

Indirektni nadzor istrošenosti svrdla kod bušenja kompozitnih materijala

Zoričić, Mate

Master's thesis / Diplomski rad

2015

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:235:662807>

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

DIPLOMSKI RAD

Mate Zoričić

Zagreb, 2015.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Doc. dr. sc. Danko Brezak

Student:

Mate Zoričić

Zagreb, 2015.

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

Zahvaljujem se doc. dr. sc. Danku Brezaku na stručnoj pomoći i kvalitetnim savjetima tijekom izrade ovog rada.

Zahvaljujem se svojoj obitelji koja mi je bila podrška tijekom cijelog mog školovanja.

Mate Zoričić



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske 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:	

DIPLOMSKI ZADATAK

Student: **Mate Zoričić**

Mat. br.: 0035182032

Naslov rada na hrvatskom jeziku: **Indirektni nadzor istrošenosti svrdla kod bušenja kompozitnih materijala**

Naslov rada na engleskom jeziku: **Indirect tool wear condition monitoring in drilling composite materials**

Opis zadatka:

Kontinuirana procjena stupnja istrošenosti reznih alata za vrijeme obrade od iznimnog je značaja za sigurnost, produktivnost i kvalitetu obradnog procesa. Uzevši u obzir sve veću zastupljenost kompozitnih materijala u velikoserijskoj proizvodnji, posebice u avionskoj i automobilske industriji, od interesa je analizirati karakteristike različitih vrsta signala i značajki procesa, te algoritama obrade signala u cilju kvalitetne procjene istrošenosti reznog alata. U industrijskim se aplikacijama dinamika procesa trošenja pokazala izrazito nelinearnom, a dijelom i stohastičke prirode. Stoga se modeliranje najčešće izvodi primjenom algoritama računalne inteligencije i značajki generiranih iz snimljenih signala procesa.

U ovome će radu biti provedena analiza signala sila rezanja i struja motora posmičnih osi stroja i glavnog vretena u procjeni istrošenosti alata u postupku bušenja polimera ojačanog staklenim vlaknima. Iz snimljenih i filtriranih signala izdvojiti će se značajke trošenja iz vremenskog i frekvencijskog područja, te će se zatim provesti detaljna analiza dobivenih značajki primjenom neuronske mreže s radijalnim baznim funkcijama.

U radu je potrebno:

1. Izraditi programsku podršku za filtriranje i obradu snimljenih signala procesa bušenja (sila rezanja i struja pogonskih motora alatnog stroja).
2. Iz pripremljenih signala izdvojiti adekvatne značajke procesa trošenja.
3. Izraditi programsku podršku za neuronsku mrežu koja će biti primijenjena u procjeni istrošenosti svrdla.
4. Izvršiti detaljnu analizu utjecaja svih značajki trošenja i njihovih kombinacija na kvalitetu procjene parametara istrošenosti svrdla.
5. Izvesti zaključke rada.

Zadatak zadan:

24. rujna 2015.


Rok predaje rada:

26. studenog 2015.

Predviđeni datum obrane:

2., 3. i 4. prosinca 2015.

Zadatak zadao:


Doc. dr. sc. Danko Brezak

Predsjednik Povjerenstva:


Prof. dr. sc. Franjo Cajner

SADRŽAJ

SADRŽAJ	III
POPIS SLIKA	V
POPIS TABLICA.....	VI
POPIS OZNAKA I KRATICA	VII
SAŽETAK.....	1
1. UVOD	2
1.1. Bušenje	2
1.1.1. Parametri obrade kod bušenja	2
1.2. Trošenje alata.....	4
1.2.1. Abrazijsko trošenje.....	5
1.2.2. Adhezijsko trošenje	6
1.2.3. Trošenje uslijed difuzije	7
1.2.4. Trošenje uslijed oksidacije	7
1.2.5. Trošenje uslijed umora	7
1.2.6. Oblici trošenja rezne oštrice alata	8
1.3. Metode mjerenja istrošenosti alata	10
1.3.1. Nadzor pomoću sila.....	11
1.3.2. Nadzor pomoću struja pogonskih motora	11
1.3.3. Nadzor primjenom signala akustične emisije.....	11
1.4. Kompozitni materijali.....	12
2. UMJETNE NEURONSKE MREŽE	14
2.1. Biološki neuron.....	14
2.2. Umjetni neuron	15
2.3. Matematički model RBF mreže.....	17
2.4. Učenje	20
3. SNIMANJE I OBRADA SIGNALA	23
3.1. Stroj	23
3.2. Mjerni sustav	24
3.3. Senzor sila.....	25
3.4. Vizijski sustav.....	27
3.5. Filtriranje	28
3.5.1. Fourierova transformacija	29
3.6. Izdvajanje značajki trošenja.....	33
3.6.1. Značajke sila.....	34

3.6.2. Značajke struja	35
4. ANALIZA REZULTATA.....	38
4.1. Učenje	38
4.2. Testiranje	38
4.3. Rezultati testiranja	38
5. ZAKLJUČAK	44
6. LITERATURA.....	45

POPIS SLIKA

Slika 1. Profil glavnih brzina rezanja kod bušenja	3
Slika 2. Sile rezanja kod bušenja.....	4
Slika 3. Proces obrade odvajanjem čestica.....	5
Slika 4. Jedinični događaj abrazije	6
Slika 5. Trošenje alata u ovisnosti o temperaturi	7
Slika 6. Mogući oblici trošenja reznih alata	8
Slika 7. Parametri trošenja alata	9
Slika 8. Trošenje stražnje površine alata	9
Slika 9. Kratersko trošenje alata.....	10
Slika 10. Raspored vlakana u vlaknima ojačanom kompozitu.....	12
Slika 11. Shematski prikaz proizvodnje cijevi od kompozitnog materijala	13
Slika 12. Pojednostavljena struktura biološkog neurona	14
Slika 13. Struktura umjetnog neurona	15
Slika 14. Struktura RBF mreže	17
Slika 15. Tok preslikavanja ulaza X na izlaz O	18
Slika 16. Primjeri radijalnih baznih funkcija	18
Slika 17. Gaussova aktivacijska funkcija	19
Slika 18. Sinkroni servo motor.....	23
Slika 19. Radni prostor stroja; 1. Posmični prigon X osi, 2. Posmični prigon Y osi, 3. Posmični prigon Z osi, 4. Glavno vreteno, 5. Stezna naprava, 6. Senzor sila, 7. Senzor vibracija, 8. Industrijska kamera s rasvjetom, 9. Ispitni uzorak, 10. Ispitno svrdlo.....	24
Slika 20. Mjerni sustav.....	25
Slika 21. Senzor sila Kistler 9257B	26
Slika 22. Kamera DMG41AF02 i telecentrični objektiv TC2309	27
Slika 23. Signal struje F_z	28
Slika 24. Transformacija funkcije iz vremenske u frekvencijsku domenu	29
Slika 25. Signal sile F_z u frekvencijskoj domeni	30
Slika 26. Niskopropusni Butterworthov filter	31
Slika 27. Filtrirani signali sile F_z	32
Slika 28. Primjeri filtriranih signala struja	32
Slika 29. Primjeri filtriranih signala sila	33
Slika 30. Trenuci kad svrdlo ulazi i izlazi iz zahvata	37
Slika 31. Ovisnost uspješnosti klasifikacije o broju neurona skrivenog sloja.....	43

POPIS TABLICA

Tablica 1. Tehničke karakteristike motora	23
Tablica 2. Tehničke karakteristike mjernog sustava	26
Tablica 3. Tehničke karakteristike vizijskog sustava	27
Tablica 4. Odabrani parametri obrade	28
Tablica 5. Primjeri često korištenih značajki	34
Tablica 6. Značajke sila	35
Tablica 7. Značajke struja	36
Tablica 8. Uspješnost klasifikacije pomoću značajki sila	39
Tablica 9. Uspješnost klasifikacije pomoću značajki struja	40
Tablica 10. Usporedba uspješnosti klasifikacije značajki sila i struja	41
Tablica 11. Uspješnost klasifikacije pomoću kombinacija više značajki	41

POPIS OZNAKA I KRATICA

oznaka	jedinica	opis
C		matrica težinskih faktora
c_j		težinski faktori
CVD		chemical vapor deposition
D	mm	promjer svrdla
d_j		Euklidijska udaljenost
f	mm/okr	posmak
F_c	N	glavna sila rezanja
F_f	N	posmična sila rezanja
F_N	N	normalna komponenta sile
F_p	N	povratna sila rezanja
F_r	N	rezultantna sila
F_T	N	tangencijalna komponenta sile
F_x	N	sila u smjeru osi X
F_y	N	sila u smjeru osi Y
F_z	N	sila u smjeru osi Z
$ G(j\omega) $	dB	omjer amplituda ulaznog i izlaznog signala signala
H		matrica učenja
h_j		vrijednost radijalne bazne funkcije
I	A	struja
K		broj neurona skrivenog sloja
KB		širina kratera na prednjoj površini alata
KM		udaljenost središta kratera od oštrice
K_t	Nm/A	konstanta momenta motora
KT		dubina kratera na prednjoj površini alata
L		broj neurona ulaznog sloja
M		broj neurona izlaznog sloja
N	s^{-1}	učestalost vrtnje
NTA		nadzor trošenja alata
O		matrica izlaza
O_w		element izlaznog neurona
P	W	snaga
PCD		polikristalični dijamant
RBF		radijalna bazna funkcija
t_j		vektori centara
VB	mm	širina istrošenosti stražnje površine svrdla
VBmax		najveća vrijednost širine trošenja stražnje površine alata
v_c	m/min	glavna brzina rezanja
w_{ij}		otežani ulaz u neuron
X		matrica ulaza u mrežu
x_i		vektor ulaza u mrežu
β		koeficijent grupiranja
σ		koeficijent širine aktivacijske funkcije
ω	rad/s	kutna brzina motora

SAŽETAK

U ovom radu obrađeni su i analizirani signali sila i signali struja pogonskih motora alatnog stroja snimljeni tijekom bušenja polimernog kompozita ojačanog staklenim vlaknima. U programskom jeziku MATLAB izrađena je programska podrška za umjetnu neuronsku mrežu s radijalnim baznim funkcijama. Pomoću značajki izdvojenih iz signala sila i struja pokušalo se utvrditi može li se umjetnom neuronskom mrežom uspješno procijeniti stupanj istrošenosti svrdla.

