

# METODOLOGIJA MODELIRANJA PROCESA OBRADJE REZANJEM PRIMENOM NEURONSKIH MREŽA

Miloš Madić<sup>1)</sup>, Miroslav Radovanović<sup>1)</sup>

Kategorizacija rada:  
ORIGINALNI NAUČNI RAD

Adresa:

<sup>1)</sup>Univerzitet u Nišu, Mašinski fakultet u Nišu

**Rezime:** *Procesi obrade rezanjem su jedni od najvažnijih i najviše korišćenih proizvodnih procesi. Kako je obrada rezanjem veoma složen proces, modeliranje obradnih procesa zasnovano na primeni neuronskih mreža, sve više ima primat u odnosu na tradicionalne metode modeliranja. U ovom radu prikazana je osnovna ideja i koncept modeliranja procesa obrade rezanjem. Takođe, u radu je predstavljena metodologija modeliranja neuronskim mrežama, a date su i određene preporuke za izbor parametara treniranja mreže i mrežne arhitekture. Ilustracije radi, kreiran je jednostavan predikcioni model neuronske mreže za glavni otpor rezanja kod struganja. Model je statistički ocenjen i uspešno testiran na novim podacima.*

**Ključne reči:** *modeliranje, procesi obrade rezanjem, neuronske mreže*

## 1. UVOD

Već duži niz godina godina, modeliranje procesa obrade rezanjem, u cilju boljeg razumevanja procesa, privlači veliku pažnju istraživača. Kao rezultat velikog interesovanja, modeliranje procesa rezanja je proučavano sa različitim aspektata i korišćenjem različitih tehnika modeliranja. Veliki broj parametara, nedovoljno poznate relacije između parametara, složena, višedimenzionalna, nelinearna i stohastička priroda obrade rezanjem, čine modeliranje obrade rezanjem prilično složenim zadatkom.

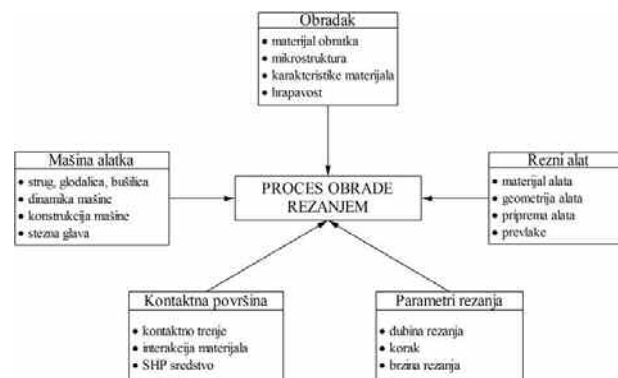
Neuronske mreže (NM) imaju niz karakteristika koje ih čine pogodnim za rešavanje ovakvih zadataka: sposobnost univerzalne aproksimacije funkcija, otpornost na podatke sa šumom, prilagođavanje višestrukim nelinearnim interakcijama između parametara, sposobnost generalizacije, mogućnost nadogradnje itd. U proteklih 20 godina, veliki broj istraživača je uspešno primenio NM za modeliranje različitih procesa obrade rezanjem. Većina modela je razvijena za predikciju: hrapavosti obrađene površine, habanja alata, sila rezanja, ali i za neke specifične svrhe. Uprkos činjenici da su NM široke primenjene u mnogim oblastima i dalje postoje određena nerešena pitanja na koja treba dati odgovore, a sve u cilju izgradnje odgovarajućih modela NM. Do sada ne postoje jasna i precizna pravila koja mogu poslužiti kao smernice u izgradnji modela NM. Najčešći metod je ponavljajući metod “probe i greške”, gde se veliki broj različitih modela analizira i međusobno upoređuje.

U ovom radu su prikazani najvažniji koraci u izgradnji modela NM. Pored toga, predstavljene su određene preporuke za izbor parametara arhitekture višeslojne perceptronske mreže (VPM) i parametara treniranja algoritma propagacije greške unazad (PGU). Preporuke su bazirane na osnovu pregleda literature, empirijskih pravila i prethodnog iskustva. Metodologija modeliranja procesa primenom NM je ilustrovana na primeru modeliranja glavnog otpora rezanja kod struganja.

## 2. MODELIRANJE PROCESA OBRADJE REZANJEM

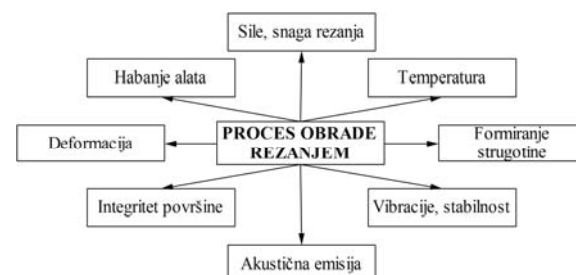
Procesi obrade rezanjem su veoma složeni, nelinearni, procesi koji zavise od različitih poznatih i nepoz-

natih parametara kao i od njihovih interakcija u manjoj ili većoj meri. Proces obrade rezanjem se odvija u specifičnom tribološko-mehaničkom sistemu koji se sastoji od pet osnovnih grupa ulaznih parametara, slika 1.



Slika 1: Ulazni parametri procesa obrade rezanjem

Kod procesa obrade rezanjem praktično svaki parametar se može menjati u širokom intervalu. Pored toga, u mnogim slučajevima, prava relacija između ovih parametara i samog procesa obrade nije u potpunosti definisana. Sam proces obrade karakterišu osam grupa izlaznih parametara, slika 2.



