

Indirektni nadzor procesa bušenja polimernog kompozita primjenom signala akustične emisije

Lučić Pech, Domagoj

Master's thesis / Diplomski rad

2020

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:235:577589>

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

Download date / Datum preuzimanja: **2024-07-10**

Repository / Repozitorij:

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



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Domagoj Lučić Pech

Zagreb, 2020.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Izv. prof. dr. sc. Danko Brezak, dipl. ing.

Student:

Domagoj Lučić Pech

Zagreb, 2020.

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

Zahvaljujem se mentoru izv. prof. dr. sc. Danku Brezaku, dipl. ing na strpljenju, korisnim savjetima i ustupljenom znanju bez kojih izrada ovog rada ne bi bila moguća.

Domagoj Lučić Pech



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomске ispite
Povjerenstvo za diplomске radove studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment,
inženjerstvo materijala te mehatronika i robotika

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

DIPLOMSKI ZADATAK

Student: **DOMAGOJ LUČIĆ PECH** Mat. br.: 0035201210

Naslov rada na hrvatskom jeziku: **Indirektni nadzor procesa bušenja polimernog kompozita primjenom signala akustične emisije**

Naslov rada na engleskom jeziku: **Indirect process monitoring during polymer composite drilling using acoustic emission signals**

Opis zadatka:

Primjena kompozitnih materijala u industriji sve je učestalija. S druge strane, razvoj obradnih sustava i procesa usmjeren je prema potpunoj digitalizaciji proizvodnje. Ona se manifestira kroz niz različitih segmenata, od kojih sustavi direktnog i indirektnog nadzora predstavljaju najznačajniji parametar s neposrednim utjecajem na sigurnost, produktivnost, ekonomičnost i kvalitetu proizvodnog procesa.

Problem koji se javlja kod bušenja kompozitnih materijala je pojava delaminacije, koja je usko povezana sa stupnjem istrošenosti svrdla. Stoga je zadatak ovog rada istražiti mogućnost indirektnog nadzora stupnja istrošenosti, a time posredno i stupnja delaminacije primjenom signala akustične emisije u procesu bušenja polimernog kompozita ojačanog staklenim vlaknima. Signali će biti snimljeni korištenjem različitih kombinacija parametara obrade te nekoliko stupnjeva istrošenosti. Iz snimljenih i filtriranih signala procesa izdvojiti će se značajke trošenja, te će se zatim provesti detaljna analiza iskoristivosti dobivenih značajki.

U radu je potrebno:

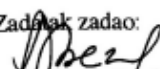
1. Izraditi programsku podršku za filtriranje i obradu snimljenih signala procesa.
2. Iz filtriranih signala izdvojiti adekvatne značajke procesa trošenja.
3. Izraditi programsku podršku za neuronsku mrežu koja će biti primijenjena u klasifikaciji stupnja istrošenosti alata i delaminacije materijala.
4. Izvršiti detaljnu analizu utjecaja svih značajki trošenja i njihovih kombinacija na kvalitetu nadzora.
5. Izvesti zaključke rada.

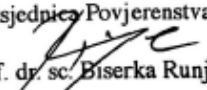
U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:
14. studenog 2019.

Rok predaje rada:
16. siječnja 2020.

Predviđeni datum obrane:
20. siječnja do 24. siječnja 2020.

Zadatak zadao:

prof. dr. sc. Danko Brezak

Predsjednica Povjerenstva:

prof. dr. sc. Biserka Runje

Sadržaj

POPIS SLIKA	III
POPIS TABLICA.....	VI
SAŽETAK.....	IX
SUMMARY	X
1. UVOD.....	1
2. Kompozitni materijali.....	3
2.1. Kompozitni materijali s polimernom matricom.....	5
2.2. Kompozitni materijali ojačani vlaknima.....	6
3. Obrada kompozita.....	9
3.2. Parametri obrade kod bušenja.....	9
3.3. Trošenje alata	10
3.3.1. Abrazijsko trošenje	11
3.3.2. Adhezijsko trošenje.....	12
3.3.3. Difuzijsko trošenje	12
3.3.4. Oksidacijsko trošenje	12
3.3.5. Plastična deformacija rezne oštrice.....	13
3.3.6. Trošenje uslijed umora materijala.....	13
4. Neuronska mreža s radijalnim baznim funkcijama	14
4.1. Struktura mreže	14
4.2. Aktivacijska funkcija	16
4.3. Matematički opis RBF NM.....	17
4.4. Proces učenja.....	17
5. Eksperimentalni postav i snimanje signala.....	19
5.1. Stroj.....	19
5.2. Mjerni sustav.....	21
5.2.1. Senzor vibracija	21
5.2.2. Senzor akustične emisije.....	22
5.2.3. Vizijski sustav	23
5.3. Pokus i provedena analiza.....	24

5.3.1. Ispitni uzorci	24
5.3.2. Ispitno svrdlo	25
5.3.3. Odabir parametara.....	26
5.3.4. Određivanje istrošenosti svrdla.....	27
5.3.5. Snimanje signala	30
6. Priprema podataka, analiza i rezultati.....	31
6.1. Obrada signala akustične emisije.....	31
6.2. Stupanj istrošenosti	35
6.2.1. Značajke signala akustične emisije.....	35
6.3. Kvantificiranje stupnja delaminacije	39
7. ZAKLJUČAK.....	49
Literatura	51
PRILOZI.....	54

POPIS SLIKA

Slika 1 Vrijednost tržišta kompozita u SAD, 2014-2025, u milijunima dolara [1].....	1
Slika 2 Okvir bicikla napravljen od kompozita s karbonskim vlaknima [12].....	4
Slika 3 Primjer slojeva u kompozitnom materijalu [13]	4
Slika 4 Primjer unutrašnje strukture polimernog kompozita s dugim usmjerenim ugljičnim vlaknima [17]	7
Slika 5 Primjer izrade staklenih vlakana [18]	7
Slika 6 Prikaz mogućih rasporeda vlakana [15].....	8
Slika 7 Prikaz glavnih gibanja kod bušenja [22].....	9
Slika 8 Prikaz raspodjele brzine rezanja po promjeru svrdla [22]	9
Slika 9 Prikaz sučelja alata i obratka [24]	10
Slika 10 Abrazijsko trošenje između dva tijela [26]	11
Slika 11 Abrazijsko trošenje između tri tijela [26]	11
Slika 12 Adhezijsko trošenje [26]	12
Slika 13 Difuzijsko trošenje [26]	12
Slika 14 Oksidacijsko trošenje [26]	13
Slika 15 Umor materijala [26].....	13
Slika 16 Struktura RBF neuronske mreže [29]	15
Slika 17 Gaussova aktivacijska funkcija [29]	16
Slika 18 Unutrašnjost i radni prostor stroja [32].....	20
Slika 19 Struktura mjernog sustava [32].....	21
Slika 20 Senzor vibracija i pripadajuće nabožno pojačalo	22
Slika 21 Senzor akustične emisije i pripadajuće pojačalo [29].....	23
Slika 22 Kamera i telecentrični objektiv	23
Slika 23 Shematski prikaz postupka namatanja vlakana [33].....	24
Slika 24 Primjer ispitnih uzoraka [32]	25
Slika 25 Crtež svrdla A1163, Walter Titex	26
Slika 26 Fotografije rezne oštrice [32].....	28

Slika 27 Određivanje širine trošenja stražnje površine alata [34]	29
Slika 28 Grafički prikaz iznosa istrošenosti stražnje površine alata [32]	30
Slika 29 Primjer sirovog signala akustične emisije.....	31
Slika 30 Snaga signala u ovisnosti o frekvenciji za posmak 0.06 mm/okr, brzinu rezanja 30 m/min te stupanj istrošenosti S1	33
Slika 31 Snaga signala u ovisnosti o frekvenciji za posmak 0.06 mm/okr, brzinu rezanja 30 m/min te stupanj istrošenosti S2.....	34
Slika 32 Snaga signala u ovisnosti o frekvenciji za posmak 0.06 mm/okr, brzinu rezanja 30 m/min te stupanj istrošenosti S3.....	34
Slika 33 Snaga signala u ovisnosti o frekvenciji za posmak 0.06 mm/okr, brzinu rezanja 30 m/min te stupanj istrošenosti S4.....	35
Slika 34 Frekvencijski pojasevi čije su energije uzete kao ulazne značajke neuronske mreže	38
Slika 35 Primjer izlazne i ulazne strane provrta [32]	39
Slika 36 Primjer ručnog određivanja područja delaminacije u Catia.....	40
Slika 37 Postupak određivanja značajki delaminacije [32].....	40
Slika 38 Prosječni iznosi srednje udaljenosti točaka za svaki stupanj istrošenosti	41
Slika 39 Prosječni iznosi maksimalne udaljenosti točaka za svaki stupanj istrošenosti	41
Slika 40 Prosječni iznosi opsega delaminacije za svaki stupanj istrošenosti	42
Slika 41 Prosječni iznosi površine delaminacije za svaki stupanj istrošenosti	42
Slika 42 Prosječni iznosi srednje udaljenosti točaka za stupnjeve S1 i S2	43
Slika 43 Prosječni iznosi srednje udaljenosti točaka za svaki stupanj istrošenosti S2 i S3	43
Slika 44 Prosječni iznosi srednje udaljenosti točaka za svaki stupanj istrošenosti S3 i S4	44
Slika 45 Prosječni iznosi površine delaminacije za stupnjeve istrošenosti S1 i S2	44
Slika 46 Prosječni iznosi površine delaminacije za stupnjeve istrošenosti S2 i S3	45
Slika 47 Prosječni iznosi površine delaminacije za stupnjeve istrošenosti S3 i S4	45
Slika 48 Iznos površine delaminacije po uzorku za nove klase stupnja istrošenosti	47
Slika 49 Iznos srednje udaljenosti između točaka po uzorku za nove klase stupnja istrošenosti	47
Slika 50 Usporedba distribucija srednje udaljenosti između točaka za uzorke istih parametara rezanja i različitog stupnja istrošenosti	48

Slika 51 Usporedba distribucija površina delaminacija za uzorke istih parametara rezanja i različitog stupnja istrošenosti 48

POPIS TABLICA

Tablica 1 Prednosti i nedostaci duromernih matrica [15]	6
Tablica 2 Tehničke karakteristike senzora vibracija i pojačala.....	22
Tablica 3 Tehničke karakteristike kamere i objektiva	24
Tablica 4 Ovisnost stupnja istrošenosti o broju izbušenih provrta.....	25
Tablica 5 Režimi obrade korišteni u glavnom pokusu [32]	27
Tablica 6 Iznosi istrošenosti stražnje površine alata [32]	29
Tablica 7 Frekvencijski pojasevi s najvećom klasifikacijskom točnošću	36
Tablica 8 Matrica konfuzije za podatke za testiranje	38
Tablica 9 Raspon broja provrta po stupnju istrošenosti	46

POPIS OZNAKA

Oznaka	Jedinica	Opis
$D1$	-	prvi stupanj delaminacije
$D2$	-	drugi stupanj delaminacije
C	-	matrica težina izlaznog sloja
c_{jm}	-	težinski faktori izlaznog sloja
ϕ	mm	promjer svrdla
d_{ij}	-	Euklidska udaljenost između i -tog neurona ulaznog i j -tog neurona skrivenog sloja
f	mm/okr	posmak svrdla
f_p	Hz	početna frekvencija spektra
f_k	Hz	krajnja frekvencija spektra
H^{-1}	-	inverzija matrice H
H	-	matrica H
h_{ij}	-	vrijednosti radijalnih baznih funkcija
K	-	broj neurona skrivenog sloja
L	-	broj ulaznih neurona
M	-	broj izlaznih neurona
N	-	broj uzoraka za učenje
O	-	matrica izlaza RBF mreže ($L \times M$)
O_w	-	Odziv w -tog izlaznog neurona
σ	-	širina aktivacijske funkcije
Sa	-	spojeni stupnjevi istrošenosti $S1$ i $S2$
Sb	-	spojeni stupnjevi istrošenosti $S3$ i $S4$
$S1$	-	prvi stupanj istrošenosti svrdla
$S2$	-	drugi stupanj istrošenosti svrdla
$S3$	-	treći stupanj istrošenosti svrdla
$S4$	-	četvrti stupanj istrošenosti svrdla
t_j	-	vektor centara neurona skrivenog sloja
VB_{max}	mm	maksimalna vrijednost širine trošenja stražnje površine alata

VB	mm	vrijednost širine trošenja stražnje površine alata
VB_{sr}	mm	srednja vrijednost širine trošenja stražnje površine alata
V_c	m/min	brzina rezanja
X_i	-	vektor ulaznih vrijednosti mreže

SAŽETAK

Kompoziti su relativno nova vrsta materijala često korištena zbog mogućnosti postizanja iznimnih kombinacija fizikalno-kemijskih svojstava. Kompozitni proizvodi često se obrađuju/izrađuju tehnologijom obrade odvajanjem čestica. Pritom je bušenje jedna od najzastupljenijih metoda obrade. Prilikom izrade provrta kod određenih tipova kompozita dolazi do raslojavanja (delaminacije) slojeva u kompozitu što nepovoljno utječe na mehanička i druga svojstva kompozita. U sklopu ovog diplomskog rada analizirana je primjena signala akustične emisije u nadzoru procesa bušenja polimernog kompozita ojačanog staklenim vlaknima. Značajke izdvojene iz navedenih vrsta signala korištene su u klasifikaciji stupnja istrošenosti reznog alata i stupnja delaminacije materijala. Za klasifikator je korištena neuronska mreža s radijalnim baznim funkcijama.

