

Multisenzorski sustav za indirektni nadzor istrošenosti medicinskih svrdla

Murat, Zrinka

Master's thesis / Diplomski rad

2016

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:235:660075>

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

Download date / Datum preuzimanja: **2024-12-20**

Repository / Repozitorij:

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



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Zrinka Murat

Zagreb, 2016.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

dr. sc. Danko Brezak, izv. prof.

Studentica:

Zrinka Murat

Zagreb, 2016.

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

Najiskrenije zahvaljujem svojem mentoru dr. sc. Danku Brezaku, izv. prof. na stručnoj i nesebičnoj pomoći, konstruktivnim savjetima, prenesenom znanju, zanimljivim raspravama i poticanju interesa za ovo područje.

Ponajviše zahvaljujem svojim najbližima koji su svakodnevno uz mene, podržavaju me te su imali razumijevanja i strpljenja u svim trenucima mojeg školovanja, a osobito u razdoblju izrade ovog rada. Hvala vam što ste uvijek tu i vjerujete u mene!

Zrinka Murat



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: **Zrinka Murat**

Mat. br.: 0035186507

Naslov rada na hrvatskom jeziku: **Multisenzorski sustav za indirektni nadzor istrošenosti medicinskih svrdla**

Naslov rada na engleskom jeziku: **Multisensory system for medical drills wear level monitoring**

Opis zadatka:

Medicinska svrdla podložna su trošenju uslijed različitih mehaničkih, toplinskih i kemijskih utjecaja koji se javljaju za vrijeme bušenja i njihove sterilizacije. Povećanjem stupnja istrošenosti rezne oštrice dolazi do porasta temperature u zoni obrade i sila rezanja. Porast temperature može rezultirati ireverzibilnim termičkim oštećenjima kosti (termička osteonekroza), a prevelike sile rezanja često dovode i do loma alata. Obje posljedice rezultiraju komplikacijama u postoperativnom tijeku liječenja i dužim vremenom oporavka pacijenta. U dosad provedenim istraživanjima vrlo je slabo zastupljena analiza i primjena sustava za nadzor istrošenosti medicinskog svrdla, koji bi trebali nadograditi postojeće kirurške bušilice niskog stupnja automatizacije. Stoga će u ovome radu biti provedena analiza signala struja motora posmičnih osi stroja i glavnog vretena, vibracija i akustične emisije u procjeni istrošenosti alata u postupku bušenja kostiju primjenom različitih parametara obrade. Iz snimljenih i filtriranih signala procesa izdvojiti će se značajke trošenja, te će se zatim primjenom neuronske mreže s radijalnim baznim funkcijama provesti detaljna analiza iskoristivosti dobivenih značajki u klasifikaciji istrošenosti medicinskog svrdla.

U radu je potrebno:

1. Izraditi programsku podršku za filtriranje i obradu snimljenih signala procesa bušenja (struja motora posmičnih osi stroja i glavnog vretena, vibracija i akustične emisije).
2. Iz pripremljenih signala izdvojiti adekvatne značajke procesa trošenja.
3. Izraditi programsku podršku za neuronsku mrežu koja će biti primijenjena u klasifikaciji stupnja istrošenosti medicinskog svrdla.
4. Izvršiti detaljnu analizu utjecaja svih značajki trošenja i njihovih kombinacija na kvalitetu procjene parametara istrošenosti svrdla.
5. Izvesti zaključke rada.

Zadatak zadan:

Rok predaje rada:

Predviđeni datum obrane:

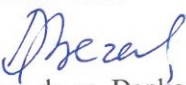
5. svibnja 2016.

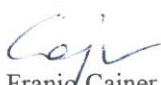
7. srpnja 2016.

13., 14. i 15. srpnja 2016.

Zadatak zadao:

Predsjednik Povjerenstva:


Doc. dr. sc. Danko Brezak


Prof. dr. sc. Franjo Cajner

SADRŽAJ

POPIS SLIKA	III
POPIS TABLICA.....	V
POPIS OZNAKA.....	VII
POPIS KRATICA	X
SAŽETAK	XI
SUMMARY	XIII
1. UVOD.....	1
2. CILJEVI RADA.....	5
3. PLAN RADA.....	6
3.1. Eksperimentalni postav	6
3.2. Ispitni uzorci	10
3.3. Tijek eksperimenta	11
4. PRIPREMA PODATAKA ZA ANALIZU	15
4.1. Priprema signala akustične emisije	15
4.2. Priprema signala vibracija	16
4.3. Priprema signala jakosti struja	17
5. NEURONSKA MREŽA S RADIJALNIM BAZNIM FUNKCIJAMA	19
5.1. Struktura mreže.....	19
5.2. Algoritam učenja	23
5.3. Struktura podataka za učenje i testiranje	24
6. REZULTATI I RASPRAVA	27
6.1. Rezultati analize stupnja istrošenosti korištenjem značajki signala akustične emisije.....	27
6.2. Rezultati analize stupnja istrošenosti korištenjem značajki signala vibracija..	41

6.3.	Rezultati analize stupnja istrošenosti korištenjem značajki signala jakosti struja	60
6.4.	Rezultati analize stupnja istrošenosti korištenjem značajki svih prikupljenih signala.....	61
7.	ZAKLJUČAK	65
	LITERATURA	69
	PRILOZI.....	73

POPIS SLIKA

Slika 1. Eksperimentalni ispitni postav.....	6
Slika 2. Eksperimentalni postav (1 – ispitni uzorak, 2 – medicinsko svrdlo, 3 – senzor akustične emisije, 4 – senzor vibracija, 5 – industrijska kamera)	7
Slika 3. Struktura mjernog sustava	8
Slika 4. Senzor akustične emisije s odgovarajućim sprežnikom	8
Slika 5. Senzor za mjerenje vibracija s pripadajućim pojačalom.....	9
Slika 6. Ispitni uzorak nakon bušenja	11
Slika 7. Standardno medicinsko spiralno svrdlo	11
Slika 8. Oblici trošenja oštrica prema stupnju istrošenosti	13
Slika 9. Struktura RBF neuronske mreže	20
Slika 10. Gaussova aktivacijska funkcija	22
Slika 11. Trokutna aktivacijska funkcija	23
Slika 12. Razvrstavanje podataka u skupove za učenje i testiranje.....	25
Slika 13. Hodogram analize podataka izdvojenih iz signala akustične emisije	27
Slika 14. Najbolji rezultati analize signala akustične emisije za svaku širinu frekvencijskog pojasa uz Gaussovu AF i $koef = 1$	28
Slika 15. Najbolji rezultati analize signala akustične emisije za svaku širinu frekvencijskog pojasa uz Gaussovu AF i $koef = 2$	29
Slika 16. Najbolji rezultati analize signala akustične emisije za svaku širinu frekvencijskog pojasa uz trokutnu AF i $koef = 2$	30
Slika 17. Najbolji rezultati analize signala akustične emisije za svaku širinu frekvencijskog pojasa uz trokutnu AF i $koef = 3$	30
Slika 18. Odabrani frekvencijski pojasevi za značajke akustične emisije koje su ostvarile $UK_{Sr} \geq 50\%$ uz Gaussovu aktivacijsku funkciju	33
Slika 19. Odabrani frekvencijski pojasevi za značajke akustične emisije koje su ostvarile $UK_{Sr} \geq 50\%$ uz trokutnu aktivacijsku funkciju	33
Slika 20. Odabrani frekvencijski pojasevi za značajke akustične emisije koje su ostvarile $UK_{Sr} \geq 60\%$ uz Gaussovu aktivacijsku funkciju	34
Slika 21. Odabrani frekvencijski pojasevi za značajke akustične emisije koje su ostvarile $UK_{Sr} \geq 60\%$ uz trokutnu aktivacijsku funkciju	35
Slika 22. Hodogram analize podataka i odabira najbolje kombinacije značajki trošenja izdvojene iz signala vibracija	41
Slika 23. Najbolji rezultati analize signala vibracija za svaku širinu frekvencijskog pojasa uz Gaussovu AF i $koef = 1$	44

Slika 24. Najbolji rezultati analize signala vibracija za svaku širinu frekvencijskog pojasa uz Gaussovu AF i $koef = 2$	45
Slika 25. Najbolji rezultati analize signala vibracija za svaku širinu frekvencijskog pojasa uz trokutnu AF i $koef = 2$	46
Slika 26. Najbolji rezultati analize signala vibracija za svaku širinu frekvencijskog pojasa uz trokutnu AF i $koef = 3$	47
Slika 27. Odabrani frekvencijski pojasevi za kombinacije značajki signala vibracija koje su ostvarile $UK_{Sr} \geq 60\%$ uz Gaussovu aktivacijsku funkciju	50
Slika 28. Odabrani frekvencijski pojasevi za kombinacije značajki signala vibracija koje su ostvarile $UK_{Sr} \geq 60\%$ uz trokutnu aktivacijsku funkciju	50
Slika 29. Odabrani frekvencijski pojasevi za kombinacije značajki signala vibracija koje su ostvarile $UK_{Sr} \geq 65\%$ uz Gaussovu aktivacijsku funkciju	51
Slika 30. Odabrani frekvencijski pojasevi za kombinacije značajki signala vibracija koje su ostvarile $UK_{Sr} \geq 65\%$ uz trokutnu aktivacijsku funkciju	52

POPIS TABLICA

Tablica 1.	Područja parametara trošenja s obzirom na stupanj istrošenosti	12
Tablica 2.	Oznake i opisi izdvojenih energija signala akustične emisije	16
Tablica 3.	Oznake i opisi izdvojenih energija signala vibracija	17
Tablica 4.	Oznake i opisi izdvojenih energija signala struja	18
Tablica 5.	Prikaz izlaznih neurona.....	26
Tablica 6.	Prikaz kombinacije značajki na ulazu u mrežu u prvom koraku analize temeljene na prikupljenim signalima akustične emisije	28
Tablica 7.	Prikaz kombinacija značajki na ulazu u mrežu u drugom koraku analize temeljene na prikupljenim signalima akustične emisije	31
Tablica 8.	Odabir koeficijenata uz AF za drugi korak analize signala akustične emisije	32
Tablica 9.	Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz odabrane frekvencijske pojaseve (signala akustične emisije) širine 5 kHz	35
Tablica 10.	Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz odabrane frekvencijske pojaseve (signala akustične emisije) širine 10 kHz.....	36
Tablica 11.	Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz odabrane frekvencijske pojaseve (signala akustične emisije) širine 15 kHz.....	37
Tablica 12.	Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz odabrane frekvencijske pojaseve (signala akustične emisije) širine 20 kHz.....	37
Tablica 13.	Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz odabrane frekvencijske pojaseve (signala akustične emisije) širine 30 kHz.....	38
Tablica 14.	Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz frekvencijske pojaseve (signala akustične emisije) širine 40 kHz.....	39
Tablica 15.	Prikaz kombinacija značajki na ulazu u mrežu u prvom koraku analize temeljene na prikupljenim signalima vibracija	42
Tablica 16.	Prikaz kombinacija značajki na ulazu u mrežu u drugom koraku analize temeljene na prikupljenim signalima vibracija	48
Tablica 17.	Rezultati klasifikacije (izraženi u %) dobiveni s kombinacijama značajki trošenja vezanim uz nepreklapajuće frekvencijske pojaseve (signala vibracija) koje su zadovoljile $UK_{Sr} \geq 60 \%$	53

Tablica 18. Rezultati klasifikacije (izraženi u %) dobiveni s kombinacijama značajki trošenja vezanim uz nepreklapajuće frekvencijske pojaseve (signala vibracija) koje su zadovoljile $UK_{sr} \geq 65\%$	54
Tablica 19. Rezultati analize po stupnjevima istrošenosti za ulaznu kombinaciju značajki XYZ uz trokutnu AF i $koef = 3$	55
Tablica 20. Rezultati analize po stupnjevima istrošenosti za ulaznu kombinaciju značajki XYZ-XYZ _{sum} uz Gaussovu AF i $koef = 2$	55
Tablica 21. Usporedba stvarnih i klasificiranih stupnjeva istrošenosti za kombinaciju značajki XYZ-XYZ _{sum}	56
Tablica 22. Usporedba stvarnih i klasificiranih stupnjeva istrošenosti za kombinaciju značajki XYZ	57
Tablica 23. Prikaz ukupnog broja uzoraka iz S_2 koji su se na pojedinom testiranju razvrstali u S_1 , S_2 i S_3	58
Tablica 24. Prikaz kombinacija značajki na ulazu u mrežu u analizi temeljenoj na prikupljenim signalima jakosti struja	60
Tablica 25. Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja izdvojenim iz signala jakosti struja	60
Tablica 26. Prikaz oznaka najpovoljnijih izdvojenih kombinacija značajki signala akustične emisije i vibracija	62
Tablica 27. Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja izdvojenim iz različitih tipova prikupljenih signala.....	63

POPIS OZNAKA

Oznaka	Jedinica	Opis
$AE(f)$	V^2Hz^{-1}	snaga frekvencijskog spektra signala akustične emisije
C	-	matrica težina izlaznog sloja
C_{jw}	-	težinski faktori izlaznog sloja
ϕ	mm	promjer svrdla
p_1, p_2	-	Euklidijeva udaljenosti j -tog neurona od njemu dva najbliža neurona u skrivenom sloju
d_{ij}	-	Euklidijeva udaljenost između i -tog neurona ulaznog i j -tog neurona skrivenog sloja
$E(AE)$	V^2	Energija spektra signala akustične emisije u intervalu frekvencija $[f_d, f_g]$
$E(VIB_x)$	V^2	Energija spektra signala vibracija u smjeru osi x u intervalu frekvencija $[f_d, f_g]$
$E(VIB_{xyz})$	V^2	Suma energija spektra signala vibracija u smjeru osi x, y, z u intervalu frekvencija $[f_d, f_g]$
$E(VIB_y)$	V^2	Energija spektra signala vibracija u smjeru osi y u intervalu frekvencija $[f_d, f_g]$
$E(VIB_z)$	V^2	Energija spektra signala vibracija u smjeru osi z u intervalu frekvencija $[f_d, f_g]$
f	mm/okr	posmak svrdla
f_c	Hz	granična frekvencija Butterworthovog filtra
f_d	Hz	donja granica frekvencijskog spektra
f_g	Hz	gornja granica frekvencijskog spektra
H^{-1}	-	inverzija matrice H
H	-	matrica aktivacijskih (radijalnih baznih) funkcija
h_{ij}	-	vrijednosti radijalnih baznih funkcija
I	-	matrica ulaznih podataka mreže sastavljena od posmaka, brzine i izdvojenih značajki signala jakosti struje
I_{GV}	A	jakost struje glavnog vretena
I_x	A	jakost struje posmičnog motora u smjeru osi x
I_y	A	jakost struje posmičnog motora u smjeru osi y
I_z	A	jakost struje posmičnog motora u smjeru osi z
K	-	broj neurona skrivenog sloja

$koef$	-	koeficijent širine aktivacijske funkcije
L	-	broj ulaznih neurona
M	-	broj izlaznih neurona
N	-	broj uzoraka za učenje
n	-	broj pojaseva u kojima je neka kombinacija značajki ostvarila vrijednost UK_{sr} veću ili jednaku od 50 %, 60 % ili 65 %
O_w	-	odziv w -tog izlaznog neurona
σ	-	širina aktivacijske funkcije
s	Hz	širina frekvencijskog pojasa
S_1	-	prvi stupanj istrošenosti svrdla
S_2	-	drugi stupanj istrošenosti svrdla
S_3	-	treći stupanj istrošenosti svrdla
t_j	-	vektor centara neurona skrivenog sloja
UK_1 - UK_5	%	uspješnost klasifikacije na testovima T_1 - T_5
UK_{sr}	%	aritmetička sredina uspješnosti klasifikacije testova T_1 - T_5
VB_{max}	mm	maksimalna vrijednost širine trošenja stražnje površine alata
VB_s	mm ²	površina trošenja stražnje površine alata
VB_{sr}	mm	srednja vrijednost širine trošenja stražnje površine alata
v_c	m/min	brzina rezanja
$VIB_x(f)$	V ² Hz ⁻¹	snaga frekvencijskog spektra signala vibracija u smjeru osi x
$VIB_y(f)$	V ² Hz ⁻¹	snaga frekvencijskog spektra signala vibracija u smjeru osi y
$VIB_z(f)$	V ² Hz ⁻¹	snaga frekvencijskog spektra signala vibracija u smjeru osi z
X	-	matrica ulaznih podataka mreže sastavljena od posmaka, brzine i $E(VIB_x)$
x_i	-	vektor ulaznih vrijednosti mreže
XY	-	matrica ulaznih podataka mreže sastavljena od posmaka, brzine, $E(VIB_x)$ i $E(VIB_y)$
XYZ	-	matrica ulaznih podataka mreže sastavljena od posmaka, brzine, $E(VIB_x)$, $E(VIB_y)$ i $E(VIB_z)$
XYZ_{sum}	-	matrica ulaznih podataka mreže sastavljena od posmaka, brzine i $E(VIB_{xyz})$

- $XYZ-XYZ_{sum}$ - matrica ulaznih podataka mreže sastavljena od posmaka, brzine, $E(VIB_x)$, $E(VIB_y)$, $E(VIB_z)$ i $E(VIB_{xyz})$
- XZ - matrica ulaznih podataka mreže sastavljena od posmaka, brzine, $E(VIB_x)$ i $E(VIB_z)$
- Y - matrica ulaznih podataka mreže sastavljena od posmaka, brzine i $E(VIB_y)$
- YZ - matrica ulaznih podataka mreže sastavljena od posmaka, brzine, $E(VIB_y)$ i $E(VIB_z)$
- Z - matrica ulaznih podataka mreže sastavljena od posmaka, brzine i $E(VIB_z)$

POPIS KRATICA

Kratika	Opis
AF	Aktivacijska funkcija
INGPOS	Inteligentni nadzor glavnog pogona obradnih sustava
NU	Numerički upravljano računalo
RBF	Radial Basis Function

SAŽETAK

Primjena istrošenih medicinskih svrdla ima brojne negativne posljedice na sigurnost obrade i naknadno cijeljenje kostiju. Zbog nemogućnosti preciznog određivanja stupnja istrošenosti oštrice medicinskog svrdla direktnim postupcima nadzora u realnom vremenu, cilj ovog rada bio je procijeniti njegovu istrošenost korištenjem indirektna metode nadzora zasnovane na značajkama trošenja izdvojenim iz signala akustične emisije, vibracija i jakosti struja prikupljenih u procesu bušenja i klasifikacijskog algoritma realiziranog u formi umjetne neuronske mreže.

Analiza procjene istrošenosti svrdla provedena je na temelju eksperimentalnih bušenja goveđih kostiju korištenjem standardnog medicinskog svrdla promjera 4,5 mm s primjenom u koštano-zglobnoj kirurgiji. Pritom su razmatrana tri stupnja istrošenosti, te je za svaki od njih provedeno 10 ponovljenih mjerenja s 12 različitih kombinacija parametara obrade.

Prikupljeni podaci su analizirani primjenom algoritma neuronske mreže s radijalnim baznim funkcijama, pri čemu su korištene Gaussova i trokutna aktivacijska funkcija neurona skrivenog sloja, te je razmatran utjecaj njihovih širina na uspješnost klasifikacije stupnja istrošenosti.