Slika 2: Izlazni parametri procesa obrade rezanjem

Za proteklih 50 godina istraživanja, razvijene su različite metode i pristupi modeliranja obradnih procesa: analitičke metode, “slip-line” rešenja, empirijske metode, metoda konačnih elemenata itd. Za svaki proces obrade rezanjem može se izabrati izlazni parametar koji se može modelirati na više načina. Prema tome, postoji širok spektar modela koji na ovaj ili onaj način modeliraju proces


rezanja. Modeli se mogu klasifikovati prema: vrsti operacije, svrsi, kvantitetu predikcije, vremenu primene i metodi modeliranja. Imajući u vidu svrhu, modeli se mogu klasifikovati na: opisne, predikcione i adaptivne. U zavisnosti od metoda modeliranja modeli se mogu klasifikovati na: empirijske, polu-empirijske i fizičke. [Van Luttervelt, 2001, 1]

U mnogim slučajevima čisto fizičko modeliranje procesa obrade nije dovoljno. U skorije vreme, većina istraživača sve više koristi polu-empirijske modele koji se baziraju na primeni NM. Za procese obrade rezanjem od specijalnog značaja su predikcioni modeli koji vrše kvantitativnu predikciju uticaja ulaznih na izlazne parametre.

### 3. MODELIRANJE PROCESA OBRADRE REZANJEM POMOĆU NEURONSKIH MREŽA

Sposobnost učenja nelinearnih relacija procesa rezanja, bez zalaženja u složenu matematiku procesa i pretpostavki u vezi funkcionalne forme relacija između ulaznih i izlaznih parametara, čine NM atraktivnim alternativnim izborom mnogih istraživača u modeliranju procesa obrade rezanjem [Mukherjee & Ray, 2006, 2]. Generalno, svaki parametar sa slike 1 može predstavljati ulazni parametar procesa obrade rezanjem. Slično, svaki parametar sa slike 2 može biti izabran za izlazni parametar procesa obrade rezanjem. Ovakav vid modeliranja se često naziva direktnim modeliranjem.

NM su masivni paralelni sistemi koji se sastoje od velikog broja jednostavnih procesnih elemenata (neurona) koji su međusobno povezani preko otežanih veza u kojima se znanje mreže čuva. Dijagram mreže sa jednim neuronom prikazan je na slici 3.




Slika 3: Struktura veštačkog neurona

NM se karakterišu svojom arhitekturom, vektorima težina i prenosnim (aktivacionim) funkcijama koje se koriste u skrivenim i izlaznim slojevima mreže. Neuroni u ulaznom sloju primaju ulazne podatke. Svaki neuron sumira ulaze i to jedan ulaz po neuronu u ulaznom sloju, ali više ulaza po neuronu u skrivenom sloju. Prag se koristi da skalira ulaze na interval kako bi se poboljšala konvergencija NM. Svaki neuron prenosi podatke preko prenosne funkcije do svih elemenata u sledećem sloju. Međutim, neuroni dobijaju različite signale usled različitih težina veza između neurona. Konačno, izlaz svakog neurona u izlaznom sloju se upoređuje sa željenim izlazom. U cilju minimizacije razlike između ovih izlaza, vrši se podešavanje težina veza između neurona. Postoje brojne metode za određivanje težina veza između neurona. Naročito se koriste neke varijante algoritma propagacije greške unazad (PGU), algoritmi konjugovanog gradijenta, kvazi-Njutnov algoritam, Levenberg–Marquardt (LM) metod itd. Određivanjem ovih težina vrši se tzv. treniranje mreže korišćen-

jem određenog broja podataka. Kada je treniranje mreže završeno, model NM se može koristiti za predikciju izlaznih parametara na osnovu novih ulaznih podataka iz skupa za testiranje. Takođe, ukoliko su dostupni podaci iz novih merenja, model NM se može adaptirati, čime se dobija nadograđeni model koji ima šire polje primene.

Najčešće korišćene NM za modeliranje procesa obrade rezanjem su: višeslojne perceptronske mreže (VPM), modeli adaptivne rezonantne teorije, modeli samo-organizujućih mapa, modeli mreža sa radijalnom baznom funkcijom itd. Najpopularnija NM za modeliranje procesa obrade rezanjem je VPM trenirana algoritmom PGU. Ova mreža se najčešće koristi iz razloga što su to modeli opšte namene koji imaju dobru sposobnost generalizacije. Takođe, ova mreža je relativno jednostavna za praktičnu primenu. VPM se algoritmom PGU trenira na tzv. nadgledan način. Algoritam PGU je metod najbržeg pada, gde se vrednosti težina podešavaju inkrementalno nakon predstavljanja svakog pojedinačnog podatka iz ulaznog skupa podataka za treniranje. Postoji mogućnost i da se težine podešavaju nakon predstavljanja svih podataka iz skupa za treniranje i to je tzv. blokovsko treniranje. Detaljan opis ovog algoritma može se naći u više literaturnih izvora uključujući [Haykin, 1999, 3]. Na slici 4 je prikazana arhitektura 3-slojne VPM koja se koristi za modeliranje procesa obrade rezanjem. Prvi sloj je ulazni sloj gde se prihvataju podaci. Poslednji sloj, odvojen od prvog jednim ili sa više srednjih tzv. skrivenih slojeva, je izlazni sloj i koristi se za izračunavanje izlaza.



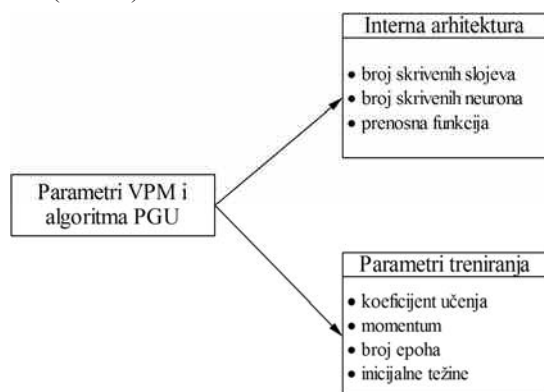
Slika 4: Arhitektura VPM za modeliranje procesa obrade rezanjem

Prema arhitekturi NM prikazanoj na slici 4, za modeliranje procesa obrade rezanjem za ulazne veličine mogu se uzeti vrednosti brzine rezanja, koraka, dubine rezanja itd. Sa druge strane, za izlazne veličine mogu se uzeti vrednosti sile rezanja, habanja alata, hrapavosti obrađene površine itd.