Ključne riječi: delaminacija, kompoziti, neuronska mreža, klasifikacija, nadzor procesa

SUMMARY

Composites are a relatively new type of products often used due to the possibility of achieving remarkable combinations of physico-chemical properties. Composite products are often fabricated by machining technologies. Drilling is one of the most common processing methods. While drilling holes in certain types of composites, layers (delamination) of layers in the composite occurs, which adversely affects the mechanical and other properties of the composite. As part of this thesis, the application of acoustic emission signals in the control of the drilling process of a glass fiber reinforced polymer composite is analyzed. The features extracted from the indicated signal types were used in the classification of the degree of wear of the cutting tool and the degree of delamination of the material. A neural network with radial basis functions was used for the classifier.

Key words: delamination, composites, neural network, classification

1. UVOD

U potrazi za materijalima sve boljih svojstava pod pritiskom konkurentnosti i isplativosti mnoge industrije su prepoznale potencijal kompozitnih materijala te kao rezultat toga, proizvodnja i uporaba kompozitnih materijala svih vrsta (polimerne, metalne i keramičke matrice te različite vrste i oblici ojačala) bilježi veliki porast. Slika 1 prikazuje rast vrijednosti tržišta kompozita u zadnjih nekoliko godina s predviđenim budućim rastom.



Slika 1 Vrijednost tržišta kompozita u SAD, 2014-2025, u milijunima dolara [1]

Kompoziti pružaju mogućnosti modeliranja svojstava te postizanje određenih kombinacija svojstava koje je teško ostvariti korištenjem drugih materijala. Kompoziti s keramičkom i metalnom matricom su većinom korišteni u specijalnim primjenama, dok kompoziti s polimernom matricom nalaze širok spektar primjene, pogotovo u zrakoplovnoj, automobilskoj i vojnoj industriji. Proces proizvodnje polimernih kompozita (npr. pultruzija, namotavanje, kalupljenje itd.) u većini slučajeva omogućuju proizvodnju oblika koji zahtjeva relativno malo dodatne obrade. Jedna od najčešćih operacija dodatne obrade je bušenje provrta, a podatak koji govori o njihovoj zastupljenosti je da je za izradu oplata modernog putničkog zrakoplova potrebno napraviti preko milijun provrta. [2]

Ključan problem prilikom bušenja kompozitnih materijala je pojava raslojavanja tj. delaminacije. Niz istraživanja na području nadzora procesa bušenja u industriji ukazuju na istrošenost svrdla kao najznačajniji parametar procesa te se može pretpostaviti da će raslojavanje uvelike biti uvjetovano istrošenošću reznog alata. [3] [4] Ostale značajke za koje se može očekivati velik utjecaj su parametri obrade, geometrija alata te utjecaj kvalitete samog materijala.

Raslojavanje ima velik utjecaj na mehanička svojstva materijala u zoni obrade, trajnost materijala i pojavu pukotina. Trud koji se ulaže u suzbijanje ove pojave pokazuju brojna provedena istraživanja. [5]

Kao što je moguće vidjeti u industrijskoj primjeni, potpuno precizno određivanje stupnja istrošenosti nije moguće zbog izrazite nelinearnosti i djelomične stohastičnosti dinamike procesa trošenja reznog alata. Precizno određivanje stanja oštrice bi bilo moguće provesti jedino direktnim postupkom nadzora kojeg zbog prirode procesa i konstantnog dodira oštrice s obrađivanim materijalom nije moguće realizirati tijekom procesa. Zbog tih razloga je nužno primijeniti neku od metoda indirektnog nadzora koje podrazumijevaju klasifikaciju stanja oštrice na temelju poznatih parametara stroja i značajki istrošenosti izdvojenih iz različitih tipova signala procesa.

Akustična emisija je prijelazni oblik energije koji većinom nastaje uslijed plastične deformacije ili loma materijala, kao rezultat razdvajanja molekula. [6] Frekvencijski raspon koji se najčešće spominje za primjene nadzora je od 100 kHz do 2 MHz. Signali akustične emisije se ističu po činjenici da su im frekvencije znatno više od frekvencija vibracija stroja i signala iz okoline, što direktno pomaže u izbjegavanju neželjenog utjecaja pojave signala nižeg frekvencijskog spektra.

U ovom diplomskom radu je proveden indirektan pristup procjene stanja oštrice alata te posredno njemu stupnja delaminacije obrađivanog kompozita s pomoću neuronske mreže s radijalnim baznim funkcijama temeljen na prikupljenim signalima akustične emisije koji se smatraju jednim od najznačajnijih mjernih signala u postupku indirektnog nadzora trošenja. [7]

2. Kompozitni materijali

Kompozitni materijali (skraćeno kompoziti) su materijali napravljeni od dva ili više sastavna materijala s bitno različitim fizikalno-kemijskim svojstvima koji kombinirani daju materijal svojstava različitih od ijednog sastavnog materijala. Ono što razlikuje kompozite od više-komponentnih materijala poput mješavina i metala s legirnim elementima je to što sastavni materijali ostaju potpuno odvojeni i zasebni. [8] [9]

Jedna od glavnih značajki i prednosti kompozitnih materijala leži u tome što se vještim kombiniranjem različitih materijala mogu dobiti novi materijali koji uvelike zadržavaju poželjna svojstva sastavnih materijala dok se njihovi nedostaci kompenziraju. Neke od kombinacija svojstava koje takvi novi materijali posjeduju je nemoguće postići ili pronaći u nekoj drugoj vrsti materijala. Kao primjer se mogu navesti kombinacije visoke čvrstoće, male gustoće, visoke otpornosti na trošenje, visoke stabilnosti u prisutnosti korozivnih medija, visoke temperaturne stabilnosti, visoke tvrdoće itd. [10]

Nedostaci i slabosti kompozitnih materijala su njihova anizotropnost i heterogenost, što utječe na kompliciranost izrade i proračun njihovih svojstava, visoka cijena te slaba mogućnost recikliranja.


Kompoziti nalaze širok spektar primjene zahvaljujući svojim dobrim svojstvima i prednostima. Neke od tih primjena su:

- zrakoplovstvo i svemirska tehnika,
- arhitektura i gradnja,
- automobilska industrija,
- energetika (vjetroturbine),
- infrastruktura,
- brodogradnja,
- cijevi i spremnici (posebno za primjene u teško korozivnim uvjetima),
- sport i rekreacija (kacige za američki nogomet, hokejaške palice, okviri bicikala – primjer prikazan na slici 2). [11]



Slika 2 Okvir bicikla napravljen od kompozita s karbonskim vlaknima [12]

Postoje dvije glavne kategorije konstitutivnih elemenata kompozita: matrice i ojačala. Matrice su najčešće metalne, keramičke ili polimerne, dok su ojačala najčešće formirana u obliku čestica ili vlakana.



Slika 3 Primjer slojeva u kompozitnom materijalu [13]

Uloga matrice je:

- držati ojačala zajedno,
- štiti ojačala od vanjskih utjecaja,
- prijenos opterećenja na ojačalo,
- davanje vanjske forme kompozitu,
- određivanje ponašanja s obzirom na vanjske uvjete (atmosfera, korozija).

Pritom je uloga ojačala da bude nosivi element kompozita te da osigura:

- visoku čvrstoću,
- visok modul elastičnosti (krutost),
- otpornost na sve oblike trošenja.

Ponašanje kompozita ovisi o: [14]

1. svojstvima matrice i ojačala
2. veličini i rasporedu, odnosno raspodjeli konstituenata
3. volumnom udjelu konstituenata
4. obliku konstituenata
5. prirodi i jakosti veze među konstituentima

2.1. Kompozitni materijali s polimernom matricom

Kompoziti s polimernom matricom su sastavljeni od polimerne smole kao matrice s vlaknima kao komponentom za ojačavanje. Za matrice se koristi široka lepeza polimera, a dvije glavne grupe su termoplasti i duroplasti. Najčešće korištene duroplastne matrice su razne smole, npr. poliesterske, epoksidne, vinil-esterske, fenolne smole[5]. Kratak pregled prednosti i nedostataka nekih duroplastnih matrica dan je u tablici 1. Najčešće upotrebljavani materijali za plastomerne matrice su polipropilen (PP), poliamid (PA), polietilen-tereftalat (PET), polibutilen-tereftalat (PBT), polisulfoni (PS), polieter-eter-keton (PEEK).

Tablica 1 Prednosti i nedostaci duromernih matrica [15]


Vrsta duromerne matrice	Prednosti	Nedostaci
Epoksidne smole	Izvrсна mehanička svojstva, postojane na atmosferilije, otporne na djelovanje vode i agresivnih medija, otpornost na zamor materijala.	Osjetljive na djelovanje UV zračenja, teško ostvariti žilavost pri povišenim temperaturama, umrežavanje pri povišenim temperaturama, cijena.
Poliesterske smole	Dobra kemijska postojanost, povišena rastezna i savojna čvrstoća, postojanost na atmosferilije, laka prerada, niska cijena.	Ograničen rok trajanja, lako se razgrađuju, isparavanje pri umrežavanju.
Fenolne smole	Postojane pri povišenim temperaturama, samogasive, povišena otpornost na djelovanje organskih otapala i kiselina, povišena tvrdoća.	Pri umrežavanju otpuštaju veliku količinu hlapljivih tvari, krhke su, mehanička svojstva su im slabija u odnosu na poliesterske i epoksidne smole.
Bismaelimidi	Otporne na gorenje, visoka čvrstoća, otporne na agresivne sredine (uglavnom se primjenjuju u aeronautici, svemirskoj tehnici).	Krhkost, cijena.

Pojam „smola“ u ovom se kontekstu koristi za obilježavanje polimerne tvari visoke molekularne mase koju treba ojačati. Najraširenije i daleko najjeftinije polimerne smole su poliesteri i vinil esteri te se primjenjuju kod staklenim vlaknima ojačanim polimernim kompozitima. Epoksidne smole znatno su skuplje te su često neprikladne za komercijalnu uporabu. Najčešće se koriste u zrakoplovstvu. Za visokotemperaturne primjene koriste se poliamidi i drugi visokotemperaturni plastomeri. [16]

2.2. Kompozitni materijali ojačani vlaknima

S obzirom na tip vlakana polimerni kompoziti mogu biti ojačani sa: [15]

- staklenim vlaknima,
- ugljičnim vlaknima,
- aramidnim vlaknima
- te ostalim vlaknastim materijalima za ojačanje.



Slika 4 Primjer unutrašnje strukture polimernog kompozita s dugim usmjerenim ugljičnim vlaknima [17]

Staklena vlakna su najrašireniji ojačavajući materijal kod polimernih kompozita. Staklo je popularan materijal za ojačavanje zbog nekoliko razloga: lako ga je izvući u vlakna, lako ga se dobavlja i ekonomično kombinira s kompozitom, ima vrlo veliku specifičnu čvrstoću te je kemijski inertno. Na slici 5 je prikazan primjer izrade staklenih vlakana.