Analiza prikupljenih signala provedena je u nekoliko koraka, pri čemu su ulazne neurone uz posmak i brzinu rezanja predstavljale razmatrane značajke prikupljenih signala. Prvo je razmatrana uspješnost klasifikacije primjenom značajki izdvojenih iz signala akustične emisije, vibracija i jakosti struja zasebno. Zatim su, uz pretpostavku poboljšanja dobivenih rezultata, međusobno kombinirane sve najpovoljnije značajke razmatranih tipova signala.

Učenje i testiranje mreže primjenom signala vibracija izvedeni su sa ulaznim neuronima, tj. značajkama trošenja sastavljenim od posmaka, brzine rezanja i energija spektra signala u smjeru jedne, dvije i/ili tri međusobno ortogonalnih osi izračunatih za niz razmatranih frekvencijskih pojaseva unutar frekvencijskog spektra 5-5000 Hz. Analiza je prvo provedena odvojeno za 9 različitih kombinacija značajki, a zatim su odabrane samo one kombinacije značajki s pripadajućim pojasevima koje su ostvarile uspješnost klasifikacije 60 % ili 65 %. Takvom kombinacijom najpovoljnijih kombinacija značajki i frekvencijskih pojaseva ostvarena je uspješnost

klasifikacije tupog svrdla u usporedbi s oštrim u 95 % slučajeva. Iz dobivenih rezultata proizlazi da se najpreciznija procjena stupnja istrošenosti postigla primjenom značajki trošenja koje su objedinjavale parametre obrade i energije spektra signala vibracija snimljenih u pravcu svih triju ortogonalnih osi, tj. u smjeru osi vrtnje alata i njoj pripadajućih dviju radijalnih osi.

Analizom temeljenom na izdvojenim značajkama signala jakosti struje ostvarena je uspješnost klasifikacije od 82,22 %.

Individualna analiza svih izdvojenih značajki trošenja pokazala je da najveći potencijal u klasifikaciji istrošenosti medicinskog svrdla imaju signali akustične emisije. U procesu učenja i testiranja mreže njihovom primjenom ulazne su značajke najprije predstavljale posmak, brzinu rezanja i energiju spektra signala izračunatu za niz razmatranih frekvencijske pojaseve unutar frekvencijskog spektra 50-400 Hz. Zatim su odabrani samo oni frekvencijski pojasevi u kojima su zadovoljene donje granice uspješnosti klasifikacije od 50 % i 60 %, te su energije tih pojaseva zajedno s vrijednostima posmaka i brzine rezanja predstavljale nove kombinacije ulaznih značajki u mrežu. Takvim je pristupom ostvarena uspješnost klasifikacije od 96,67 %, pri čemu su svi stupnjevi istrošenosti podjednako uspješno klasificirani.

Konačno, istovremenom kombinacijom izdvojenih značajki svih prikupljenih tipova signala ostvarena je uspješnost klasifikacije od 100 %, neovisno o korištenoj aktivacijskoj funkciji i koeficijentu njezine širine. S obzirom na to, može se zaključiti da je provedena analiza ukazala na potencijal primjene signala vibracija, akustične emisije i jakosti struja motora u indirektnom nadzoru istrošenosti medicinskih svrdla.

Ključne riječi: istrošenost medicinskog svrdla, termička osteonekroza, vibracije, akustična emisija, jakost struja motora, RBF neuronska mreža

SUMMARY

Usage of worn medical drills in medical interventions has many negative consequences on machining safety and postoperative bone healing. Since precise and real time direct measurement of wear level of medical drill cutting edge is not possible, the main goal of this work was to estimate its wear using indirect tool condition monitoring method based on wear features extracted from acoustic emission, vibration and servomotor drive current signals measured during drilling process and classification algorithm formed as artificial neural network.

Analysis of drill wear estimation was based on experimental bovine bone drilling performed using 4.5 mm standard medical drill with application in bone and joint surgery. Three tool wear levels were analysed and for each of them 10 repeated measurements with 12 different machining parameter combinations were performed.

Collected data were analysed using Radial Basis Function Neural Network algorithm with Gaussian and triangular activation functions of the hidden layer neurons, whose width impact on wear level classification performance was taken into consideration.

This analysis was divided into several steps. At first, combinations of features belonging to every type of signal were tested separately. At the end, in order to improve obtained results, the most favourable combinations of features selected from different types of signals were tested together.

Learning and testing of neural network using vibration signals were performed with input neurons, such as feed rates, cutting speeds and spectrum energies related to one, two and/or three mutually perpendicular axes, which were calculated for the set of analysed frequency ranges within 5-5000 Hz frequency spectrum. In the first step analysis was separately performed for 9 different feature combinations, while in the second step only those feature combinations which accomplished classification precision of 60 % or 65 %, with belonging ranges, were selected. Classification precision of worn drill from sharp one with the most favourable feature combinations and frequency ranges was achieved in 95 % of cases. Based on obtained results, it can be found that the most precise wear level estimation was achieved using wear features that encompassed machining parameters and energy spectrum of vibration

signals measured in the direction of all three perpendicular axes, that is in the direction of tool rotation axis and its belonging two radial axes.

Analysis based on machining parameters and extracted current combination features resulted in classification precision of 82,22 %.

Performed analysis revealed that the greatest potential in wear level estimation of medical drill have acoustic emission features. At first, analysis was separately performed for acoustic emission features calculated for the set of analysed frequency ranges within 50-400 kHz frequency spectrum. After that, drill wear classification was performed with all features that accomplished classification precision of 60 % or 65 % together with feed rates and cutting speeds. This feature combination achieved classification precision of 96,67 %, wherein all tool wear levels were successfully classified.

Finally, combination of features extracted from all types of signals achieved the best result. Classification precision of 100 % was accomplished with all observed combinations of activation functions and their widths. According to that, it can be concluded that the performed analysis revealed potential usage of vibration, acoustic emission and current signals in indirect monitoring of level estimation of medical drill.

Key words: tool wear estimation, thermal osteonecrosis, vibrations, acoustic emission, servomotor referent current, RBF Neural Network

1. UVOD

S razvojem suvremene kirurgije, bušenje kostiju postalo je sastavan dio velikog broja traumatoloških, ortopedskih i stomatoloških zahvata. Bušenje kostiju nužno je kod fiksiranja implantanata i spajanja kostiju (osteosinteza) na mjestu prijeloma [1]. Priroda takvih zahvata je invazivna jer bušenjem dolazi do oštećenja kostiju. Rezna oštrica kirurškog svrdla uzrokuje naprezanja u kortikalnom dijelu kosti uslijed kojih dolazi do pucanja intermolekularnih veza što rezultira porastom temperature obrađivanog materijala. Uslijed kontakta između stražnje oštrice svrdla i kortikalnog dijela kosti nastaje trenje. Trenje se također javlja i između odvojenih čestica kosti i prednje površine alata, odnosno između tijela svrdla i unutarnje stijenke provrta. Nastalo trenje je dodatan i to značajan izvor generirane topline [1]. Nizak koeficijent toplinske vodljivosti ($\lambda = 0,3 - 0,6 \text{ W/mK}$) može doprinijeti značajnijem porastu temperature kosti [3], a radi niskog protoka i brze koagulacije krvi, toplina se ne uspijeva u dovoljnoj mjeri odvesti krvlju [4].

Iako mehanizmi toplinskog oštećenja kostiju još uvijek nisu u potpunosti razjašnjeni, poznato je da spomenuti prirast generirane količine topline uzrokuje značajni porast temperature kosti i ima negativne posljedice na stabilnost osteosinteze, odnosno cijeljenja kosti [5]. Povišena temperatura oštećuje strukturu čija je uloga obnavljanje kosti, te može doći do odumiranja koštanog tkiva (termička osteonekroza). Istovremeno, kost gubi čvrstoću neposredno uz mjesto bušenja, te se nadomješta vezivnim tkivom, koje ima manju čvrstoću od kortikalisa pa može doći do povećanja gibljivosti vijaka [2].

Važnost utjecaja temperature na kost za vrijeme bušenja uočio je Hipokrat još 500 godina prije nove ere i predložio sporo bušenje sa stalnim vađenjem svrdla uz hlađenje hladnom vodom [1]. Danas je eksperimentalno dokazano da je kritična temperatura koja uzrokuje termičku osteonekrozu 47 °C tijekom 1 minute [6]. Dakle, ako tijekom bušenja dolazi do porasta temperature iznad kritične vrijednosti, nastupit će ireverzibilna oštećenja kosti, odnosno izostat će njeno kvalitetno cijeljenje i regeneracija, te će biti otežan postoperativni oporavak [1].

Veći broj parametara je u funkcijskoj ovisnosti s promjenom temperature bušenja, te može utjecati na potencijalnu pojavu termičke osteonekroze. Neki od njih su

mehanička svojstva kosti (gustoća, tvrdoća, debljina kortikalisa) [6][7], karakteristike svrdla (geometrija, dimenzije, materijal), tehnološki parametri procesa (brzina rezanja, posmak) i istrošenost svrdla [1].

Niz istraživanja na području nadzora procesa bušenja u industrijskoj primjeni ukazuje na istrošenost svrdla kao najznačajniji parametar procesa [8]. Istovremeno, mnogi radovi na području oralne i maksilofacijalne kirurgije pokazuju izraženu proporcionalnost između dinamike trošenja alata i porasta temperature bušenja kosti [9]. Prilikom svake obrade odvajanjem čestica istrošenost alata utječe na porast trenja između svrdla i obrađivanog materijala. Uz to, s porastom istrošenosti svrdla povećavaju se sile rezanja i vibracije alata, što može rezultirati lomom alata. Lom vrha ili oštrice alata, odnosno potpun lom tijela svrdla uzrokovao bi dodatne negativne posljedice u obliku mehaničkog oštećenja kosti [5]. Za pretpostaviti je također da bi dodatan čimbenik intenzivnijeg trošenja alata mogao biti povezan s toplinskim i/ili kemijskim utjecajem postupka sterilizacije na svrdlo.

Bušenje spiralnim svrdlom je postupak kontinuirane obrade, koji karakterizira istovremen zahvat svih oštrice alata. Glavne oštrice se zbog svoje nesimetričnosti neujednačeno troše. Naime, trošenje počinje na izbočenijoj oštrici i traje sve do izjednačavanja njihove istrošenosti. Zatim oštrija oštrica počinje rezati, a intenzitet trošenja se izmjenjuje do potpunog iščeznuća širina faze [13].

Budući da je trošenje alata neizbježan i ireverzibilan proces, precizna procjena stupnja istrošenosti svrdla spriječila bi porast temperature kosti na stjenci provrta iznad dozvoljene granice, odnosno nastanak toplinskih i mehaničkih oštećenja [5]. Prema [15], mehanizmi trošenja alata ovise o međusobnom odnosu parametara vezanih uz obrađivani materijal, alat i uvjete obrade. Interakcije tih parametara su vrlo složene, a nadzor nad procesom trošenja vrlo zahtjevan pa do danas nije predložen opće prihvaćen model trošenja.

Nameće se pitanje je li moguće neka od predloženih i postojećih industrijskih rješenja primijeniti u medicinskoj praksi. Unatoč nedostatku takvih analiza, može se pretpostaviti da bi se metodologija korištena u industrijskim sustavima za nadzor istrošenosti alata mogla primijeniti u identifikaciji istrošenosti medicinskog svrdla. Kao što je industrijska primjena pokazala, potpuno precizno određivanje stupnja istrošenosti nije moguće zbog izrazite nelinearnost i djelomične stohastičnosti

dinamike procesa trošenja reznog alata. Naime, precizno određivanje stanja oštrice bilo bi moguće provesti direktnim postupkom nadzora (*off-line* metode), koji zbog konstantnog dodira oštrice alata i kosti nije moguće realizirati tijekom procesa bušenja. Takvo neposredno mjerenje bilo bi moguće samo uz stalne prekide obradnog procesa, a to bi rezultiralo kašnjenjima u procjeni stupnja istrošenosti i dužim ukupnim vremenom obrade. Iz tih je razloga nužno primijeniti neku od metoda indirektnog nadzora (*on-line* metode) istrošenosti alata, koje podrazumijevaju procjenu stanja oštrice na temelju poznatih parametara stroja i značajki istrošenosti izdvojenih iz različitih tipova signala procesa [1][4]. Donošenje zaključaka o istrošenosti na temelju posrednih kriterija istrošenosti ima neke nedostatke, od kojih je najznačajnije rasipanje promatranih veličina. U laboratorijskim uvjetima ono je prisutno u rasponu od 10-20 %, a u eksploataciji i znatno više [15]. S druge strane, mogućnost nadzora oštrice u realnom vremenu uz kontinuirani tijek obradnog procesa čini ovakve metode pogodnima za primjenu. Uz to, korištene su u većini nedavnih istraživanja iz područja nadzora stanja alata pri bušenju u strojarstvu [8].

S obzirom na navedeno, u ovom je radu proveden indirektan pristup procjene stanja oštrice alata, temeljen na prikupljenim signalima akustične emisije, vibracija i jakosti struja motora glavnog i posmičnog prigona (pogonski signali), a koji se smatraju jednim od najznačajnijih mjernih signala u postupku indirektnog nadzora trošenja reznog alata [16].

Akustična emisija je prijelazni oblik energije koji primarno nastaje uslijed plastične deformacije ili loma materijala, kao posljedica razdvajanja molekula [18]. Njeno frekvencijsko područje spada u područje ultrazvuka, pri čemu se najčešće spominje u frekvencijskom rasponu od 100 kHz do 2 MHz. Jedna od glavnih prednosti signala akustične emisije je činjenica da su im frekvencije znatno više od frekvencija vibracija stroja i signala iz okoline, zbog čega se mogu direktno izbjeći neželjeni utjecaji pojava signala nižeg frekvencijskog spektra.

Općenito, ultrazvučni signali su primjenjivani u više istraživanja, a u [19] je pokazano da je njihova primjena tijekom bušenja efikasnija od primjene izmjerenih momenata, aksijalnih i bočnih sila. Izvori akustične emisije prisutne u procesu obrade odvajanjem mogu se podijeliti na kontinuirane i skokovite [20]. Kontinuirani obuhvaćaju plastične deformacije u obratku i odvojenoj čestici, kao i kontakte trenjem između prednje površine alata i odvojene čestice, odnosno između stražnje površine alata i obratka.

Skokoviti su izvori kolizija odvojene čestice s alatom, krhanje ili lom alata i stvaranje pukotina u odvojenoj čestici. S obzirom na podložnost distorziji i prigušivanju uslijed prolaska kroz različite stezne spojeve, mjerne senzore akustične emisije potrebno je postaviti u neposrednoj blizini alata ili obratka [1].

Signali vibracija spadaju u grupu najčešće analiziranih signala u postupku indirektnog nadzora trošenja alata. Vibracije se javljaju uslijed rotacije dijelova stroja i alata (utjecaj masa, njihove centriranosti, frekvencija vrtnje, krutosti, odnosa dužine i promjera alata,...) te utjecaja sila rezanja na alat. Iako signali vibracija ponekad znaju biti opterećeni šumom, primjena suvremenih piezoelektričnih vrsta senzora, koji svojom ugradnjom ne zahtijevaju gotovo nikakve modifikacije na alatnom stroju, a mogu se ugraditi blizu izvora vibracija, kao i razni alati za obradu signala čine ovaj tip signala vrlo interesantnim u nadzoru obradnih sustava i procesa [1]. Prema [14], signali vibracija snimljeni u smjeru aksijalne i radijalnih osi s obzirom na os alata sadrže značajke koje visoko koreliraju sa stanjem rezne oštrice alata. Pouzdanima ih čini i to što se vibrirajući dio svrdla tijekom bušenja ne mijenja pa modovi frekvencija ostaju praktički konstantni. U svojim istraživanjima Jantunen et al. [21] su zaključili da je najefikasnija metoda nadzora trošenja alata upravo mjerenje vibracija.

Signal jakosti struja također je korišten u brojnim istraživanjima [21]. Sadrži slične informacije o dinamici promatranog procesa obrade kao i ukupni moment, no prednost mu je jednostavniji postupak mjerenja, koje se provodi upravljačkim sustavom pripadajućeg regulatora motora [1]. Uz to, poznato je da signali jakosti struja visoko koreliraju sa signalima sila rezanja, a istovremeno pokazuju i proporcionalnost sa stupnjem istrošenosti alata. S obzirom na to, jakosti struja servo motora koristi se kao potencijalna zamjena sila rezanja, za čija je mjerenja često potrebna vrlo skupa oprema.

S obzirom na navedeno, utemeljeno je pretpostaviti korisnost primjene izloženih signala u procjeni istrošenosti medicinskog svrdla, te shodno tome provesti detaljnu eksperimentalnu analizu u cilju određivanja parametara njihove primjene u realnim eksploatacijskim uvjetima.

2. CILJEVI RADA

Uzevši u obzir iznesene moguće probleme uzrokovane prevelikom istrošenošću medicinskog svrdla, te ograničenja vezana uz nadzor istrošenosti svrdla kod kontinuiranog tijeka obrade, postavlja se sljedeća hipoteza ovog rada: na temelju značajki trošenja izdvojenih iz signala akustične emisije, vibracija i jakosti struja prikupljenih korištenjem različitih vrijednosti parametara obrade i uzoraka kostiju različitih mehaničkih karakteristika, te njihovom naknadnom analizom primjenom umjetnih neuronskih mreža, moguće je kvalitetno procijeniti trošenje medicinskog svrdla, odnosno klasificirati njegov stupanj istrošenosti.


Na temelju iznesene hipoteze rada, proizlazi da glavni cilj ovog istraživanja predstavlja analizu prikupljenih tipova signala u klasifikaciji stupnja istrošenosti medicinskog svrdla s ciljem sprječavanja toplinskih i mehaničkih oštećenja kosti. U tu je svrhu potrebno:

- iz signala akustične emisije, vibracija i jakosti struja snimljenih pri različitim režimima obrade izdvojiti adekvatne značajke trošenja,
- za svaki tip signala odabrati grupu značajki trošenja (filtrirati značajke) koje pokazuju najveći stupanj korelacija sa stupnjem istrošenosti svrdla,
- analizirati primjenu izdvojenih značajki svakog tipa signala zasebno, kao i njihove međusobne kombinacije,
- utvrditi stupanj istrošenosti koji ima najveću uspješnost klasifikacije, i
- analizirati primjenu nekoliko različitih parametara klasifikatora, tj. RBF neuronske mreže u cilju odabira najpogodnije strukture.

3. PLAN RADA


3.1. Eksperimentalni postav

Kao ispitni postav (slika 1.) korišten je sustav otvorene upravljačke strukture razvijen suradnjom Katedre za alatne strojeve i Katedre za strojarsku automatiku pri FSB-u u sklopu tehnologijskog projekta „INGPOS inteligentni nadzor glavnog pogona obradnih sustava“ [1]. Sustav je prikladan za analizu različitih upravljačkih algoritama i tehnika nadzora obradnih procesa i sustava.