### 4. METODOLOGIJA MODELIRANJA PROCESA NEURONSKIM MREŽAMA

Izgradnja adekvatnog modela NM kojim se modelira proces nije jednostavan zadatak. Pitanja koja se tiču izbora odgovarajućih parametara NM kao i određeni koraci u izgradnji modela moraju se sagledati pažljivo. Kako bi se osiguralo dobre karakteristike modela VPM trenirane algoritmom PGU, neophodno je sva ova pitanja rešavati na sistematski način. Jedan takav pristup treba da odgovori na sledeća pitanja: izbor odgovarajućih ulaza modela, deljenje podataka, priprema podataka, izbor odgovarajuće interne arhitekture, izbor parametara treniranja itd. Naime, dva su procesa od ključnog značaja: koraci u izgradnji modela i pitanja vezana za izbor parametara VPM tj. određivanje

parametara treniranja algoritma PGU i interne arhitekture VPM (slika 5).



Slika 5: Izbor parametara VPM i algoritma PGU

#### 4.1 Izbor parametara VPM i algoritma PGU

Izbor parametara VPM i algoritma PGU uključuje donošenje odluka vezanih za internu arhitekturu i parametre treniranja NM.

**Interna arhitektura.** Specifikacija interne arhitekture podrazumeva određivanje broja skrivenih slojeva, broja skrivenih neurona u svakom skrivenom sloju i izbor prenosnih funkcija neurona u skrivenom i izlaznom sloju. Prva dva parametra su naročito važna jer direktno utiču na performanse modela NM tj. na njegovu sposobnost generalizacije.

**Broj skrivenih slojeva.** Uloga skrivenih slojeva je da mapiraju složene relacije između mrežnih ulaza i izlaza. Do sada, nije predložen uopšteni metod za određivanje broja skrivenih slojeva. Pregledom literature može se videti da se u najvećem broju slučajeva koriste najviše dva skrivena sloja. Kada je reč o primeni NM za modeliranje procesa obrade rezanjem, u svrhu predikcije, većina autora koristi samo jedan skriveni sloj.

**Broj skrivenih neurona.** Broj skrivenih neurona je sigurno jedno od najznačajnijih pitanja jer broj neurona određuje “ekspesivnu snagu” mreže. Dodavanje skrivenih neurona uvek rezultira smanjenjem greške na treningu, ali ponašanje mreže na testu je neizvesno. Naime, dodavanjem skrivenih neurona do određenog broja, greška se i na testu smanjuje, ali sve preko tog broja dovodi do tzv. “overfitting” problema. Obično se broj skrivenih neurona određuje eksperimentisanjem tzv. metodom “proba i greška”. Korišćenje NM sa minimalnim brojem skrivenih neurona je uvek poželjno iz praktičnih i teorijskih razloga. U literaturi se može naći veliki broj empirijskih pravila i preporuka za određivanje broja skrivenih neurona. Međutim, treba istaći da broj skrivenih neurona zavisi od broja dostupnih podataka za treniranje. Da bi NM bila matematički definisana potrebno je da broj otežanih veza, u najmanju ruku, bude manji ili jednak broju podataka za treniranje. Pri tom pod brojem otežanih veza podrazumeva se suma proizvoda između broja neurona u svakom susednom sloju.

**Prenosna funkcija** je matematička funkcija kojom se formira izlaz iz neurona kao funkcija ulaznih signala. Najčešće korišćene prenosne funkcije su sigmoidne funkcije i linearna funkcija. Izbor prenosne funkcije zavisi od vrste podataka koji se koriste i tipa sloja NM. U svrhu predikcije obično se koriste sigmoidne funkcije u skrivenom i izlaznom sloju ili sigmoidna funkcija u skrivenom i

linearna u izlaznom sloju.

**Parametri treniranja.** Izbor parametara treniranja je veoma značajan za efikasno treniranje mreže, a sve u cilju izgradnje adekvatnog modela NM. Najznačajniji parametri treniranja su: koeficijent učenja, momentum, epohe i inicijalne težine.

**Koeficijent učenja** je parametar kojim se definiše brzina učenja NM. Velika vrednost koeficijenta učenja ubrzava konvergenciju, ali takođe može dovesti i do preskakanja globalnog minimuma. Nasuprot tome, male vrednosti koeficijenta učenja, usporavaju proces učenja pa nije neobično da je potrebno i više desetina hiljada epoha da bi algoritam konvergirao. Korišćenje manjih vrednosti za koeficijent učenja je preporučljivo jer se tako osigurava dostizanje globalnog minimuma. Dosadašnja praksa pokazuje da, zavisno od problema, koeficijent učenja može uzimati vrednosti od 0.001 do 10. Preporuke za izbor ovog parametra se mogu naći u više literaturnih izvora, a jedan pregled je dat u [Basheer & Hajmeer, 2000, 4].

**Momentum** je parametar treniranja koji se koristi kako bi se ubrzao i stabilizovao proces treniranja. Velika vrednost momentuma smanjuje rizik da se NM zaglavi u lokalnom minimumu, a male vrednosti ovog parametra povećavaju mogućnost da se rešenje preskoči. Obično ovaj parametar uzima vrednost između 0 i 1. Vrednosti 0.01 za koeficijent učenja i 0.9 za momentum su preporučene vrednosti jer algoritam PGU sa ovim vrednostima parametara ima najbolje performanse predikcije, a pri tom je mreža trenirana sa najmanjim brojem epoha.