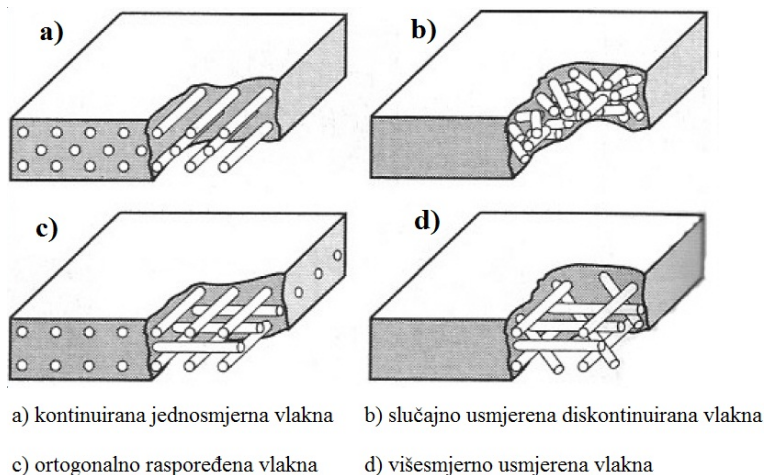


Slika 5 Primjer izrade staklenih vlakana [18]

Postoji nekoliko vrsta staklenih vlakana [19]:

- A-staklo: dobra kemijska otpornost, slaba električna svojstva,
- C-staklo: specijalan sastav za primjenu s jako agresivnim kemikalijama,
- E-staklo: najčešće se koristi, preko 50% svih staklenih ojačala, otporno je na utjecaj morske vode te posjeduje dobru čvrstoću,
- S-staklo: ima puno bolja mehanička svojstva od E-stakla, ali je nekoliko puta skuplje,
- T-staklo: podnosi visoke temperature (do 1050 °C), ima visoku čvrstoću i visok modul elastičnosti.

Postoje još i D, M i R vrste stakla koja se manje koriste.




Slika 6 Prikaz mogućih rasporeda vlakana [15]

3. Obrada kompozita

3.1. Bušenje


Bušenje je postupak obrade odvajanjem čestica koji se koristi za bušenje provrta malih dimenzija ili proširivanje provrta većih promjera, pri čemu razlikujemo provrt i uvt. Glavno gibanje je kružno kontinuirano, a posmično je pravolinijsko kontinuirano. Alat korišten za bušenje je svrdlo, najčešće standardno spiralno svrdlo s dvije glavne oštrice i jednom poprečnom. [20] [21] Na slici 7 je prikazano glavno gibanje G i posmično gibanje P.



Slika 7 Prikaz glavnih gibanja kod bušenja [22]

3.2. Parametri obrade kod bušenja


Osnovni parametri kod bušenja su posmak (f), brzina rezanja (v_c) i učestalost vrtnje (n). Posmak je udaljenost koju svrdlo prijeđe u smjeru osi alata za jedan okretaj alata. Brzina rezanja se mijenja linearno duž rezne oštrice. U osi svrdla je jednaka nuli, dok je na obodu maksimalnog iznosa. [23]



Slika 8 Prikaz raspodjele brzine rezanja po promjeru svrdla [22]

3.3. Trošenje alata

Tijekom postupka obrade odvajanjem čestica alatom definirane geometrije dolazi do odvajanja, deformacija i trenja te je tijekom navedenog procesa alat izložen iznimno složenom opterećenju karakteriziranom visokim tlakom, brzinama rezanja i temperaturama. Zbog navedenog dolazi do trošenja alata, pojava koja je karakterizirana kao stohastička, progresivna i izrazito nepovoljna. Na slici 9 je detaljno prikazana interakcija alata i obratka.



Slika 9 Prikaz sučelja alata i obratka [24]


Stanje istrošenosti alata je bitna informacija za vrijeme obrade, tim više što sustav ima veći stupanj automatizacije. Proporcionalno istrošenosti alata rastu sile rezanja i kvaliteta obrađene površine pada. Uslijed prevelike istrošenosti može doći do pucanja alata, pregrijavanja ili oštećenja obratka. [25]

Mehanizmi trošenja su:

- Abrazijsko trošenje,
- Adhezijsko trošenje,
- Difuzijsko trošenje,
- Oksidacijsko trošenje,
- Plastična deformacija rezne oštrice,
- Trošenje uslijed umora materijala.


3.3.1. Abrazijsko trošenje

Abrazijsko trošenje nastaje kontaktom između alata i obratka, najčešće utjecajem različitih uključina unutar materijala obratka čega je primjer prikazan na slici 10.



Slika 10 Abrazijsko trošenje između dva tijela [26]


. Postoje dvije vrste abrazijskog trošenja: **Abrazijsko trošenje između dva tijela** nastaje kada vrhovi neravnina jednog ili drugog tijela prodiru i skidaju mikro čestice drugog tijela. Ova vrsta trošenja je neizbježna te se uvijek javlja kod konvencionalnih postupaka obrade odvajanjem čestica zbog kontakta alata i obratka. Javlja se u većoj mjeri zbog nedovoljnog podmazivanja između površina alata i obratka, neodgovarajućeg medija za podmazivanje ili neadekvatne hrapavosti površina. **Abrazijsko trošenje između tri tijela** prikazano na slici 1 pojavljuje se kod klizanja površine alata i obratka gdje se između njih javljaju još i čestice trećeg tijela koje uzrokuju nastajanje malih ogrebotina u smjeru glavnog gibanja. [25]



Slika 11 Abrazijsko trošenje između tri tijela [26]

3.3.2. Adhezijsko trošenje

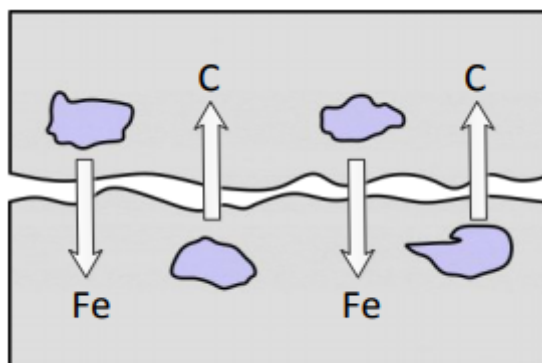
Vrsta trošenja koja nastaje neposredno nakon procesa rezanja, većinom kod nižih temperatura ,procesom mehaničkog „lijepljenja“ odnosno zavarivanjem malih komada čestica (slika 12). Nakon nekog vremena može doći do otkidanja naljepka, a s njime i dijela rezne oštrice. [25]



Slika 12 Adhezijsko trošenje [26]

3.3.3. Difuzijsko trošenje

Zbog prisutnosti velikih brzina rezanja, pogotovo u suvremenoj proizvodnji, dolazi do porasta temperatura što uzrokuje trošenje temeljeno na mehaničkim i kemijskim djelovanjima. Pojava toplinski aktiviranog procesa difuzije je uzrokovana kemijskim opterećenjima koja rastu s porastom temperature te afinitetom materijala alata prema materijalu obratka (slika 13). [25]




Slika 13 Difuzijsko trošenje [26]

3.3.4. Oksidacijsko trošenje

Uzrok ove vrste trošenja su kemijske promjenama unutar materijala alata pri povišenim temperaturama u prisutnosti zraka, najčešće na početku i na kraju dijela oštrice koji je u zahvatu s obrađivanim materijalom. Uspješno se kontrolira pravilnim odabirom alata, uporabom

različitih vrsta prevlaka ili upotrebom alata od tvrdog metala građenih s nekim drugim vezivom (Ni, Cr, Mo) [26] Primjer je prikazan na slici 14.



Slika 14 Oksidacijsko trošenje [26]


3.3.5. *Plastična deformacija rezne oštrice*

Navedena vrsta trošenja nastaje uslijed djelovanja visokih temperatura (900-1300 °C) i tlačnih naprezanja na reznoj oštrici alata. Utjecajni parametri su:

- čvrstoća i tvrdoća materijala obratka,
- geometrija, čvrstoća i tvrdoća rezne oštrice,
- parametri obrade. [25]

3.3.6. *Trošenje uslijed umora materijala*

Pojava ovog oblika trošenja najčešća je kod isprekidane obrade odvajanjem čestica poput glodanja, gdje se pojavljuje cikličko opterećenje/rasterećenje reznih oštrica. Prilikom ulaska u zahvat opterećenje na reznju oštricu naglo raste, kao i temperatura u kontaktnoj zoni, a navedeno stanje traje sve dok reznja oštrica ne izađe iz zahvata te se naglo rasterećuje i hladi. Cijeli proces se ciklički ponavlja za svaku oštricu visokom frekvencijom što može dovesti do umora materijala kao što je prikazano na slici 15. Glavni faktori za izbjegavanje su korištenje alata visoke tvrdoće, čvrstoće i žilavosti na povišenim temperaturama.



Slika 15 Umor materijala [26]

4. Neuronska mreža s radijalnim baznim funkcijama


Osim analitičkih metoda, često korištena opcija za izradu matematičkog modela za povezivanje određenih parametara i značajki procesa je primjena strojnog učenja. U situacijama u kojima se razmatraju značajke signala poput akustične emisije, primjena nekog oblika strojnog učenja je gotovo jedina opcija zbog velikih kompleksnosti, nelinearnosti i nepoznatih čimbenika.

Primjenom algoritama strojnog učenja moguće je realizirati model koji opisuje različite kompleksne sustave i procese. [27] Najveću primjenu su našli algoritmi umjetnih neuronskih mreža uslijed mogućnosti brzog, paralelnog procesiranja skupa ulaznih varijabli (značajki sustava/procesa), a što omogućuje razvoj sustava koji mogu u realnom vremenu obraditi velike količine podataka. Navedena karakteristika im osigurava potencijal generiranja korisnih informacija iz procesa složene, pa čak i djelomično stohastičke dinamike. Zbog ovih svojstava primjenu nalaze i u raznim sustavima nadzora strojne obrade, kao npr. u klasifikaciji i estimaciji parametara trošenja reznih alata.

Modeli u ovom diplomskom radu su zasnovani na primjeni neuronske mreže s radijalnim baznim funkcijama (RBF NM). Prvobitna arhitektura ove vrste neuronske mreže je predložena 80-ih godina [28], te je s vremenom došlo do nadogradnje i usavršavanja predloženih i stvaranja novih modela učenja pogodnih za rješavanje klasifikacijskih i regresijskih problema. Iako slične strukture, RBF NM se bitno razlikuju od danas vrlo popularnih višeslojnih perceptronskih neuronskih mreža učenih iterativnom metodom povratnog prostiranja greške po tome što se učenje provodi u jednom koraku što, uz jednostavnu adaptaciju strukture, rezultira bržim učenjem i lakšim postizanjem dobrih generalizacijskih svojstava. [28]

4.1. Struktura mreže

Neuronske mreže s radijalnim baznim funkcijama spadaju u skupinu unaprijednih tj. statičkih (feed-forward) neuronskih mreža te njihovu strukturu čine tri sloja: ulazni, skriveni i izlazni što je i prikazano na slici 16.



Slika 16 Struktura RBF neuronske mreže [29]

Ulazni sloj se sastoji od L ulaznih, a izlazni od M izlaznih neurona čiji su brojevi definirani karakteristikama danog problema. Heurističko pravilo je da se za ulazne neurone odabiru međusobno nezavisne varijable za koje se smatra da koreliraju s varijablama dodijeljenim izlaznim neuronima, tj. onima koje mreža treba predvidjeti.


Broj neurona skrivenog sloja (K) se određuje u fazi učenja, te on uvelike utječe na generalizacijska svojstva i kvalitetu odziva mreže. Postoje dva slučaja pri izboru broja neurona skrivenog sloja: interpolacija i aproksimacija. Pri interpolaciji broj neurona je jednak broju uzoraka za učenje N , dok je u slučaju aproksimacije broj neurona manji od broja uzoraka za učenje. Interpolacija je povoljnija u slučaju relativno manjeg ukupnog broja uzoraka, dok aproksimacija smanjuje mogućnosti za pojavu pretreniranosti (overfitting) mreže pri velikom broju podataka. Uzimajući u obzir broj uzoraka u ovom radu, izabrana je interpolacija.