1. UVOD

Jedan od preduvjeta autonomnosti obradnih sustava je mogućnost adekvatnog nadzora stanja rezne oštrice alata. Mnogo istraživanja provodi se u svrhu pronalaska pouzdanih metoda za nadzor trošenja alata (NTA). Međutim, takvi sustavi još uvijek nisu šire primijenjivi u industriji. Jedan od glavnih razloga za nedostatak primjene sustava za NTA je činjenica da se postojeće metode temelje na matematičkim modelima za koje je potrebno prikupiti velike količine empirijskih podataka. Prepreku pouzdanim NTA sustavima također predstavlja dinamika procesa rezanja koja je često nelinearne, a dijelom i stohastičke prirode.

U cilju što uspješnijeg modeliranja procesa trošenja reznih alata, u ovome je radu primjenjena umjetna neuronska mreža s radijalnim baznim funkcijama. Navedeni tip neuronske mreže pokazao se uspješnim u rješavanju problema klasifikacije i estimacije.

1.1. Bušenje


Bušenje je postupak obrade odvajanjem čestica za bušenje provrta ili proširivanje već postojećih provrta, pri čemu provrt može biti zatvoren ili prolazan. Glavno gibanje kod bušenja je rotacijsko kontinuirano, a posmično je pravocrtno kontinuirano. Alat za bušenje je svrdlo, definirane geometrije reznog dijela, najčešće s dvije glavne oštrice i jednom poprečnom.

1.1.1. Parametri obrade kod bušenja [1]

Osnovni parametri obrade kod bušenja su posmak (f), brzina rezanja (v_c) i učestalost vrtnje (N). Posmak je aksijalna udaljenost koju svrdlo prijeđe tijekom jednog okretaja. Brzina rezanja računa se izrazom:


$$v_c = D\pi N \quad (1)$$

gdje je D promjer svrdla. Budući da je glavno gibanje rotacijsko, brzina rezanja duž oštrice nije konstantna. Prema izrazu (1), brzina rezanja u osi svrdla jednaka je nuli, dok je na obodu maksimalna (slika 1).



Slika 1. Profil glavnih brzina rezanja kod bušenja [1]

Sila rezanja jedne oštrice svrdla se može rastaviti na tri komponente: glavnu silu rezanja F_c , posmičnu silu F_f i natražnu silu F_p . Glavnu silu rezanja čine dvije komponente (za svrdla s dvije oštrice), $F_c/2$. Isto vrijedi za posmičnu i natražnu silu. Navedene sile rezanja prikazane su na slici 2.




Slika 2. Sile rezanja kod bušenja [1]

Glavna sila rezanja poprečne oštrice označena je s F_{cp} , a posmična s F_{fp} . Također u sustavu je prisutna i sila trenja, F_t , koja je rezultat dodira i relativnog gibanja između alata, obratka i odvojene čestice.

1.2. Trošenje alata [2]

Trošenje se javlja gdje god postoji relativno gibanje dvaju tijela u kontaktu, pa je tako i pri obradi odvajanjem čestica pojava trošenja neizbježna. Trošenje nastaje kao posljedica opterećenja kojima je alat izložen tijekom obrade. Faktori koji utječu na trošenje alata mogu se podijeliti u tri skupine (slika 3):

- parametri vezani uz pripremak
- parametri vezani uz alat
- parametri vezani uz uvjete obrade



Slika 3. Proces obrade odvajanjem čestica [2]

Procesi trošenja mogu se podijeliti u dvije skupine:


- procesi koji su posljedica mehaničkih opterećenja (abrazija i adhezija),
- procesi koji su posljedica kemijskog djelovanja između alata, obratka i okoline (oksidacija, difuzija).

1.2.1. Abrazijsko trošenje

Abrazija je proces istiskivanja materijala uzrokovan tvrdim izbočinama ili tvrdim česticama. Abrazijsko je trošenje uvijek prisutno te se najčešće smatra glavnim procesom trošenja u trošenju stražnje površine alata, a sudjeluje pri najstajanju i drugih oblika trošenja. Na abrazijsko trošenje najznačajnije utječe odnos tvroća dvaju tijela u kontaktu.

Na slici 4 prikazan je jedinični događaj abrazije. Sastoji se od dvije faze:

- faza I: prodiranje abraziva (a) u površinu materijala (b) pod utjecajem normalne komponente opterećenja F_N ,
- faza II: istiskivanje materijala u obliku čestica trošenja (č) pod utjecajem tangencijalne komponente opterećenja F_T .



Slika 4. Jedinični događaj abrazije [3]

S obzirom na međusobni odnos tvrdoća materijala u kontaktu, moguća su tri slučaja:

- 1) **Čista** abrazija djeluje kada je tvrdoća abraziva veća od tvrdoće trošene podloge.
- 2) **Selektivna** abrazija djeluje kada u abradiranom materijalu postoji faza tvrđa od abraziva. Abraziv troši samo zahvaćeni sloj mekše faze. Površina je izbrazdana s prekidima na mjestima gdje se na površini nalaze zrna tvrđe faze.
- 3) **Nulta** abrazija nastaje kada je cijela abradirana površina tvđa od abraziva. Površina ima polirani izgled, a čestice trošenja najčešće su sitne ljuskice koje potječu od vanjskog graničnog sloja. Nulta abrazija najčešće se javlja na površinskim slojevima dobivenim različitim postupcima modificiranja ili prevlačenja površine (boriranje, vanadiranje, CVD, PVD...).

1.2.2. Adhezijsko trošenje

Adhezijsko trošenje nastaje uzastopnim mikrozavarivanjem mikroneravnina na površini dvaju tijela u kontaktu. Pri trganju mikrozavara s površine tijela odnose se sitne čestice. Ovaj mehanizam trošenja svojstven je alatima od brzoreznog čelika i alatima od tvrdog metala koji rade na manjim brzinama.

1.2.3. Trošenje uslijed difuzije

Visoke temperature koje se javljaju tijekom obrade velikim brzinama rezanja stvaraju uvjete za kemijske procese u materijalu, gdje atomi (npr. C ili Fe) prelaze s jednog tijela na drugo, što za posljedicu ima smanjenje mehaničkih i triboloških svojstava.


1.2.4. Trošenje uslijed oksidacije

Visoka temperatura i prisutnost zraka na većini metala uzrokuje oksidaciju. Svojstva oksida ovise o materijalu alata. Na primjer, volfram i kobalt formiraju porozne oksidne filmove koji se lako skidaju, što dovodi do trošenja, pa su tako tvrdi metali na bazi tih elemenata najskloniji oksidacijskom trošenju.

1.2.5. Trošenje uslijed umora

Trošenje uslijed umora nastupa kao posljedica periodički promjenjivih mehaničkih i toplinskih naprezanja. Prekidne obrade (kao što je glodanje) osobito su sklone generiranju takvog oblika trošenja zbog činjenice da one uzrokuju stalno periodičko grijanje i hlađenje te mehaničke udare prilikom ulaska i izlaska alata iz zahvata.


Slika 5 prikazuje u kojoj su mjeri zastupljeni različiti mehanizmi trošenja s obzirom na temperaturu. Vidljivo je kako abrazijsko trošenje uvijek podjednakim intenzitetom sudjeluje u trošenju alata, dok se mehanizmi kemijskog djelovanja javljaju tek pri visokim temperaturama.



Slika 5. Trošenje alata u ovisnosti o temperaturi

1.2.6. Oblici trošenja rezne oštrice alata [4]

Primjeri mogućih oblika trošenja reznih alata prikazani su na slici 6.




Slika 6. Mogući oblici trošenja reznih alata [5]

- 1) trošenje stražnje površine,
- 2) kratersko trošenje,
- 3) zarezno trošenje,
- 4) trošenje stražnje površine (maksimalno),
- 5) oksidacijsko zarezno trošenje,
- 6) plastična deformacija,
- 7) naljepak,
- 8) toplinska napuknuća,
- 9) uzdužna napuknuća,
- 10) razgradnja oštrice,
- 11) lom oštrice.

Najčešće korišteni parametri trošenja (slika 7) su:

- VB – širina trošenja stražnje površine alata,
- VB_{max} – najveća vrijednost širine trošenja stražnje površine alata,
- KT – dubina kratera na prednjoj površini alata,
- KM – udaljenost središta kratera od oštrice,
- KB – širina kratera.



Slika 7. Parametri trošenja alata [1]

Trošenje stražnje površine alata (slika 8) pojavljuje se u većini obrada odvajanjem čestica. Širinu područja trošenja koja se označava s VB (njem. *Verschleißbreite*) moguće je mjeriti s dovoljnom preciznošću pa je to najčešće korišteni kvantitativni parametar trošenja alata. [4]



Slika 8. Trošenje stražnje površine alata [2]

Kratersko trošenje (slika 9) nastaje na prednjoj površini alata na mjestu gdje odvojena čestica klizi po površini alata. Do formiranja kratera najčešće dolazi na udaljenosti 0,2-0,5 mm od ruba oštrice. Najčešće se pojavljuje prilikom obrade čelika ili ostalih materijala s visokom točkom tališta pri relativno velikim brzinama rezanja. Krater postupno postaje sve dublji i može u potpunosti uništiti reznu oštricu, a time i sam alat. [4]

Kratersko trošenje nastaje u području maksimalnih temperatura pa su kemijski mehanizmi trošenja dominantan uzrok pojave kratera.