Slika 1. Eksperimentalni ispitni postav

Osnova ispitnog stroja je mala troosna glodalica (slika 2.), čiji je glavni prigon izveden izravnim prijenosom momenta glavnog motora na svrdlo putem stezne glave. Posmični prigon ostvaren je kliznim vodilicama i kugličnim navojnim vretenom. Kako bi se tijekom izvođenja pokusa osigurali stalni temperaturni uvjeti, radni prostor stroja je oklopljen limenim kućištem s dvostrukim stjenkama, između kojih se nalazi stiropor. Temperatura radnog prostora održavana je infracrvenom grijalicom.



Slika 2. Eksperimentalni postav (1 – ispitni uzorak, 2 – medicinsko svrdlo, 3 – senzor akustične emisije, 4 – senzor vibracija, 5 – industrijska kamera)

Postojeći ispitni sustav prilagođen je potrebama eksperimenta u smislu ugradnje niza eksternih mjernih uređaja za nadzor trošenja alata direktnim i indirektnim putem. Indirektni nadzor istrošenosti izveden je ugradnjom senzora akustične emisije i trokomponentnog senzora vibracija, dok je direktno određivanje parametara trošenja izvedeno industrijskom kamerom (tip DMK41AF02, proizvođača Imaging Source Europe GmbH) s telecentričnim objektivom (tip TC2309, proizvođača Opto Engineering S.r.l.) i prstenastom LED rasvjetom.

Upravljački dio postava činilo je numerički upravljano (NU) računalo temeljeno na PC konfiguraciji, uz koju je ugrađen niz upravljačkih i akvizicijskih kartica.

Uz NU, korišteno je i vanjsko računalo s prijenosnom mjernom stanicom. Struktura mjernog sustava sa svim ugrađenim mjernim sustavima prikazana je na slici 3.

Signali akustične su snimani kratkotrajno, tj. 0,1 s po ulasku svrdla u zahvat. Snimanje je izvedeno u sklopu upravljačkog sustava s akvizicijskom karticom za snimanje signala visokih frekvencija PCI-DAS4020/12. Frekvencija uzorkovanja iznosila je 2 MHz, čime je prikupljeno 200000 podataka o signalima akustične emisije.

Senzor za mjerenje vibracija (slika 5.) izveden je kao trokomponentni piezoelektrični akcelometar (tip 8688A50) s odgovarajućim pojačalom (5134B) proizvođača Kistler Holding AG. Radno područje senzora deklarirano od strane proizvođača iznosi 0,5 do 5000 Hz.

Senzor vibracija potrebno je ugraditi blizu zone rezanja kako bi se prigušilo djelovanje poremećaja na signal. Stoga je u ovom eksperimentu on pričvršćen na nosač glavnog motora u blizini, tj. između stezne glave svrdla i prednjeg ležaja vretena (slika 2.) preko kojeg se u sustav prenose vibracije nastale kod rezanja.



Slika 5. Senzor za mjerenje vibracija s pripadajućim pojačalom

Signali vibracija snimani su akvizicijskom karticom PCI-DAS4020/12 na 3 kanala, tj. u smjeru osi x, y, i z. Svaki je signal sniman 2 sekunde po ulasku svrdla u zahvat, frekvencijom uzorkovanja 100 kHz. Prema tome, za svaki je signal (po kanalu) prikupljeno 200000 podataka.

Signali jakosti struja svih pogonskih motora prikupljani su iz odabranih servo-regulatora u sklopu CNC upravljačkog sustava stroja. Uz modul s analogno-digitalnim pretvornicima u sklopu prijenosne mjerne stanice, za prijenos signala je korištena i CAN sabirnica s odgovarajućim CAN/USB pretvornikom. Početak snimanja određen je izvršavanjem naredbe programa NU računala, pri čemu su frekvencije uzorkovanja ovisile o vrsti signala i načinu akvizicije. Signali frekvencije

uzorkovanja 2 kHz prikupljani su kroz upravljački sustav, dok su oni prikupljani putem CAN sabirnice imali frekvenciju uzorkovanja jednaku 1 kHz.

U prikupljenim analognim signalima prisutno je izobličenje uslijed A/D i D/A pretvorbe, kao i šum uslijed prijenosa signala analognim vodovima. S obzirom na to da je eksperimentalno utvrđeno zanemarivo kašnjenje signala prikupljenih putem CAN sabirnice u usporedbi s odgovarajućim analognim signalima, te da su frekvencije uzorkovanja signala u sklopu mjernog računala dovoljne za izdvajanje i odabir odgovarajućih značajki trošenja, iste su uzete u daljnje razmatranje.

Modul za akviziciju i izdavanje signala jakosti struja motora ugrađen je u osnovni dio vanjskog mjernog sustava, mjernu stanicu (tip NI cDAQ-9178, proizvođač National Instruments Co) spojenu na mjerno računalo USB vezom. Time je ostvarena akvizicija na 4 kanala, tj. prikupljeni su signali struja posmičnih prigona u smjeru osi x, y, i z i jakosti struja motora glavnog vretena.

3.2. Ispitni uzorci

Ispitne uzorke na kojima su provedeni pokusi i prikupljanje podataka predstavljale su goveđe goljenične kosti prosječne debljine kortikalisa od 8,5 mm (slika 6.). Razlog tomu je sličnost mehaničkih i toplinskih karakteristika goveđih i ljudskih kostiju [27]. U odnosu na svinjske kosti, goveđe imaju veće debljine kortikalisa, što omogućuje dulje snimanje obradnog procesa. Uz to, goveđe kosti imaju i veće duljine, što je pogodno za izvođenje većeg broja bušenja na istom uzorku. Budući da podrijetlo i starost kosti nisu bili uvjet njihovog odabira, različite kosti imale su i različita mehanička svojstva. Ovaj je detalj predstavljao vrlo utjecajan parametar eksperimenta, jer se kod operativnih zahvata također očekuju varijacije mehaničkih svojstava kostiju, s naglaskom na tvrdoću koja je u direktnoj proporcionalnoj vezi s trošenjem alata. Kako im se mehanička i termodinamička svojstva tijekom skladištenja ne bi promijenila, kosti su zamrznute na temperaturu ispod $-10\text{ }^{\circ}\text{C}$ [28][27].



Slika 6. Ispitni uzorak nakon bušenja

Prije bušenja, električnom pilom su uklonjene epifize (proširenja na krajevima koštane cijevi, dijafize). Dijafiza je, prije bušenja, progrijana na normalnu ljudsku temperaturu od približno 37 °C. Na svakom ispitnom uzorku je bušeno više provrta, čiji su razmaci birani tako da najtanja debljina stjenke iznosi 0,5 mm. Ovisno o obliku i veličini kosti, na svakoj je kosti izbušen različit broj provrta.

3.3. Tijek eksperimenta

Sva bušenja su izvedena korištenjem standardnog medicinskog spiralnog svrdla, promjera $\phi = 4,5$ mm, koje se najčešće koristi u ortopedskim i traumatološkim zahvatima. Provrti su bušeni izravno, bez prethodnog bušenja ili zabušivanja (slika 7.).



Slika 7. Standardno medicinsko spiralno svrdlo

Analizirana su tri stupnja istrošenosti. Prvi stupanj istrošenosti (S_1) se odnosi na potpuno oštro svrdlo, drugi (S_2) na srednje istupljeno svrdlo, a treći (S_3) na najviše istrošeno svrdlo. Nakon izvođenja eksperimenta oštricom prvog stupnja istrošenosti, svrdlo je dodatnim bušenjima istrošeno do drugog stupnja, te je nastavljen eksperiment. Također, nakon bušenja svrdlom drugog stupnja istrošenosti, ono je ponovo podvrgnuto dodatnom trošenju kako bi se došlo do trećeg stupnja istrošenosti svrdla. Granice područja trošenja svakog stupnja određene su na temelju površine trošenja stražnje površine, odnosno srednje i maksimalne širine trošenja


stražnje površine alata.

Slike oštrice svakog razmatranog svrdla su umjerene prema slici potpuno oštrog svrdla čije su geometrijske veličine izmjerene alatnim mikroskopom u Laboratoriju za precizna mjerenja dužina pri FSB-u. Na temelju tako dobivenih slika, korištenjem CAD sustav CATIA, određeni su parametri trošenja stražnje površine svrdla (VB_{sr} , VB_{max} , VB_s), a s obzirom na koje je stupanj istrošenosti klasificiran je u tri kategorije (tablica 1.).

Tablica 1. Područja parametara trošenja s obzirom na stupanj istrošenosti

Parametri trošenja stražnje površine	Oznaka	Stupanj istrošenosti	Područje		Jedinica
			Početno stanje	Konačno stanje	
Srednja širina trošenja stražnje površine	VB_{sr}	S_1	0	0,0355	mm
		S_2	0,0703	0,0784	
		S_3	0,1314	0,1613	
Maksimalna širina trošenja stražnje površine	VB_{max}	S_1	0	0,0865	mm
		S_2	0,1750	0,1865	
		S_3	0,2745	0,4055	
Površina trošenja stražnje površine	VB_s	S_1	0	0,1053	mm ²
		S_2	0,2077	0,2321	
		S_3	0,3856	0,4734	

Oblici trošenja oštrica (tamno područje uz oštricu alata) prikazani su na slici 8.



Slika 8. Oblici trošenja oštrica prema stupnju istrošenosti

Mjerenja su izvedena uz različite iznose brzina i posmaka, s obzirom na ograničenja praktične primjene i mogućnosti postizanja ispitnim strojem. Nakon niza bušenja izvedenih u okviru pretpokusa, odabrane su njihove konačne vrijednosti.

Općenito, brzina rezanja smatra se najznačajnijim parametrom obrade odvajanjem čestica. Eksperimentalno je pokazano da s porastom brzine rezanja raste i temperatura alata, iz čega proizlazi da postupnom porastu trošenja alata ponajviše doprinosi upravo porast brzine rezanja.

Uz brzinu, najznačajniji parametar procesa trošenja je posmak. Povećanjem njegovog iznosa rastu sile rezanja, te se povećava mehaničko opterećenje alata, koje je jedan od uzroka njegovog trošenja. Istovremeno se smanjuje vrijeme bušenja, odnosno količina generirane topline. Prema [30], variranjem posmaka može se utjecati na postojanost alata. Istraživanja [32] pokazuju da bi brzinu rezanja trebalo smanjiti, a posmak povećati što je više moguće.

Vrijednosti brzina rezanja korištenih u eksperimentu iznosile su 10; 30 i 50 m/min, dok su posmaci iznosili 0,01; 0,03; 0,05 i 0,1 mm/okr. Sa svakom od 12 kombinacija parametara obrade provedeno je 10 ponovljenih bušenja za svaki od tri stupnja

istrošenosti svrdla. Na taj je način provedeno 10 mjerenja s 36 različitih kombinacija brzina rezanja, posmaka i stupnja istrošenosti alata, odnosno ukupno 360 mjerenja. Važno je napomenuti da su kombinacije parametara obrade nasumično mijenjane za uzastopna bušenja provrta na ispitnim uzorcima.

4. PRIPREMA PODATAKA ZA ANALIZU

Uspješnost opisa dinamike obradnog procesa, odnosno procjene istrošenosti medicinskog svrdla, ovisit će o kvaliteti snimljenih signala, odgovarajućem filtriranju i odabiru značajki trošenja iz snimljenih signala.

U okviru ovog rada korištene su tri vrste mjernih sustava (opisane u poglavlju 3.1.), te su značajke trošenja izdvajane iz snimljenih signala akustične emisije, vibracija i jakosti struja svih pogonskih motora. S obzirom na složenost procesa obrade odvajanjem čestica, za očekivati je da se sve informacije potrebne za opis stanja procesa neće moći u svakom trenutku nadzora jasno izdvojiti iz svih snimljenih signala, kao i da će uporabom različitih značajki biti osigurane različite uspješnosti klasifikacije stupnja istrošenosti svrdla. Prema tome, cilj je osigurati veći broj značajki trošenja koje realno opisuju trenutno stanje procesa.

U ovom je poglavlju prikazana priprema podataka za analizu, izvedena zasebno za svaku vrstu snimljenih signala, tj. dan je pregled značajki izdvojenih iz pojedinih vrsta signala, koje bi se potencijalno mogle koristiti u klasifikaciji stupnja istrošenosti medicinskog svrdla.

4.1. Priprema signala akustične emisije

Signali akustične emisije snimani se u frekvencijskom području 50–400 kHz.

Određivanje značajki trošenja započeto je određivanjem snaga frekvencijskog spektra signala akustične emisije ($AE(f)$) primjenom metode brze Fourierove transformacije (eng. *Fast Fourier Transformation*, FFT). FFT analizom je za svaki signal akustične emisije dobivena informacija o raspodjeli snaga komponenti spektra u analiziranom frekvencijskom području (50-400 kHz). Koristeći tako dobivene snage spektra izračunate su energije spektra signala za različite frekvencijske pojaseve unutar radnog područja senzora akustične emisije. Pritom su granice frekvencijskih pojaseva određene podjelom frekvencijskog spektra na pojaseve različitih širina. Odabrane širine pojaseva iznosile su $s = \{5, 10, 15, 20, 30, 40\}$ kHz. Dakle, ako širina iznosi 40 kHz, onda je frekvencijsko područje podijeljeno na pojaseve ($[f_d, f_g]$): [50, 90], [90, 130], [130, 170], [170, 210], [210, 250], [250, 290], [290, 330],

[330, 370], [370, 400] kHz. Za svaki razmatrani frekvencijski pojas ($[f_d, f_g]$) je energija signala akustične emisije određena integriranjem pripadajuće krivulje spektralne gustoće snage

$$E(AE) = \int_{f_d}^{f_g} AE(f) df. \quad (3.1.)$$

Prema tome, značajke akustične emisije (tablica 2.) korištene u daljnjoj analizi predstavljaju energije pripadajućih frekvencijskih pojaseva.

Tablica 2. Oznake i opisi izdvojenih energija signala akustične emisije

Oznaka	Opis
$E(AE)$	Energija spektra signala akustične emisije u intervalu frekvencija $[f_d, f_g]$

4.2. Priprema signala vibracija

Značajke trošenja snimljenih signala vibracija koje su sudjelovale u klasifikaciji stupnja istrošenosti medicinskog svrdla izdvajane su iz frekvencijskog područja 0,5 – 5000 Hz koje odgovara radnom području senzora. Odabir značajki unutar tog područja, odnosno filtriranje poremećaja/šuma provedeno je za vrijeme samog učenja neuronske mreže, pri čemu je mreža odabrala značajke iz onih frekvencijskih pojaseva koji su pokazali najbolju korelaciju sa stupnjem istrošenosti svrdla.

Postupak određivanja iznosa značajki trošenja započeo je određivanjem snaga frekvencijskog spektra signala vibracija u smjeru osi x , y i z ($VIB_x(f)$, $VIB_y(f)$ i $VIB_z(f)$). I u analizi signala vibracija je provedena FFT analiza, pomoću koje je za svaki signal vibracija dobivena informacija o raspodjeli snaga komponenti spektra u analiziranom frekvencijskom području (0,5 - 5000 Hz). Na temelju tako dobivenih spektara snage izračunate su zatim energije spektra signala za različite frekvencijske pojaseve unutar radnog područja senzora, a koje su korištene kao značajke trošenja u klasifikaciji istrošenosti medicinskog svrdla (tablica 3.). Energija svakog odabranog frekvencijskog pojasa ($[f_d, f_g]$) određena je integriranjem pripadajuće krivulje spektralne gustoće snage

$$E(VIB_x) = \int_{f_d}^{f_g} VIB_x(f) df, \quad (3.2.)$$

$$E(VIB_y) = \int_{f_d}^{f_g} VIB_y(f) df, \quad (3.3.)$$

$$E(VIB_z) = \int_{f_d}^{f_g} VIB_z(f) df. \quad (3.4.)$$

U ovom su radu razmatrani frekvencijski pojasevi različitih širina, kojima je pokriveno cijelo radno područje senzora. Odabrane širine pojaseva iznosile su $s = \{5, 10, 20, \dots, 90, 100, 200, \dots, 900, 1000, 1500, 2500, 5000\}$ Hz. Primjerice, ako je širina pojasa iznosila 1000 Hz, onda je frekvencijsko područje podijeljeno na pojaseve ($[f_d, f_g]$): [5, 1005], [1005, 2005], [2005, 3005], [3005, 4005], [4005, 5000] Hz.

Tablica 3. Oznake i opisi izdvojenih energija signala vibracija

Oznaka	Opis
$E(VIB_x)$	Energija spektra signala vibracija u smjeru osi x u intervalu frekvencija $[f_d, f_g]$
$E(VIB_y)$	Energija spektra signala vibracija u smjeru osi y u intervalu frekvencija $[f_d, f_g]$
$E(VIB_z)$	Energija spektra signala vibracija u smjeru osi z u intervalu frekvencija $[f_d, f_g]$
$E(VIB_{xyz})$	Suma energija spektra signala vibracija u smjeru osi x, y, z u intervalu frekvencija $[f_d, f_g]$

Utjecaj tako dobivenih energija signala vibracija na identifikaciju trošenja će biti razmatran zasebno, njihovom međusobnom kombinacijom, kao i u kombinaciji sa značajkama izdvojenim iz ostalih razmatranih tipova signala (poglavlje 6.).

4.3. Priprema signala jakosti struja

Treći tip signala snimljenih tijekom izvedbe eksperimenta [1] predstavljaju signali struja posmičnih prigona u smjeru osi x, y, i z (I_x, I_y, I_z) i glavnog vretena (I_{GV}). Primjenom FFT analize prikupljeni signali su analizirani u frekvencijskoj domeni, te je određen odgovarajući filter za pripremu za izdvajanje značajki u vremenskom području. S obzirom na to da je uočeno da je dominantna komponenta spektra vezana uz frekvenciju 0 Hz i njoj susjedne frekvencije, za filtriranje signala jakosti struja odabran je Butterworthov niskopropusni filter granične frekvencije $f_c = 2$ Hz.

S obzirom na niske vrijednosti horizontalnih komponenti struja posmičnog prigona (obično ispod 0,1 A), utjecaj jakosti struja analiziran je samo koristeći I_z i I_{GV} signale.

Značajke signala jakosti struja (tablica 4.) korištene u [5] izdvojene su iz frekvencijskog i vremenskog područja.

Iz vremenskog područja su nakon filtriranja izvojene dvije vrste značajki. Prva se odnosi na maksimalni iznos signala, izračunat kao srednja vrijednost 10 % najvećih vrijednosti signala, pri čemu je izračun prosjeka ekstremnih vrijednosti signala korišten kako bi se smanjio utjecaj lokalnih maksimuma. Drugi tip značajke predstavljaju srednje vrijednosti signala struja prikupljenih za vrijeme obrade.

Analiza snaga frekvencijskog spektra pokazala je da se dominantne spektralne komponente nalaze na frekvenciji vrtnje i na frekvenciji oštrice. Prema tome, snage spektralnih komponenti na tim frekvencijama također su korištene kao značajke u analizi istrošenosti svrdla.