Svaki neuron skrivenog sloja određen je L -dimenzijskim vektorom centara (t_j) koji određuju poziciju tog neurona u L -dimenzijskom prostoru. Poveznica između neurona skrivenog i izlaznog sloja su pripadajući težinski faktori (c_j). Vektor težinskih faktora je rezultat koraka

učenja koji se sastoji od inverzije matrice radijalnih baznih funkcija H , čiji elementi h_{ij} ovise o aktivacijskoj funkciji, njezinim parametrima te euklidskim udaljenostima ulaznih neurona od centara neurona skrivenog sloja što je poveznica ulaznog i skrivenog sloja. Unutarnji model mreže o procesu, tj. njezino znanje, je sadržano u vrijednostima centara skrivenog sloja i težinama prema izlaznom sloju. Jednom kada se završi s učenjem mreže, ona se može promatrati kao crna kutija, engl. „Black box“, jer su jedine informacije koje učitelj posjeduje točnost s kojom mreža preslikava ulazne na željene vrijednosti dok priroda veze ulaznih i izlaznih vrijednosti ostaje uvelike nepoznata. [28] [30]

4.2. Aktivacijska funkcija

Aktivacijska funkcija neurona skrivenog sloja kod ove vrste mreže mora biti odabrana iz skupine radijalnih baznih funkcija po kojima je i dobila naziv. Radijalne bazne funkcije su klasa funkcija čije su karakteristike monotonno rastuće ili padajuće s obzirom na središte. Njihova primjena je za funkcionalnost RBF mreže ključna regularnost matrice učenja, tj. matrice radijalnih baznih funkcija H koja je prema Micchellijevom teoremu [28] ostvarena ukoliko je prva derivacija aktivacijske funkcije u potpunosti monotona. Pri izračunavanju težinskih parametara ključna je invertibilnost matrice H . Iako postoji niz različitih radijalnih baznih funkcija primjenjivanih u RBF mrežama, u sklopu ovog rada je korištena najčešće primjenjivana Gaussova aktivacijska funkcija (slika 17).



Slika 17 Gaussova aktivacijska funkcija [29]

4.3. Matematički opis RBF NM

Matematički opis započinjemo definiranjem matematičke veze između neurona izlaznog i skrivenog sloja:

$$O(x_i) = \sum_{j=1}^K h(r_{ij})c_{jw}, \quad w = 1, \dots, M, \quad i = 1, \dots, N, \quad (4.1)$$

pri čemu je O_w element w -tog izlaznog neurona koji ovisi o ulaznom vektoru (\mathbf{x}) koji se sastoji od elemenata svih ulaznih neurona u i -tom uzorku za učenje, $h(*)$ aktivacijska funkcija, d_{ij} euklidska udaljenost između i -tih elemenata ulaznih neurona i elemenata vektora centra j -tog neurona skrivenog sloja, c_{jw} težinski faktor koji povezuje j -ti neuron skrivenog sloja i w -ti neuron izlaznog sloja, K broj neurona skrivenog sloja, M broj izlaznih, a L broj ulaznih neurona. Gaussova aktivacijska funkcija je oblika:

$$H_{ij} = h(d_{ij}) = e^{-\left(\frac{d_{ij}}{\sigma}\right)^2}, \quad (4.2)$$

gdje je H_{ij} element matrice radijalnih baznih funkcija H , a σ širina radijalne bazne funkcije.

Vrijednost parametra σ se određuje preko metode P najbližih susjeda (eng. P nearest neighbour) [31]. Jednadžba prema kojoj se računa širina aktivacijske funkcije svakog j -tog neurona u skrivenom sloju je:

$$\sigma_j = \sqrt{p_1 p_2}, \quad (4.3)$$

gdje su p_1, p_2 Euklidske udaljenosti j -tog neurona od njemu dva euklidski najbliža neurona u skrivenom sloju.

4.4. Proces učenja

Učenje započinje određivanjem centara neurona skrivenog sloja gdje se u slučaju interpolacije u obzir uzimaju svi ulazni elementi uzoraka za učenje, te svaki od njih predstavlja jedan od centara skrivenog sloja. Nakon što su određeni centri neurona skrivenog sloja, izračunavaju se Euklidske udaljenosti između uzoraka za učenje i centara neurona skrivenog sloja prema sljedećoj jednadžbi:

$$d_{ij} = ||x_i - t_j|| \quad (4.4)$$

gdje d_{ij} predstavlja element matrice udaljenosti d između i -tog ulaznog neurona i j -tog skrivenog neurona. Na svaki od elemenata matrice d se primjeni Gaussova aktivacijska funkcija prema jednadžbi:

$$H_{ij} = h(d_{ij}). \quad (4.5)$$

Računanje matrice težinskih faktora C započinjemo zapisivanjem izraza 4.1 u matričnoj formi

$$O = H C \quad (4.6)$$

gdje O označava matricu izlaza dimenzija $N \times M$, H matricu radijalnih baznih funkcija dimenzija $N \times K$, a C matricu težinskih faktora mreže s dimenzijama $K \times M$. Matricu C tada možemo izračunati kao umnožak inverza kvadratne matrice H i matrice izlaza O

$$C = H^{-1}O. \quad (4.7)$$

S tim korakom je završeno učenje težina izlaznog sloja i učenje neuronske mreže. Testiranje i validacija se provodi kroz sljedeće korake.

1. Izračun Euklidskih udaljenosti za svaki ulazni podatak iz skupa za testiranje od svih centara neurona skrivenog sloja.
2. Izračun nove matrice radijalnih baznih funkcija
3. Izračun izlaza mreže na temelju matrice H i težinskih faktora C preko jednadžbe 4.6
4. Razvrstavanje testiranih uzorka u definirane klasifikacijske skupine na temelju izlaza mreže. Uspješnost klasifikacije se definira kao postotak ispravno klasificiranih uzoraka od broja ukupnih podataka za testiranje.

5. Eksperimentalni postav i snimanje signala


Cilj ovog diplomskog rada je klasificirati stupanj istrošenosti alata uz pomoć neuronske mreže te posredno odrediti i klasificirati stupanj delaminacije. U tu svrhu su iskorišteni podaci dobiveni u [32] gdje je osmišljen pokus bušenja kompozita i proveden u Laboratoriju za alatne strojeve Fakulteta strojarstva i brodogradnje u Zagrebu. Pokus je proveden u dva dijela: pretpokus i glavni pokus. Cilj pretpokusa bio je utvrditi parametre brzinu rezanja i posmak, koji su se koristili u glavnom pokusu .

Nakon pretpokusa, gdje su se odredili parametri rezanja te korišteno svrdlo, uslijedilo je provođenje glavnog pokusa. Odabrane su 4 brzine rezanja i 4 posmaka, što zajedno daje 16 kombinacija posmaka i brzine rezanja. Svaka od 16 kombinacija ponavljana je 10 puta za svaki od 4 stupnja istrošenosti, za sveukupno 640 uzoraka. Tijekom izvođenja glavnog pokusa kontinuirano su snimani signali akustične emisije, vibracija, sila motora te sila rezanja, a periodički je slikana i rezna oštrica. Takvo prikupljanje podataka omogućilo je povezivanje iznosa značajki naknadno izdvojenih iz snimljenih signala sa stanjem oštrice. Nakon što je završeno bušenje industrijskom kamerom su snimljene ulazne i izlazne strane provrta. [32]

5.1. Stroj

Stroj na kojem se izvodilo bušenje je tro-osna glodalica, sa 3 translacijske osi i vertikalnim glavnim vretenom. Glavni prigon je izveden direktno, odnosno na motor je montiran odgovarajući prihvatač alata. Posmični prigon je izveden kombinacijom kliznih vodilica i kugličnog navojnog vretena.

Na slici 18 prikazana je unutrašnjost i radni prostor stroja, gdje se vidi: 1. Posmični prigon X osi, 2. Posmični prigon Y osi, 3. Posmični prigon Z osi, 4. Glavno vreteno, 5. Stezna naprava, 6. Senzor sila koji je smješten ispod stezne naprave, 7. Senzor vibracija i senzor akustičnih emisija smješteni tik uz prednji ležaj glavnog vretena, 8. Industrijska kamera s rasvjetom, 9. Ispitni uzorak, 10. Ispitno svrdlo [32]

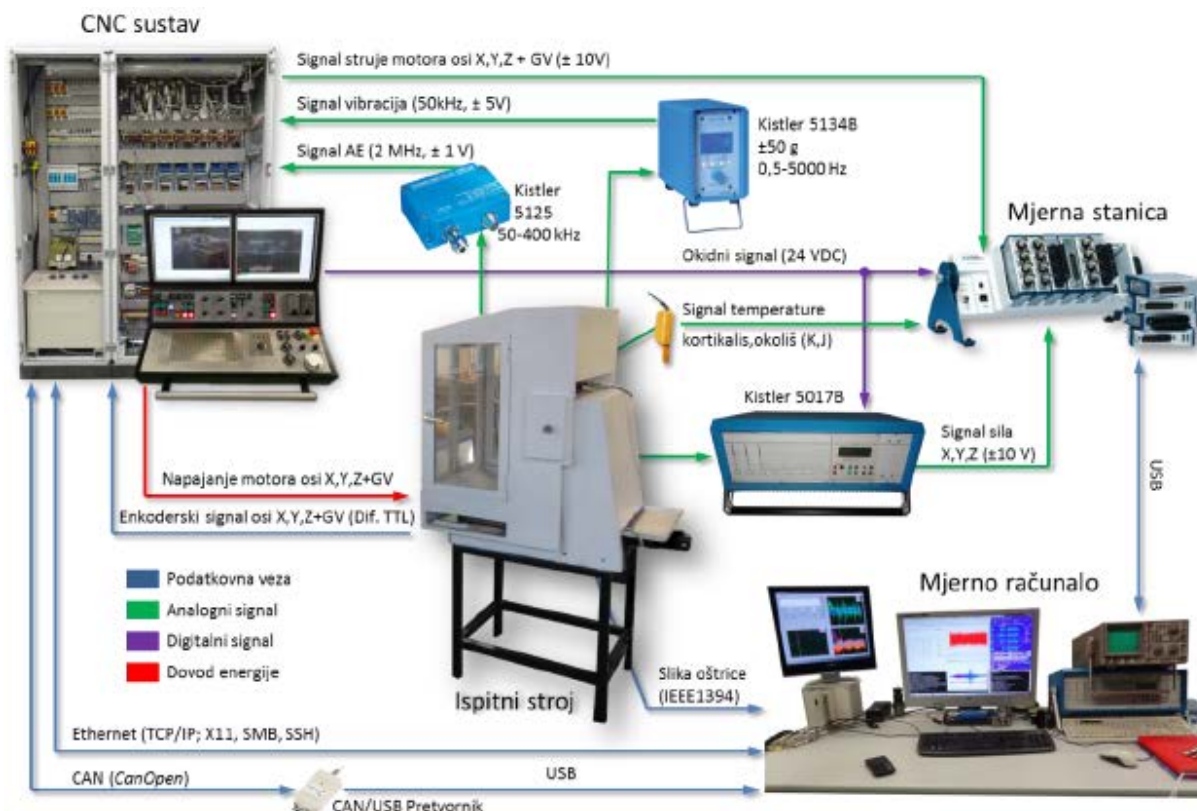


Slika 18 Unutrašnjost i radni prostor stroja [32]

Bitna značajka stroja je opremljenost nizom prethodno spomenutih senzora koji mjere iznose signala u realnom vremenu na temelju kojih će se potencijalno moći donijeti zaključci o stanju alata, odnosno koji će služiti za direktni i indirektni nadzor alata. Senzori koji služe za indirektni nadzor alata su senzori sila, vibracija i akustičnih emisija dok se za direktni nadzor koristi industrijska kamera. Signali jakosti struje prikupljeni su iz servo-regulatora upravljačkog sustava. U nastavku je detaljnije opisan mjerni sustav stroja. Upravljački dio stroja sastavljen od NC računala, napajanja, servo regulatora motora i ostalih ulazno-izlaznih sklopova smješten je u elektro-ormar prikazan na slici 18.