**Epohe.** Broj epoha procesa treniranja predstavlja broj predstavljanja podataka za treniranje mreže. Algoritam PGU obezbeđuje da se greška na trening skupu smanjuje paralelno sa povećanjem broja epoha. Međutim, ukoliko je broj epoha jako veliki može se pojaviti tzv. “overtraining” problem. Broj epoha koji je potreban za izgradnju modela NM koji ima dobru generalizaciju može se odrediti metodom “probe i greške” i metodom ukrštene validacije (kada je dostupan veći broj podataka).

**Inicijalne težine.** VPM trenirana algoritmom PGU je senzitivna na inicijalne vrednosti težina. Suviše male vrednosti težina produžavaju vreme treniranja, ali se može javiti i problem konvergencije do optimalnog rešenja. Sa druge strane, ako su inicijalne vrednosti težina suviše velike, tokom treniranja javljaju se tzv. nestabilne težine što dovodi do zasićenja i zaglavlivanja u lokalnim minimumima. Inicijalizacija težina se može izvršiti na slučajan način iz određenog intervala ili pomoću evolutivnih algoritama. Praktična preporuka za inicijalizaciju težina je izbor početnih težina iz uniformne raspodele na intervalu  $\pm 0.5$  ili  $\pm 1$ . Naprednije podešavanje težina može se izvršiti imajući u vidu broj veza svakog neurona. U ovom slučaju, inicijalizacija se vrši iz opsega

$$[-3/\sqrt{v}, +3/\sqrt{v}], \text{ gde je } v \text{ broj ulaznih veza u neuronu.}$$

#### 4.2 Izgradnja modela neuronske mreže

Postoji nekoliko koraka u izgradnji modela NM. Uopšteno, proces izgradnje modela NM uključuje: izbor ulaznih i izlaznih parametara, prikupljanje podataka, filtriranje podataka, pripremu podataka, izbor skupova podataka za treniranje, testiranje i validaciju modela.

**Izbor ulaznih i izlaznih parametara.** Ideja korišćenja NM za modeliranje procesa je da kreira mrežu koja

uzima ulazne procesne parametre kao ulaze i izlazne procesne parametre kao izlaze. Kako bi se kreirao adekvatni model NM neophodno je identifikovati ulazne parametre koji utiču na izlazne parametre i selektovati ih kao ulaze u mrežu. Izbor mrežnih izlaza zahteva određeno poznavanje procesa. NM se mogu trenirati za predikciju jednog ili više izlaza istovremeno.

**Prikupljanje podataka.** Za uspešno modeliranje procesa pomoću NM, potrebno je prikupiti što je moguće više podataka. Kada su u pitanju performanse modela NM, ne samo kvantitet, već kvalitet i reprezentativnost prikupljenih podataka su naročito važni. Izvori podataka mogu biti različiti kao npr. simulacija, eksperimentalna ispitivanja, podaci iz industrijskih procesa, a svi oni se mogu i kombinovati. U svakom slučaju, sve prikupljene podatke je potrebno filtrirati i pripremiti.

**Filtriranje podataka** uključuje proveru integriteta podataka i uklanjanje ekstremnih podataka. Greške kao što su nepravilno uneti podaci, duplirani podaci ili nepotpuni podaci se moraju ispraviti ili u krajnjem slučaju izbaciti iz skupa. Podatke sa jako ekstremnim vrednostima takođe treba ukloniti jer mogu ometati proces treniranja.

**Priprema podataka** ima za cilj da se različite forme i tipovi podataka konvertuju u odgovarajuće formate i intervale sa kojima NM može uspešno da radi. Priprema podataka je važan korak jer se njome ubrzava konvergencija algoritma odnosno proces treniranja. Priprema podataka uključuje skaliranje (normalizaciju) podataka kako bi se izbegao negativan efekat dominantnih vrednosti, ali i zbog prirode prenosnih funkcija. Skaliranje na interval  $[-1, 1]$  je tipično ako je prenosna funkcija hiperbolički tangens, a na interval  $[0, 1]$  ako je u pitanju sigmoidna funkcija. U nekim situacijama, kada ulazne veličine imaju izuzetno velike opsege, od pomoći može biti logaritmovanje podataka pre samog skaliranja.

**Izbor skupova podataka za treniranje i testiranje.** Nakon prikupljanja i pripreme podataka, podatke je potrebno podeliti u dva skupa: za treniranje i za testiranje. Skup podataka za treniranje se koristi za kreiranje modela NM, a skup podataka za testiranje za izračunavanje sposobnosti predikcije modela NM. Ukoliko je dostupan veći broj podataka, preporučljivo je da se podaci podele u tri skupa: za treniranje, za validaciju i za testiranje. Validacioni test se ne koristi za promenu težina mreže već za ocenu performansi mreže u toku treniranja. Korišćenjem validacionog testa, "overfitting" i "overtraining" problemi se mogu izbeći. Odnos između skupa podataka za treniranje i testiranje jako varira u literaturi. Međutim, uobičajeno je da se 90, 80 ili 70 % podataka koristi za treniranje NM, a ostatak za testiranje modela NM. Kada se primenjuje i validacija NM, podela podataka se vrši na tri dela: 50 % za treniranje i po 25 % za validaciju i testiranje.