Slika 9. Kratersko trošenje alata [2]

1.3. Metode mjerenja istrošenosti alata

Kontinuirani nadzor stupnja istrošenosti alata potreban je radi pravodobne zamjene alata. U današnje se vrijeme zamjena alata još uvijek vrši na temelju iskustva i „osjećaja“ operatera, ili pak na temelju predviđene trajnosti alata. Te su procjene nekad prekonzervativne što dovodi do zamjene alata prije nego je njegov životni vijek u potpunosti iskorišten. S druge strane, prekasna zamjena alata može biti uzrok nezadovoljavajućim dimenzijama i/ili hrapavošću površine obratka.

Metode mjerenja stupnja istrošenosti reznih alata mogu se općenito kategorizirati u skupinu direktnih i indirektnih metoda. Tehnikama direktnog nadzora alata izravno se identificira stanje oštrice alata, tj. kvantificira se aktualna vrijednost razmatranog parametra trošenja. Kao takve, te metode daju vrlo preciznu informaciju o stupnju istrošenosti alata. Međutim, u industrijskim uvjetima obrade kvantifikaciju istrošenosti često ometaju vanjski uvjeti kao što su odvojene čestice i sredstva za hlađenje, ispiranje i podmazivanje. Nadalje, većina direktnih metoda primjenjiva je samo kada se alat nalazi izvan zahvata, stoga im je nedostatak što nastupa kašnjenje u procjeni stupnja istrošenosti. [6]

Kod indirektnih se metoda parametri trošenja procjenjuju primjenom različitih signala procesa vezanih uz trošenje alata, kao što su sile rezanja, vibracije i slično. Postupci mjerenja tih signala relativno su jednostavni, no s druge strane potrebna je zahtjevna obrada signala koja uključuje filtriranje signala i izdvajanje adekvatnih značajki trošenja. No za razliku od direktnih metoda, indirektna metode pružaju mogućnost nadzora alata u realnom vremenu ('on-line' nadzor), čime se osigurava nužan preduvjet inteligentnog vođenja alatnog stroja. [6]

Tijekom procesa obrade generira se niz signala kao što su sile rezanja, momenti, akustična emisija, vibracije i drugi, čiji iznosi u većoj ili manjoj mjeri koleriraju s istrošenošću alata pa se njihovim praćenjem može vršiti indirektna procjena istrošenosti alata.

1.3.1. Nadzor pomoću sila [7]

Signali sila jedna su od osnovnih informacija o procesu obrade u obradi odvajanjem čestica. Pri kontaktu alata s obratkom dolazi do elastičnih i plastičnih deformacija u smičnim zonama, što uzrokuje rezanje materijala. Pojave pri tom procesu odražavaju se u silama rezanja. Kako bi se u svakom trenutku mjerenjem sila mogao procijeniti stupanj istrošenosti alata, potrebno je poznavati točan odnos između trošenja i sila rezanja. Poznato je da postoji korelacija između sila rezanja i trošenja, no problem je što na sile rezanja, osim istrošenosti, utječe i niz drugih parametara kao što su tvrdoća materijala, struktura materijala, parametri obrade i sl.

1.3.2. Nadzor pomoću struja pogonskih motora

Uvid u stanje istrošenosti alata mogu dati i signali struja pogonskih motora alatnog stroja budući da one direktno ovise o opterećenju motora, koje pak ovisi o parametrima procesa rezanja. Prednost mjerenja struja nad mjerenjem sila leži u činjenici da je mjerenje strujnih signala već integrirano u servo-regulaciji elektromotora, što uklanja potrebu za ugradnjom dodatnih mjernih uređaja.

1.3.3. Nadzor primjenom signala akustične emisije

Tijekom obrade odvajanjem čestica dolazi do elastičnih i plastičnih deformacija, trenja, lomova. Te su pojave generatori akustične emisije. Signali akustične emisije su uz sile jedni od najčešće korištenih mjernih signala. Međutim, u dosadašnjim istraživanjima još uvijek nije postignut konsenzus oko pitanja mogu li signali akustične emisije poslužiti za kvalitetnu procjenu istrošenosti alata. Trenutno je prevladavajući trend primjene signala akustične emisije u problemima klasifikacije dva ili tri područja trošenja, odnosno u procjenama loma alata. [6]

1.4. Kompozitni materijali [8]


Kompozitni materijali proizvedeni su umjetnim spajanjem dvaju ili više materijala različitih svojstava s ciljem dobivanja materijala takvih svojstava kakva ne posjeduje ni jedna komponenta sama za sebe. Osnova kompozita (matrica) može biti metalna, keramička ili polimerna.

U praksi su najrašireniji kompoziti s polimernom matricom ojačani vlaknima, koja su najčešće staklena, ugljična ili aramidna. Zadatak polimerne matrice je da:

- povezuje vlakna
- prenosi opterećenje na vlakna
- štiti vlakna od vanjskih utjecaja

Značajka mnogih polimernih kompozita su visoka specifična čvrstoća (omjer čvrstoće i gustoće) i specifična krutost, tj. omjer modula elastičnosti i gustoće. Takva svojstva proizlaze iz činjenice da se u polimernu matricu koja je niske gustoće i relativno loše čvrstoće i krutosti ugrađuju čvrsta i kruta vlakna. Materijal matrice prenosi opterećenje na vlakna te osigurava duktilnost i žilavost budući da vlakna nose veći dio opterećenja. Kao takvi, sve više nalaze primjenu u područjima gdje je vrlo važno masu svesti na minimum, ali zadržati određena mehanička svojstva, kao što su avioindustrija, automobilska industrija, svemirska tehnika, brodogradnja.

Vlakna se u matrici mogu rasporediti na više različitih načina (slika 10). Ukoliko se kontinuirana vlakna polože samo u jednom smjeru (slika 10a), kompozit će biti izrazito anizotropan, tj. imat će različita mehanička svojstva u različitim smjerovima. Optimalna vlačna čvrstoća se postiže ukoliko je opterećenje paralelno s vlaknima. Jednoličnija svojstva kompozita mogu se postići polaganjem vlakana u različitim smjerovima, ali se time žrtvuje maksimalna čvrstoća. Korištenjem kraćih, diskontinuiranih vlakana postiže se manja čvrstoća zbog činjenice da srednji dio vlakna nosi više opterećenja od krajeva vlakana.




Slika 10. Raspored vlakana u vlaknima ojačanom kompozitu

Staklo je kao ojačalo široko primjenjivano iz nekoliko razloga:

- Lako se u rastaljenom stanju izvlači u oblik vlakna
- Lako je nabavljiv materijal i brojnim tehnikama proizvodnje se može vrlo ekonomično proizvoditi
- staklena vlakna relativno su čvrsta, što rezultira relativno visokom specifičnom čvrstoćom kompozita
- Kombiniranjem s različitim polimerima postiže se kemijska inertnost, što rezultira kompozitima korisnim za primjenu u različitim korozivnim sredinama

U ovome je radu modelirano trošenje svrdla tijekom bušenja kompozita s polimernom matricom (nezasićena poliesterska smola) ojačanog staklenim vlaknima. Udio ojačala iznosi oko 60%. Cijev je izrađena postupkom namatanja kontinuiranih vlakana na rotirajući kalup kao što je prikazano na slici 11. [1]



Slika 11. Shematski prikaz proizvodnje cijevi od kompozitnog materijala

2. UMJETNE NEURONSKE MREŽE


Umjetne neuronske mreže nastale su u pokušajima modeliranja funkcije ljudskog mozga. Psiholog William James 1890. godine iznosi tvrdnju kako aktivnost bilo koje točke mozga predstavlja zbroj tendencija svih ostalih točaka da se „prazne“ u nju. Te tendencije proporcionalne su:

- 1) broju točaka (veza) koje djeluju na promatranu točku,
- 2) intenzitetu tih uzbuda (težini veza) i
- 3) odsutnosti rivalne točke koja nije u funkcionalnoj vezi s promatranom točkom, a u koju bi se „pražnjenje“ ostalih točaka moglo skrenuti.

Ta je tvdnja služila kao temelj za izgradnju osnovne strukture umjetnog neurona pa se tako aktivnost umjetnog neurona može modelirati kao zbroj otežanih ulaza neurona (ulaza pomnoženih s težinskim faktorima). Takav neuron služi kao osnovni blok za izgradnju umjetnih neuronskih mreža, a mreže se međusobno razlikuju po strukturi veza među neuronima i neurona s okruženjem mreže, te po metodologiji određivanja intenziteta tih veza. [9]

2.1. Biološki neuron

Biološki neuron je živčana stanica i osnovna je jedinica živčanog sustava. Pojednostavljeno gledano, sastoji se od tijela, aksona i mnoštva dendrita (slika 12). Iz tijela izlaze razgranati izdanci – dendriti. Oni se povezuju sa susjednim neuronima i time stanici omogućuju primanje podražaja. Mjesto kontakta između dva neurona naziva se sinapsa. Iz tijela stanice također izlazi i jedan dugi izdanak – akson. On primljeni podražaj prenosi na dendrite susjednog neurona.




Slika 12. Pojednostavljena struktura biološkog neurona [8]

Neki neuron poslat će impuls kroz svoj akson ako je doveden u stanje dovoljne uzbude. Signali koje prima od dendrita mogu biti smirujući ili uzbudni. Neuron će poslati impuls kroz svoj akson ako je njegova uzbuda veća od smirujućeg utjecaja za kritični iznos, koji predstavlja prag osjetljivosti neurona. [9]

2.2. Umjetni neuron

Jedan od osnovnih modela umjetnog neurona (tzv. perceptron) prikazan je na slici 13. Umjetni neuron dizajniran je s namjerom da oponaša osnovne funkcije biološkog neurona. Tijelo biološkog neurona zamjenjuje se sumatorom, a ulogu dendrita preuzimaju ulazi u sumator. Izlaz iz sumatora je akson umjetnog neurona, a uloga praga osjetljivosti bioloških neurona preslikava se na tzv. aktivacijske funkcije. Funkcijske sinaptičke veze biološkog neurona s njegovom okolinom preslikavaju se na težinske faktore, preko kojih se ostvaruje veza umjetnog neurona s okolinom. [9]



Slika 13. Struktura umjetnog neurona [9]

Naravno, ovo je vrlo pojednostavljeni model koji zanemaruje mnoge karakteristike biološkog neurona.