5.2. Mjerni sustav

Mjerni sustav, čija je cjelovita struktura prikazana na slici 19, sastoji se od senzora sila i pripadajućeg pojačala, senzora vibracija i pripadajućeg pojačala, senzora akustičnih emisija i pripadajućeg pojačala, industrijske kamere s telecentričnim objektivom i rasvjetom, mjernog računala i mjerne aplikacije. [32]



Slika 19 Struktura mjernog sustava [32]

5.2.1. Senzor vibracija

Mjerni sustav kojim su tijekom pokusa mjerene vibracije sastoji se od tro-komponentno piezo-električnog akcelerometra – senzora model 8688A50 proizvođača Kistler Holding AG uparenog s nabojsnim pojačalom model 5134B, također proizvođača Kistler Holding AG.



Slika 20 Senzor vibracija i pripadajuće nabojno pojačalo

Slika 20 prikazuje mjerni sustav kojeg čine senzor vibracija i pripadajuće nabojno pojačalo, dok su u tablici 2 dane osnovne karakteristike istog.

Tablica 2 Tehničke karakteristike senzora vibracija i pojačala

		Područje	Jedinica
Senzor vibracija (tip 8688A50)	Mjerno područje akceleracije	± 50	g
	Maksimalna dozvoljena akceleracija	± 80	
	Prag osjetljivosti	$3,6 \cdot 10^{-4}$	\bar{g}_{RMS}
	Osjetljivost ($\pm 10\%$)	100	mV/g
	Frekvencijsko područje	0,5 ... 5000	Hz
Nabojno pojačalo (tip 5134B)	Broj kanala	4	
	Vremenska konstanta ulaznog kruga	10/1/0,1/0	s
	Programibilni faktor pojačanja	0,5 ... 150	
	Programibilni nisko propusni filter (-3dB)	0,001 ... 10^7	Hz
	Izlazni signal (po kanalu)	$\pm 10, \pm 5$	V

5.2.2. Senzor akustične emisije

Mjerenje akustične emisije izvedeno je piezoelektričnim senzorom (tip 8152B1/12sp) i odgovarajućim pojačalom (tip 5125B) proizvođača Kistler Holding AG. Radno područje senzora navedeno od strane proizvođača iznosi 50 do 400 kHz. Senzor akustične emisije prikazan na slici 18 ugrađen je u blizini stezne glave svrdla.



Slika 21 Senzor akustične emisije i pripadajuće pojačalo [29]

5.2.3. Vizijski sustav

Vizijski sustav koji je služio za periodičko direktno mjerenje istrošenosti rezne oštrice se sastojao od industrijske kamere proizvođača Imaging Source Europe GmbH model DMK41AF02, telecentričnog objektiv proizvođača Opto Engineering S.r.l. model TC2309 i prstenaste led rasvjete. Kompletan vizijski sustav smješten je na nosač fiksiran za posmični prigon X osi i orijentiran na način da u određenoj poziciji svrdla (jednoj od nul-točaka) optička os kamere odgovara normali glavne oštrice svrdla. Obradom slika kvantificirana je istrošenost mjerne oštrice. Slika 22 prikazuje kameru i telecentrični objektiv. [32]



Slika 22 Kamera i telecentrični objektiv

Tablica 3 daje tehničke karakteristike kamere i objektiv.


Tablica 3 Tehničke karakteristike kamere i objektiva

		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 prihvaća		C		
Rezolucija mjernog sustava u opisanoj konfiguraciji		5	µm	

5.3. Pokus i provedena analiza

5.3.1. Ispitni uzorci

Ispitni uzorci izrezani su iz kompozitne cijevi proizvođača tvrtke Domitran Novitas d.o.o. Materijal cijevi je kompozit s polimernom matricom (nezasićena poliesterska smola) ojačan staklenim vlaknima, s udjelom ojačala od oko 60%. Dimenzije uzoraka su 180x100x10 mm. Cijev je izrađena postupkom namatanja kontinuiranih vlakana na rotirajući kalup, koji je shematski prikazan na slici 23, dok je primjer ispitnog uzorka prikazan na slici 24.



Slika 23 Shematski prikaz postupka namatanja vlakana [33]



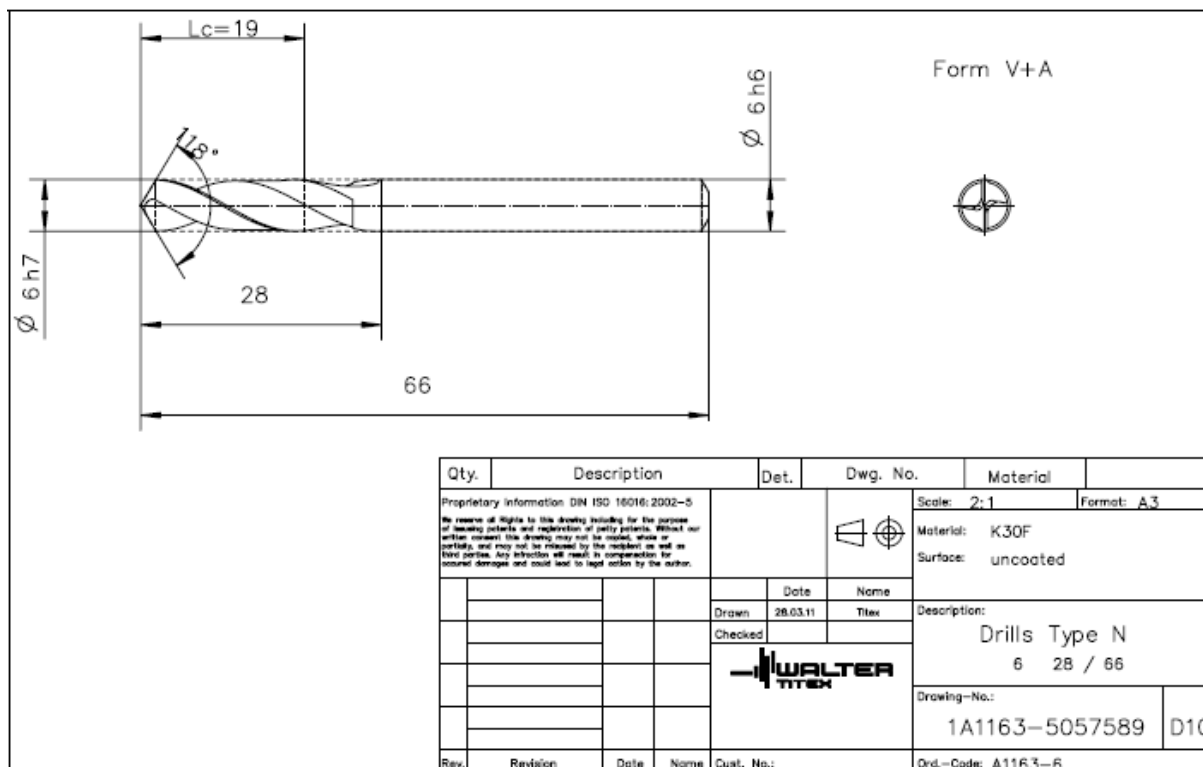
Slika 24 Primjer ispitnih uzoraka [32]

5.3.2. Ispitno svrdlo

Za izvođenje pokusa odabrano je svrdlo izrađeno od tvrdog metala, model A1163, proizvođača Walter Titex. Promjer svrdla je 6 mm, vršni kut 118° , a ostale dimenzije prikazane su na slici 25. U sklopu istraživanja ispitana su 4 stupnja istrošenosti navedenog svrdla čija je ovisnost o broju izbušenih provrta prikazana u tablici 4.

Tablica 4 Ovisnost stupnja istrošenosti o broju izbušenih provrta

Stupanj istrošenosti svrdla	<i>S1</i>	<i>S2</i>	<i>S3</i>	<i>S4</i>
Broj izbušenih provrta	0-160	1500-1660	2500-2660	3500-3660



Slika 25 Crtež svrdla A1163, Walter Titex

5.3.3. Odabir parametara

Parametri obrade korišteni u glavnom pokusu određeni su u pretpokusu. Parametri su odabrani s obzirom na maksimalna opterećenja stroja i alata, karakteristike motora i vrijeme trajanja same obrade.


Na kraju su odabrane 4 brzine rezanja i 4 posmaka, što rezultira sa 16 različitih kombinacija posmaka i brzine rezanja. Sveukupno je bilo 64 različita stanja pokusa jer se 16 kombinacija posmaka i brzine rezanja koristilo za svaki od 4 stupnja istrošenosti svrdla ($S1$, $S2$, $S3$, $S4$). Svaka od 16 kombinacija se ponovila 10 puta za svaki stupanj istrošenosti, čime je sveukupno snimljeno 640 mjerenja. U tablici 5 su detaljnije prikazani režimi obrade glavnog pokusa. [32]

Tablica 5 Režimi obrade korišteni u glavnom pokusu [32]

Promjer svrdla	Brzina rezanja	Posmak	Učestalost vrtnje G.V.	Posmična brzina	Dubina bušenja	Vrijeme bušenja	Broj ponavljanja za svaki stupanj istrošenosti
d_1	v_c	f	$n = \frac{v_c * 10^3}{d_1 * \pi}$	$v_f = f * n$	a_p	$t_b = \frac{a_p * 60}{v_f}$	
mm	m/min	mm/okr.	min ⁻¹	mm/min	mm	s	
6	15	0,03	796,2	23,9	18	45,2	10
	30		1592,4	47,8		22,6	
	45		2388,5	71,7		15,1	
	60		3184,7	95,5		11,3	
	15	0,06	796,2	47,8		22,6	
	30		1592,4	95,5		11,3	
	45		2388,5	143,3		7,5	
	60		3184,7	191,1		5,7	
	15	0,09	796,2	71,77		15	
	30		1592,4	143,3		7,5	
	45		2388,5	215		5	
	60		3184,7	286,6		3,8	
	15	0,12	796,2	95,5		11,3	
	30		1592,4	191,1		5,7	
	45		2388,5	286,6		3,8	
	60		3184,7	382,2		2,8	


5.3.4. Određivanje istrošenosti svrdla

Istrošenost se određivala direktnim putem na temelju slika oštrica reznog alata. Oštrice su za svaki stupanj istrošenosti snimljene 2 puta, prije i nakon izvođenja kompleta bušenja na tom stupnju istrošenosti (npr. za stupanj istrošenosti S2 svrdlo je snimljeno nakon izbušenih 1500 provrta i opet nakon odrađenih bušenja za S2 što je 1660 provrta). Snimanje se izvodilo ranije opisanim vizijskim sustavom.



Slika 26 Fotografije rezne oštrice [32]

Na prikupljenim slikama je primijenjena analiza uz pomoć paketa Catia V5R20 u svrhu određivanja dominantnih oblika trošenja i njihovih iznosa. Jedan od rezultata analize je bio taj da je dominantan oblik trošenja trošenje stražnje površine oštrice *VB* čija se maksimalna i srednja vrijednost uzima kao glavni indikator trošenja u nastavku rada. Na slici 27 je prikazan princip određivanja značajke *VB*.




Slika 27 Određivanje širine trošenja stražnje površine alata [34]

Na sljedećoj slici su dane izmjerene vrijednosti trošenja oštrice VB u ovisnosti o udaljenosti od središta svrdla te o broju izbušenih provrta. Očekivano je da će trošenje reznog alata biti veće što je veća udaljenost od središta svrdla, tj. središta rotacije, zbog veće brzine rezanja koja je veća na obodu.

Sljedeća tablica i slika daju kvantitativne vrijednosti maksimalne, minimalne i srednje vrijednosti istrošenosti VB za sva četiri stupnja istrošenosti.