Tablica 4. Oznake i opisi izdvojenih energija signala struja

Oznaka	Opis
$(I_z)_{max}$	Aritmetička sredina 10 % najvećih apsolutnih vrijednosti signala I_z
$(I_{gv})_{max}$	Aritmetička sredina 10 % najvećih vrijednosti signala I_{gv}
$(I_z)_{sred}$	Srednja vrijednost signala I_z
$(I_{gv})_{sred}$	Srednja vrijednost signala I_{gv}
$I_{gv}(f_v)$	Snaga signala I_{gv} na frekvenciji vrtnje
$I_{gv}(f_o)$	Snaga signala I_{gv} na frekvenciji oštrice

5. NEURONSKA MREŽA S RADIJALNIM BAZNIM FUNKCIJAMA

Prema [34], jedna od komponenti koje automatski sustav za nadzor trošenja reznog alata mora sadržavati je modul za učenje i adaptaciju strukture.

Korištenjem algoritama računalne inteligencije moguće je modelirati parametre različitih kompleksnih sustava i procesa. Pritom su najveću primjenu doživjeli algoritmi umjetnih neuronskih mreža zbog mogućnosti brzog, paralelnog procesiranja informacija što omogućuje razvoj sustava nadzora koji bi funkcionirali u realnom vremenu, te integracije velikog broja ulaznih (utjecajnih) parametara čime se postiže sposobnost adaptacije njihove strukture na različite uvjete obrade i vrste trošenja, kao i prigušivanje šumova u signalima nastalim uslijed stohastičke prirode procesa trošenja [5][35]. Primarno se koriste u klasifikaciji, a dijelom i u estimaciji parametara trošenja [1].


Neuronske mreže s radijalnim baznim funkcijama (eng. *Radial basis function*, RBF) predložene su 1980.-ih, a i danas su jedne od često korištenih vrsta umjetnih neuronskih mreža. Osnovne prednosti uporabe RBF mreže su učenje u jednom koraku i jednostavna adaptacija strukture, što rezultira bržim učenjem i postizanjem potrebnih generalizacijskih karakteristika mreže [35].

Učenje RBF mreže se može promatrati kao aproksimacija ili interpolacija hiperravnine kroz zadani skup točaka za učenje. U ovom radu je odabran interpolacijski pristup, pri čemu interpolirana funkcija više varijabli prolazi kroz sve točke skupa za učenje. Nakon završenog učenja, odziv mreže predstavlja aproksimaciju vrijednosti naučene hiperravnine za zadani ulazni vektor [36], tj. L -dimenzionalni ulazni vektor preslikava se u M -dimenzionalni izlazni vektor ($R^L \rightarrow R^M$).

5.1. Struktura mreže

Struktura mreže (slika 9.) se sastoji od tri sloja: ulaznog, skrivenog i izlaznog. Ulazni sloj čini L ulaznih, a izlazni M izlaznih neurona. Njihov broj je definiran prirodom promatranog problema. Za ulazne neurone se u pravilu odabiru međusobno nezavisne varijable za koje se pretpostavlja da koreliraju s varijablama učenog problema pridijeljenima izlaznim neuronima mreže. S obzirom na to da je dinamika

trošenja alata uvjetovana parametrima obrade, logično je brzinu rezanja i posmak alata pri bušenju odabrati za ulazne neurone. Preostale ulazne neurone predstavljat će različite kombinacije iznosa energija spektra signala akustične emisije i vibracija, kao i vrijednosti i snage signala jakosti struja, što će biti detaljnije prikazano u poglavlju 6. S druge strane, broj neurona izlaznog sloja određen je brojem odabranih stupnjeva istrošenosti svrdla. RBF mreža će za svaki skup vrijednosti navedenih ulaznih varijabli i naučenih vrijednosti parametara svog skrivenog sloja svakom izlaznom neuronu pridijeliti određeni iznos, pri čemu će izlazni neuron s najvećim iznosom biti pobjednički i definirati aktualni stupanj istrošenosti svrdla.



Slika 9. Struktura RBF neuronske mreže

Generalizacijska svojstva i kvaliteta odziva mreže ovise o njenom skrivenom sloju. Broj neurona skrivenog sloja (K) se određuje u fazi učenja. U slučaju interpolacije jednak je broju uzoraka za učenje N , ($i=1, \dots, N$). Svaki neuron skrivenog sloja je opisan L -dimenzionalnim vektorom centara (t_j) i parametrima aktivacijske funkcije. Neuroni skrivenog sloja povezani su s neuronima izlaznog sloja preko pripadajućih težinskih faktora (c_j). Njihov se izračun temelji na izvođenju inverzije matrice radijalnih baznih funkcija H , čiji elementi h_{ij} ovise o odabranoj aktivacijskoj funkciji, njezinoj širini i odstupanjima vrijednosti ulaznih neurona od centara neurona

skrivenog sloja. Time su povezani ulazni i skriveni sloj mreže. Konačne vrijednosti centara skrivenog sloja i težina izlaznog sloja predstavljaju svojevršno znanje neuronske mreže o učenom problemu, te se na njima temelji uspješnost naknadnog testiranja i primjene mreže.

Zadatak svake neuronske mreže je kvalitetno preslikavanje ulaznih na željene izlazne vrijednosti. Prikaz matematičkog modela učenja i testiranja započinje definiranjem veze između neurona skrivenog i izlaznog sloja:

$$O_w(x_i) = \sum_{j=1}^K h(d_{ij})c_{jw} , \quad i = 1, \dots, L, \quad w = 1, \dots, M, \quad (3.5.)$$

pri čemu je O_w element w -tog izlaznog neurona koji ovisi o ulaznom vektoru x sastavljenom od svih ulaznih neurona, K broj neurona skrivenog sloja, $h(\bullet)$ aktivacijska funkcija, d_{ij} Euklidijeva udaljenost između i -tog elementa ulaznog neurona i j -tog elementa vektora centra skrivenog sloja, c_{jw} težinski faktor koji povezuje j -ti neuron skrivenog sloja s w -tim neuronom izlaznog sloja, L broj ulaznih, a M broj izlaznih neurona.

Elementi h_{ij} čine matricu vrijednosti radijalnih baznih funkcija H , te ovise o odabranoj aktivacijskoj funkciji (AF). Sam naziv mreže implicira da aktivacijska funkcija mora biti odabrana iz skupine radijalnih baznih funkcija. Prema Micchellievom teoremu, ako je funkcija kontinuirana u intervalu $[0, \infty)$ i pozitivna u intervalu $(0, \infty)$, te joj je prva derivacija u potpunosti monotona, tada je determinanta matrice radijalnih baznih funkcija H pozitivna, te će biti ostvaren uvjet njene invertibilnosti.


Veći broj funkcija zadovoljava taj kriterij pa se mogu koristiti kao radijalne bazne funkcije [36]. U praksi se najčešće koristi zvonolika Gaussova funkcija, prikazana slikom 10., definirana kao:

$$h(d) = e^{-\left(\frac{d}{\sigma}\right)^2}, \quad (3.6.)$$

pri čemu je σ širina radijalne bazne funkcije. Vrijednost parametra σ određena je metodom P najbližih susjeda (eng. *P nearest neighbour*) [37], modificiranom množenjem koeficijentom *koef*. Prema tome, širinu aktivacijske funkcije svakog j -tog neurona skrivenog sloja određuje izraz:

$$\sigma_j = \text{koef} \cdot \sqrt{p_1 p_2}, \quad (3.7.)$$

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



Slika 10. Gaussova aktivacijska funkcija

Uz Gaussovu aktivacijsku funkciju, u referenci [38] razmatrana je i primjena inverzne kvadratne i trokutne aktivacijske funkcije na uspješnost klasifikacije mreže. Kako se na razmatranim klasifikacijskim problemima moglo uočiti da su rezultati dobiveni korištenjem trokutne AF podjednako dobri ili čak bolji od onih dobivenih Gaussovom AF, odlučeno je da se u ovom postupku učenja RBF mreže primjene obje spomenute aktivacijske funkcije. Uz to, razmatran je i utjecaj koeficijenta *koef*, kojim se modificira širina aktivacijske funkcije, na uspješnost klasifikacije. Pritom valja biti pažljiv pri odabiru širine aktivacijske funkcije jer preuska AF neće pokriti cijelo područje učenja, a posljedica će biti ograničenost adekvatnog određivanja izlaznih vrijednosti samo onih elemenata koji se nalaze u neposrednoj blizini centara AF. S druge strane, ako je AF preširoka, gube se lokalna svojstva mreže i može doći do problema u izračunu matrice H .


S obzirom na navedeno, a na temelju preliminarno provedenih učenja/testiranja mreže primjenom različitih vrijednosti faktora *koef*, u konačnu je analizu podataka uzeta kombinacija Gaussove AF i $koef = \{1, 2\}$, odnosno trokutne AF i $koef = \{2, 3\}$.

Izgled trokutne funkcije prikazuje slika 11., a njen je oblik određen iz izraza:

$$\text{za } d > gd, h(d) = 0, \quad (3.8.)$$

$$\text{za } d < gd, h(d) = \left|1 - \frac{d}{gd}\right|, \quad (3.9.)$$

pri čemu vrijedi da je $gd = 3\sigma$.



Slika 11. Trokutna aktivacijska funkcija

5.2. Algoritam učenja

Proces učenja započinje određivanjem centara neurona skrivenog sloja, pri čemu se u obzir uzimaju svi ulazni elementi u neuronsku mrežu, tj. svaki uzorak skupa za učenje predstavlja jedan od centara neurona skrivenog sloja.

Nakon određivanja centara skrivenog sloja računaju se Euklidijske udaljenosti između uzoraka za učenje i centara skrivenog sloja

$$d_{ij} = \|x_i - t_j\| . \quad (3.10.)$$

S obzirom na odabranu aktivacijsku funkciju, matrica vrijednosti neurona skrivenog sloja računa se kao

$$H_{ij} = h(\|x_i - t_j\|) . \quad (3.11.)$$

Izraz (3.5.) kojim je definirana povezanost neurona skrivenog i izlaznog sloja može se zapisati u matričnoj formi

$$O = H C , \quad (3.12.)$$

gdje O označava matricu izlaza ($N \times M$), H matricu vrijednosti radijalnih baznih funkcija

($N \times K$), a C matricu težinskih faktora mreže ($K \times M$). Matrica težinskih faktora tada se računa kao umnožak inverza kvadratne matrice H i matrice izlaza O

$$C = H^{-1}O. \quad (3.13.)$$


Time je ostvareno učenje težina izlaznog sloja, koje se uz centre neurona skrivenog sloja koriste u naknadnom testiranju mreže. Faza testiranja provodi se kroz sljedeće korake:

1. Izračun Euklidijevih udaljenosti svih ulaznih podataka skupa za testiranje od svih centara skrivenog sloja.
2. Izračun nove matrice radijalnih baznih funkcija, ovisno o aktivacijskoj funkciji uz koju je provedeno učenje.
3. Izračun odziva (izlaza) mreže na temelju matrice H i težinskih faktora izračunatih u procesu učenja.
4. Razvrstavanje testiranih uzoraka u klasifikacijske skupine na temelju izračunatih odziva. Pritom se uspješnost klasifikacije definira kao postotak ispravno klasificiranih uzoraka razmatranog skupa za testiranje.

5.3. Struktura podataka za učenje i testiranje

Prethodno je navedeno da je u toku eksperimenta provedeno 360 mjerenja, tj. po 10 mjerenja za 3 različita stupnja istrošenosti, 3 različite brzine rezanja i 4 različita posmaka. Da bi učenje mreže, a time i testiranje, bilo uspješno, potrebno je podatke dobivene mjerenjima adekvatno razvrstati u skup podataka za učenje, odnosno skup podataka za testiranje. Stoga je 180 podataka odabrano u skup za učenje, a preostalih 180 u skup za testiranje. Pritom je svaki skup podataka sadržavao podatke o 5 ponovljenih bušenja izvedenih jednom od kombinacija parametara i stupnja istrošenosti svrdla. Shema razvrstavanja podataka prikazana je slikom 12.

Skup uzoraka za testiranje dodatno je podijeljen na 5 grupa ili testova, pri čemu se svaka grupa sastojala od 36 uzoraka koji su pripadali svakoj od 36 različitih kombinacija brzine rezanja, posmaka i stupnja istrošenosti svrdla.



Slika 12. Razvrstavanje podataka u skupove za učenje i testiranje

S obzirom na to da generalizacijska svojstva mreže označavaju njenu sposobnost da daje zadovoljavajuće rezultate na skupu ulaznih podataka različitom od onog na kojem je učila, odabir podataka za učenje ima veliku ulogu u procesu učenja mreže.

Odabir energija signala akustične emisije, korištenih u učenju i testiranju mreže prikazan je u poglavlju 6.1.

Kako bi se istražilo koje su ulazne kombinacije izračunatih energija signala vibracija najpovoljnije za korištenje u procjeni stupnja istrošenosti svrdla, razmatrano je više različitih ulaznih značajki, izloženih u poglavlju 6.2.

Značajke snimljenih signala jakosti struja izložene su u poglavlju 6.3.

Neovisno o razmatranoj ulaznoj konfiguraciji, odziv mreže mora biti formiran tako da se uzorci za testiranje razvrstavaju u tri različite skupine (S_1 , S_2 , S_3) pa je izlazne neurone pogodno oblikovati binarnim vrijednostima (tablica 5.).

Tablica 5. Prikaz izlaznih neurona

Opis	Izlazi iz mreže			Broj izlaza
S_1	1	0	0	3
S_2	0	1	0	3
S_3	0	0	1	3

Tako definirani izlazi iz mreže korišteni su u analizi svih razmatranih ulaznih kombinacija značajki.

Konačno, nakon što su definirani struktura ulaznih i izlaznih neurona, odabrane aktivacijske funkcije neurona skrivenog sloja i njihovi koeficijenti, može započeti postupak učenja mreže, odnosno testiranja njenih generalizacijskih svojstava.

6. REZULTATI I RASPRAVA

Već je spomenuto da u procjeni nadziranja istrošenosti svrdla veći broj značajki realnije opisuje promatrano stanje procesa, tj. omogućuje prigušivanje utjecaja trenutno neadekvatnih značajki.

Iz tog je razloga analiza razmatranih značajki provedena u nekoliko koraka. Prvo je razmatrana uspješnost klasifikacije stupnja istrošenosti medicinskog svrdla korištenjem značajki izdvojenih iz svakog razmatranog tipa signala (akustična emisija, vibracije, jakosti struja) zasebno. Nakon toga su iz svakog tipa signala izdvojene one značajke čija je uporaba rezultirala najvećim uspješnostima klasifikacije, te su međusobno kombinirane kako bi se postiglo dodatno poboljšanje karakteristika mreže.

6.1. Rezultati analize stupnja istrošenosti korištenjem značajki signala akustične emisije

U procesu učenja i testiranja umjetne neuronske mreže su kao ulazne značajke korištene energije spektra signala akustične emisije računane za razmatrane frekvencijske pojaseve. Postupak je proveden u nekoliko koraka (slika 13.)



Slika 13. Hodogram analize podataka izdvojenih iz signala akustične emisije

U prvom koraku ulazne neurone u mrežu predstavljaju posmak, brzina rezanja i energija spektra signala akustične emisije, izračunata za sve razmatrane frekvencijske pojaseve iz frekvencijskog spektra 50-400 kHz. Izračun granica


frekvencijskih pojaseva ovisi o njihovim širinama, kao što je već prikazano u poglavlju 4.1. Opisanom se kombinacijom značajki trošenja (tablica 6.) provodi učenje i testiranje mreže odvojeno za svaki od tako određenih intervala frekvencija.

Tablica 6. Prikaz kombinacije značajki na ulazu u mrežu u prvom koraku analize temeljene na prikupljenim signalima akustične emisije

Oznaka kombinacije značajki	Ulazi u mrežu			Broj ulaza
	f	v_c	$E(AE)$	
AE	f	v_c	$E(AE)$	$2+n$

Nakon provedenog učenja i testiranja dobiveni su rezultati klasifikacije s obzirom na 6 različitih širina frekvencijskih pojaseva. Rezultati su iskazani kao prosječna uspješnost klasifikacije UK_{sr} , tj. srednja vrijednost uspješnosti klasifikacija dobivenih na testovima $T1-T5$ (UK_1-UK_5).


Za svaku širinu frekvencijskog pojasa su, s obzirom na korištenu aktivacijsku funkciju i $koef$, prikazani najbolji ostvareni rezultati (slike 14.-17.).



Slika 14. Najbolji rezultati analize signala akustične emisije za svaku širinu frekvencijskog pojasa uz Gaussovu AF i $koef = 1$

Svi najbolji rezultati dobiveni korištenjem Gaussove AF i $koef = 1$ (slika 14.) imali su UK_{sr} veću od 65 %. Najbolji među njima je iznosio 82,22 %, a ostvaren je kombinacijom značajki iz frekvencijskog područja 200-215 kHz (slika 14.), tj. korištenjem energije akustične emisije izračunate za frekvencijski pojas širine 15 kHz.

Zanimljivo je uočiti da su najbolji rezultati za preostale širine pojaseva imali znatno manju UK_{Sr} .




Slika 15. Najbolji rezultati analize signala akustične emisije za svaku širinu frekvencijskog pojasa uz Gaussovu AF i $koef = 2$


Kombinacijom Gaussove AF i $koef = 2$ (slika 15.) najbolji rezultati za svaku od razmatranih širina frekvencijskog pojasa su imali uspješnost klasifikacije veću od 65 %, a među njima se ističe UK_{Sr} koja iznosi 76,11 %. Osim što je najbolji rezultat ponovno ostvaren izračunavanjem značajke akustične emisije u frekvencijskom pojasu širine 15 kHz, valja napomenuti da se također radi o pojasu 200-215 kHz.

Sličan razmještaj najboljih rezultata ostvaren je i trokutnom AF uz $koef = 2$ (slika 16.). Naime, najveća uspješnost klasifikacije od 72,78 % ponovo je ostvarena značajkom akustične emisije iz frekvencijskog pojasa 200-215 kHz. U ovom slučaju, UK_{Sr} svih najboljih rezultata po frekvencijskim pojasovima je bila veća od 60 %.

Kombinacijom trokutne AF i $koef = 3$ (slika 17.) svi najbolji rezultati se imali UK_{Sr} veću od 62 %. Najbolji među njima iznosili su 70,00 %, a ostvareni su značajkama akustične emisije iz pojaseva 200-215 kHz i 80-110 kHz.



Slika 16. Najbolji rezultati analize signala akustične emisije za svaku širinu frekvencijskog pojasa uz trokutnu AF i $koef = 2$



Slika 17. Najbolji rezultati analize signala akustične emisije za svaku širinu frekvencijskog pojasa uz trokutnu AF i $koef = 3$

Dakle, u prvom koraku analize primjernom signala akustične emisije je najveća uspješnost klasifikacije postignuta Gaussovom AF uz $koef = 1$. Iznosi 82,22 % i dobivena je korištenjem značajke akustične emisije izračunate za frekvencijski pojas 200-215 kHz. U odnosu na taj rezultat, većina ostalih najboljih rezultata ima znatno manju UK_{sr} .

Temeljem prikazane analize uspješnosti klasifikacije u svim razmatranim frekvencijskim pojasevima, u drugom je koraku analize kao kriterij odabira pojaseva određeno postizanje definiranih donjih granica uspješnosti postavljenih na vrijednosti $UK_{Sr} \geq 50\%$ i $UK_{Sr} \geq 60\%$. Takvim odabirom se nastojao smanjiti broj razmatranih frekvencijskih pojaseva i istovremeno izdvojiti one pojaseve koji su se pokazali najpogodnijima za izdvajanje energija akustične emisije. S obzirom na tako odabrane frekvencijske pojaseve formirani su novi ulazni neuroni u mrežu (tablica 7.).