**Validacija modela.** Kada je model NM kreiran, potrebno je izvršiti njegovu validaciju. Cilj validacije je da se ispita sposobnost generalizacije predloženog modela NM. Ovo se vrši merenjem performansi modela NM na skupu za testiranje koji sadrži podatke koji mreži nikada nisu predstavljani. Najvažnija mera performanse je preciznost predikcije. Mera preciznosti se često definiše preko greške predikcije koja predstavlja razliku između stvarne (željene) vrednosti i vrednosti predikcije modela NM. Postoji veliki broj mera preciznosti koje se mogu naći u literaturi i svaka od njih ima određene prednosti i nedostatke.

Neke od njih su navedene u [Zhang et al., 1998, 5]. (Pirsonov) koeficijent korelacije (R), koren srednje kva-

dratne greške i srednja apsolutna procentualna greška su glavni kriterijumi koji se često koriste za izračunavanje predikcionih performansi modela NM. Koeficijent korelacije predstavlja meru kojom se određuje relativna korelacija između stvarnih i predikcionih vrednosti. To je bezdimenzionalna veličina čija se vrednost kreće u intervalu  $\pm 1$ . Interpretacija koeficijenta korelacije je sledeća:

$|R| \geq 0.8$  – postoji jaka korelacija,  
 $0.8 \geq |R| \geq 0.2$  – postoji korelacija,  
 $|R| \leq 0.2$  – postoji slaba korelacija.

Kada se koristi koren srednje kvadratne greške kao mera performanse, veće greške dobijaju znatno veću pažnju nego manje. Srednja apsolutna procentualna greška ima dobru interpretabilnost, i za razliku od korena srednje kvadratne greške ne tretira male greške simetrično sa velikim greškama. Dobar model NM, bi trebalo da ima korelacioni koeficijent veći od  $|0.8|$ , a poželjno je da koren srednje kvadratne greške i srednja apsolutna procentualna greška budu što je moguće bliže 0.

## 5. PRIMER MODELIRANJA GLAVNOG OTPORA REZANJA

Metodologija modeliranja NM je prikazana na primeru modeliranja glavnog otpora rezanja kod struganja. Eksperimentalni podaci za glavni otpor rezanja u zavisnosti od dubine rezanja –  $a_p$ , brzine rezanja –  $v$ , koraka –  $f$  i napadnog ugla –  $\kappa$  dati u tabeli 1 [Radovanović et al., 2008, 6].

Tabela 1: Glavni otpor rezanja – eksperimentalni podaci

$a_p$ [mm]	$v$ [m/min]	$f$ [mm/o]	$\kappa$ [°]	$F_c$ [N]
1.5	143	0.499	95	1671
0.75	143	0.499	95	840
1.5	143	0.124	95	535
0.75	143	0.124	95	300
<b>1.5</b>	<b>94</b>	<b>0.499</b>	<b>95</b>	<b>1663</b>
0.75	94	0.499	95	837
1.5	94	0.124	95	575
0.75	94	0.124	95	330
1	116	0.249	95	674
1	116	0.249	95	672
<b>1</b>	<b>116</b>	<b>0.249</b>	<b>95</b>	<b>676</b>
1	116	0.249	95	682
1.5	143	0.499	85	1472
0.75	143	0.499	85	843
1.5	143	0.124	85	502
<b>0.75</b>	<b>143</b>	<b>0.124</b>	<b>85</b>	<b>301</b>
1.5	94	0.499	85	1532
0.75	94	0.499	85	904
1.5	94	0.124	85	542
0.75	94	0.124	85	317
1	116	0.249	85	628
1	116	0.249	85	644
<b>1</b>	<b>116</b>	<b>0.249</b>	<b>85</b>	<b>639</b>
1	116	0.249	85	630
<b>1.5</b>	<b>143</b>	<b>0.499</b>	<b>75</b>	<b>1460</b>
0.75	143	0.499	75	801
1.5	143	0.124	75	492
0.75	143	0.124	75	282
1.5	94	0.499	75	1567
0.75	94	0.499	75	847
1.5	94	0.124	75	511
0.75	94	0.124	75	286
1	116	0.249	75	615
<b>1</b>	<b>116</b>	<b>0.249</b>	<b>75</b>	<b>618</b>
1	116	0.249	75	619
1	116	0.249	75	631

□ skup podataka za testiranje

Troslojna VPM, sa četiri ulazna neurona za predstavljanje dubine rezanja, brzine rezanja, koraka i napadnog ugla, jednim skrivenim slojem i jednim neuronom u izlaznom sloju za izračunavanje glavnog otpora rezanja, je kreirana i trenirana algoritmom PGU. Gornja granica broja skrivenih neurona je određena imajući u vidu da broj otežanih veza ne prelazi ukupan broj podataka za treniranje. Jednostavno je izračunati da je za 4 ulaza i 1 izlaz, a za 30 podataka za treniranje, maksimalni broj skrivenih neurona 6.

Izabrana je arhitektura NM sa jednim skrivenim slojem i 4 skrivena neurona (često se preporučuje da broj skrivenih neurona bude jednak broju ulaznih). Za prenosnu funkciju u skrivenom sloju izabran je hiperbolički tangens (tansig), a u izlaznom sloju izabrana je linearna funkcija (purelin1). Izabrani su sledeći parametri treniranja: koeficijent učenja 0.05, momentum 0.9. Inicijalne težine su generisane Nguyen-Widrow metodom koja je standardna u MATLAB-u, dok je maksimalni broj epoha limitiran na 10000.