Paralelno složen skup neurona čini jedan sloj neuronske mreže. Mreže se prema tipu mogu podijeliti na nekoliko različitih načina, na primjer:

- jednostlojne i višeslojne,
- unaprijedne i povratne,
- supervizorne i nesupervizorne.

Umjetne neuronske mreže najčešće se sastoje od ulaznog i izlaznog sloja između kojih se nalazi jedan ili više tzv. skrivenih slojeva. Ako signali neuronskom mrežom putuju samo u jednom smjeru, tada se govori o unaprijednim neuronskim mrežama. Ako postoji povratna petlja, to se naziva povratnom neuronskom mrežom. [9]

Podešavanje strukture mreže i njenih parametara naziva se učenjem. Kao i biološke neuronske mreže, umjetne mreže uče iz iskustva. Na mrežu se dovede neki set ulaznih podataka te s njima povezani izlazni podaci na temelju kojih se pomoću određenih algoritama (ovisno o tipu mreže) izračunavaju parametri mreže.

Kod supervizornog učenja vanjski „učitelj“ prati ponašanje mreže i korigira ju dok se ne dobije željeno ponašanje mreže. Kod takvog učenja najprije se odredi određena struktura mreže, zatim se na ulaz mreže dovede skup ulaznih varijabli te se izlaz iz mreže uspoređuje sa željenim. Razlika između dobivenih i željenih izlaza predstavlja pogrešku mreže koja se pomoću određenih algoritama koristi pri računanju novih parametara. Postupak se ponavlja iteracijski sve dok vrijednost pogreške ne padne ispod neke zadane vrijednosti. [9]

Kod nesupervizornog učenja mreža se sama organizira, bez korištenja vanjskog učitelja. Na ulaz se dovodi skup ulaznih varijabli, a parametri mreže se podešavaju prema definiranim algoritmima. [9]

Nakon postupka učenja provodi se postupak testiranja gdje se na ulaz mreže dovede skup uzoraka koji nije bio korišten u postupku učenja. Mreža sada daje nove izlazne podatke koji se uspoređuju sa željenima. Iznos greške služi za procjenu generalizacijskih svojstava mreže, tj. sposobnosti mreže da daje zadovoljavajuće rezultate za skup ulaza kojim nije bila učena.

Osnovne prednosti neuronskih mreža leže u mogućnosti paralelnog procesiranja informacija, prilagodljivosti te u sposobnosti učenja. Također, neuronske mreže su u mogućnosti dati zadovoljavajući izlaz čak i ako im se na ulaz pošalju nepotpuni podaci ili podaci koji sadrže šum.


Neke od primjena neuronskih mreža su [10] :

- brza obrada slike i prepoznavanje oblika,
- analiza signala i filtriranje šuma,
- konverzija teksta u govor i obrnuto,
- predviđanje (npr. prognoza vremena),
- dijagnostika (medicina, tehnika),
- upravljanje i regulacija.

U ovom radu korištena je umjetna neuronska mreže s radijalnim baznim funkcijama (RBF).

2.3. Matematički model RBF mreže


Struktura RBF mreže prikazana je na slici 14. Strukturirana u tri sloja: ulazni, skriveni i izlazni sloj. Ulazni i izlazni sloj definirani su razmatranim problemom. Broj neurona ulaznog sloja (L) ovisi o broju ulaznih vektora, tj. u ovom konkretnom slučaju o broju značajki sila i struja koje će se razmatrati. Broj neurona izlaznog sloja (M) određen je brojem klasifikacijskih skupina, što su u ovom slučaju stupnjevi istrošenosti svrdla. Jedino je broj neurona skrivenog sloja (K) određen od strane korisnika u fazi učenja mreže. Svaki neuron skrivenog sloja opisan je L -dimenzionalnim vektorom centra. Neuroni ulaznog i skrivenog sloja vezani su vektorima centara t_j i parametrima aktivacijske funkcije. Naposljetku, skriveni sloj je preko težinskih faktora c_j povezan s neuronima izlaznog sloja. Time se ostvaruje preslikavanje L -dimenzionalnog ulaznog vektora na M -dimenzionalni izlazni vektor. [11]



Slika 14. Struktura RBF mreže [11]

Dakle, skriveni sloj je glavni dio RBF mreže i zajedno s težinskim faktorima predstavlja znanje mreže o promatranom problemu.


Na slici 15 prikazan je tok preslikavanja ulaza X na izlaz O .

Slika 15. Tok preslikavanja ulaza X na izlaz O

Najprije se uspoređuju ulazni vektori x_i s vektorima centara skrivenog sloja t_j (vektori centara određuju se u fazi učenja mreže koja je opisana u poglavlju 2.4.). Odabrana metoda uspoređivanja je metoda Euklidijevih udaljenosti. Ako su vektori $x = (x_1, x_2, \dots, x_n)$ i $t = (t_1, t_2, \dots, t_n)$, Euklidijeva udaljenost d između njih definirana je izrazom:

$$d = \sqrt{(x_1 - t_1)^2 + (x_2 - t_2)^2 + \dots + (x_n - t_n)^2} \quad (2)$$

Pomoću izračunatih vrijednosti Euklidijevih udaljenosti d_{ij} računaju se vrijednosti aktivacijske funkcije $h(d_{ij})$. Kao što naziv mreže kaže, aktivacijska funkcija mora biti odabrana iz grupe radijalnih baznih funkcija. To su funkcije koje su simetrične s obzirom na središte, u središtu imaju ekstremnu vrijednost (minimum ili maksimum) te ih karakterizira monoton rast ili pad s obzirom na njihovo središte. Neke radijalne bazne funkcije prikazane su na slici 16.




Slika 16. Primjeri radijalnih baznih funkcija [9]

Prema Micchellievom teoremu, ako je funkcija h kontinuirana u intervalu $[0, \infty)$ i pozitivna u intervalu $(0, \infty)$, a prva derivacija joj je u potpunosti monotona, tada će matrica $\mathbf{H}$ imati pozitivnu determinantu, čime je ostvaren uvjet njene invertibilnosti. Taj je uvjet nužan kako bi se mogao provesti postupak učenja. [9]

Postoji niz funkcija koje zadovoljavaju navedene uvjete. Neke od njih su Gaussova funkcija, inverzna kvadratna funkcija, trokutna funkcija. U ovom radu primijenjena je Gaussova aktivacijska funkcija (slika 17). Njena vrijednost računa se izrazom:

$$h(d) = e^{-\left(\frac{d}{\sigma}\right)^2} \quad (3)$$

gdje je d Euklidijska udaljenost ulaznog uzorka od centra neurona skrivenog sloja, a σ koeficijent koji određuje širinu funkcije.



Slika 17. Gaussova aktivacijska funkcija [12]

Nakon izračuna vrijednosti $h(d_{ij})$ ostalo je još povezati skriveni sloj s izlaznim slojem. Ta veza je ostvarena preko težinskih faktora jednačbom:

$$O_w(x_i) = \sum_{j=1}^K h(d_{ij})c_{jw}, \quad i = 1, \dots, L; w = 1, \dots, M \quad (4)$$

pri čemu je O_w element w -tog izlaznog neurona. Izraženo u matricnom obliku, skup vrijednosti $h(d_{ij})$ tvori matricu $\mathbf{H}$ koja pomnožena s matricom težinskih faktora $\mathbf{C}$ daje matricu izlaza $\mathbf{O}$.

$$\mathbf{O} = \mathbf{HC} \quad (5)$$

2.4. Učenje

U fazi učenja određuje se broj neurona skrivenog sloja, računaju se položaji njihovih centara te se računa matrica težinskih faktora $\mathbf{C}$.

Postoji više metoda određivanja položaja centara skrivenog sloja t_j . Najjednostavniji način je da se kao centri slučajnim odabirom izaberu neke od točaka skupa za učenje. No u cilju kvalitetnijeg određivanja broja neurona skrivenog sloja i njima pripadajućih vektora centara, primijenjena je metoda opisana u nastavku.

Prvo se određuju početne (inicijalne) vrijednosti centara, zatim se one dodatno podešavaju metodom K-srednjih vrijednosti (eng. *K-means clustering*). Izračunom inicijalnih vrijednosti također se definira broj neurona u skrivenom sloju. Inicijalni položaji centara određuju se na sljedeći način [12]:

1. Definira se vrijednost koeficijenta grupiranja β .
2. Uzima se prvi uzorak te se on proglasi centrom prve grupe uzoraka.
3. Taj centar se uspoređuje sa svim ostalim uzorcima izračunom Euklidijove udaljenosti između centra i svakog pojedinog uzorka.
4. Dobivene Euklidijeve udaljenosti uspoređuju se s vrijednošću β . Ako je udaljenost između promatranog uzorka i centra manja ili jednaka vrijednosti β , tada se taj uzorak svrstava u grupu s tim centrom.
5. Kad se formira grupa uzoraka, centar se računa kao srednja vrijednost uzoraka te grupe
6. Uzorci koji su svrstani u grupu izuzimaju se iz daljnjeg izračuna centara
7. Iz reduciranog skupa uzoraka uzima se prvi uzorak koji se proglašava centrom nove grupe uzoraka.
8. Postupak se ponavlja od 3. koraka sve dok se svi uzorci ne razvrstaju u svoje grupe. Na kraju se dobiva K broj centara, što predstavlja K neurona skrivenog sloja.

