical Gazette, pp. 43 – 47, 2009.
- [3] D. Bajić, B. Lela, D. Živković, „Modeling of machined surface roughness and optimization of cutting parameters in face milling“, Metalurgija, Vol. 47 Issue 4, p 331-334, 2008.
- [4] O. Spaić, Z. Krivokapić, M. Soković, "Prediction of tool condition by applying a family of artificial neural networks", 10<sup>th</sup> International Conference on Management of Innovative Technologies MIT Fiesa, Slovenia, 2009, 28<sup>th</sup> – 29<sup>th</sup> September 2009.
- [5] <http://people.etf.unsa.ba/~jvelagic/laras/dok/Lekcijam13.pdf>
- [6] <http://eris.foi.hr/11neuronske/nn-predavanje5.html>
- [7] O. Spaić, Z. Krivokapić, S. Grče, „Modeliranje aksijalne sile rezanja primjenom neuronskih mreža“, 1st International Scientific Conference, Jahorina, B&H, Republic of Srpska, 28th – 30th November 2012.

#### ABSTRACT

Artificial neural networks have the possibility to use experimental results to learn and generalize the nature of phenomena, which gives them ability to apply in modeling and prediction of different phenomena and processes. These models of artificial neural networks are the basis for intelligent control of variety of performance of technical system. The special quality of neural networks enables the simultaneous monitoring of multiple objective functions according to research objectives and the desire of researchers. In this paper authors develop a neural network model for direct and indirect monitoring of cutting tools wearing, and neural model for simultaneous monitoring of wear bandwidth, axial drilling force and torque as the most faithful information about the phenomenon of tools wearing.

#### NEURAL NETWORK MODEL FOR DIRECT AND INDIRECT MONITORING OF WEARING OF CUTTING TOOLS

Obrad Spaić, Radislav Brđanin, Budimirka Marinović