Tablica 6 Iznosi istrošenosti stražnje površine alata [32]

	$S1$	$S2$	$S3$	$S4$
VB_{MAX}	0,077	0,211	0,284	0,320
VB_{SR}	0,016	0,081	0,106	0,135
VB_{MIN}	0,000	0,013	0,017	0,019



Slika 28 Grafički prikaz iznosa istrošenosti stražnje površine alata [32]

5.3.5. Snimanje signala

Za vrijeme provođenja istraživanja snimljeni su sljedeći signali:

- Signali sila rezanja u smjeru X , Y i Z osi pomoću prethodno navedenog senzora sila
- Signali jakosti struja posmičnih motora te signal jakosti struje glavnog vretena
- Signali akustične emisije
- Signali vibracija u smjeru X , Y i Z osi


Signali akustičnih emisija i vibracija zbog velike frekvencije uzorkovanja i velike količine podataka koja se generira nisu snimani kontinuirano. Od trenutka kada je svrdlo ušlo u puni zahvat, signal akustične emisije se snimao 0.1 sekundu s frekvencijom uzorkovanja 2 MHz, dok su se signali vibracija snimali 2 sekunde s frekvencijom uzorkovanja 100 kHz. Prema tome je za svaki od signala prikupljeno 200 000 uzoraka po kanalu.

6. Priprema podataka, analiza i rezultati

Kao što je ranije spomenuto, glavni rezultat ovog diplomskog rada je matematički model koji će na osnovu ulaznih parametara, koji se mogu izdvojiti iz signala snimljenih tijekom obrade, klasificirati stupanj istrošenosti reznog alata te posredno i stupanj delaminacije u blizini provrta. Kvaliteta odziva matematičkog modela dobivenog tehnikama strojnog učenja značajno ovisi o kvaliteti snimljenih signala i prikupljenih podataka te kvalitetnom odabiru relevantnih značajki iz istih. U ovome poglavlju je prikazana priprema i analiza podataka i signala te postignuti rezultati.

6.1. Obrada signala akustične emisije

Signali akustične emisije su snimani tijekom procesa bušenja u frekventijskom području od 50-400 kHz u periodu od 0.1 sekunde s frekvencijom uzorkovanja od 2 MHz. Primjer sirovog signala je prikazan na slici 29.




Slika 29 Primjer sirovog signala akustične emisije

Signali u sirovom stanju su vrlo nepogodni kao odabir za ulazne značajke neuronske mreže. Stoga je sljedeći korak određivanje značajki iz sirovih signala koje će sadržavati bitne i korisne informacije o procesu. U sličnim istraživanjima, energije signala u određenim frekventijskim pojasevima su dale značajan uspjeh. U nastavku je prikazan postupak izdvajanja energija iz sirovih signala.

Proces određivanja značajki započinje primjenom metode brze Fourierove transformacije (eng. Fast Fourier Transformation, FFT) iz čijih se rezultata mogu odrediti snage frekvencijskog spektra signala akustične emisije. Primjenom FFT se za svaki signal dobije informacija o raspodjeli snaga komponenti spektra u specificiranom mjernom području. Iz tako dobivene raspodjele snaga signala izračunate su energije spektra signala za različite frekvencijske pojaseve. Širine pojaseva odabrane u ovom radu su iznosile $p \in [5, 10, 15, 20, 30, 40]$ kHz. Ako uzmemo 40 kHz kao primjer, onda je frekvencijsko područje podijeljeno na pojaseve $[f_p, f_k]$: [50, 90], [90, 130], [130, 170], [170, 210], [210, 250], [250, 290], [290, 330], [330, 370], [370, 400] kHz. Kao što se može vidjeti iz zadnjeg člana, ako bi širina pojasa prelazila graničnu vrijednost frekvencijskog područja, krajnja vrijednost tog pojasa bi se postavila na tu graničnu vrijednost. Za svaki od frekvencijskih pojaseva s početnom i krajnjom vrijednosti f_p i f_k je određena energija signala akustične emisije tako što je određena površina ispod pripadajuće krivulje spektralne gustoće snage. Koristeći jednadžbu 6.1 izračunate su energije frekvencijskih pojaseva, $E(AE)$, za svaki od 640 uzoraka.


$$E[AE(f_p, f_k)] = \frac{\sum_{f_p}^{f_k} AE(f)}{n} * (f_k - f_p) \quad (6.1)$$

Na slikama 30,31,32 i 33 su prikazani neki od grafova snage signala akustične emisije u ovisnosti o frekvenciji.




Slika 30 Snaga signala u ovisnosti o frekvenciji za posmak 0.06 mm/okr, brzinu rezanja 30 m/min te stupanj istrošenosti S1


Iz navedenih slika proizlazi da su snage signala najviše u rasponima od 50 do 100 kHz te u manjoj mjeri u frekvencijskim rasponima od 100 do 170 kHz. Prema tome, moglo bi se zaključiti da je u tim rasponima i najviše informacija o procesu te da će energije iz tih raspona imati najveći utjecaj na klasifikaciju.



Slika 31 Snaga signala u ovisnosti o frekvenciji za posmak 0.06 mm/okr, brzinu rezanja 30 m/min te stupanj istrošenosti S2



Slika 32 Snaga signala u ovisnosti o frekvenciji za posmak 0.06 mm/okr, brzinu rezanja 30 m/min te stupanj istrošenosti S3



Slika 33 Snaga signala u ovisnosti o frekvenciji za posmak 0.06 mm/okr, brzinu rezanja 30 m/min te stupanj istrošenosti S4

6.2. Stupanj istrošenosti

Prethodno je navedeno da je tijekom eksperimenta provedeno sveukupno 640 mjerenja, tj. po 10 mjerenja za svaku od kombinacija 4 stupnja istrošenosti, 4 brzine rezanja i 4 posmaka.

Alat kojim će se služiti za povezivanje snimljenih signala sa stupnjem istrošenosti je RBF neuronska mreža kojoj će kao ulaz služiti energije signala u različitim frekvencijskim pojasevima.

Odabir značajki na kojima će mreža učiti i koji će biti dani na njene ulaze ima velik utjecaj na generalizacijska svojstva mreže, tj. uspješnu primjenu „znanja“ stečenog pri učenju na podacima za testiranje. Ulazne značajke koje ne koreliraju s izlaznim značajkama su ekvivalentne šumu te loše utječu na konačnu točnost i kvalitetu naučene mreže.

6.2.1. Značajke signala akustične emisije

U svrhu određivanja značajki koje sadrže korisne informacije za mrežu te koreliraju s izlazom, svaka od mogućih značajki, koja je u ovom slučaju energija na određenom frekvencijskom pojasu, je zasebno dana na ulaz neuronskoj mreži zajedno s parametrima rezanja. Nakon provedenog učenja za svaku od značajki, izabrane su one koje su rezultirale najvećom točnošću.

Kako bi se osiguralo da prethodno opisano testiranje značajki da stvarnu sliku o korisnosti informacija sadržanih na tim frekvencijskim pojasevima, podatci za učenje i testiranje nisu bili svrstavani nasumično, nego odabirom po sljedećem algoritmu.

Unutar 10 mjerenja za svaku od 64 kombinacije stupnja istrošenosti, brzine rezanja i posmaka, uzeto je 5 podataka za učenje i 5 podataka za testiranje. Podatci za učenje su birani po sljedećim koracima:

1. Odrediti srednju vrijednost energije na zadanom pojasu za razmatranih 10 mjerenja
2. Uzeti uzorak po iznosu najbliži srednjoj vrijednosti i svrstati ga u uzorke za učenje
3. Uzeti 4 uzorka po iznosu najdaljih od srednje vrijednosti te ih svrstati u uzorke za učenje

Ovakav način odabira osigurava većinsku pokrivenost mogućeg raspona vrijednosti unutar značajke što povoljno utječe na generalizacijska svojstva.

Nakon što su na prethodno opisani način razvrstani uzorci za učenje od onih za testiranje, pristupilo se određivanju klasifikacijske točnosti stupnja istrošenosti za svaku značajku pojedinačno. U tablici 7 su prikazane najveće točnosti za svaku razmatranu širinu frekvencijskog pojasa te raspon pojasa za koji je ostvarena točnost.

Tablica 7 Frekvencijski pojasevi s najvećom klasifikacijskom točnošću

Širina pojasa	5	10	15	20	30	40
Raspon pojasa	60-65	60-70	50-65	50-70	50-80	50-90
Točnost	48%	51%	50%	48%	40%	38%

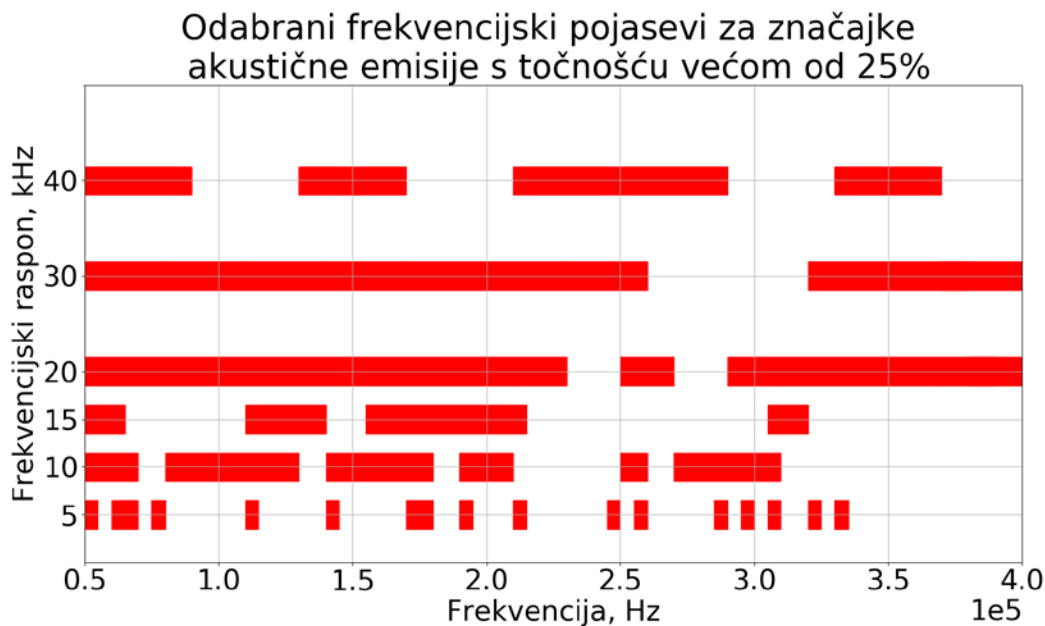
Iz prikazanih točnosti se može zaključiti da se najkorisnije informacije za povezivanje signala akustičnih emisija sa stupnjem istrošenosti alata nalaze u rasponu od 50 do 90 kHz. Kao raspon s najvećim utjecajem se može izdvojiti raspon od 50 do 70 kHz gdje se nalaze energije koje omogućavaju točnosti do 48% do 51%. Prikazane točnosti frekvencijskih raspona 50-90 kHz su u skladu sa zaključcima donesenim prema slikama od 30 do 33.

Nakon određivanja individualnih klasifikacijskih točnosti, značajke su dodatno filtrirane na način da ako značajka energije određenog frekvencijskog raspona ima manju klasifikacijsku točnost od energije frekvencijskog raspona koji ga obuhvaća, onda je obuhvaćeni frekvencijski raspon izbačen iz daljnjeg razmatranja. Za primjer možemo uzeti energiju frekvencijskog raspona 60-70 kHz sa klasifikacijskom točnošću 35%, te energiju frekvencijskog raspona 55-70 kHz sa klasifikacijskom točnošću 45%. U tom slučaju bi raspon 60-70 kHz bio izbačen jer je obuhvaćen širim rasponom veće točnosti. Značajke su se filtrirale i na ovaj način jer bi uzimanje u obzir obuhvaćenih značajki manje točnosti značilo dvostruko uzimanje iste informacije.

Konačna faza je predstavljala konačno učenje mreže sa svim odabranim korisnim značajkama. Prvi korak je odabir podataka za učenje i testiranje mreže. Omjer podataka za učenje i testiranje je izabran na 1:1, iliti 320 uzoraka za učenje i 320 uzoraka za testiranje. Da bi se pri učenju pokrio cijeli spektar mogućih kombinacija ulaznih i izlaznih značajki, od 10 uzoraka za svaku od 64 kombinacije parametara rezanja i stupnja istrošenosti je nasumično odabrano 5 uzoraka za učenje i 5 za testiranje.