Podaci su na slučajan način podeljeni u dva skupa: trening skup sa 30 podataka i test skup sa 6 podataka (tabela 1). Pošto je korišćen hiperbolički tangens kao prenosna funkcija u skrivenom sloju, svi podaci su skalirani na interval [-1,1]. MATLAB kod za izgradnju i treniranje (traingdm<sup>1</sup>) NM je:

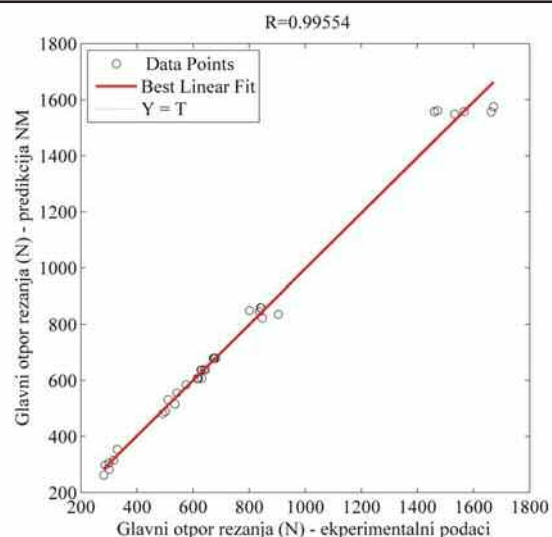
```
net=newff(minmax(p),[4,1],{'tansig','purelin'},'traingdm');
net.trainParam.show = 250; % (broj epoha koji se prikazuje)
net.trainParam.lr = 0.05; % (koeficijent učenja)
net.trainParam.mc = 0.9; % (momentum)
net.trainParam.epochs = 10000; % (broj epoha)
net.trainParam.goal = 1e-5; % (greška treniranja)
[net,tr]=train(net,p,t); % (treniranje mreže, gde je p matri-
ca ulaza i t vektor izlaza)
```

Kada je treniranje NM uspešno završeno, NM se testira na test skupu podataka. MATLAB kod za testiranje istrenirane NM je:

```
sim(net,p);
sim(net,t);
```

Ovim MATLAB kodom dobijen je odziv NM na skupu za treniranje i testiranje. Za ukupnu ocenu modela korišćeni su svi podaci (trening+test). Statistička ocena modela NM izvršena je izračunavanjem koeficijenta korelacije, korena srednje kvadratne greške i srednje apsolutne procentualne greške. Performanse modela NM za predikciju glavnog otpora rezanja su prikazane na slici 6. Visoke vrednosti statističke ocene potvrđuju visoku tačnost ovog modela (koeficijent korelacije je 0.99554, koren srednje kvadratne greške je 36.71 a srednja apsolutna procentualna greška je 2.89 %).

**Zahvalnica.** Autori se zahvaljuju Ministarstvu nauke i tehnološkog razvoja. Rad je rezultat projekta iz oblasti tehnološkog razvoja TR35034: "Istraživanje primene savremenih nekonvencionalnih tehnologija u proizvodnim preduzećima sa ciljem povećanja efikasnosti korišćenja, kvaliteta proizvoda, smanjenja troškova i uštede energije i materijala".



Slika 6: Performanse modela NM za predikciju glavnog otpora rezanja

## 6. ZAKLJUČAK

U ovom radu su prikazane osnovne ideje i koncept primene NM za modeliranje procesa obrade rezanjem. U radu je predstavljena metodologija izgradnje modela NM za predikciju glavnog otpora rezanja kod struganja. Modeliranje primenom NM nije jednostavan zadatak, imajući u vidu da ne postoje jasna pravila kojima bi se odredio, a priori, optimalni model NM. U radu su date praktične preporuke za određivanje arhitekture VPM i parametara treniranja algoritma PGU koje mogu biti od koristi istraživačima u ovoj oblasti. Sama metodologija modeliranja se može podeliti u dva dela: koraci u izgradnji modela i izbor parametara treniranja. Primenom NM izgrađen je predikcioni model za glavni otpor rezanja kod struganja, koji je uspešno testiran na novim podacima.

<sup>1</sup>MATLAB command for the corresponding function

## LITERATURA

- [1] Van Luttervelt, C.A.: Typology of models and simulation methods for machining operations, *Machining Science and Technology*, 5, 3, 2001, pp. 415-428.
- [2] Mukherjee, I., Ray, P.K.: A review of optimization techniques in metal cutting processes, *Computers and Industrial Engineering*, 50, 1, 2006, pp. 15-34.
- [3] Haykin, S.: *Neural networks: a comprehensive foundation*, Prentice Hall, New Jersey, 1999.
- [4] Basheer, A., Hajmeer, M.: Artificial neural networks: fundamentals, computing, design, and application, *Journal of Microbiological Methods*, 43, 1, 2000, pp. 3-31.
- [5] Zhang, G., Patuwo, B.E., Hu, M.Y.: Forecasting with artificial neural networks: the state of the art, *International Journal of Forecasting*, 14, 1, 1998, pp. 35-62.
- [6] Radovanović, M., Madić M., Janković P., Comparison of regression model and artificial neural network model for predicting the main cutting force by turning, *Buletinul institutului politehnic din Iasi, Tomul LIV, Fasc. 2*, 2008, pp. 95-104
- [7] Madić, M., Radovanović, M., Veštačke neuronske mreže i njihova primena u proizvodnim procesima, *IMK-14, Istraživanje i razvoj, časopis Instituta IMK "14. oktobar"*, Kruševac, godina XV, broj 32-33, 3-4/2009, s. 39-44
- [8] Nikolić, R., Đorđević, Lj., Temperaturno polje u strugarskom nožu pri završnoj obradi na suvo čelika Č.1730, *IMK-14, Istraživanje i razvoj, časopis Instituta IMK "14. oktobar"*, Kruševac, godina XVI, broj 35, 2/2010, s. 55-58
- [9] Radovanović, M., Madić M., Janković P., Artificial neural network modeling of cutting force components by turning, *International Scientific Conference UNITECH'08, Gabrovo*, 2008, pp. II486-II490
- [10] Marinković, V., Racionalizacija eksperimentalnih istraživanja primenom teorije višefaktornog eksperimenta, *IMK-14, Istraživanje i razvoj, časopis Instituta IMK "14. oktobar"*, Kruševac, godina XIII, broj 26-27, 1-2/2007, s. 23-36
- [11] Dašić, P., Petropoulos, G., Regresiona zavisnost parametara hrapavosti obradene površine pri struganju reznim alatom od prevučenog tvrdog metala, *IMK-14, Istraživanje i razvoj, časopis Instituta IMK "14. oktobar"*, Kruševac, godina VIII, broj 14-15, 1-2/2002, s. 93-98