Tablica 7. Prikaz kombinacija značajki na ulazu u mrežu u drugom koraku analize temeljene na prikupljenim signalima akustične emisije

Oznaka kombinacije značajki	Ulazi u mrežu			Broj ulaza
<i>AE</i>	<i>f</i>	<i>v_c</i>	$E(AE)_1 \dots E(AE)_n$	2+n

Prema tome, u drugom je koraku analize za svaku kombinaciju aktivacijske funkcije i *koef* odabrano *n* pojaseva u kojima je razmatrana kombinacija značajki ostvarila uspješnost klasifikacije veću ili jednaku od 50 %, odnosno 60 %. Iznosi energija akustične emisije svakog od odabranih pojaseva istovremeno su uz iznose posmaka i brzine rezanja predstavljali ulaze u mrežu. S obzirom na to da je broj pojaseva *n* određen na temelju rezultata dobivenih u prvom koraku analize, on nije bio jednak za svaku kombinaciju AF i *koef*. Opisani je pristup odabran zbog pretpostavke da će se kombinacijom energija iz najpovoljnijih pojaseva postići poboljšanje rezultata, odnosno veća uspješnost klasifikacije stupnja istrošenosti alata.

Odabir pojaseva izvršen je zasebno za svaku razmatranu širinu podjele frekvencijskog spektra, tj. u svakom učenju i testiranju mreže su korištene energije odabranih pojaseva iste širine ($s = \{5, 10, 15, 20, 30, 40\}$ kHz). Naime, prethodnom je analizom utvrđeno da se istovremenim korištenjem energija izračunatih za frekvencijske pojaseve jednakih širina ostvaruju bolji rezultati nego kombinacijom energija pojaseva čije su širine različite.

Radi detaljnijeg uvida i pripreme za drugi korak analize, tablicom 8. su dodatno prikazani svi najbolji rezultati u ovisnosti o aktivacijskoj funkciji, koeficijentu i širini frekvencijskog pojasa u kojem su ostvareni.


Tablica 8. Odabir koeficijenata uz AF za drugi korak analize signala akustične emisije

Najbolja UK_{sr} , [%]		Širina frekvencijskog pojasa, [kHz]					
		5	10	15	20	30	40
Gaussova AF	$koef = 1$	70,56	74,44	82,22	65,56	75,56	67,78
	$koef = 2$	69,44	70,56	76,11	67,22	72,78	66,67
trokutna AF	$koef = 2$	67,22	67,22	72,78	61,11	72,22	65,56
	$koef = 3$	67,22	68,89	70,00	62,78	70,00	63,33

Za većinu širina frekvencijskih pojaseva se može uočiti da odabir AF i $koef$ nema jako velik utjecaj na iznos uspješnosti klasifikacije. Dodatno, uspoređivanjem rezultata ostvarenih pojedinom AF i njenim koeficijentima može se uočiti da u većini kombinacija varijacija uspješnosti klasifikacije s obzirom na korišteni koeficijent iznosi oko 2 %. To opravdava odluku da se u daljnjoj analizi reducira broj korištenih koeficijenata, tj. broj razmatranih kombinacija aktivacijskih funkcija i koeficijenata


Dakle, u daljnjoj je analizi učenje i testiranje mreže za svaku kombinaciju aktivacijske funkcije i širina frekvencijskih pojaseva provedeno samo s jednom vrijednošću koeficijanta $koef$. Za svaku je kombinaciju aktivacijske funkcije i širine frekvencijskog pojasa odabrana ona vrijednost koeficijanta $koef$ (tablica 8., sivo obojana polja) uz koju je u prvom koraku analize ostvaren veći iznos najveće uspješnosti klasifikacije .

Nakon toga su odabrani pojasevi (slike 18.-21.) čije energije frekvencijskog spektra predstavljaju ulazne značajke u mrežu u drugom koraku analize temeljene na signalima akustične emisije.



Slika 18. Odabrani frekvencijski pojasevi za značajke akustične emisije koje su ostvarile $UK_{sr} \geq 50\%$ uz Gaussovu aktivacijsku funkciju


Promatrajući frekvencijske pojaseve ($UK_{sr} \geq 50\%$) za Gaussovu aktivacijsku funkciju, može se uočiti da je pojasevima većih širina prekriven veći dio spektra nego pojasevima manjih širina (slika 18.) Također, vidljivo je da se velik broj pojaseva nalazi uz frekvencije 100, 200 i 300 kHz.



Slika 19. Odabrani frekvencijski pojasevi za značajke akustične emisije koje su ostvarile $UK_{sr} \geq 50\%$ uz trokutnu aktivacijsku funkciju

Broj odabranih pojaseva za trokutnu aktivacijsku funkciju ($UK_{sr} \geq 60\%$) nešto je manji od broja pojaseva za Gaussovu AF odabranih uz isti kriterij uspješnosti klasifikacije. Može se uočiti vrlo sličan razmještaj pojaseva po frekvencijskom spektru, kao i to da

se ponovo većina njih nalazi uz frekvencije 100, 200 i 300 kHz (slika 19.). S obzirom na to, može se pretpostaviti da u drugom koraku analize odabir aktivacijske funkcije neće imati značajan utjecaj na klasifikaciju stupnja istrošenosti svrdla primjenom signala akustične emisije.




Slika 20. Odabrani frekvencijski pojasevi za značajke akustične emisije koje su ostvarile $UK_{Sr} \geq 60\%$ uz Gaussovu aktivacijsku funkciju

Za Gaussovu AF i odabrane koeficijente je pojasevima u kojima je ostvareno $UK_{Sr} \geq 60\%$ (slika 20.) prekriven uočljivo manji dio frekvencijskog spektra nego pojasevima za koje vrijedi $UK_{Sr} \geq 50\%$. Zanimljivo je uočiti da većina pojaseva ponovo obuhvaća frekvencije 100, 200 i 300 kHz, ali i da nakon frekvencije 310 kHz nije odabran ni jedan pojas.

Za trokutnu AF i pripadajuće *coef* (slika 21.) ponovo vrijedi da se većina pojaseva nalazi uz frekvencije 100, 200 i 300 kHz, kao i da nakon frekvencije 305 kHz nema pojaseva koji su zadovoljili postavljeni kriterij odabira. Unatoč smanjenju broja odabranih pojaseva, vidljivo je da je za svaku od razmatranih širina frekvencijskih pojaseva barem jedan pojas zadovoljio postavljeni uvjet uspješnosti klasifikacije.

Zbog sličnosti između svih odabranih pojaseva u kojima je ostvareno $UK_{Sr} \geq 60\%$ za Gaussovu i trokutnu AF, ponovo se može pretpostaviti da odabir aktivacijske funkcije neće imati značajniji utjecaj u analizi temeljenoj na značajkama izdvojenim iz signala akustične emisije.



Slika 21. Odabrani frekvencijski pojasevi za značajke akustične emisije koje su ostvarile $UK_{sr} \geq 60\%$ uz trokutnu aktivacijsku funkciju

Rezultate klasifikacije dobivene značajkama iz tako odabranih pojaseva prikazuju tablice 9.-14. Pritom plavo šrafirana polja označavaju najbolje rezultate drugog koraka analize, dok zelena prikazuju preostale dobivene UK_{sr} . Osim prikazane srednje uspješnosti klasifikacije izračunate za cijeli skup uzoraka za testiranje, također je vidljivo koliko su uspješno klasificirani pojedini stupnjevi istrošenosti svrdla.

Tablica 9. Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz odabrane frekvencijske pojaseve (signala akustične emisije) širine 5 kHz

			Pojasevi $\geq 50\%$	Pojasevi $\geq 60\%$
širina pojasa, [kHz]	AF, koef	stupanj istrošenosti	UK_{sr} , [%]	UK_{sr} , [%]
5	Gaussova AF, koef = 1	1	98,33	100,00
		2	93,33	85,00
		3	98,33	98,33
		Σ	96,67	94,44
	trokutna AF, koef = 2	1	98,33	98,33
		2	86,67	91,67
		3	100,00	100,00
		Σ	95,00	96,67

Najveća uspješnost klasifikacije ostvarena značajkama izdvojenim iz odabranih frekvencijskih pojaseva širine 5 kHz iznosi 96,67 % (tablica 9.), što ujedno predstavlja i najbolji rezultat drugog koraka analize primjenom značajki izdvojenih iz signala

akustične emisije. Ostali su rezultati dobiveni značajkama iz pojaseva ove širine nešto lošiji, no također predstavljaju znatno poboljšanje u odnosu na najbolje rezultate dobivene istim značajkama u prvom koraku analize. Naime, ostvareni su porasti uspješnosti klasifikacije za oko 25 % u usporedbi s rezultatima koje su navedene kombinacije značajki postigle s energijom spektra samo najboljeg frekvencijskog pojasa. Rezultati pokazuju da je UK_{sr} u iznosu od 96,67 % ostvarena uporabom obiju aktivacijskih funkcija, čime je potvrđena pretpostavka da odabir AF neće značajnije utjecati na rezultate drugog koraka analize značajki akustične emisije. Uz to, zanimljivo je da je taj rezultat ostvaren i za pojaseve u kojima su značajke individualno ostvarile $UK_{sr} \geq 50 \%$ i za one u kojima je ostvareno $UK_{sr} \geq 60 \%$.

Tablica 10. Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz odabrane frekvencijske pojaseve (signala akustične emisije) širine 10 kHz

			Pojasevi $\geq 50 \%$	Pojasevi $\geq 60 \%$
širina pojasa, [kHz]	AF, koef	stupanj istrošenosti	UK_{sr} , [%]	UK_{sr} , [%]
10	Gaussova AF, koef = 1	1	95,00	95,00
		2	86,67	91,67
		3	100,00	100,00
		Σ	93,89	95,56
	trokutna AF, koef = 3	1	95,00	93,33
		2	80,00	80,00
		3	100,00	100,00
		Σ	91,67	91,11

Iako nešto lošiji od onih dobivenih značajkama izdvojenim iz pojaseva širine 5 kHz, rezultati dobiveni istovremenim korištenjem svih značajki izdvojenih iz odabranih frekvencijskih pojaseva širine 10 kHz pokazuju poboljšanje od oko 20 % u odnosu na najbolje rezultate ostvarene istim značajkama individualno (tablica 10.). Rezultati ostvareni korištenjem Gaussove AF su nešto bolji od onih u kojima je korištena trokutna AF, što bi se moglo povezati s većom pokrivenošću frekvencijskog spektra odabranim pojasevima u slučaju korištenja Gaussove AF (slike 18.-21.).

Tablica 11. Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz odabrane frekvencijske pojaseve (signala akustične emisije) širine 15 kHz

			Pojasevi $\geq 50\%$	Pojasevi $\geq 60\%$
širina pojasa, [kHz]	AF, koef	stupanj istrošenosti	UK_{sr} , [%]	UK_{sr} , [%]
15	Gaussova AF, koef = 1	1	98,33	100,00
		2	85,00	96,67
		3	100,00	93,33
		Σ	94,44	96,67
	trokutna AF, koef = 2	1	91,67	100,00
		2	86,67	93,33
		3	100,00	96,67
		Σ	92,78	96,67

Korištenjem značajki vezanih uz frekvencijske pojaseve širine 15 kHz očekivano je ostvaren najbolji rezultat drugog koraka analize temeljene na signalima akustične emisije (tablica 11.). Naime, upravo su individualnim značajkama izračunatim za pojaseve te širine ostvareni najbolji rezultati u prvom koraku analize. Može se uočiti da je $UK_{sr} = 96,67\%$ ostvarena uz korištenje obiju aktivacijskih funkcija, ali samo izdvajanjem značajki iz pojaseva u kojima su one individualno ostvarile $UK_{sr} \geq 60\%$.

Tablica 12. Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz odabrane frekvencijske pojaseve (signala akustične emisije) širine 20 kHz

			Pojasevi $\geq 50\%$	Pojasevi $\geq 60\%$
širina pojasa [kHz]	AF, koef	stupanj istrošenosti	UK_{sr} , [%]	UK_{sr} , [%]
20	Gaussova AF, koef = 2	1	93,33	90,00
		2	91,67	88,33
		3	98,33	100,00
		Σ	94,44	92,78
	trokutna AF, koef = 3	1	95,00	55,00
		2	78,33	33,33
		3	98,33	100,00
		Σ	90,56	62,78

Rezultati dobiveni kombinacijom značajki iz pojaseva širine 20 kHz lošiji su od onih dobivenih korištenjem pojaseva manjih širina (tablica 12.). Taj se trend osobito učituje u slučaju korištenja trokutne aktivacijske funkcije i pojaseva u kojima su

razmatrane značajke individualno ostvarile $UK_{sr} \geq 60 \%$. Naime, u drugom koraku analize je uspješnost klasifikacije ostvarena tom kombinacijom značajki jednaka onoj postignutoj primjenom individualnih značajki u prvom koraku analize, što ukazuje na to da do poboljšanja rezultata nije došlo.

Tablica 13. Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz odabrane frekvencijske pojaseve (signala akustične emisije) širine 30 kHz

			Pojasevi $\geq 50 \%$	Pojasevi $\geq 60 \%$
širina pojasa [kHz]	AF, koef	stupanj istrošenosti	UK_{sr} , [%]	UK_{sr} , [%]
30	Gaussova AF, koef = 1	1	95,00	91,67
		2	93,33	96,67
		3	98,33	96,67
		Σ	95,56	95,00
	trokutna AF, koef = 2	1	93,33	98,33
		2	96,67	71,67
		3	100,00	100,00
		Σ	96,67	90,00

Rezultati dobiveni korištenjem energija frekvencijskih pojaseva širine 30 kHz pokazuju da su veće uspješnosti klasifikacije ostvarene onim značajkama koje su izdvojene iz pojaseva u kojima su individualno ostvarile $UK_{sr} \geq 50 \%$ (tablica 13.). Najboljim rezultatom ($UK_{sr} = 96,67 \%$), ostvarenim uz trokutnu AF, je postignuto značajno povećanje uspješnosti klasifikacije u odnosu na najbolji rezultat postignut kombinacijom značajki sastavljenom od energije spektra samo jednog frekvencijskog pojasa (75,56 %).

Poboljšanje u odnosu na uspješnost klasifikacije u prvom koraku analize vidjiva je i na rezultatima ostvarenim istovremenim korištenjem značajki izračunatih za odabrane frekvencijske pojaseve širine 40 kHz (tablica 14.). Ipak, dobiveni su rezultati znatno lošiji od onih dobivenih korištenjem energija akustične emisije izračunatih za frekvencijske pojaseve manjih širina, a kojima je pokriven vidljivo manji dio analiziranog frekvencijskog spektra. Uz to, uspoređujući rezultate s obzirom na pojaseve iz kojih su značajke izdvojene, može se uočiti da su veće uspješnosti klasifikacije ostvarene značajkama izdvojenim iz onih pojaseva u kojima su iste individualno ostvarile $UK_{sr} \geq 50 \%$.

Tablica 14. Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja vezanim uz frekvencijske pojaseve (signala akustične emisije) širine 40 kHz

			Pojasevi ≥ 50 %	Pojasevi ≥ 60 %
širina pojasa [kHz]	AF, koef	stupanj istrošenosti	UK_{Sr} , [%]	UK_{Sr} , [%]
40	Gaussova AF, koef = 1	1	100,00	81,67
		2	75,00	75,00
		3	98,33	100,00
		Σ	91,11	85,56
	trokutna AF, koef = 2	1	98,33	86,67
		2	75,00	68,33
		3	98,33	100,00
		Σ	90,56	85,00

Dakle, najbolji rezultat drugog koraka procjene istrošenosti medicinskog svrdla primjenom signala akustične emisije iznosi $UK_{Sr} = 96,67$ %. Ostvaren je korištenjem energija frekvencijskog spektra odabranih pojaseva širine 5, 15 ili 30 kHz. Postignut je uz obje korištene aktivacijske funkcije i to izdvajanjem značajki iz obje skupine odabranih pojaseva ($UK_{Sr} \geq 50$ % i $UK_{Sr} \geq 60$ %). Općenito, može se uočiti da je korištenje pojaseva koji su zadovoljili uvjet $UK_{Sr} \geq 50$ % rezultiralo podjednako dobrim ili neznatno lošijim rezultatima od korištenja pojaseva u kojima je zadovoljeno $UK_{Sr} \geq 60$ %. Također, u provedenoj su se analizi obje korištene aktivacijske funkcije pokazale podjednako prikladnima za uporabu.

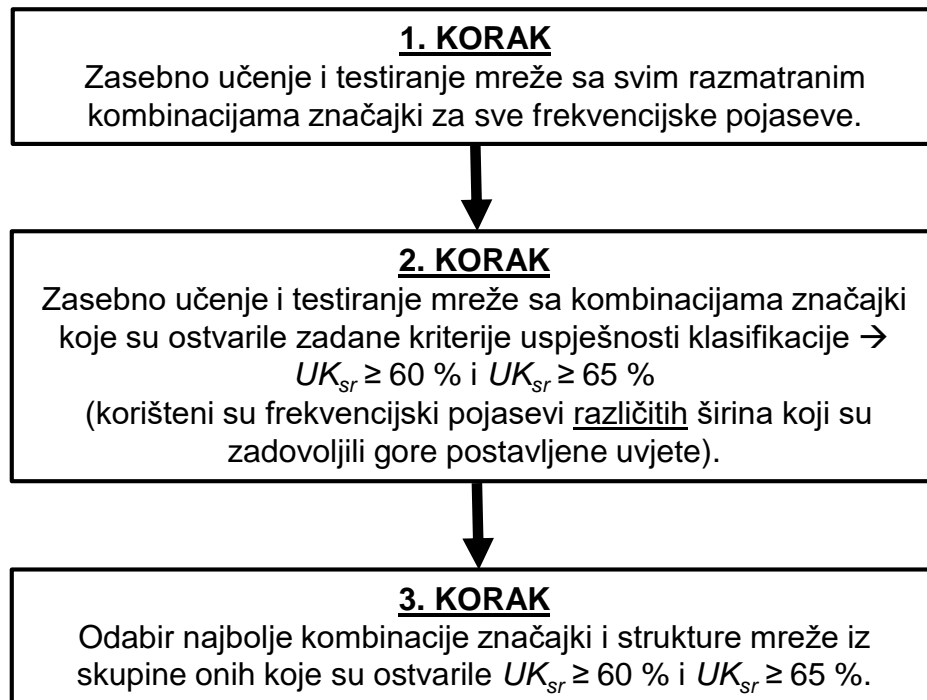
Uočljivo je da s porastom širina izdvojenih pojaseva iznad 15 kHz trend porasta uspješnosti klasifikacije opada. Iznimka tome su pojasevi širine 30 kHz u kojima je ponovo ostvaren najbolji rezultat, tj. uspješnost klasifikacije jednaka onima postignutim kombinacijom značajki iz pojaseva širine 5 ili 15 kHz. Takvi rezultati ukazuju na djelomičnu disproporcionalnost ostvarenih uspješnosti klasifikacije i pokrivenosti frekvencijskog spektra odabranim pojasevima. Naime, odabranim pojasevima širina 5 i 15 kHz pokriven je znatno manji udio frekvencijskog spektra nego pojasevima širine 40 kHz, a istovremeno je njihova uporaba rezultirala znatno većim uspješnostima klasifikacije stupnja istrošenosti medicinskog svrdla. No, to bi se moglo objasniti činjenicom da je broj odabranih pojaseva manjih širina bio veći od broja odabranih pojaseva većih širina pa je u tom slučaju i broj ulaznih neurona u mrežu bio veći, čime je osigurano kvalitetnije učenje mreže.