Sljedeći korak je određivanje granice klasifikacijske točnosti ispod koje značajke više ne dodaju korisne informacije, te zbog toga ne ulaze u konačno učenje mreže. Značajke su razvrstane po izračunatoj klasifikacijskoj točnosti, te je za početak odabrana granična točnost od 50%. Zatim je provedeno učenje s ulaznim značajkama koje zadovoljavaju ovaj uvjet i zabilježena je ukupna klasifikacijska točnost. Nakon toga je granica snižena i postupak ponavljen.

Ponavljanjem ovih koraka došlo se do zaključka da maksimalna ukupna klasifikacijska točnost stupnja istrošenosti iznosi 83.23%, a dobivena je primjenom značajki koje su individualno postigle klasifikacijsku točnost veću od 25%. Slika 34 prikazuje frekvencijske pojaseve čije energije su uzete kao značajke u konačnom učenju mreže.



Slika 34 Frekvencijski pojasevi čije su energije uzete kao ulazne značajke neuronske mreže

Tablica 8 prikazuje matricu konfuzije (engl. *Confusion matrix*) izlaza neuronske mreže koja je bolji pokazatelj kapaciteta mreže u klasifikaciji stupnja istrošenosti. Redci prikazuju stvarni stupanj istrošenosti alata podataka za testiranje, a stupci daju predikciju mreže. Može se uočiti da su točno klasificirani uzorci jednoliko podijeljeni među klasifikacijskim skupinama što upućuje na to da je cijeli raspon mogućih ulaza dobro pokriven u učenju. Relativno jednolika raspodjela pogrešno klasificiranih uzoraka daje naslutiti da nema sustavnih grešaka.


Tablica 8 Matrica konfuzije za podatke za testiranje

Rezultat mreže

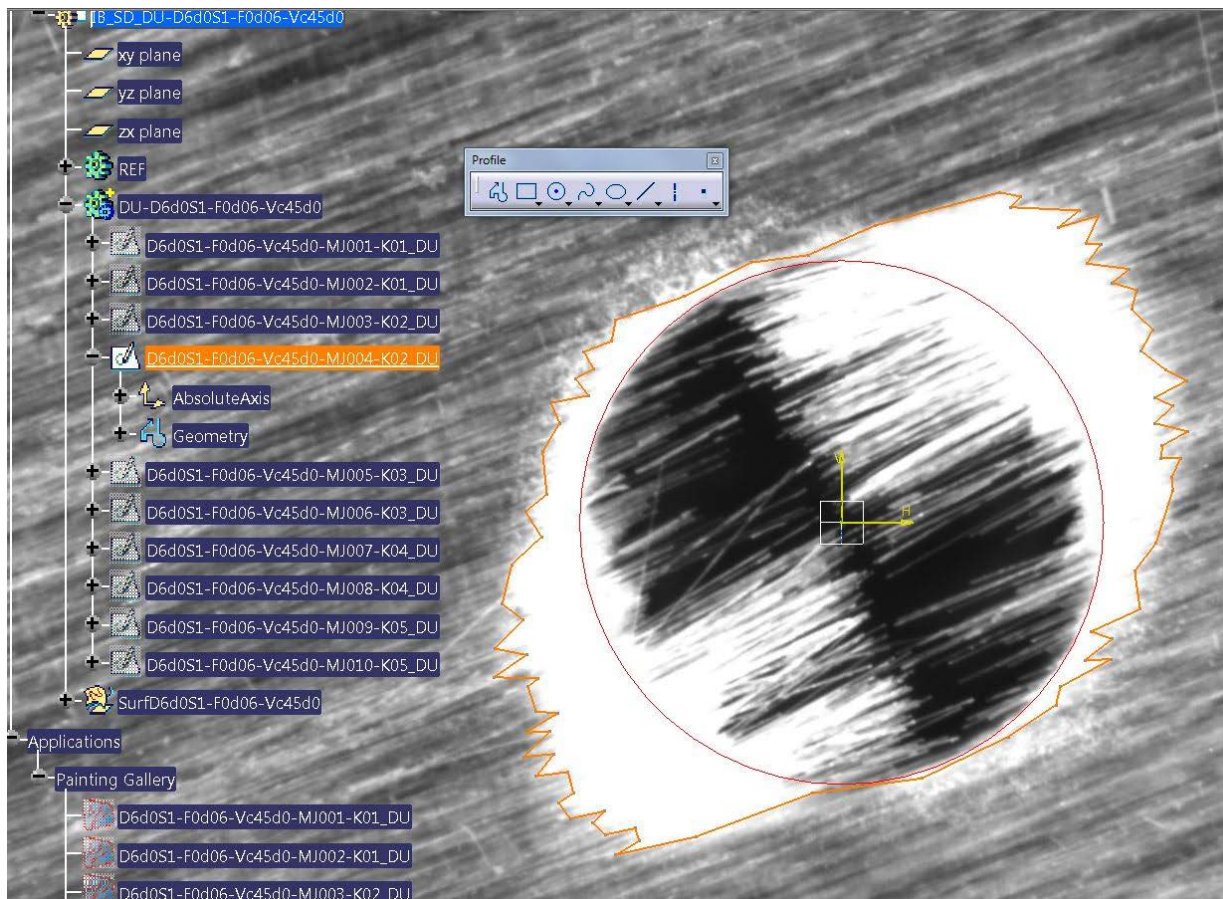
	<i>S1</i>	<i>S2</i>	<i>S3</i>	<i>S4</i>	
Stvarni rezultat	<i>S1</i>	64	1	7	7
<i>S2</i>	4	66	0	9	
<i>S3</i>	9	0	67	3	
<i>S4</i>	4	5	4	66	

6.3. Kvantificiranje stupnja delaminacije

Stupanj delaminacije na rubovima provrta je kvantificiran prema slikama provrta iz [32] uz pomoć programskog paketa Catia V5R20. U prvom koraku su ručno iscrtavane konture delaminacije na svakoj slici kao što je prikazano na slici 36. Provrta su slikani s ulazne i izlazne strane, ali su obrađeni samo oni s izlazne strane zbog teškoća u kvantificiranju delaminacije na slikama provrta s ulazne strane. Razlika provrta ulazne i izlazne strane je prikazana na slici 35. Iako su u [32] obrađena 3 mjerenja od 10 za svaki provrt, u sklopu ovog diplomskog rada je obrađeno svih 640 mjerenja zbog velikog utjecaja individualnog načina obrade na konzistenciju rezultata.

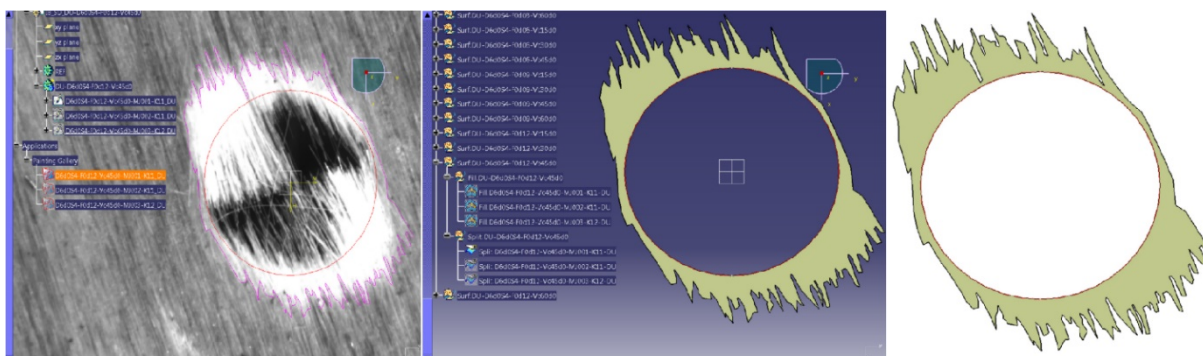


Slika 35 Primjer izlazne i ulazne strane provrta [32]



Slika 36 Primjer ručnog određivanja područja delaminacije u Catia


Nakon iscertavanja svih provrta, pomoću programa napisanog u Catia VBA alatu, su izvučene značajke koje opisuju stanje delaminacije svakog provrta. Odabrane značajke su: površina delaminacije, opseg delaminacije, maksimalna udaljenost između točaka te srednja udaljenost između točaka. Na slici 37 je prikazan postupak određivanja površine delaminacije pomoću programa Catia.




Slika 37 Postupak određivanja značajki delaminacije [32]

Jedna od glavnih pretpostavki je da za iste parametre obrade, tj. isti posmak i brzinu rezanja, stupanj delaminacije visoko korelira sa stupnjem istrošenosti alata. Na sljedećim grafovima su


prikazane ovisnosti ploha srednjih vrijednosti iznosa stupnja delaminacije o parametrima rezanja za svaku od razmatranih značajki delaminacije. Može se vidjeti da značajke maksimalne udaljenosti točaka te opsega delaminacije pokazuju vrlo izražene nelinearnosti te slabu korelaciju sa stupnjem istrošenosti, stoga se te značajke uklanjaju iz daljnjeg razmatranja.




Slika 38 Prosječni iznosi srednje udaljenosti točaka za svaki stupanj istrošenosti




Slika 39 Prosječni iznosi maksimalne udaljenosti točaka za svaki stupanj istrošenosti




Slika 40 Prosječni iznosi opsega delaminacije za svaki stupanj istrošenosti



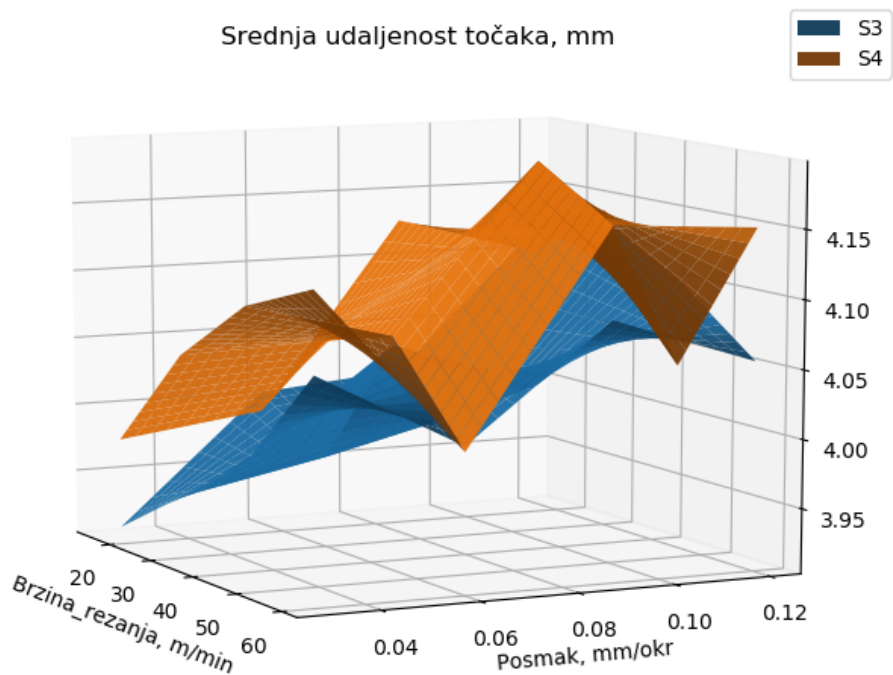
Slika 41 Prosječni iznosi površine delaminacije za svaki stupanj istrošenosti




Slika 42 Prosječni iznosi srednje udaljenosti točaka za stupnjeve S1 i S2



Slika 43 Prosječni iznosi srednje udaljenosti točaka za svaki stupanj istrošenosti S2 i S3




Slika 44 Prosječni iznosi srednje udaljenosti točaka za svaki stupanj istrošenosti S3 i S4




Slika 45 Prosječni iznosi površine delaminacije za stupnjeve istrošenosti S1 i S2

Prikazani grafovi (slike 42 do 47) prikazuju usporedbe individualnih plohi značajki koje su i dalje razmatrane, površine delaminacije i srednje udaljenosti između točaka. Prikazane su usporedbe stupnjeva istrošenosti S1 i S2, S2 i S3 te S3 i S4.