## METHODOLOGY OF NEURAL NETWORK BASED MODELING OF MACHINING PROCESSES

**Abstract :** *Machining is the most important and widely used manufacturing process. As machining is very complex process, in recent years neural network based modeling has been preferred modeling of machining processes. This paper outlines and discusses the basic idea and concept of neural network modeling of machining processes. Furthermore this paper discusses the methodology of developing neural network model as well as proposing some guidelines for selecting the network training parameters and network architecture. For illustration purpose, simple neural prediction model for cutting power was developed and validated.*

**Key words:** *Modeling, machining, neural networks*

## UTICAJ IMPREGNANTA AKTIVNOG UGLJA CINK OKSIDA NA HEMISORPCIJU KARBONIL DIHLORIDA

Mladen Nikolić<sup>1)</sup>, Sladjana Savić<sup>1)</sup>, Dragan Nikolić<sup>1)</sup>

Kategorizacija rada:  
ORIGINALNI NAUČNI RAD

Adresa:  
Visoka hemijsko-tehnološka škola Kruševac

**Rezime:** Svi sorbenti a posebno aktivni ugalj imaju izuzetan značaj za sorpciju toksičnih materija. Neki toksikanti mogu biti adsorbovani mehanizmom fizičke sorpcije dok drugi ne podležu ovom mehanizmu. Za toksikante koji ne podležu fizičkoj sorpciji aktivni ugalj se mora impregnirati.

Aktivni ugalj je impregnisiran rastvorom cink oksida (ZnO) u različitim koncentracijama, od 0,47 mol/dm<sup>3</sup> do 1 mol/dm<sup>3</sup>, i istraživana je efekat impregnacije na sorpcioni kapacitet aktivnog uglja za karbonil dihlorid (COCl<sub>2</sub>). Rezultati istraživanja su pokazali da količina ZnO od 1 mola pruža najveći sorpcioni kapacitet.


**Ključne reči:** Aktivni ugalj, sorpcioni kapacitet, cink oksid, impregnacija, hemisorpcija

### 1. UVOD

Aktivni ugalj je veoma čest i popularan sorbent koji ima veoma široku primenu u procesima separacije i prečišćavanja zbog svog velikog kapaciteta sorpcije, velike aktivne površine i adekvatne raspodele pora. Kod para i gasova koji imaju malu molekulska masu, nisku tačku ključanja i znatan polaritet, sorpcioni kapacitet slabi i aktivni ugalj više nije efektivan [1]. Aktivni ugalj je zbirno ime za grupu poroznih ugljeva koji su dobijeni tretiranjem uglja oksidirajućim gasovima ili karbonizacijom ugljeničnih materijala, impregnisanih isušivajućim hemikalijama. Svi ovi ugljevi pokazuju veoma visok stepen poroznosti i veoma veliku specifičnu površinu [2].

Prostori između slojeva kod aktivnog uglja obrazuju udubljenja, pore različitih veličina koje se dele na mikropore, prelazne pore i makropore.

Mikropore su najsitnije pore sa prečnikom ispod 2 nm [3]. Na osnovu ispitivanja Dubinina, veliki broj mikroporoznih aktivnih ugljeva ima prečnike mikropora u intervalu od 0,4 nm do 0,8 nm. Veličina ovih pora poklapa se sa veličinom adsorbujućih molekula (sl. 1.).



Slika 1. Kristalna struktura aktivnog uglja

Specifična zapremina mikropora kod aktivnih ugljeva kreće se u intervalu od 0,20 cm<sup>3</sup>/g do 0,60 cm<sup>3</sup>/g a površina 1g mikropora od 10 m<sup>2</sup> do 200 m<sup>2</sup> [1].

Prelazne pore ili mezopore su krupnije od mikropora i imaju prečnike od 2 nm do 50 nm. Specifična zapremina prelaznih pora aktivnih ugljeva kreće se u granicama od 0,1 cm<sup>3</sup>/g do 0,5 cm<sup>3</sup>/g. Površina po jednom gramu mezopora je u intervalu od 20 m<sup>2</sup> do 70 m<sup>2</sup>. Efektivni prečnici prelaznih pora nalaze se u intervalu od 40 nm do 100 nm.

Makropore imaju prečnik iznad 50 nm i najkrupnije su pore aktivnog uglja. Specifična zapremina makropora kreće se u intervalu od 0,2 cm<sup>3</sup>/g do 0,8 cm<sup>3</sup>/g a površina 1g makropora u granicama od 0,5 m<sup>2</sup> do 2 m<sup>2</sup>.

Veliki broj toksičnih materija sorbuje se na određenim sorbentima fizičkom sorpcijom, hemisorpcijom i katalitičkom sorpcijom. Za toksične materija koje se sorbuju fizičkom sorpcijom nije potrebna impregnacija sorbenta. Za one toksikante koji se ne sorbuju fizičkom sorpcijom neophodno je izvršiti impregnaciju sorbenta, određenim hemijskim materijama, da bi se povećao sorpcioni kapacitet sorbenta, odnosno da bi se povećalo vreme filtracije [4]. Za određene toksikante hemisorbenti koji se nalaze na sorbentu imaju i ulogu katalizatora procesa oksidacije i hidrolize. Međutim, hemisorbenti koji se nalaze na aktivnom uglju smanjuju fizičku sorpciju drugih zagađivača, što uslovljava i količinu hemisorbenta na uglju.