Provedena analiza pokazala je razlike u uspješnosti klasifikacije pojedinih stupnjeva istrošenosti svrdla. Spomenute su razlike minimalno izražene u najboljim dobivenim rezultatima, u kojima variraju ovisno o širini odabranih frekvencijskih pojaseva i korištenim aktivacijskih funkcija.

S obzirom na sve navedeno, može se zaključiti da su energije spektra odabranih frekvencijskih pojaseva signala akustične emisije zaista primjenjive u procjeni stupnja istrošenosti medicinskog svrdla.

6.2. Rezultati analize stupnja istrošenosti korištenjem značajki signala vibracija

Kako bi se pronašla kombinacija frekvencijskih pojaseva i ulaznih značajki signala vibracija koja osigurava željenu preciznost u klasifikaciji stupnja istrošenosti medicinskog svrdla, postupak učenja i testiranja primjenom signala vibracija proveden je u nekoliko koraka shematski prikazanih slikom 22.



Slika 22. Hodogram analize podataka i odabira najbolje kombinacije značajki trošenja izdvojene iz signala vibracija

U prvom koraku su učenje i testiranje mreže provedeni odvojeno za 9 različitih kombinacija ulaznih značajki. Uz posmak i brzinu rezanja, ulazne neurone čini energija spektra signala vibracija u smjeru jedne ili više osi. Dakle, izdvojene energije se razmatraju odvojeno i u međusobnim kombinacijama s drugima. Energije se izračunavaju za sve razmatrane frekvencijske pojaseve čije granice ovise o njihovim širinama, a računaju se tako da se pojas 5-5000 Hz podijeli na manje pojaseve jednakih širina kako je pojašnjeno u poglavlju 4.2. Za svaki od tih intervala provodi se odvojeno učenje i testiranje mreže s različitim kombinacijama značajki trošenja (tablica 15.).

Tablica 15. Prikaz kombinacija značajki na ulazu u mrežu u prvom koraku analize temeljene na prikupljenim signalima vibracija

Oznaka kombinacije značajki	Ulazi u mrežu (značajke)						Broj ulaza
	f	v_c					
X	f	v_c	$E(VIB_x)$				3
Y	f	v_c	$E(VIB_y)$				3
Z	f	v_c	$E(VIB_z)$				3
XY	f	v_c	$E(VIB_x)$	$E(VIB_y)$			4
YZ	f	v_c	$E(VIB_y)$	$E(VIB_z)$			4
XZ	f	v_c	$E(VIB_x)$	$E(VIB_z)$			4
XYZ	f	v_c	$E(VIB_x)$	$E(VIB_y)$	$E(VIB_z)$		5
XYZ_{sum}	f	v_c	$E(VIB_{xyz})$				3
$XYZ-XYZ_{sum}$	f	v_c	$E(VIB_x)$	$E(VIB_y)$	$E(VIB_z)$	$E(VIB_{xyz})$	6

Nakon provedenog učenja i testiranja dobiveni su rezultati za 9 različitih kombinacija ulaznih značajki s obzirom na 23 različite širine pojasa frekvencijskog spektra.

Izdvojeni su najbolji rezultati postignuti za svaku širinu frekvencijskog pojasa i to s obzirom na korištenu AF i *koef* (slike 23.-26.). Za svaki je rezultat vidljivo kojom je kombinacijom ulaznih značajki ostvaren.

Kombinacijom Gaussove AF i *koef* = 1 dobiveno je 19 rezultata s UK_{sr} većom ili jednakom 60 %, dok je za 12 frekvencijskih pojaseva UK_{sr} bila veća ili jednaka 65 % (slika 23.). Vidljivo je da su svi prikazani rezultati ostvareni četirima različitim kombinacijama značajki (XY, YZ, XYZ i $XYZ-XYZ_{sum}$). Najveća uspješnost klasifikacije od 69,44 % ostvarena je kombinacijom značajki $XYZ-XYZ_{sum}$ i to za širine pojasa

200 Hz (1405-1605 Hz) i 700 Hz (1405-2105 Hz).


Korištenjem Gaussove AF i *koef* = 2 najbolji dobiveni rezultati po frekvencijskim pojasevima ponovo su iznosili 69,44 % (slika 24.). Ostvareni su kombinacijom značajki $XYZ-XYZ_{sum}$ u pojasu 1405-2105 Hz, odnosno XYZ u pojasu 1545-1565 Hz. Općenito, većina rezultata dobivena je korištenjem te dvije kombinacije značajki. Za 16 frekvencijskih pojaseva UK_{sr} je bila veća ili jednaka 60 %, a za njih 12 veća ili jednaka 65 %.

U oba slučaja kod primjene Gaussove AF vrijedi da su najbolji rezultati postignuti za


širine frekvencijskih pojaseva čije su vrijednosti bile iz područja između 20 i 700 Hz, te da je većina njih ostvarena uz kombinacije značajki trošenja XYZ i $XYZ-XYZ_{sum}$.

Slični su se rezultati postigli trokutnom AF uz $koef = 2$ (slika 25.). Najveća uspješnost klasifikacije ponovo iznosi 69,44 %, te je postignuta kombinacijom značajki XYZ u frekvencijskim pojasevima 1405-2105 Hz i 1405-1605 Hz. Istom kombinacijom značajki je ostvarena većina ostalih prikazanih rezultata. U ovom slučaju UK_{Sr} je za 17 frekvencijskih pojaseva bila veća ili jednaka 60 %, a kod njih 12 veća ili jednaka 65 %.


Konačno, najveća uspješnost klasifikacije ostvarena je trokutnom AF uz $koef = 3$ (slika 26.). Dobivena je korištenjem kombinacije značajki XYZ i iznosi 72,22 %. Istom je kombinacijom značajki postignuta većina najboljih rezultata po pojasevima. Općenito, 18 frekvencijskih pojaseva ostvarilo je UK_{Sr} veću ili jednaku 60 %, a njih 9 veću ili jednaku 65 %.




Slika 23. Najbolji rezultati analize signala vibracija za svaku širinu frekvencijskog pojasa uz Gaussovu AF i $koef = 1$



Slika 24. Najbolji rezultati analize signala vibracija za svaku širinu frekventijskog pojasa uz Gaussovu AF i $coef = 2$



Slika 25. Najbolji rezultati analize signala vibracija za svaku širinu frekvencijskog pojasa uz trokutnu AF i $koef = 2$

Slika 26. Najbolji rezultati analize signala vibracija za svaku širinu frekvencijskog pojasa uz trokutnu AF i $koef = 3$

Razmatrajući rezultate dobivene trokutnom AF, s obzirom na odabrane širine frekvencijskih pojaseva, ponovo se može zaključiti da su najveći iznosi UK_{Sr} dobiveni kombinacijama značajki izdvojenim iz pojaseva čije su vrijednosti širina bile iz područja između 20 i 700 Hz, te da je većina njih ostvarena kombinacijom značajki XYZ.

Ipak, valja imati na umu da su prikazani samo najbolji rezultati za svaku širinu pojasa. Prema tome, visoke vrijednosti UK_{Sr} ostvarene su i s ostalim kombinacijama ulaznih značajki.

Na temelju provedene analize uspješnosti klasifikacije svake odabrane kombinacije značajki individualno i to za svaki analizirani frekvencijski pojas, u drugom koraku analize podataka (slika 22.) korištene su samo one kombinacije značajki i frekvencijski pojasevi koji su zadovoljili postavljeni kriterij odabira. Formiranje ulaznih neurona u mrežu prikazano je tablicom 16.

Tablica 16. Prikaz kombinacija značajki na ulazu u mrežu u drugom koraku analize temeljene na prikupljenim signalima vibracija

Oznaka kombinacije značajki	Ulazi u mrežu (značajke)		Broj ulaza	
X	f	v_c	$E(VIB_x)_1 \dots E(VIB_x)_n$	$2+n$
Y	f	v_c	$E(VIB_y)_1 \dots E(VIB_y)_n$	$2+n$
Z	f	v_c	$E(VIB_z)_1 \dots E(VIB_z)_n$	$2+n$
XY	f	v_c	$E(VIB_x)_1 \dots E(VIB_x)_n E(VIB_y)_1 \dots E(VIB_y)_n$	$2+2n$
YZ	f	v_c	$E(VIB_y)_1 \dots E(VIB_y)_n E(VIB_z)_1 \dots E(VIB_z)_n$	$2+2n$
XZ	f	v_c	$E(VIB_x)_1 \dots E(VIB_x)_n E(VIB_z)_1 \dots E(VIB_z)_n$	$2+2n$
XYZ	f	v_c	$E(VIB_x)_1 \dots E(VIB_x)_n E(VIB_y)_1 \dots E(VIB_y)_n E(VIB_z)_1 \dots E(VIB_z)_n$	$2+3n$
XYZ_{sum}	f	v_c	$E(VIB_{xyz})_1 \dots E(VIB_{xyz})_n$	$2+n$
$XYZ-XYZ_{sum}$	f	v_c	$E(VIB_x)_1 \dots E(VIB_x)_n E(VIB_y)_1 \dots E(VIB_y)_n E(VIB_z)_1 \dots E(VIB_z)_n E(VIB_{xyz})_1 \dots E(VIB_{xyz})_n$	$2+4n$

Kriterij odabira određen je postizanjem definiranih donjih granica uspješnosti klasifikacije postavljenih na vrijednosti $UK_{Sr} \geq 60\%$ i $UK_{Sr} \geq 65\%$. U tom je smislu drugi korak analize podrazumijevao da se za svaku kombinaciju značajki odabere n pojaseva u kojima je ta kombinacija značajki ostvarila uspješnost klasifikacije veću ili jednaku od 60 %, odnosno 65 %. Zatim su za svaki od tih pojaseva izračunati

pripadajući iznosi energija koji su uz posmak i brzinu rezanja predstavljali ulazne neurone u mrežu. Broj pojaseva n proizlazi iz rezultata dobivenih u prvom koraku analize iz čega proizlazi da on nije bio jednak za svaku razmatranu kombinaciju značajki. Prema tome, način odabira pojaseva sličan je onome primijenjenom za odabir pojaseva značajki signala akustične emisije, s razlikom u tome da su značajke akustične emisije istovremeno izdvajane iz pojaseva jednakih širina, dok se za kombinacije značajki signala vibracija istovremeno odabiru pojasevi različitih širina.

Navedeni je pristup analize značajki i njihovih kombinacija ponovo odabran zbog pretpostavke da će se kombiniranjem najpovoljnijih kombinacija značajki i energija iz njima pripadajućih frekvencijskih pojaseva postići preciznija i pouzdanija procjena istrošenosti alata.


S obzirom da su ostvareni najbolji rezultati po frekvencijskim pojasevima bili podjednako dobri za sve četiri prethodno odabrane kombinacije aktivacijske funkcije i parametra *koef*, sve su kombinacije zasebno sudjelovale i u drugom koraku analize.

U cilju izbjegavanja utjecaja preklapajućih frekvencijskih pojaseva na iznose energija, za svaku su se kombinaciju značajki pojasevi odabirali počevši od onog koji je ostvario najveću vrijednost UK_{sr} prema onima s najmanjom vrijednošću (min 60 % ili 65 %) uz zanemarivanje onih pojaseva koji su se djelomično ili potpuno preklapali s već odabranim pojasevima.


U nastavku su prikazani pojasevi čije energije frekvencijskog spektra predstavljaju nove ulaze u neuronsku mrežu (slike 27.-30.).

Promatrajući odabrane frekvencijske pojaseve ($UK_{sr} \geq 60\%$) za Gaussovu AF i pripadajuće koeficijente (slika 27.), može se uočiti da su pojasevi za kombinacije značajki XYZ i $XYZ-XYZ_{sum}$ prekrili veći dio spektra nego kod ostalih kombinacija značajki. Sličnost u raspodjeli pojaseva za $koef = 1$ i $koef = 2$ je osobito vidljiva za kombinaciju značajki $XYZ-XYZ_{sum}$.

Za trokutnu aktivacijsku funkciju također vrijedi da je odabranim pojasevima ($UK_{sr} \geq 60\%$) kombinacija značajki XYZ i $XYZ-XYZ_{sum}$ prekriven puno veći dio frekvencijskog spektra nego kod ostalih kombinacija značajki (slika 28.). Kod tih je kombinacija značajki uočljiv međusobno sličan razmještaj odabranih pojaseva po spektru, ali i sličan razmještaj pojaseva za svaku od njih s obzirom na *koef*.




Slika 27. Odabrani frekvencijski pojasevi za kombinacije značajki signala vibracija koje su ostvarile $UK_{sr} \geq 60\%$ uz Gaussovu aktivacijsku funkciju



Slika 28. Odabrani frekvencijski pojasevi za kombinacije značajki signala vibracija koje su ostvarile $UK_{sr} \geq 60\%$ uz trokutnu aktivacijsku funkciju


Za obje aktivacijske funkcije vrijedi da su pojasevi kombinacija značajki XYZ , $XYZ-XYZ_{sum}$ i XZ ravnomjernije raspodijeljeni po frekvencijskom spektru nego pojasevi ostalih kombinacija značajki.

Broj odabranih pojaseva koji su zadovoljili uvjet $UK_{sr} \geq 65\%$ je znatno manji od onog za koje je $UK_{sr} \geq 60\%$ (slika 29.). Uočava se da je uz uporabu Gaussove AF najveća pokrivenost frekvencijskog spektra ostvarena kombinacijom značajki $XYZ-XYZ_{sum}$ uz $koef = 2$.



Slika 29. Odabrani frekvencijski pojasevi za kombinacije značajki signala vibracija koje su ostvarile $UK_{sr} \geq 65\%$ uz Gaussovu aktivacijsku funkciju

Za trokutnu AF, najveća pokrivenost frekvencijskog spektra (uz uvjet uvjet $UK_{sr} \geq 65\%$) ostvarena je za kombinacije značajki $XYZ-XYZ_{sum}$ i XYZ (slika 30.). Odabrani pojasevi ostalih kombinacija značajki prekrili su znatno manje područje spektra.



Slika 30. Odabrani frekvencijski pojasevi za kombinacije značajki signala vibracija koje su ostvarile $UK_{sr} \geq 65\%$ uz trokutnu aktivacijsku funkciju

Općenito se za sve četiri kombinacije AF i *koef* može zaključiti da su za kombinacije značajki koje su postigle najviše najboljih rezultata klasifikacije kod pojedinačne analize svih širina frekvencijskih pojaseva (slike 23.-26.) odabrani pojasevi (slike 27.-30.) prekrili veće područje frekvencijskog spektra nego za ostale kombinacije značajki. U tome se posebno ističu kombinacije značajki XYZ i $XYZ-XYZ_{sum}$ pa je za očekivati da će korištenje odabranih pojaseva upravo tih kombinacija značajki rezultirati najboljim rezultatima klasifikacije stupnja istrošenosti medicinskog svrdla.

Rezultati klasifikacije postignuti kombinacijama značajki iz njima pripadajućih frekvencijskih pojaseva iz drugog koraka analize za sve četiri kombinacije aktivacijskih funkcija i koeficijenta *koef* (slike 27.-30.) prikazani su tablicama 17. i 18.

Tablica 17. Rezultati klasifikacije (izraženi u %) dobiveni s kombinacijama značajki trošenja vezanim uz nepreklapajuće frekvencijske pojaseve (signala vibracija) koje su zadovoljile $UK_{sr} \geq 60\%$

Gaussova, koef = 1						
Kombinacija značajki	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{sr}
XY	58,33	61,11	63,89	61,11	58,33	60,56
YZ	80,56	66,67	61,11	63,89	72,22	68,89
XZ	80,56	61,11	72,22	72,22	66,67	70,56
XYZ	86,11	72,22	86,11	69,44	72,22	77,22
XYZ-XYZ _{sum}	80,56	75,00	75,00	66,67	75,00	74,44
Gaussova, koef = 2						
Kombinacija značajki	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{sr}
Y	75,00	63,89	55,56	50,00	55,56	60,00
XY	75,00	83,33	69,44	58,33	63,89	70,00
YZ	72,22	63,89	61,11	63,89	63,89	65,00
XZ	66,67	75,00	77,78	69,44	69,44	71,67
XYZ	66,67	80,56	77,78	72,22	83,33	76,11
XYZ-XYZ _{sum}	77,78	66,67	66,67	75,00	69,44	71,11
trokutna, koef = 2						
Kombinacija značajki	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{sr}
XY	66,67	61,11	63,89	69,44	58,33	63,89
YZ	69,44	58,33	63,89	61,11	58,33	62,22
XZ	72,22	75,00	77,78	69,44	66,67	72,22
XYZ	88,89	63,89	63,89	61,11	63,89	68,33
XYZ-XYZ _{sum}	69,44	69,44	69,44	66,67	66,67	68,33
trokutna, koef = 3						
Kombinacija značajki	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{sr}
XY	55,56	61,11	58,33	44,44	72,22	58,33
YZ	80,56	61,11	61,11	66,67	58,33	65,56
XZ	72,22	63,89	80,56	69,44	72,22	71,67
XYZ	86,11	75,00	77,78	77,78	75,00	78,33
XYZ-XYZ _{sum}	72,22	69,44	69,44	72,22	66,67	70,00

Analizirajući rezultate dobivene korištenjem energija pojaseva u kojima su pripadajuće kombinacije značajki individualno ostvarile $UK_{sr} \geq 60\%$, vidljivo je da je najveća uspješnost klasifikacije ostvarena kombinacijom XYZ. Njena $UK_{sr} = 78,33\%$ dobivena je uz uporabu trokutne AF i $koef = 3$. Time je ostvaren porast uspješnosti klasifikacije za 6,11 % u usporedbi s rezultatom koji je navedena kombinacija značajki postigla s energijama spektra najboljeg frekvencijskog pojasa u prvom koraku analize (72,22 %). Najbolji rezultati ostalih kombinacija AF i $koef$ su nešto lošiji, no također su znatno bolji od onih ostvarenih kombinacijama značajki energija

spektra svakog pojasa zasebno.