Odabirom koeficijenta grupiranja β korisnik direktno utječe na strukturu mreže, a time i na kvalitetu njenog odziva. Ukoliko je koeficijent grupiranja jednak nuli, skriveni sloj imat će onoliko neurona koliko ima ulaznih uzoraka, budući da će svaki uzorak pripadati svojoj vlastitoj grupi. Ukoliko se odabere veći koeficijent grupiranja, broj neurona skrivenog sloja bit će manji.

Nakon izračuna inicijalnih vrijednosti centara slijedi dodatno podešavanje metodom K-srednjih vrijednosti [12]:

1. Računa se Euklidijska udaljenost između svakog ulaznog uzorka i svakog centra izračunatog u prethodnom postupku.
2. Za svaki ulazni uzorak pronalazi se njemu najbliži centar, tj. centar od kojeg taj uzorak ima najmanju Euklidijsku udaljenost
3. Svi uzorci koji imaju minimalnu Euklidijsku udaljenost od promatranog centra svrstavaju se u istu grupu
4. Za svaku grupu računa se srednja vrijednost uzoraka u toj grupi te se rezultat proglašava novim centrom te grupe.
5. Ako centri poprima nove vrijednosti, postupak se ponavlja. Ako su vrijednosti izračunatih centara jednake prethodno izračunatim centrima, postupak se prekida, te se iste vrijednosti proglašavaju konačnim vrijednostima centara neurona skrivenog sloja.

Slijedi izračun parametra širine aktivacijske funkcije σ . On je određen metodom P najbližih susjeda. Širina aktivacijske funkcije j -tog neurona skrivenog sloja izražunava se izrazom:

$$\sigma_j = \sqrt{d_1 d_2} \quad (6)$$

gdje su d_1 i d_2 Euklidijske udaljenosti j -tog neurona od dva njemu najbliža neurona u skrivenom sloju.

Parametar širine σ mora biti takav da postoji preklapanje između susjednih aktivacijskih funkcija. Ukoliko se odabere premalena vrijednost σ , aktivacijske funkcije će biti preuske pa neće pokriti cijelo područje učenja. Posljedica toga bi bila mogućnost adekvatnog određivanja izlaznih vrijednosti samo onih elemenata koji se nalaze u neposrednoj blizini centra aktivacijske funkcije. S druge strane, odabirom prevelike vrijednosti σ , tj. širine aktivacijske funkcije gube se lokalna svojstva mreže, a mogu se javiti i problemi u izračunu inverzije, tj. pseudoinverzije matrice učenja H . [12]

Posljednji korak učenja je izračun matrice težinskih faktora C . Veza između skrivenog i izlaznog sloja definirana je izrazom (5).

Matrica učenja H formirana na temelju ulaznih uzoraka prema postupku opisanom u poglavlju 2.3. Vektori ulaznih uzoraka sastoje se od informacije o parametrima obrade za svaki pojedini uzorak te od pripadajućih vrijednosti odabranih značajki. Matrica izlaza O sadrži informacije o stupnjevima istrošenosti svrdla za pojedine uzorke. Ona je fazi učenja poznata mreži kako bi se pomoću nje izračunala matrica težinskih faktora C . Ukoliko je matrica H kvadratna, matrica težinskih faktora C može se izračunati množenjem izraza (5) inverzijom matrice H :

$$C = H^{-1}O \quad (7)$$

Ukoliko je matrica H pravokutna, matricu težinskih faktora potrebno je računati pseudoinverzom matrice H :

$$\mathbf{C} = \mathbf{H}^+ \mathbf{O} \quad (8)$$

gdje je $\mathbf{H}^+$ Moore-Penroseov pseudoinverz matrice koji se računa prema izrazu:

$$\mathbf{H}^+ = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \quad (9)$$

Izračunom matrice težinskih faktora završen je postupak učenja mreže. Centri neurona skrivenog sloja, parametri aktivacijske funkcije i matrica težinskih faktora $\mathbf{C}$ predstavljaju znanje umjetne neuronske mreže o razmatranom problemu.


3. SNIMANJE I OBRADA SIGNALA

3.1. Stroj

Bušenje se izvedeno na 3-osnoj glodalici s 3 translacijske osi i vertikalnim glavnim vretenom. Glavni prigon je izveden direktno, tj. prihvat alata ugrađen je na motor. Posmični prigon izveden je kombinacijom kliznih vodilica i kugličnog navojnog vretena. Za sva četiri pogonska motora koriste se sinkroni servo motori proizvođača Mecapion Ltd., tip APMSB04ADK (slika 18). Karakteristike pogonskog motora prikazane su u tablici 1. [1]

Tablica 1. Tehničke karakteristike motora [1]


	Vrijednost	Jedinica
Nazivna snaga	400	W
Nazivni moment	1,274	N·m
Maksimalni moment	3,822	N·m
Moment inercije	0,321	$\text{kg}\cdot\text{m}^2\times 10^4$
Nazivna učestalost vrtnje	3000	min^{-1}
Nazivna jakost struje	2,89	A_{RMS}
Maksimalna učestalost vrtnje	5000	min^{-1}
Rezolucija enkodera	3000	impulsa/okretaju
Konstanta momenta vrtnje motora (K_T)	0,46	$\text{N}\cdot\text{m}/A_{\text{RMS}}$
Naponska konstanta vrtnje motora (K_V)	29,5	$V_{\text{RMS}}/(\text{min}^{-1}\times 10^3)$




Slika 18. Sinkroni servo motor [1]

3.2. Mjerni sustav [1]

Radni prostor stroja prikazan je na slici 19, a mjerni sustav na slici 20. Sastoji se od senzora sila, senzora vibracija te njima pripadajućih pojačala, industrijske kamere s telecentričnim objektivom i rasvjetom, mjernog sustava i mjerne aplikacije.



Slika 19. Radni prostor stroja; 1. Posmični prigon X osi, 2. Posmični prigon Y osi, 3. Posmični prigon Z osi, 4. Glavno vreteno, 5. Stezna naprava, 6. Senzor sila, 7. Senzor vibracija, 8. Industrijska kamera s rasvjetom, 9. Ispitni uzorak, 10. Ispitno svrdlo [1]



Slika 20. Mjerni sustav [1]

3.3. Senzor sila

Za mjerenje signala sila korišten je mjerni sustav sačinjen od tro-komponentnog piezo-električnog sila proizvođača Kistler Holding AG, model 9257B (slika 21) u kombinaciji s odgovarajućim nabojnim pojačalom istog proizvođača, model 5017B. Senzor je ugrađen ispod stezen naprave na posmičnom prigonu X osi. Tehničke karakteristike mjernog sustava sila prikazane su u tablici 2. [1]



Slika 21. Senzor sila Kistler 9257B [1]

Tablica 2. Tehničke karakteristike mjernog sustava sila [1]

			Područje	Jedinica
Senzor sila (tip 9257B)	Mjerno područje	F_x, F_y	-5 ... 5	kN
		F_z	-5 ... 10	
	Maksimalne dozvoljene sile	F_x, F_y	-7,5/7,5	
		F_z	-7,5/15	
	Osjetljivost	F_x, F_y	-7,5	pC/N
		F_z	-3,7	
	Prag osjetljivosti		<0,01	N
	Linearnost u mjernog područja		<±1	%
	Prag histereze mjernog područja		<0,5	%
Nabojno pojačalo (tip 5017B)	Broj kanala		3 (do 8)	
	Mjerno područje (podesivo po kanalu)		±10 ... 10 ⁶	pC
	Frekvencijsko područje		0 ... 200	kHz
	Osjetljivost (podesiva po kanalu)		0,01 ... 9990	pC/N
	Skaliranje mjerne veličine (podesivo po kanalu)		0,001 ... 10 ⁷	N/V
	Izlazni signal (po kanalu)		±10	V

3.4. Vizijski sustav

Vizijski sustav korišten je za direktno mjerenje rezne oštrice alata. Sastoji se od industrijske kamere proizvođača Imaging Source Europe GmbH model DMK41AF02, telecentričnog objektiva proizvođača opto Engineering S.r.l. model TC2309 i prstenaste LED rasvjete (slika 22). Osnovne tehničke karakteristike vizijskog sustava prikazane su u tablici 3. Obradom fotografija snimljenih vizijskim sustavom kvantificirana je istrošenost alata mjerenjem širine područja trošenja na stražnjoj površini alata (VB i VBmax). To su parametri koji se u ovom slučaju smatraju najznačajnijim parametrima trošenja. [1]



Slika 22. Kamera DMG41AF02 i telecentrični objektiv TC2309 [1]

Tablica 3. Tehničke karakteristike vizijskog sustava

			Područje	Jedinica
Kamera (DMK41AF02)	Rezolucija		1280x960	piksela
	Osjetljivost		0,05	lx
	Frekv. osvježavanja slike		3,75 ... 15	Hz
	Format osjetilnog senzora		1/2	in
	Izvedba osjetilnog senzora		CCD	
	Prihvat objektiva		C/CS	
Objektiv (TC2309)	Faktor povećanja		1,00 ±3 %	
	Vidno polje (za format senzora 1/2")		6,4x4,8	mm
	Radna udaljenost		63,3±2	mm
	Dubinska oštrina		0,9	mm
	Distorzija	tipična	<0,04	%
		maksimalna	0,08	
	Telecentričnost	tipična	<0,08	°
		maksimalna	0,10	
Izvedba prihvata		C		
Rezolucija mjernog sustava u opisanoj konfiguraciji			5	µm

Kao parametri obrade odabrane su 4 brzine rezanja i 4 posmaka, što daje 16 kombinacija parametara obrade. Za svaku od tih 16 kombinacija parametara obrade snimljeni su pokusi s 4 različita stupnja istrošenosti svrdla. Svaki pokus ponovljen je 10 puta, čime je prikupljeno ukupno 640 mjerenja. Odabrani parametri obrade prikazani su u tablici 4.