U radu je opisano istraživanje uticaja hemisorbenta aktivnog uglja ZnO (u količinama od 0,47 mol do 1 mol) na hemisorpciju COCl<sub>2</sub>.

### 3. EKSPERIMENTALNO ISTRAŽIVANJE

Polazna sirovina za impregnaciju bila je ugljenisana kokosova ljuska, koja je pre toga drobljena i aktivirana vodenom parom. U toku aktivacije, aktivirane su pore uglja i postale su dostupne toksičnim parama i gasovima, a prelazne pore i makro pore i hemisorbentima.

Pripremljen aktivni ugalj za impregnaciju posedovao je sledeće karakteristike:

- masa po dm<sup>3</sup> = 324 g
- pepeo po dm<sup>3</sup> = 2,43%
- isparljive materije po dm<sup>3</sup> = 3,71%

Upotrebom sita predviđenog standardom dobijen je aktivni ugalj određenog granulometrijskog sastava.

Granulometrijski sastav aktivnog uglja koji je korišćen u impregnaciji prikazan je u tabeli 1..

**Tabela 1. Granulometrijski sastav korišćenog aktivnog uglja**

Prečnik čestica (mm)	Procentualna zastupljenost (%)
2,0	0,9
1,6	14,3
1,25	46,95
1,0	18,8
0,8	17,7
0,5	1,4

Površina aktivnog uglja, koji je korišćen u eksperimentu, iznosila je 1278,58 m<sup>2</sup>/g. Za impregnaciju su korišćena 4 uzorka aktivnog uglja.

**Tabela 2. Impregnacija aktivnog uglja sa ZnO**

Redni broj	Količina ZnO (mol)	Zapremina aktivnog uglja (dm <sup>3</sup> )	Masa aktivnog uglja (g)	Procenat Zn na aktivnom uglju (%)	Masa Zn na aktivnom uglju (g)
1.	0,47	1	423	6,77	30,72
2.	0,49	1	423	7,04	32,03
3.	0,6	1	423	8,49	39,22
4.	1	1	423	13,38	65,37

Ovako dobivenim aktivnim ugljem punjeni su mikroprobni filteri. Prilikom punjenja aktivni uglj je posedovao vlagu od 0 % do 7 %. Visina mikroprobnih filtera iznosila je 27 mm a prečnik 105 mm.

Mikroprobni filteri pripremljeni na ovaj način ispitivani su na aparaturi za dinamičku sorpciju.

Za ispitivanje sorpcionog kapaciteta aktivnog uglja korišćena je gasna smeša COCl<sub>2</sub> i vazduha, sa pro-

tokom od 0,0066964 mola COCl<sub>2</sub> i 29,85 dm<sup>3</sup> vazduha u minuti.

Relativna vlažnost vazduha podešavana je propuštanjem vazduha kroz sud sa vodom i koncentrovanom sumpornom kiselinom.

Rezultati ispitivanja sorpcionog kapaciteta mikroprobnih filtera prikazani su u tabeli 3..

**Tabela 3. Sorpcioni kapacitet mikroprobnih filtera**

Impregnant	ZnO			
Količina impregnanta (mol)	0,47	0,49	0,6	1
Redni broj merenja	Sorpcioni kapacitet (g)			
I	9,61	9,50	9,61	8,62
II	9,61	9,61	9,94	9,94
III	9,28	9,28	9,28	10,94
Srednja vrednost sorpcionog kapaciteta	9,50	9,46	9,61	9,83

#### 4. ZAKLJUČAK

Na osnovu eksperimentalnog istraživanja može se zaključiti da sa porastom količine impregnanta ZnO na aktivnom uglju, u intervalu od 0,47 mol do 1 mol, raste i sorpcioni kapacitet impregnisanog, aktivnog uglja za COCl<sub>2</sub>. Količina od 0,47 mol ZnO obezbeđuje sorpcioni kapacitet mikroprobnih filtera za COCl<sub>2</sub> od 9,5 g, dok količina od 1 mola ZnO obezbeđuje najveći sorpcioni kapacitet za COCl<sub>2</sub> od 9,83 g.

#### LITERATURA

- [1] R.C. Bansal, J.B. Donnet and H.F. Stoeckli: Active Carbon, Marcel Dekker, New York (1988).
- [2] F. Rodriguez-Reinoso: Encyclopedia of Materials, Science and Technology, Activated Carbon, Elsevier Ltd., (2006).
- [3] K.S.W. Sing et al.: Pure Appl. Chem. 57, (1985), p. 603.
- [4] D. Nikolić i dr.: Impregnisanje aktivnog uglja i konstrukcija filtera u cilju povećanja zaštitne moći, I Inter-nacionalna konferencija o ekologiji, 26.-27. jun, Banja Luka, (2009).

### EFFECTS OF ACTIVE COAL ZINC OXIDE IMPREGNANT ON THE CHEMISORPTION CARBONYL DICHLORIDE

**Abstract:** All of the sorbents, and especially activated charcoal have significant importance for sorption of the toxic materials. Some of the toxicants can be adsorbed by the mechanism of physical sorption, while others are not subjected to this kind of mechanism. For toxicants that are not subjected to physical sorption impregnation of activated carbon must be done. Activated charcoal were impregnated with the solution of zinc oxide (ZnO) of various concentrations, from 0.47 mol/dm<sup>3</sup> up to 1 mol/dm<sup>3</sup>, and the effect of impregnation on the sorption capacity of the activated charcoal for carbonyl dichloride (COCl<sub>2</sub>) was investigated. Research results showed that the amount of ZnO from 1 mol offering the highest sorption capacity.

**Key words:** Activated charcoal, sorption capacity, zinc oxide, impregnation, chemisorption.