Tablica 18. Rezultati klasifikacije (izraženi u %) dobiveni s kombinacijama značajki trošenja vezanim uz nepreklapajuće frekvencijske pojaseve (signala vibracija) koje su zadovoljile $UK_{Sr} \geq 65\%$

Gaussova, koef = 1						
Kombinacija značajki	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{Sr}
XY	83,33	61,11	61,11	66,67	69,44	68,33
YZ	80,56	66,67	61,11	63,89	72,22	68,89
XZ	75,00	63,89	66,67	58,33	66,67	66,11
XYZ	77,78	69,44	69,44	63,89	61,11	68,33
XYZ-XYZ _{sum}	83,33	66,67	80,56	75,00	72,22	75,56
Gaussova, koef = 2						
Kombinacija značajki	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{Sr}
YZ	72,22	66,67	66,67	52,78	72,22	66,11
XYZ	66,67	69,44	66,67	77,78	72,22	70,56
XYZ-XYZ _{sum}	77,78	80,56	80,56	77,78	77,78	78,89
trokutna, koef = 2						
Kombinacija značajki	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{Sr}
XY	80,56	55,56	63,89	63,89	69,44	66,67
YZ	72,22	66,67	66,67	63,89	58,33	65,56
XZ	66,67	72,22	66,67	69,44	61,11	67,22
XYZ	77,78	69,44	77,78	77,78	75,00	75,56
XYZ-XYZ _{sum}	61,11	63,89	58,33	72,22	50,00	61,11
trokutna, koef = 3						
Kombinacija značajki	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{Sr}
XY	77,78	69,44	66,67	58,33	61,11	66,67
YZ	80,56	61,11	61,11	66,67	58,33	65,56
XYZ	75,00	61,11	77,78	75,00	66,67	71,11
XYZ-XYZ _{sum}	69,44	80,56	77,78	58,33	69,44	71,11

S druge strane, najbolji rezultat postignut kombinacijom frekvencijskih pojaseva koji su zadovoljili uvjet $UK_{Sr} \geq 65\%$ iznosio je $UK_{Sr} = 78,89\%$ što ujedno predstavlja i najbolji rezultat u dosadašnjoj analizi podataka. Ostvaren je kombinacijom značajki XYZ-XYZ_{sum}, uz Gaussovu AF i koef = 2. Tako je ostvaren porast uspješnosti klasifikacije u iznosu od 9,45 % u odnosu na najbolji rezultat koji je postigla ista kombinacija značajki sastavljena od energija spektra jednog frekvencijskog pojasa (69,44 %).

Na temelju najboljih rezultata iz obje tablice može se zaključiti da je potvrđena

prethodno iznesena logična pretpostavka o proporcionalnom odnosu između uspješnosti određene kombinacije značajki u klasifikaciji stupnja istrošenosti i stupnja pokrivenosti frekvencijskog spektra pojasevima iz kojih su izdvajane energije spektra za tu kombinaciju značajki.

Naime, uglavnom su veće vrijednosti UK_{sr} ostvarene uz veće pokriveno područje spektra. Također, valja napomenuti da je uočena povezanost povećanja koeficijenta širine aktivacijske funkcije (*koef*) s većom prekrivenošću frekvencijskog spektra.

U posljednjem, trećem koraku analize sudjelovale su kombinacije značajki koje su ostvarile najbolje rezultate (tablice 17. i 18.) za uvjete $UK_{sr} \geq 60\%$ (XYZ) i $UK_{sr} \geq 65\%$ ($XYZ-XYZ_{sum}$). Njihovi rezultati prikazani u navedenim tablicama dodatno su analizirani po stupnjevima istrošenosti (tablice 19. i 20.).

Tablica 19. Rezultati analize po stupnjevima istrošenosti za ulaznu kombinaciju značajki XYZ uz trokutnu AF i $koef = 3$

Stupanj istrošenosti	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{sr}
S_1	100,00	91,67	83,33	91,67	83,33	90,00
S_2	66,67	50,00	58,33	58,33	41,67	55,00
S_3	91,67	83,33	91,67	83,33	100,00	90,00

Tablica 20. Rezultati analize po stupnjevima istrošenosti za ulaznu kombinaciju značajki $XYZ-XYZ_{sum}$ uz Gaussovu AF i $koef = 2$

Stupanj istrošenosti	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{sr}
S_1	100,00	75,00	83,33	83,33	91,67	86,67
S_2	41,67	66,67	66,67	50,00	50,00	55,00
S_3	91,67	100,00	91,67	100,00	91,67	95,00

Iz obje tablice vidljivo je da klasifikacija stupnjeva istrošenosti S_1 i S_3 ima veću uspješnosti nego S_2 . Uspješnost klasifikacije stupnja istrošenosti S_2 jednaka je u oba slučaja i iznosi 55 %. Istovremeno, oštro svrdlo je nešto bolje klasificirano kombinacijom značajki XYZ , a tupo svrdlo kombinacijom značajki $XYZ-XYZ_{sum}$.

Dodatnom analizom je za obje kombinacije značajki utvrđeno u koje su se skupine razvrstali uzorci za testiranje (tablice 21. i 22.).

Tablica 21. Usporedba stvarnih i klasificiranih stupnjeva istrošenosti za kombinaciju značajki
 XYZ-XYZ_{sum}

POSMAK (m/min)	BRZINA REZANJA (mm/okr)	STUPANJ ISTROŠENOSTI	KLASIFICIRANI STUPANJ ISTROŠENOSTI				
			T ₁	T ₂	T ₃	T ₄	T ₅
0,01	10	1	1	1	1	1	1
0,01	30	1	1	1	1	1	1
0,01	50	1	1	1	1	1	1
0,03	10	1	1	1	1	1	1
0,03	30	1	1	1	1	1	3
0,03	50	1	1	1	1	1	1
0,05	10	1	1	1	1	1	1
0,05	30	1	1	1	1	1	1
0,05	50	1	1	1	1	1	1
0,1	10	1	1	1	1	1	1
0,1	30	1	1	3	1	1	1
0,1	50	1	1	3	3	2	3
0,01	10	2	2	2	2	2	2
0,01	30	2	2	3	2	2	1
0,01	50	2	2	1	2	3	1
0,03	10	2	1	2	2	2	2
0,03	30	2	1	3	3	3	3
0,03	50	2	2	2	2	2	1
0,05	10	2	2	1	2	2	2
0,05	30	2	2	2	1	2	2
0,05	50	2	2	2	3	2	3
0,1	10	2	1	2	3	3	3
0,1	30	2	2	3	2	1	2
0,1	50	2	3	1	3	3	3
0,01	10	3	3	3	3	3	3
0,01	30	3	3	1	3	3	3
0,01	50	3	3	1	3	1	3
0,03	10	3	3	3	3	3	3
0,03	30	3	3	3	3	3	3
0,03	50	3	3	3	1	3	3
0,05	10	3	3	3	3	3	3
0,05	30	3	3	3	3	3	3
0,05	50	3	3	3	3	3	3
0,1	10	3	1	3	3	1	3
0,1	30	3	3	3	3	3	3
0,1	50	3	3	3	3	3	3

Tablica 22. Usporedba stvarnih i klasificiranih stupnjeva istrošenosti za kombinaciju značajki XYZ

POSMAK (m/min)	BRZINA REZANJA (mm/okr)	STUPANJ ISTROŠENOSTI	KLASIFICIRANI STUPANJ ISTROŠENOSTI				
			T_1	T_2	T_3	T_4	T_5
0,01	10	1	1	1	1	1	1
0,01	30	1	1	1	1	1	1
0,01	50	1	1	1	1	1	1
0,03	10	1	1	1	1	1	1
0,03	30	1	1	2	1	1	2
0,03	50	1	1	2	2	2	1
0,05	10	1	1	1	1	1	1
0,05	30	1	1	1	1	1	1
0,05	50	1	1	1	1	1	1
0,1	10	1	1	1	1	1	1
0,1	30	1	1	1	1	3	1
0,1	50	1	1	3	3	1	1
0,01	10	2	2	2	2	2	2
0,01	30	2	3	3	1	1	1
0,01	50	2	2	2	1	1	2
0,03	10	2	2	1	2	1	1
0,03	30	2	3	1	2	3	1
0,03	50	2	1	2	2	2	1
0,05	10	2	1	2	2	2	1
0,05	30	2	2	2	2	3	2
0,05	50	2	2	2	2	2	2
0,1	10	2	3	1	1	3	2
0,1	30	2	3	2	3	2	1
0,1	50	2	1	2	2	2	2
0,01	10	3	3	3	3	3	3
0,01	30	3	3	3	3	3	3
0,01	50	3	1	3	2	3	3
0,03	10	3	3	3	3	3	3
0,03	30	3	3	3	3	3	3
0,03	50	3	3	3	3	3	3
0,05	10	3	3	3	3	3	3
0,05	30	3	3	3	3	3	3
0,05	50	3	3	3	3	3	3
0,1	10	3	3	3	3	3	3
0,1	30	3	3	3	3	3	1
0,1	50	3	3	3	3	3	3

Analizirajući rezultate postignute kombinacijom značajki $XYZ-XYZ_{sum}$ (tablica 21.), uočava se da se većina pogrešno razvrstanih uzoraka vezanih uz S_1 razvrstala u skupinu sa stupnjem istrošenosti S_3 , odnosno da su se svi uzorci vezani uz S_3 razvrstali u skupinu sa stupnjem istrošenosti S_1 . S druge strane, korištenjem kombinacije značajki XYZ (tablica 22.), pogrešno klasificirani uzorci vezani uz stupnjeve istrošenosti S_1 i S_3 su se razvrstali u oba preostala dva stupnja istrošenosti, S_2 i S_3 , tj. S_1 i S_2 , respektivno. Za obje kombinacije značajki su pogrešno klasificirani uzorci stupnja istrošenosti S_2 u podjednakom broju ($UK_{sr} = 55\%$) razvrstani u stupnjeve S_1 i S_3 , bez uočljivog obrasca razvrstavanja.

Konačno, za obje je kombinacije značajki sumiran broj uzoraka koji su se iz stupnja S_2 pogrešno klasificirali u stupnjeve S_1 , odnosno S_3 (tablica 23.).

Tablica 23. Prikaz ukupnog broja uzoraka iz S_2 koji su se na pojedinom testiranju razvrstali u S_1 , S_2 i S_3

XYZ				XYZ-XYZ _{sum}			
test	UK(S ₂)	stupanj istrošenosti (S _x)	N(S _x)	test	UK(S ₂)	stupanj istrošenosti (S _x)	N(S _x)
T ₁	66.67%	S ₁	3	T ₁	41.67%	S ₁	3
		S ₂	8			S ₂	5
		S ₃	1			S ₃	4
T ₂	50.00%	S ₁	3	T ₂	66.67%	S ₁	3
		S ₂	6			S ₂	8
		S ₃	3			S ₃	1
T ₃	58.33%	S ₁	1	T ₃	66.67%	S ₁	3
		S ₂	7			S ₂	8
		S ₃	4			S ₃	1
T ₄	58.33%	S ₁	1	T ₄	50.00%	S ₁	3
		S ₂	7			S ₂	6
		S ₃	4			S ₃	3
T ₅	41.67%	S ₁	3	T ₅	50.00%	S ₁	6
		S ₂	5			S ₂	6
		S ₃	4			S ₃	0
T _{sr}	55.00%	S ₁	11	T _{sr}	55.00%	S ₁	18
		S ₂	33			S ₂	39
		S ₃	16			S ₃	9

Iz tablice je uočljivo da su pogrešno klasificirani uzorci iz S_2 , a koji pripadaju

kombinaciji značajki XYZ , klasificirani većinom u S_3 , dok je za kombinaciju značajki $XYZ-XYZ_{sum}$ veći broj uzoraka klasificiran u S_1 .

Na temelju dobivenih rezultata proizlazi da je kombinacija značajki $XYZ-XYZ_{sum}$ najuspješnije i to s visokom preciznošću ($UK_{sr} = 95\%$) uspjela klasificirati tupo (S_3) od oštrog svrdla (S_1), iz čega se može izvesti zaključak o potencijalnoj primjenjivosti energija spektra odabranih frekvencijskih pojaseva signala vibracija u procjeni stupnja istrošenosti medicinskog svrdla.

6.3. Rezultati analize stupnja istrošenosti korištenjem značajki signala jakosti struja

Razmatranjem izdvojenih značajki prikupljenih signala struja (poglavlje 4.3.) pokazano je da se najbolji rezultati ostvaruju ukoliko se skup ulaznih značajki u mrežu sastoji od svih 6 razmatranih značajki struja zajedno s vrijednostima parametara obrade [5]. Stoga je isti pristup korišten i u ovom radu.

Prema tome, u ovom su dijelu analize značajke izdvojene iz frekvencijskog i vremenskog područja zajedno s brzinom rezanja i posmakom predstavljale ulazne neurone (tablica 24.) u mrežu.

Tablica 24. Prikaz kombinacija značajki na ulazu u mrežu u analizi temeljenoj na prikupljenim signalima jakosti struja

Oznaka kombinacije značajki	Ulazi u mrežu							Broj ulaza	
	f	V_c	$(I_z)_{max}$	$(I_{gv})_{max}$	$(I_z)_{sred}$	$(I_{gv})_{sred}$	$I_{gv}(f_v)$		$I_{gv}(f_o)$
I									8

Kao i u analizama temeljenim na prikupljenim signalima akustične emisije i vibracija, ponovo je kao algoritam za obradu podataka korišten opisani tip RBF neuronske mreže, zajedno sa svim već razmatranim aktivacijskim funkcijama i pripadajućim koeficijentima. Dobiveni rezultati prikazani su tablicom 25.

Tablica 25. Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja izdvojenim iz signala jakosti struja

AF	koef	UK_1	UK_2	UK_3	UK_4	UK_5	UK_{sr}
Gaussova	1	69,44	88,89	75,00	72,22	80,56	77,22
	2	66,67	91,67	77,78	72,22	80,56	77,78
trokutna	2	77,78	88,89	80,56	83,33	80,56	82,22
	3	75,00	88,89	77,78	66,67	75,00	76,67

Najbolji rezultat analize kombinacije značajki I iznosi $UK_{sr} = 82,22\%$, a dobiven je uz trokutnu AF i $koef = 2$, dok su rezultati ostvareni ostalim kombinacijama aktivacijskih funkcija i koeficijenata nešto lošiji.

6.4. Rezultati analize stupnja istrošenosti korištenjem značajki svih prikupljenih signala

Rezultati provedenih analiza temeljenih na prikupljenim signalima akustične emisije, vibracija i jakosti struja zasebno značajno se razlikuju. Najveće uspješnosti klasifikacije ostvarene su značajkama izdvojenim iz odabranih pojaseva signala akustične emisije ($UK_{sr} = 96,67 \%$), dok su rezultati dobiveni značajkama preostala dva tipa signala uočljivo lošiji. Naime, najveća uspješnost klasifikacije ostvarena odabranim značajkama iz odabranih frekvencijskih pojaseva signala vibracija iznosila je 78,89 %, dok je klasifikacijom temeljenom na svim razmatranim značajkama prikupljenih signala jakosti struja ostvaren nešto bolji rezultat, tj. uspješnost klasifikacije od 82,22 %

Već je spomenuto da je iz više razloga preporučljivo model za procjenu istrošenosti svrdla temeljiti ne na jednom, već na više različitih tipova signala prikupljenih tokom obradnog procesa. Dosadašnja analiza je pokazala da se kombinacijom značajki pojedinog signala, koje su individualno ostvarile visoke uspješnosti klasifikacije, mogu postići značajna poboljšanja rezultata. Stoga je logično u posljednjem koraku analize izdvojiti sve povoljne kombinacije značajki pojedinih vrsta signala i razmotriti hoće li njihove međusobne kombinacije rezultirati dodatnim povećanjem uspješnosti klasifikacije stupnja istrošenosti medicinskog svrdla.

Prema tome, u učenju i testiranju mreže će se kao ulazne značajke koristiti vrijednosti posmaka i brzine rezanja, energije signala vibracija i akustične emisije izdvojene iz odabranih frekvencijskih pojaseva te sve razmatrane značajke signala jakosti struja. Pritom su odabrane one kombinacije značajki akustične emisije i vibracija (tablica 26.) s kojima su ostvarene najveće uspješnosti klasifikacije u analizama izloženim u poglavljima 6.1. i 6.2.

Tablica 26. Prikaz oznaka najpovoljnijih izdvojenih kombinacija značajki signala akustične emisije i vibracija

Oznaka kombinacije značajki	Opis
$(AE_5)_{50}$	Energije signala akustične emisije, izračunate za frekvencijske pojaseve širine 5 kHz odabrane s obzirom na kriterij $UK_{sr} \geq 50 \%$
$(AE_{30})_{50}$	Energije signala akustične emisije, izračunate za frekvencijske pojaseve širine 30 kHz odabrane s obzirom na kriterij $UK_{sr} \geq 50 \%$
$(AE_5)_{60}$	Energije signala akustične emisije, izračunate za frekvencijske pojaseve širine 5 kHz odabrane s obzirom na kriterij $UK_{sr} \geq 60 \%$
$(AE_{15})_{60}$	Energije signala akustične emisije, izračunate za frekvencijske pojaseve širine 15 kHz odabrane s obzirom na kriterij $UK_{sr} \geq 60 \%$
$(XYZ)_{60}$	Energije spektra signala vibracija u smjeru osi x, y i z, izračunate za frekvencijske pojaseve odabrane s obzirom na kriterij $UK_{sr} \geq 60 \%$
$(XYZ-XYZ_{sum})_{65}$	Energije spektra signala vibracija u smjeru osi x, y i z te suma navedenih energija, izračunate za frekvencijske pojaseve odabrane s obzirom na kriterij $UK_{sr} \geq 65 \%$

S obzirom na to da se u prethodnim analizama svih korištenih kombinacija značajki ni jedna aktivacijska funkcije nije posebno istaknula, učenje i testiranje su ponovo provedeni uz obje AF i pripadajuće im koeficijente. Dobiveni rezultati prikazani su tablicom 27.

Tablica 27. Rezultati klasifikacije dobiveni s kombinacijama značajki trošenja izdvojenim iz različitih tipova prikupljenih signala

UK_{sr} , [%]	Gaussova AF		trokutna AF	
	<i>koef</i> = 1	<i>koef</i> = 2	<i>koef</i> = 2	<i>koef</i> = 3
Kombinacija značajki				
$f + v_c + (AE_5)_{50} + (XYZ)_{60}$	96,67	97,78	96,67	90,00
$f + v_c + (AE_{30})_{50} + (XYZ)_{60}$	100,00	100,00	100,00	100,00
$f + v_c + (AE_5)_{60} + (XYZ)_{60}$	100,00	100,00	100,00	100,00
$f + v_c + (AE_{15})_{60} + (XYZ)_{60}$	99,44	100,00	100,00	100,00
$f + v_c + (AE_5)_{50} + (XYZ-XYZ_{sum})_{65}$	97,22	96,67	95,00	94,44
$f + v_c + (AE_{30})_{50} + (XYZ-XYZ_{sum})_{65}$	100,00	100,00	100,00	100,00
$f + v_c + (AE_5)_{60} + (XYZ-XYZ_{sum})_{65}$	100,00	100,00	100,00	100,00
$f + v_c + (AE_{15})_{60} + (XYZ-XYZ_{sum})_{65}$	99,44	100,00	100,00	100,00
$f + v_c + (AE_5)_{50} + I$	97,78	98,33	95,56	98,89
$f + v_c + (AE_{30})_{50} + I$	95,00	100,00	96,11	98,33
$f + v_c + (AE_5)_{60} + I$	99,44	100,00	97,78	100,00
$f + v_c + (AE_{15})_{60} + I$	93,33	98,89	91,67	98,33
$f + v_c + (XYZ)_{60} + I$	77,22	84,44	81,11	75,00
$f + v_c + (XYZ-XYZ_{sum})_{65} + I$	84,44	83,33	83,89	80,00
$f + v_c + (AE_5)_{50} + (XYZ)_{60} + I$	100,00	100,00	100,00	100,00
$f + v_c + (AE_{30})_{50} + (XYZ)_{60} + I$	100,00	100,00	100,00	100,00
$f + v_c + (AE_5)_{60} + (XYZ)_{60} + I$	100,00	100,00	100,00	100,00
$f + v_c + (AE_{15})_{60} + (XYZ)_{60} + I$	100,00	100,00	100,00	100,00
$f + v_c + (AE_5)_{50} + (XYZ-XYZ_{sum})_{65} + I$	100,00	100,00	100,00	100,00
$f + v_c + (AE_{30})_{50} + (XYZ-XYZ_{sum})_{65} + I$	100,00	100,00	100,00	100,00
$f + v_c + (AE_5)_{60} + (XYZ-XYZ_{sum})_{65} + I$	100,00	100,00	100,00	100,00
$f + v_c + (AE_{15})_{60} + (XYZ-XYZ_{sum})_{65} + I$	100,00	100,00	100,00	100,00

Dobiveni rezultati su potvrdili pretpostavku da će korištenje značajki izvojenih iz različitih tipova odabranih signala rezultirati dodatnim povećanjem uspješnosti klasifikacije stupnja istrošenosti.