Slika 46 Prosječni iznosi površine delaminacije za stupnjeve istrošenosti S2 i S3



Slika 47 Prosječni iznosi površine delaminacije za stupnjeve istrošenosti S3 i S4


Iz prethodnih grafova se može zaključiti da postoji značajna razlika u prosječnom iznosu delaminacije između stupnjeva istrošenosti $S2$ i $S3$, no da između stupnjeva $S1$ i $S2$, te $S3$ i $S4$ ima značajnih preklapanja. Navedeno se može uočiti i za značajku površine delaminacije i za srednju udaljenost između točaka. Također je vidljivo da što su parametri obrade agresivniji, tj. što su veće vrijednosti posmaka i brzine rezanja, to je kvaliteta provrta lošija i stupanj delaminacije veći. Međutim, plohe nisu monotone, pokazuju znatna izobličenja i nelinearnosti te prethodno spomenuti trendovi ne vrijede za sve slučajeve.

S ciljem klasificiranja stupnja delaminacije, prema prethodnim grafovima dalo bi se zaključiti da je pogodno spojiti preklapajuće stupnjeve istrošenosti $S1$ i $S2$ te $S3$ i $S4$ u nove klasifikacijske skupine Sa i Sb . Vežući se na glavnu pretpostavku da stupanj delaminacije u velikoj većini ovisi o stupnju istrošenosti alata, može se pretpostaviti da će provrti izrađeni sa svrdlom čija istrošenost pripada skupini Sa odgovarati skupini manje delaminacije ($D1$), a da će provrti iz skupine Sb odgovarati skupini veće delaminacije ($D2$).


Prethodna pretpostavka je provjerena izradom grafova koji daju ovisnost iznosa delaminacije u ovisnosti o broju uzorka. Uzorci odgovaraju stupnju istrošenosti prema sljedećoj tablici:

Tablica 9 Raspon broja provrta po stupnju istrošenosti

Novi stupanj istrošenosti	<i>Sa</i>		<i>Sb</i>	
Stupanj istrošenosti	<i>S1</i>	<i>S2</i>	<i>S3</i>	<i>S4</i>
Raspona broja provrta	1-160	161-320	321-480	481-640




Slika 48 Iznos površine delaminacije po uzorku za nove klase stupnja istrošenosti




Slika 49 Iznos srednje udaljenosti između točaka po uzorku za nove klase stupnja istrošenosti

Slike 48 i 49 pokazuju korelaciju stupnja istrošenosti sa stupnjem delaminacije, poglavito u manjoj zastupljenosti najkvalitetnijih rupa u skupini *Sb* te pojavu provrta s većom delaminacijom.

No korelacija je premala, a distribucije pokazuju preveliko preklapanje i stohastičnost što uzrokuje nemogućnost posredne klasifikacije stupnja delaminacije. Sljedeći grafovi 50 i 51, prikazujući usporedbe distribucija 20 uzoraka istih parametara obrade, ali različitih stupnjeva istrošenosti dodatno potvrđuju tu nemogućnost jer distribucije u većini slučajeva pokazuju značajna preklapanja.



Slika 50 Usporedba distribucija srednje udaljenosti između točaka za uzorke istih parametara rezanja i različitog stupnja istrošenosti



Slika 51 Usporedba distribucija površina delaminacija za uzorke istih parametara rezanja i različitog stupnja istrošenosti

7. ZAKLJUČAK

S razvojem industrije i napretkom tehnologije raste i učestalost primjene kompozitnih materijala. Kompozitni proizvodi se često obrađuju/izrađuju tehnologijom obrade odvajanjem česticama pri čemu je bušenje jedna od najzastupljenijih metoda obrade. Kod većine kompozitnih materijala je prisutna slojevita struktura, te kod istih prilikom izrade provrta lako dolazi do raslojavanja (delaminacije) slojeva što nepovoljno utječe na mehanička i druga svojstva kompozita.

U sklopu ovog diplomskog rada je provedena analiza primjene značajki izdvojenih iz signala akustične emisije u nadzoru stupnja istrošenosti i delaminacije u obradi bušenja uzoraka polimernog kompozita sa staklenim vlaknima. Podatci su prikupljeni u eksperimentalnom istraživanju gdje su razmatrana četiri stupnja istrošenosti reznog alata koja su kombinirana s četiri posmaka i brzine rezanja. Kako je za svaku kombinaciju navedenih parametara obrade provedeno deset ponavljajućih mjerenja, ukupno je snimljeno 640 signala akustične emisije. Stupanj istrošenosti alata je definiran u ovisnosti o iznosu širine trošenja na stražnjoj površini alata (VB).

Sirovi signali svakog uzorka su obrađeni primjenom algoritma brze Fourierove transformacije pomoću kojeg su u konačnici određene energije frekvencijskog spektra za različite intervale frekvencija. Dobivene energije su najprije testirane individualno u klasifikaciji stupnja istrošenosti, te su zatim one energije koje su zadovoljile postavljeni kriterij prihvatljivosti dodatno međusobno kombinirane u drugoj fazi klasifikacije. Algoritam za obradu podataka i modeliranje dinamike procesa je činila neuronska mreža s radijalnim baznim funkcijama. Ulazne neurone u mrežu su predstavljali posmak, brzina rezanja i energije odabranih pojaseva frekvencijskog spektra signala akustične emisije dok je izlaz predstavljao stupanj istrošenosti alata.

Proces učenja i testiranja neuronske mreže primjenom signala akustične emisije iz područja frekvencijskog spektra 50-400 kHz je pokazao da se najkorisnije informacije o dinamici procesa nalaze u frekvencijskom rasponu od 50-90 kHz, te da je primjenom signala akustične emisije uz parametre rezanja moguće postići klasifikacijsku točnost stupnja istrošenosti alata od 83.23%.

Značajke stupnja delaminacije su se određivale u nekoliko koraka. Prilikom provođenja istraživanja uzimale su se slike ulazne i izlazne strane provrta od kojih su samo izlazne

pokazivale značajnu delaminaciju. Sljedeći korak se sastojao od ručne obrade slika izlazne strane provrta prema kojem su određene značajke površine delaminacije i srednje udaljenosti između točaka kao jedine koje su pokazivale korelaciju sa stupnjem istrošenosti.

Međutim, pretpostavka da se može uspostaviti direktna veza između stupnja delaminacije i stupnja istrošenosti nije opravdana za provedeno eksperimentalno istraživanje. Distribucije iznosa delaminacije obje odabrane značajke pokazuju veliku varijancu te gotovo stohastično ponašanje.

Moguća poboljšanja u daljnjim istraživanjima mogla bi biti ostvarena automatiziranjem procesa određivanja značajki delaminacije s ciljem uklanjanja ljudskog faktora te poboljšanje kvalitete i ujednačenosti kompozitnih uzoraka za provođenje istraživanja.

Literatura

- [1] grandviewresearch, Dostupno na <https://www.grandviewresearch.com/static/img/research/us-composites-market.png>, 14.1.2020.
- [2] www.aeronestv.com, Dostupno na <https://www.aeronestv.com/en/lifestyle/in-your-opinion/2782-a-boeing-747-8-has-how-many-rivets.html>, 2020.
- [3] E. Jantunen, »A summary of methods applied to tool condition monitoring in,« g. *International Journal of Machine Tools & Manufacture*, svez. Vol. 42, pp. pp. 997-1010, 2002.
- [4] D. Lovrić, Utjecaj parametara obrade i trošenja svrdla na raslojavanje kompozitnih materijala, Diplomski rad, Zagreb, 2014.
- [5] Y. L. Daxi Geng, »Delamination formation, evaluation and suppression during drilling of composite laminates: A review,« *Composite Structures*, 2019.
- [6] A. Quadro, » Analysis of the acoustic emission during drilling,« *Surface & Coating Technology*, Sves. %1 od %2 Vol. 94-95, br. no. 1-3, p. pp. 691–695, 1997.
- [7] D. Snr, »Sensor signals for tool-wear monitoring in metal cutting,« *International Journal of Machine Tools &*, svez. Vol. 8, pp. 1073-1098, 2000.
- [8] V. L. S. ., A. M. Rani Elhajjar, Smart Composites, CRC Press, 2017.
- [9] Z. Schauerl, Predavanja - Kompozitni materijali, Zagreb: FSB, 2009/2010.
- [10] D. C. M. Knight, »Composite Materials,« u *Encyclopedia of Physical Science and Technology*, Elsevier, 2001.
- [11] Composites Lab, Dostupno na <http://compositeslab.com/where-are-composites-used/>, 30.12.2020.
- [12] ecplaza, Dostupno na <https://is2.ecplaza.com/ecplaza2/products/2/2f/2f2/1612264363/carbon-framecarbon-bike.jpg>, 2019.

- [13] Perox, »Wikipedia,« 2009. [Mrežno]. Available: https://en.wikipedia.org/wiki/Composite_material.
- [14] T. F. G Marić, Predavanja – Napredne tehnologije materijala -- Postupci proizvodnje kompozita, FSB, Zagreb, 2013.
- [15] M. Šercer, Predavanja - Proizvodnja kompozitnih tvorevina, Zagreb: FSB.
- [16] F. K. J. I. T Filetin, Svojstva i primjena materijala, Zagreb: FSB, 2007.
- [17] www.researchgate.net, Dostupno na https://www.researchgate.net/figure/283308870_fig2_Figure-2-Typical-structure-of-Carbon-Fiber-Reinforced-Polymer-CFRP, 2020.
- [18] www.build-on-prince.co, Dostupno na <http://www.build-on-prince.com/glass-fiber.html>, 2020.
- [19] Z. Schauerl, Predavanja - Kompozitni materijali, Zagreb: FSB, 2010.
- [20] S. Ekinović, "Postupci obrade rezanjem, Mašinski fakultet, Zenica, 2003.
- [21] D. Ciglar, Predavanja Oblikovanje deformiranjem i obrada odvajanjem, dio Obrada odvajanjem, Zagreb: FSB, 2009.
- [22] S. Škorić, »Predavanje Oblikovanje deformiranjem i obrada odvajanjem,« *Zagreb Fsb*, 2009.
- [23] S. Škorić, Predavanja Oblikovanje deformiranjem i obrada odvajanjem, dio Obrada odvajanjem, Zagreb: FSB, 2009.
- [24] D. Brezak, »Razvoj hibridnog estimatora trošenja alata i metoda vođenja alatnog stroja,« *Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu*, Doktorski rad 2007.
- [25] M. Klaić, »Doktorski rad, Indirektni nadzor istrošenosti alata i tvrdoće obratka kod bušenja kamena,« Zagreb, 2018.
- [26] T. Udiljak, »Doprinos razvoju metoda za ispitivanje i praćenje stupnja istrošenosti,« *Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu*, Disertacija 1996..
- [27] F. G. T Poggio, A theory of networks for approximation and learning, Cambridge: MIT Artif.Intell.Lab, Massachusetts Inst.Technol, 1989.

- [28] D. M. D. Š. B Novaković, Umjetne neuronske mreže, Zagreb: Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu., 1998.
- [29] Z. Murat, Diplomski rad Multisenzorski sustav za indirektni nadzor istrošenosti medicinskih svrdla, Zagreb: Fakultet strojarstva i brodogradnje, 2016.
- [30] T. U. D. M. B. N. J. K. Danko Brezak, Tool Wear Monitoring Using Radial Basis Function Neural Network, Budapest, Hungary: Proceedings of IEEE International Joint Conference on Neural Networks - IJCNN 2004, Vol. 3, 2004.
- [31] C. D. J Moody, »Fast learning in networks of locally tuned processing units,« *Neural Computation*, svez. Vol. 1, br. No. 2, pp. 281-294, 1989.
- [32] I. Bartolin, »Utjecaj trošenja alata i parametara obrade na raslojavanje pri bušenju kompozitnih materijala,« *Diplomski rad*, 2015.
- [33] nuplex, Dostupno na <http://www.nuplex.com/composites/processes/filament-winding>, , 24.06.2015.
- [34] T. Staroveški, Modeliranje trošenja medicinskog svrdla, Doktorski rad, Zagreb, 2013.
- [35] G. Marić, »Predavanja - Napredne tehnologije materijala - Postupci proizvodnje kompozita,« 2013.
- [36] G. Marić, »Materijali 2 - Kompozitni materijali,« 2012.
- [37] D. L. Pech, Nadzor stupnja delaminacije prilikom bušenja polimernog kompozita sa staklenim vlaknima, Zagreb: Diplomski rad, 2017.

PRILOZI

I. CD-R disc