Tablica 4. Odabrani parametri obrade

Brzina rezanja v_c [m/min]	Posmak f [mm/okr]	Stupanj istrošenosti
15	0,03	S1
30	0,06	S2
45	0,09	S3
60	0,12	S4

3.5. Filtriranje

Prije nego se signali mogu upotrijebiti u neuronskoj mreži, potrebno ih je prvo analizirati te po potrebi digitalno filtrirati i obraditi.

Slika 23 prikazuje jedan od snimljenih signala sila u smjeru Z osi. Kao što je vidljivo, signal sadrži šum. Izvori tog šuma mogu biti vibracije stroja i okoline, deformacije, lomovi odvojenih čestica i sl. Iz takvog signala potrebno je ukloniti šumove koji nisu direktno vezani za promatrani proces kako bi ostao samo dio signala koji je nosioc informacija o promatranom procesu.



Slika 23. Signal struje F_z

U današnje vrijeme velik broj industrijskih mjernih sustava već sadrži ugrađen filter signala. Pomoću njega se najčešće ograničava frekvencijski pojas na područje u kojem senzor može kvalitetno mjeriti, imajući u vidu njegove karakteristike. Uz navedeno, signal je potrebno dodatno filtrirati unutar radnog područja senzora kako bi se prigušili šumovi. Odabir vrste filtra može ovisiti o karakteristikama signala, alata, stroja, obratka, parametara obrade i sl. Drugim riječima, postupak filtriranja potrebno je odrediti za svaki slučaj zasebno, imajući na umu individualne karakteristike procesa. Time se izbjegava prigušivanje onih dijelova signala koji su nositelji potrebnih informacija o stanju oštice alata. [10]

Kako bi se primjenio odgovarajući postupak filtriranja, signale je potrebno najprije analizirati u frekvencijskoj odmeni.


3.5.1. Fourierova transformacija

Svaki signal može se razložiti na niz sinusoidalnih signala određenih amplituda i frekvencija, koje predstavljaju komponente frekvencijskog spektra signala.

Na primjer, neka je funkcija:


$$x(t) = 4 + 2 \cdot \sin(14\pi t) + 5 \cdot \cos(30\pi t)$$

Navedena funkcija prikazana je na slici 24a. Iz jednadžbe je vidljivo da se funkcija sastoji od tri komponente. Prva je komponenta konstanta 4 koja cijelu krivulju translatira u pozitivnom smjeru ordinate za 4 jedinice. Druga je komponenta sinusoida čija je amplituda jednaka 2 jedinice, a frekvencija jednaka 7 Hz. Treća je komponenta kosinusoida amplitude 5 jedinica i frekvencije 15 Hz. Transformiranjem navedene funkcije u frekvencijsku domenu dobiva se dijagram amplituda-frekvencija prikazan na slici 24b. Na dijagramu su vidljive tri točke, i to upravo onih frekvencija i amplituda koje karakteriziraju komponente promatrane funkcije.



Slika 24. Transformacija funkcije iz vremenske u frekvencijsku domenu

Primjenom Fourierove transformacije na signalu prikazanom na slici 23 dobiva se dijagram prikazan na slici 25. Odmah se uočava nekoliko dominantnih komponenti signala. Komponente najviših amplituda nalaze se tik uz nulu. Te su komponente najdominantnije pa se može pretpostaviti da su upravo one nosioci glavnog djela signala.



Slika 25. Signal sile F_z u frekvencijskoj domeni

Sljedeća komponenta od interesa nalazi se na frekvenciji od 13,1 Hz. Promatrani signal snimljen je pri obradi brzinom rezanja $v_c = 15$ m/min, a svrdlo je promjera 6 mm. Prema jednaždbi (1), učestalost vrtnje izračunava se izrazom:


$$N = \frac{v_c}{D\pi} \quad (10)$$

$$N = \frac{\frac{15}{60}}{6 \cdot 10^{-3} \cdot \pi}$$

$$N = 13,26 \text{ s}^{-1}$$



Slijedi da frekvencija vrtnje svrdla iznosi $13,26 \text{ s}^{-1}$, što je približno jednako frekvenciji od 13,1 Hz na kojoj se nalazi komponenta signala. Kako svrdlo sadrži dvije rezne oštrice, treća komponenta signala nalazi se na dvostruko većoj frekvenciji, tj. 26,2 Hz. Te dvije komponente signala uzrokovane su rotacijom svrdla, pa se može pretpostaviti da u vremenskom području ne nose korisnu informaciju o istrošenosti svrdla. Prema tome, taj dio signala potrebno je filtrirati.

Iz navedenog slijedi da je signale potrebno filtrirati niskopropusnim filtrom koji će prigušiti više frekvencije (šum), a zadržati komponente signala koje nose korisne informacije. Pri odabiru frekvencije rezanja treba voditi računa da se ne odabere preniska frekvencija. Naime, ne postoji idealni filter. Realni niskopropusni filter će u određenoj mjeri prigušiti i frekvencije koje se nalaze tik ispod frekvencije rezanja, kao što je to kvalitativno prikazano Bodeovim dijagramom niskopropusnog Butterworthovog filtra na slici 26. Ukoliko se odabere preniska frekvencija rezanja, može se dogoditi da se djelomično priguši i dio signala koji nosi korisnu informaciju, ali ukoliko je frekvencija rezanja previsoka, u signalu će ostati značajan dio šuma.




Slika 26. Niskopropusni Butterworthov filter

Odabran je Butterworthov niskopropusni filter trećeg reda frekvencije rezanja 2 Hz koji je primijenjen na svih 7 tipova signala sila i struja. Slika 27 prikazuje signal prije i poslije primjene filtra. Može se primijetiti da je u signalu ostala određena količina šuma jer su parametri filtra odabrani tako da prigušenje kreće od frekvencije koja je na sigurnoj udaljenosti od glavne komponente signala.

Slika 27. Filtrirani signali sile F_z 

Slika 28. Primjeri filtriranih signala struja



Slika 29. Primjeri filtriranih signala sila

Na slikama 28 i 29 prikazani su primjeri svih snimanih struja i sila. Iz snimljenih signala je vidljivo da je među silama dominantna ona u smjeru Z osi koja je višestruko veća od sila u smjeru X i Y osi. To je i bilo za očekivati budući da se jedino posmično gibanje kod bušenja odvija u smjeru Z osi, dok gibanja drugim dvjema osima nema. Slično je i kod signala struja. Dominantne su struje motora Z osi i motora glavnog vretena.

3.6. Izdvajanje značajki trošenja

Nakon filtriranja, potrebno je iz signala izdvojiti značajke trošenja koje će služiti kao ulaz u neuronsku mrežu. Općenito govoreći, pri obradi signala značajke se mogu podijeliti u tri glavne skupine: statističke značajke, značajke iz vremenskog područja i značajke iz frekvencijskog područja. U tablici 5 prikazane su najčešće korištene značajke. [10]

Tablica 5. Primjeri često korištenih značajki [10]

Statističke značajke	Značajke iz vremenskog područja	Značajke iz frekvencijskog područja
- Aritmetička sredina - Varijanca - Standardna devijacija - Koeficijent spljoštenosti - Koeficijent asimetrije - Koeficijenti AR, MA, ARMA - Različiti koeficijenti graničnih vrijednosti - Križna korelacija - Harmonijska sredina	- Prosječne i efektivne vrijednosti signala u nekom vremenskom intervalu - Kratkotrajni porasti ili smanjenja vrijednosti u signalima - Omjeri sila - Faktori krijeste - Polinomne aproksimacije signala	- Dominantne amplitude/snage spektra - Spektralna gustoća snage cijelog signala - Spektralna gustoća snage u pojedinim segmentima signala - Frekvencija najveće amplitude spektra - Ukupna snaga signala u okolini frekvencije najveće amplitude spektra

3.6.1. Značajke sila

Prve dvije značajke sila iz vremenskog područja bit će maksimalna vrijednost sile u smjeru Z osi F_z i maksimalna vrijednost rezultantne sile F_r . Kako bi se izbjegao utjecaj vršnih vrijednosti sila nastalih uslijed stohastičkih pojava, izračunata je srednja vrijednost najvećih 10% izmjerenih vrijednosti. Rezultantna sila određena je izrazom:

$$F_r = \sqrt{F_x^2 + F_y^2 + F_z^2} \quad (11)$$

U cilju dodatne analize primjene signala sila rezanja u određivanju stupnja istrošenosti, korištene su još dvije značajke iz vremenskog područja – površina ispod krivulje F_z i površina ispod krivulje F_r .

Kako bi se analizirala povezanost između istrošenosti svrdla i sila okomitih na smjer bušenja (F_x i F_y), izdvojena je i značajka površine ispod krivulje F_r' koja je definirana izrazom:

$$F_r' = \sqrt{F_x^2 + F_y^2} \quad (12)$$

Izdvajanje značajki iz frekvencijskog područja provedeno je primjenom Fourierove transformacije. Pritom su kao značajke odabrane snage spektralnih komponenti svih triju sila na frekvenciji vrtnje i na frekvenciji oštrica. Tablica 6 prikazuje svih jedanaest izdvojenih značajki sila.

Tablica 6. Značajke sila

Oznaka	Opis	Oznaka	Opis
Max(Fz)	Prosjek 10% najvećih vrijednosti sile F_z	S_FV(Fx)	Snaga spektralne komponente sile F_x na frekvenciji vrtnje
Max(Fr)	Prosjek 10% najvećih vrijednosti sile F_r	S_FO(Fx)	Snaga spektralne komponente sile F_x na frekvenciji oštrica
Pov(Fz)	Površina ispod krivulje sile F_z	S_FV(Fy)	Snaga spektralne komponente sile F_y na frekvenciji vrtnje
Pov(Fr)	Površina ispod krivulje sile F_r	S_FO(Fy)	Snaga spektralne komponente sile F_y na frekvenciji oštrica
Pov(Fr')	Površina ispod krivulje sile F_r'	S_FV(Fz)	Snaga spektralne komponente sile F_z na frekvenciji vrtnje
		S_FO(Fz)	Snaga spektralne komponente sile F_z na frekvenciji oštrica

3.6.2. Značajke struja

Kako bi se utvrdilo mogu li značajke struja zamijeniti značajke sila u klasifikaciji istrošenosti svrdla, analizirat će se i značajke signala struja. Značajke struja izdvojene su na sličan način kao i značajke sila. Izdvojene su značajke maksimalnih struja i površina ispod krivulja struja motora glavnog vretena i motora Z osi, te snage spektralnih komponenti na frekvenciji vrtnje i frekvenciji oštrica struja svih četiriju motora.