Većina kombinacija značajki sastavljenih od parametara obrade i izdvojenih energija signala akustične emisije i vibracija ostvarila je uspješnost klasifikacije od 100 %. Pritom je zanimljivo da taj rezultat nije postignut nijednom kombinacijom značajki u kojoj su se nalazile energije akustične emisije izdvojene iz odabranih pojaseva širine 5 kHz s obzirom na kriterij $UK_{sr} \geq 50$ %. Štoviše, neki od tako dobivenih rezultata su i lošiji od najboljih rezultata dobivenih samo sa značajkama akustične emisije.

Razmatrajući rezultate dobivene kombinacijom značajki sastavljenom od posmaka, brzine rezanja i izdvojenih značajki signala akustične emisije i jakosti struja, može se uočiti da je većinom kombinacija postignuto poboljšanje rezultata, ali je svega nekoliko korištenih kombinacija značajki rezultiralo porastom uspješnosti klasifikacije na 100 %.

Kombinacijom značajki sastavljenom od parametara obrade i izdvojenih značajki vezanih uz signale vibracija i jakosti struja ostvareni su znatno lošiji rezultati nego preostalim kombinacijama značajki. Naime, neki dobiveni rezultati su lošiji od onih dobivenih individualnim korištenjem odabranih značajki signala vibracija ili jakosti struja.

Konačno, svim razmatranim kombinacijama značajki sastavljenim od posmaka, brzine rezanja i odabranih značajki signala akustične emisije, vibracija i jakosti struja ostvarena je uspješnost klasifikacije od 100 % i to uz korištenje svih razmatranih kombinacija aktivacijskih funkcija i *koef.* Prema tome, procjena istrošenosti temeljena na različitim tipovima signala ostvaruje jednaku uspješnost prepoznavanja svakog od tri razmatrana stupnja istrošenosti svrdla, čime je potvrđena postavljena hipoteza ovog rada.

7. ZAKLJUČAK

Primjena istrošenih medicinskih svrdla ima brojne negativne posljedice na sigurnost obrade i naknadno cijeljenje kostiju. Zbog nemogućnosti preciznog određivanja stupnja istrošenosti oštrice medicinskog svrdla direktnim postupcima nadzora u realnom vremenu, cilj ovog rada bio je procijeniti njegovu istrošenost korištenjem indirektna metode nadzora zasnovane na značajkama trošenja izdvojenim iz signala akustične emisije, vibracija i jakosti struja prikupljenih u procesu bušenja i klasifikacijskog algoritma realiziranog u formi umjetne neuronske mreže.

Analiza je provedena na temelju podataka prikupljenih eksperimentalnim bušenjem uzoraka formiranih od goveđih kostiju korištenjem standardnog medicinskog svrdla promjera 4,5 mm. Razmatrana su tri stupnja istrošenosti svrdla, te za svaki od njih provedeno 10 ponovljenih mjerenja s 12 različitih kombinacija parametara obrade (brzina rezanja i posmaka), čime je prikupljeno ukupno 360 skupova podataka koji su zatim analizirani u nekoliko koraka.

Algoritam za obradu podataka i modeliranje dinamike trošenja predstavljala je neuronska mreža s radialnim baznim funkcijama. Pritom je razmatrana primjena dviju aktivacijskih funkcija neurona skrivenog sloja, Gaussove i trokutne, kao i utjecaj njihovih širina na uspješnost klasifikacije.

Analiza prikupljenih signala provedena je u nekoliko koraka, pri čemu su ulazne neurone u mrežu predstavljali posmak, brzina rezanja i značajke izdvojene iz prikupljenih signala. Prvo je razmatrana uspješnost klasifikacije medicinskog svrdla primjenom značajki izdvojenih iz svakog tipa signala zasebno, a zatim su iz svakog tipa signala izdvojene one značajke kojima su ostvarene najveće uspješnosti klasifikacije, te su međusobno kombinirane s ciljem dodatnog poboljšanja karakteristika mreže.

Proces učenja i testiranja mreže primjenom signala akustične emisije je najprije zasebno proveden sa svim značajkama izdvojenim iz razmatranih frekvencijskih pojaseva unutar frekvencijskog spektra 50-400 kHz. Najveća uspješnost klasifikacije ostvarena takvim pristupom iznosila je 82,22 %.

Zatim su odabrani samo oni frekvencijski pojasevi u kojima su značajke postigle definirane donje granice uspješnosti klasifikacije od 50 % i 60 %. Uz pretpostavku da

će se kombiniranjem najpovoljnijih značajki postići preciznija procjena istrošenosti alata, u drugom su koraku analize signala akustične emisije ulazne neurone uz posmak i brzinu rezanja istovremeno predstavljale i sve značajke izdvojene iz odabranih frekvencijskih pojaseva iste širine. Time su ostvarena znatna poboljšanja rezultata, pri čemu najbolji rezultat uspješnosti klasifikacije iznosi 96,67 %. Ostvaren je korištenjem energija frekvencijskog spektra iz odabranih pojaseva širine 5, 15 ili 30 kHz. Može se reći da su ovakvim pristupom, osim poboljšanja iznosa ukupne uspješnosti klasifikacije, ostvarene približno podjednake uspješnosti klasifikacija razmatranih stupnjeva istrošenosti svrdla.

S druge strane, učenje i testiranje primjenom signala vibracija najprije su provedeni odvojeno za 9 različitih kombinacija ulaznih značajki, pri čemu su značajke predstavljale energije spektra signala vibracija u smjeru jedne, dvije i/ili tri međusobno ortogonalne osi izračunate za razmatrane frekvencijske pojaseve unutar frekvencijskog spektra 5-5000 Hz. Na temelju dobivenih rezultata zaključeno je da uspješnost procjene stupnja istrošenosti ovisi o odabiru relevantnih kombinacija značajki. Tako je u prvom koraku analize vibracija najveća uspješnost klasifikacije (72,22 %) ostvarena uz ulazne neurone koji su predstavljali posmak, brzinu rezanja i energije spektra vibracija izračunate u smjeru osi x, y i z. Zatim su iz daljnjeg razmatranja izuzete one značajke koje nisu postigle definirane donje granice uspješnosti klasifikacije postavljene na 60 % i 65 %.

U drugom su koraku analize odabrani samo oni frekvencijski pojasevi u kojima su pojedine kombinacije značajki ostvarile postavljene kriterije, te su energije tih pojaseva predstavljale nove ulaze u neuronsku mrežu. Kombinacije ulaznih značajki kojima su ostvarene najbolje uspješnosti klasifikacije su posmak, brzina rezanja i energije spektra vibracija izračunate u smjeru osi x, y i z (78,33 %), odnosno posmak, brzina rezanja, energije spektra vibracija izračunate u smjeru osi x, y i z te suma navedenih energija (78,89 %).

Dodatna analiza najboljih kombinacija značajki signala vibracija i pripadajućih struktura mreže pokazala je izrazito visoku uspješnost klasifikacije potpuno oštrog i tupog svrdla (≈ 90 %), no istovremeno je uočena značajno niža uspješnost klasifikacije srednje istrošenog svrdla. Ovakav rezultat potencijalno ukazuje na nemogućnost samostalne primjene signala vibracija i navedenih značajki trošenja u procjeni srednjih oštećenja

oštrice, ali bi prije donošenja konačnog i općenitog zaključka trebalo provesti dodatna mjerenja s različitim uzorcima kostiju i primjenom svrdla različitih promjera i proizvođača.

U analizi temeljenoj na prikupljenim signalima jakosti struja su ulazne značajke u mrežu predstavljale posmak, brzinu rezanja i sve izdvojene značajke signala struja istovremeno. Najveća uspješnost klasifikacije ostvarena tom kombinacijom značajki iznosi 82,22 %.

Konačno, učenjem i testiranjem mreže kombinacijom značajki sastavljenom od posmaka, brzine rezanja i odabranih značajki sva tri tipa razmatranih signala istovremeno ostvaren je najbolji rezultat, odnosno uspješnost klasifikacije od 100 %. Taj je rezultat dobiven i uz Gaussovu i uz trokutnu aktivacijsku funkciju, neovisno o korištenim koeficijentima njihove širine.

Dakle, individualna analiza svih izdvojenih značajki trošenja pokazala je da najveći potencijal u klasifikaciji istrošenosti medicinskog svrdla imaju signali akustične emisije. Njihova primjenjivost i važnost očituju se u tome da osim što i sami osiguravaju vrlo visoku uspješnost klasifikacije (96,67 %), istovremenom kombinacijom s izdvojenim značajkama vibracija i struja osiguravaju uspješnost klasifikacije od 100 %, neovisno o korištenoj aktivacijskoj funkciji i koeficijentu njezine širine.

Raznolikost dobivenih rezultata potvrđuje da se u svakom trenutku nadzora ne mogu iz svih snimljenih signala izdvojiti one značajke koje će osigurati visoke uspješnosti klasifikacije. Pokazano je da se najpouzdaniji nadzor istrošenosti medicinskog svrdla ostvaruje istovremenom primjenom kombinacija najpovoljnijih značajki različitih tipova signala. Prema tome, navedeni rezultati ukazuju na mogućnost pouzdane klasifikacije svih razmatranih stupnjeva istrošenosti medicinskog svrdla primjenom multisenzorskog indirektnog nadzora istrošenosti, čime se potvrđuje utemeljenost postavljene hipoteze rada.

Eventualno poboljšanje rezultata ostvarenih pojedinim značajkama trošenja individualno moglo bi biti ostvareno izračunavanjem širina aktivacijskih funkcija zasebno za svaki neuron skrivenog sloja, a s obzirom na postavljene zadane kriterije (maksimalnu uspješnost klasifikacije). Općenito, još kvalitetnija procjena stupnja istrošenosti medicinskog svrdla potencijalno bi se mogla ostvariti korištenjem nekih

drugih vrsta algoritama odlučivanja ili njihovom integracijom, čime bi do izražaja došle njihove individualne karakteristike u modeliranju složenih nelinearnih procesa.

LITERATURA

- [1] Staroveški, T. *Modeliranje trošenja medicinskog svrdla – Disertacija*. Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu. Zagreb. 2013.
- [2] Augustin, G. *Termičko oštećenje kosti tijekom bušenja dvostupnjevanim svrdlom i svrdlom s protočnim hlađenjem – Disertacija*. Medicinski fakultet. Sveučilište u Zagrebu. Zagreb. 2011.
- [3] Davidson, S. R. H.; James D.F. *Measurement of thermal conductivity of bovine cortical bone*. Medical Engineering & Physics, Vol. 22, pp. 741-747. 2000.
- [4] Karmani, S. *The thermal properties of bone and the effects of surgical intervention*. Current Orthopaedics, Vol. 20, pp. 52-58. 2006.
- [5] Staroveški, T.; Brezak, D.; Udiljak, T. *Drill wear monitoring in cortical bone drilling*. Medical Engineering and Physics, Vol. 37, pp. 560-566, 2015.
- [6] Eriksson, A. R.; Albrektsson, T. *Temperature threshold levels for heat induced bone tissue injury: a vital microscopic study in rabbit*. Journal of Prosthetic Dentistry, Vol. 50, pp. 101-107. 1983.
- [7] Cordioli, G.; Majzoub, Z. *Heat generation during implant site preparation: an in vitro study*. Int J Oral Maxillofac Impl, 12:186–93. 1997.
- [8] Jantunen, E. *A summary of methods applied to tool condition monitoring in drilling*. International Journal of Machine Tools & Manufacture, Vol. 42, pp. 997-1010. 2002.
- [9] Allan, W.; Williams, E. D.; Kerawala, C. J. *Effects of repeated drill use on temperature of bone during preparation for osteosynthesis self-tapping screws*. Br J Oral Maxillofac Surg, 43:314–19. 2005.
- [10] Chacon, G. E.; Bower D. L.; Larsen P.E. i dr. *Heat production by 3 Implant Drill Systems after repeated drilling and sterilization*. J Oral Maxillofac Surg, 64:265–9. 2006.
- [11] Queiroz, T. P.; Souza F. Á.; Okamoto, R. i dr. *Evaluation of immediate bone-cell viability and of drill wear after implant osteotomies: immunohistochemistry and scanning electron microscopy analysis*. J Oral Maxillofac Surg, 66:1233–40. 2008.
- [12] Jochum, R. M.; Reichart, P. A. *Influence of multiple use of Timedur® – titanium cannon drills: thermal response and scanning electron microscopic findings*.

- Clin Oral Implants Res, 11:139–43. 2000.
- [13] Braun, S.; Lenz, E.; Wu, C. L. *Signature analysis applied to drilling*. Journal Mechanical Design, Transactions of the ASME 104, pp. 268–276. 1982.
- [14] El-Wardany, T.I.; Gao, D.; Elbestawi, M.A. *Tool condition monitoring in drilling using vibration signature analysis*. International Journal of Machine Tools & Manufacture, Vol. 36 (6), pp. 687–711. 1996.
- [15] Udiljak, T. *Doprinos razvoju metoda za ispitivanje i praćenje stupnja istrošenosti oštrice reznog alata – Disertacija*. Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu. 1996.
- [16] Dimla Snr, E. D. *Sensor signals for tool-wear monitoring in metal cutting operations – a review of methods*. International Journal of Machine Tools & Manufacture, Vol. 8, pp. 1073-1098. 2000.
- [17] Prickett, P. W.; Johns, C. *An overview of approaches to end milling tool monitoring*. International Journal of Machine Tools & Manufacture, Vol. 39/1, no. 1, pp. 105-122. 1999.
- [18] Quadro, A. L.; Branco, J. R. T. *Analysis of the acoustic emission during drilling test*. Surface & Coating Technology, Vol. 94-95, no. 1-3, pp. 691–695. 1997.
- [19] Schehl, U. *Werkzeuguberwachung mit Acoustic-Emission beim Drehen*. Fräsen und Bohren. Aachen. 1991.
- [20] Dornfeld, D.A. *Tool Wear Sensing via Acoustic Emission Analysis*. In Proceedings of the 8th NSF Grantee's Conference on Production, Research and Technology. Stanford Univ, pp. A1-A8. 1981.
- [21] Jantunen, E.; Jokinen, H. *Automated On-line Diagnosis of Cutting Tool Condition*. International Journal of Flexible Automation and Integrated Manufacturing, Vol. 4, no. 3-4, pp. 273–287. 1996.
- [22] Subramanian, K.; Cook, N.H. *Sensing of drill wear and prediction of drill life (I)*. Journal of Engineering for Industry, Transactions of the ASME, Vol. 101, pp. 295–301. 1977.
- [23] Erdelyi, F.; Santha, C. *Monitoring tasks on boring and milling production cells*. Computers in Industry, Vol. 7, pp. 65–71.1986.
- [24] Li, X. *On-line detection of the breakage of small diameter drills using current signature wavelet transform*. International Journal of Machine Tools & Manufacture, Vol. 39, no. 1, pp. 157–164. 1999.
- [25] Staroveški, T.; Brezak, D.; Udiljak, T.; Majetić, D. *Implementation of a LINUX-*

- Based CNC Open Control System*. 12th International Scientific Conference on Production Engineering, Computer Integrated Manufacturing and High Speed Machining, CIM 2009. Zagreb, pp. 209-216. 2009.
- [26] Staroveški, T.; Brezak, D.; Udiljak, T.; Majetić, D. *Three-Axis Milling Machine with the Enhanced Machine Controller*. 13th International Scientific Conference on Production Engineering, Zagreb, pp. 229-236. 2011.
- [27] Vashishth, D. *Rising crack-growth-resistance behaviour in cortical bone: implications for toughness measurements*. Journal of Biomechanics, Vol. 37, pp. 943-946. 2004.
- [28] Alam, K.; Mitrofanov A. V.; Silberschmidt, V. V. *Experimental investigations of forces and torque in conventional and ultrasonically-assisted drilling of cortical bone*. Medical Engineering & Physics, Article in press. 2010.
- [29] Laurito, D.; Lamazza, L.; Garreffa, G.; De Biase, A. *An alternative method to record rising temperatures during dental implant site preparation: a preliminary study using bovine bone*. Annali dell'Istituto Superiore di Sanita, Vol. 46, pp. 405-410. 2010.
- [30] Balazinski, M.; Songmene, V.; Kops, L. *Improvement of Tool Life through Variable Feed Milling of Inconel 600*. CIRP Annals - Manufacturing Technology, Vol. 44, no. 1, pp. 55-58. 1995.
- [31] Balazinski, M.; Ennajimi, E. *Influence of Feed Variation on Tool Wear When Milling Stainless Steel*. Journal of Manufacturing Science and Engineering, Vol. 116, no. 4, pp. 516-520. 1994.
- [32] Udiljak, T.; Ciglar, D.; Skoric, S. *Investigation into bone drilling and thermal bone", Advances in Production Engineering & Management*. Vol. 2, pp. 103-112. 2007.
- [33] Nam, O. H.; Yu, W. J.; Choi, M. Y.; Kyung, H. M. *Monitoring of bone temperature during osseous preparation for orthodontic micro-screw implants: effect of motor speed and pressure*. Key Engineering Materials, Vol. 321-323, pp. 1044-1047. 2006.
- [34] Rangwala, S.; Dornfeld, D. *Sensor Integration Using Neural Networks for Intelligent Tool Condition Monitoring*. ASME Journal of Engineering for Industry, Vol. 112, pp. 219-228. 1990.
- [35] Novaković, B., Majetić, D., Široki, M. *Umjetne neuronske mreže*. Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu. Zagreb. 1998.

- [36] Poggio T.; Girosi, F. *A theory of networks for approximation and learning*. MIT Artif.Intell.Lab., Massachusetts Inst.Technol., Cambridge, MA, A.I. Memo 1140. 1989.
- [37] Moody, J.; Darken, C. *Fast learning in networks of locally tuned processing units*. Neural Computation, Vol. 1, No. 2, pp. 281-294. 1989.
- [38] Murat, Z. *Utjecaj parametara aktivacijskih funkcija na odziv RBF neuronske mreže – Završni rad*. Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu. Zagreb. 2015.

PRILOZI

1. CD-R disc