Nadalje, izdvojene su značajke površina ispod krivulje snage motora glavnog vretena i motora Z osi. Snage motora izračunate su sljedećim izrazom:

$$P = K_T \cdot I \cdot \omega \quad (13)$$

gdje je K_T momentna konstanta motora koja iznosi 0,46 Nm/A, ω je kutna brzina motora, a I struja motora. Pregled svih značajki struja prikazan je u tablici 7.

Tablica 7. Značajke struja


Oznaka	Opis	Oznaka	Opis
Max(I_z)	Prosjeak 10% najvećih vrijednosti struja I_z	S_FO(I_x)	Snaga spektralne komponente struje I_x na frekvenciji oštrica
Max(I_{gv})	Prosjeak 10% najvećih vrijednosti struja I_{gv}	S_FV(I_y)	Snaga spektralne komponente struje I_y na frekvenciji vrtnje
Pov(I_z)	Površina ispod krivulje struja I_z	S_FO(I_y)	Snaga spektralne komponente struje I_y na frekvenciji oštrica
Pov(P_I_z)	Površina ispod krivulje snage struja I_z	S_FV(I_z)	Snaga spektralne komponente struje I_z na frekvenciji vrtnje
Pov(I_{gv})	Površina ispod krivulje struja glavnog vretena I_{gv}	S_FO(I_z)	Snaga spektralne komponente struje I_z na frekvenciji oštrica
Pov(P_I_{gv})	Površina ispod krivulje snage struja I_{gv}	S_FV(I_{gv})	Snaga spektralne komponente struje I_{gv} na frekvenciji vrtnje
S_FV(I_x)	Snaga spektralne komponente struje I_x na frekvenciji vrtnje	S_FO(I_{gv})	Snaga spektralne komponente struje I_{gv} na frekvenciji oštrica

Sve podatke također je potrebno normirati kako bi svi ulazni i izlazni podaci bili istog reda veličine. Podaci su normirani na sljedeći način:

$$e_{norm,ij} = \frac{e_{ij}}{e_{max,j}} \quad (14)$$

pri čemu je e_{ij} i -ti uzorak j -te značajke, $e_{max,j}$ maksimalna vrijednost j -te značajke, a $e_{norm,ij}$ normirana vrijednost značajke. Normiranjem na taj način maksimalna vrijednost značajke poprima vrijednost 1, dok sve druge poprimaju neku vrijednost između 0 i 1, s tim da su relativni odnosi među vrijednostima očuvani.

Sve značajke iz vremenskog područja izuzete su samo iz vremenskog intervala u kojem je svrdlo bilo u zahvatu. Na to je osobito važno obratiti pažnju kod računanja površina ispod krivulja kako bi se izbjeglo da događaji koji su snimljeni prije ili nakon zahvata utječu na rezultat. U tu je svrhu napisan algoritam koji na temelju signala sile F_z traži trenutak početka i kraja zahvata kao što je prikazano na slici 30.



Slika 30. Trenuci kad svrdlo ulazi i izlazi iz zahvata

Naposljetku, potrebno je formirati grupu uzoraka za učenje i grupe uzoraka za testiranje. Od 640 raspoloživih uzoraka, polovica uzoraka odvojena je za učenje mreže, a druga polovica za testiranje, budući da se pri testiranju klasifikacijskih svojstava mreže mora koristiti skup uzoraka koji nisu korišteni prilikom učenja.

Uzorci za učenje izdvojeni su na sljedeći način:

1. Za svaku grupu od 10 uzoraka koji su snimljeni istom kombinacijom posmaka, brzina i stupnjeva istrošenosti izračuna se vektor koji je srednja vrijednost svih 10 razmatranih vektora.
2. Izračunaju se Euklidijske udaljenosti između tog vektora i svakog od 10 uzoraka.
3. Za skup uzoraka za učenje odabire se uzorak koji je najbliži susjed vektoru srednjih vrijednosti, te četiri najudaljenija.

Preostalih 320 uzoraka razvrstano je u pet grupa uzoraka za testiranje, i to tako da se u svakoj grupi nalazi po jedan uzorak svake kombinacije parametara obrade i stupnjeva istrošenosti. Ovakvim odabirom uzoraka pokušalo se osigurati da uzorci za učenje na najbolji mogući način pokrivaju područje učenja kako bi se omogućilo neuronskoj mreži da kvalitetno nauči razmatrani problem.

4. ANALIZA REZULTATA

4.1. Učenje

Modeliranje procesa trošenja primjenom umjetnih neuronskih mreža započinje fazom učenja mreže. Najjednostavnije rečeno, u ovoj fazi neuronska mreža uči na koji je način ulaz u mrežu povezan s izlazom. Točnije, u fazi učenja podešavaju se parametri skrivenog sloja tj. broj neurona i položaji njihovih centara, parametri aktivacijske funkcije i formira se matrica težinskih faktora C . Postupak učenja RBF mreže detaljno je opisan u poglavlju 2.4.

4.2. Testiranje

Slijedi testiranje mreže kako bi se utvrdilo može li neuronska mreža na temelju naučenog u fazi učenja zaista iz novog, njoj nepoznatog seta ulaznih podataka procijeniti stupanj istrošenosti alata.

Testiranje, tj. izračun izlazne matrice O provodi se prema postupku opisanom slikom 15. S obzirom na položaje centara skrivenog sloja i parametre aktivacijskih funkcija koji su određeni u fazi učenja, izračunava se nova matrica H na temelju novih ulaznih podataka. Zatim se prema izrazu 5 matrica H množi s matricom težinskih faktora kako bi se izračunala matrica izlaza. Svaki uzorak u matrici izlaza klasificira se u onu skupinu čiji neuron poprimi najveću vrijednost. Drugim riječima, ako se najveća vrijednost promatranog vektora (uzorka) nalazi na trećem elementu, taj se uzorak klasificira u kategoriju istrošenosti S3.

Izlaz iz mreže uspoređuje se s poznatim kategorijama istrošenosti za svaki pojedini uzorak. Uspješnost klasifikacije izražava se postotkom uzoraka koje je mreža točno klasificirala.

4.3. Rezultati testiranja

Mreža je testirana najprije za svaku značajku zasebno kako bi se odredilo u kojoj mjeri svaka od njih ispravno klasificira istrošenost svrdla. Faktor grupiranja β bio je jednak nuli, što znači da je broj neurona skrivenog sloja bio jednak broju ulaznih uzoraka za učenje, što iznosi 320. Mreža je testirana s 5 različitih skupova uzoraka za testiranje. Rezultati testiranja pojedinačnih značajki prikazani su u tablicama 8 i 9.

Tablica 8. Uspješnost klasifikacije pomoću značajki sila

Uspješnost klasifikacije [%]						
značajka	Test 1	Test 2	Test 3	Test 4	Test 5	prosjek
Max(Fz)	90,6	93,7	92,1	89,0	87,5	90,6
Max(Fr)	89,0	93,7	89,0	89,0	85,9	89,3
Pov(Fz)	81,2	84,3	89,0	81,2	90,6	85,3
Pov(Fr)	76,5	85,9	79,6	79,6	87,5	81,8
Pov(Fr')	48,4	60,9	45,3	48,4	54,6	51,5
S_FV(Fx)	56,2	46,8	45,3	53,1	50,0	50,3
S_FO(Fx)	45,3	48,4	35,9	43,7	39,0	42,5
S_FV(Fy)	53,1	50,0	50,0	46,8	53,1	50,6
S_FO(Fy)	31,2	26,5	37,5	31,2	35,9	32,5
S_FV(Fz)	51,5	50,0	54,6	46,8	53,1	51,2
S_FO(Fz)	60,9	57,8	54,6	62,5	62,5	59,6

Tablica 9. Uspješnost klasifikacije pomoću značajki struja

Uspješnost klasifikacije [%]						
značajka	Test 1	Test 2	Test 3	Test 4	Test 5	prosjeak
Max(I _z)	93,7	93,7	96,8	96,8	92,1	94,6
Max(I _{gv})	90,6	93,7	92,1	89,0	87,5	90,6
Pov(I _z)	67,1	81,2	70,3	67,1	73,4	71,8
Pov(P_I _z)	59,3	64,0	59,3	53,1	59,3	59,0
Pov(I _{gv})	32,8	45,3	50,0	48,4	37,5	42,8
Pov(P_I _{gv})	32,8	45,3	50,0	48,4	37,5	42,8
S_FV(I _x)	31,2	29,6	40,6	43,7	26,5	34,3
S_FO(I _x)	34,3	26,5	26,5	28,1	42,1	31,5
S_FV(I _y)	43,7	43,7	17,1	42,1	35,9	36,5
S_FO(I _y)	37,0	32,8	29,6	29,6	29,6	31,8
S_FV(I _z)	39,0	26,5	23,4	26,5	31,2	29,3
S_FO(I _z)	56,2	43,7	46,8	45,3	46,8	47,8
S_FV(I _{gv})	32,8	34,3	29,6	28,1	34,3	31,8
S_FO(I _{gv})	31,2	35,9	39,0	40,6	35,9	36,5

Među značajkama sila, najuspješnijima su se pokazale značajke maksimalnih sila F_z i F_r , te površine ispod krivulja tih sila. Među značajkama struja, najuspješnije su značajke maksimalnih struja I_z i I_{gv} , te značajka površine ispod krivulje struje I_z . Ostale značajke nisu pokazale zadovoljavajuću razinu uspješnosti u klasifikaciji stupnja istrošenosti svrdla. Takav rezultat bio je za očekivati budući da se proces bušenja odvija u smjeru osi Z.

Pretpostavi li se da su značajke sila u smjeru X, Y i Z osi ekvivalentne značajkama struja pogonskih motora X, Y i Z osi, te da je rezultantna sila F_r ekvivalentna struji motora glavnog vretena, može se usporediti da li značajke sila i struja u jednakoj mjeri identificiraju proces trošenja svrdla. Usporedba je dana u tablici 10.

Tablica 10. Usporedba uspješnosti klasifikacije značajki sila i struja

Značajka	Uspješnost [%]	Značajka	Uspješnost [%]	Razlika [%]
Max(Fz)	90,63	Max(Iz)	94,69	-4,06
Max(Fr)	89,38	Max(Igv)	90,63	-1,25
Pov(Fz)	85,31	Pov(Iz)	71,88	13,44
Pov(Fr)	81,88	Pov(Igv)	42,81	39,06
S_FV(Fx)	50,31	S_FV(Ix)	34,38	15,94
S_FO(Fx)	42,50	S_FO(Ix)	31,56	10,94
S_FV(Fy)	50,63	S_FV(Iy)	36,56	14,06
S_FO(Fy)	32,50	S_FO(Iy)	31,88	0,63
S_FV(Fz)	51,25	S_FV(Iz)	29,38	21,88
S_FO(Fz)	59,69	S_FO(Iz)	47,81	11,88

Iz usporedbe je vidljivo da su značajke sila općenito znatno uspješnije od značajki struja. Kod dviju najuspješnijih značajki (značajki maksimalnih vrijednosti) nema znatne razlike u uspješnosti.

Nakon testiranja pojedinačnih značajki, odabrano je nekoliko kombinacija značajki koje su se u prethodnim testovima pokazale najuspješnijima. U ovoj seriji testova također su korištene vrijednosti koeficijenta grupiranja β veće od nule što je rezultiralo manjim brojem neurona skrivenog sloja. Cilj variranja koeficijenta β bio je analizirati na koji način broj neurona skrivenog sloja utječe na kvalitetu odziva mreže. Rezultati testova dani su u tablici 11.

Tablica 11. Uspješnost klasifikacije pomoću kombinacija više značajki


	Prosječna uspješnost klasifikacije na temelju 5 testova [%]					
β	0	0,01	0,05	0,1	0,2	0,25
Max(Fz)-Max(Fr)	90,00	93,44	95,00	90,31	74,57	60,63
Max(Fz)-Pov(Fz)	94,06	95,00	95,63	91,88	71,56	65,94
Max(Fz)-S_FO(Fz)	90,31	91,56	93,13	83,13	64,38	61,56
Max(Iz)-Max(Igv)	95,00	97,50	97,19	88,13	72,81	61,88
Max(Iz)-Pov(Iz)	95,31	95,00	90,00	72,19	53,13	52,19
Max(Iz)-Pov(P_Iz)	94,69	94,69	90,94	70,63	51,88	49,38
Max(Igv)-Pov(Iz)	92,50	92,81	94,38	81,88	65,94	60,94
Max(Igv)-Pov(P_Iz)	77,19	80,00	49,38	34,38	25,00	25,00
Max(Iz)-Max(Igv)-Pov(Iz)- Pov(P_Iz)	95,31	96,56	96,88	88,13	71,56	67,50
Max(Fz)-Max(Iz)-Max(Igv)	93,75	97,19	97,81	93,13	82,19	75,31

Sve kombinacije značajki osim jedne pokazale su vrlo dobar rezultat pri manjim vrijednostima koeficijenta grupiranja β . Jedini loš rezultat ostvarila je kombinacija značajki maksimalne struje motora glavnog vretena i površine ispod krivulje snage motora Z osi. Razlog tome mogla bi biti slaba povezanost značajke $Pov(P_Iz)$ s istrošenošću alata. Njena uspješnost u pojedinačnom testu iznosila je samo 60%.

Pri većim vrijednostima koeficijenta β , tj. pri manjim brojevima neurona skrivenog sloja gubi se na kvaliteti odziva mreže. Kod vrijednosti koeficijenta $\beta = 0,2$ broj neurona skrivenog sloja iznosi 30-40 (ovisno o skupu ulaznih podataka), a uspješnost klasifikacije gotovo svih kombinacija značajki pada ispod 75%.

Niti jedna kombinacija značajki ne daje značajno bolje rezultate od ostalih kombinacija. Jedino kombinacija značajki sila i struja $Max(Fz)-Max(Iz)-Max(Igv)$ pokazuje za nekoliko postotaka bolje rezultate od većine drugih značajki. Također, ta kombinacija pri većoj vrijednosti koeficijenta β daje bolje rezultate u odnosu na ostale kombinacije značajki, što sugerira da se kombiniranjem različitih vrsta signala može kvalitetnije vršiti nadzor alata.

Na slici 31 grafički je prikazana ovisnost uspješnosti klasifikacije o broju neurona skrivenog sloja. Uočljivo je kako mreža zadržava visoku uspješnost do određenog broja neurona te uspješnost klasifikacije čak bilježi i lagani rast. Nakon što se broj neurona skrivenog sloja smanji na 60-tak, odziv mreže postaje sve lošiji jer mreža počinje gubiti potrebna generalizacijska svojstva. Kvalitetan odziv mreže s manjim brojem neurona skrivenog sloja je važan jer se značajno skraćuje vrijeme izvršenja programskog koda. U ovom konkretnom slučaju, vrijeme izvršenja koda mreže sa 100 neurona skrivenog sloja trostruko je kraće od vremena izvršenja koda mreže s 320 neurona skrivenog sloja. Naravno, navedene vrijednosti vrijede samo za ovaj konkretan slučaj. Parametre mreže potrebno je testirati i podešavati za svaki slučaj individualno kako bi se postigao najbolji mogući odziv mreže.



Slika 31. Ovisnost uspješnosti klasifikacije o broju neurona skrivenog sloja

5. ZAKLJUČAK

Primjenom umjetne neuronske mreže s radijalnim baznim funkcijama analizirani su signali sila i struja pogonskih motora alatnog stroja snimljeni tijekom bušenja polimernog kompozita ojačanog staklenim vlaknima. Na temelju analize rezultata, mogu se donijeti sljedeći zaključci:

- Utvrđeno je da je primjenom neuronske mreže pomoću signala sila i struja moguće procijeniti razinu istrošenosti svrdla s točnošću većom od 90%
- Značajke sila koje najbolje klasificiraju istrošenost svrdla su vrijednost maksimalnih sila u smjeru Z osi, vrijednost maksimalne rezultantne sile F_r te površina ispod krivulja istih sila.
- Značajke struja koje najbolje klasificiraju istrošenost svrdla su vrijednosti maksimalnih struja motora Z osi i motora glavnog vretena te površina ispod krivulje struje motora Z osi.
- Istodobnim korištenjem barem dviju značajki u procjeni istrošenosti svrdla, mreža pokazuje bolja klasifikacijska svojstva u odnosu na analizu korištenjem samo jedne značajke, čime se postiže manja osjetljivost na stohastične pojave koje se mogu javiti tijekom procesa obrade
- Analizom različitih kombinacija značajki utvrđeno je da se značajke sila i značajke struja mogu jednako uspješno koristiti pri procjeni istrošenosti svrdla. Postoji naznaka da bi se kombiniranjem značajki sila i struja mogao postići bolji rezultat u odnosu na korištenje značajki samo jednog tipa.
- Broj neurona skrivenog sloja može se smanjiti do određene mjere bez da se naruši uspješnost klasifikacije.

Međutim, potreba za skupljanjem velike količine ekperimentalnih podataka kojima bi se učila i testirala mreža velik je nedostatak umjetnih neuronskih mreža, stoga ovaj način nadzora alata nikako nije primjenjiv kod proizvodnje manjih i srednjih serija.

6. LITERATURA

- [1] Bartolin, I.: *Utjecaj trošenja alata i parametara obrade na raslojavanje pri bušenju kompozitnih materijala*, diplomski rad, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2015.
- [2] Stepčić, A.: *Trošenje svrdla za beton*, diplomski rad, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2013.
- [3] Grilec. K., Ivušić, V.: *Autorizirana predavanja iz kolegija Tribologija*, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2011.
- [4] Šolić, S.: *Utjecaj mikrostrukture brzoreznog čelika na tribološka svojstva reznih alata*, doktorski rad, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2010.
- [5] Škorić, S.: *Materijali za predavanja iz kolegija Oblikovanje deformiranjem i obrada odvajanjem*, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2015.
- [6] Brezak, D.: *Razvoj hibridnog estimatora trošenja alata i metoda vođenja alatnog stroja*, doktorski rad, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2007.
- [7] Pavlović, Z.: *Nadzor oštrice reznog alata primjenom M – funkcija*, diplomski rad, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2010.
- [8] Filetin, T., Kovačiček, F., Indof, J.: *Svojstva i primjena materijala*, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, 2009.
- [9] Novaković, B., Majetić, D., Široki, M.: *Umjetne neuronske mreže*, Fakultet strojarstva i brodogradnje, Zagreb, 1998.
- [10] Brezak, D., Staroveški, T.: *Materijali za predavanja iz kolegija Regulacija obradnih strojeva*, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2015.
- [11] Grđan, V.: *Procjena istrošenosti medicinskog svrdla primjenom umjetnih neuronskih mreža*, diplomski rad, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2013.
- [12] Murat, Z.: *Utjecaj parametara aktivacijskih funkcija na odziv RBF neuronske mreže*, završni rad, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2015.