

Klasifikacija temperature kosti kod obrade bušenjem

Topić, Tin

Undergraduate thesis / Završni rad

2018

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://um.nsk.hr/um:nbn:hr:235:907094>

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

ZAVRŠNI RAD

Tin Topić

Zagreb, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

**KLASIFIKACIJA
TEMPERATURE KOSTI KOD
OBRADJE BUŠENJEM**

Mentor:

dr. sc. Danko Brezak, izv. prof.

Student:

Tin Topić

Zagreb, 2018.

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

Najsrdajnije se zahvaljujem mentoru dr. sc. Danku Brezaku, izv. prof. na uloženom trudu i vremenu, stručnoj pomoći, konstruktivnim savjetima te potpori za ostvarenje rada.

Posebno se zahvaljujem obitelji koja mi je omogućila studiranje i pružala podršku tijekom preddiplomskog studija.

Tin Topić



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
 Povjerenstvo za završne 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:	

ZAVRŠNI ZADATAK

Student: **Tin Topić**

Mat. br.: 0035195875

Naslov rada na hrvatskom jeziku: **Klasifikacija temperature kosti kod obrade bušenjem**

Naslov rada na engleskom jeziku: **Bone drilling temperature classification**

Opis zadatka:

U medicinskim zahvatima koji uključuju bušenja kostiju posebna se pažnja mora posvetiti ograničavanju unosa topline u kost kako bi se spriječilo njezino prekomjerno zagrijavanje. Porast temperature iznad 55°C u trajanju kraćem od 30s rezultira nekrozom koštanog tkiva, a time potencijalno i postoperativnim komplikacijama.

Stoga će u ovome radu biti provedena analiza primjene signala sila rezanja i struja pogonskih motora osi bušilice na mogućnost klasifikacije temperature kosti kod bušenja.

Iz snimljenih i filtriranih signala izdvojiti će se niz značajki procesa čija će se iskoristivost u procjeni temperature bušenja detaljno analizirati primjenom algoritma umjetne neuronske mreže.

U radu je potrebno:

1. Izraditi programsku podršku za filtriranje i obradu snimljenih signala procesa bušenja.
2. Iz pripremljenih signala izdvojiti adekvatne značajke procesa.
3. Izraditi programsku podršku za neuronsku mrežu koja će biti primijenjena u klasifikaciji temperature kosti kod bušenja.
4. Izvršiti detaljnu analizu utjecaja svih značajki na kvalitetu procjene temperature.

Zadatak zadan:
 30. studenog 2017.

Zadatak zadao:

Izv. prof.dr.sc. Danko Brezak

Rok predaje rada:
 1. rok: 23. veljače 2018.
 2. rok (izvanredni): 28. lipnja 2018.
 3. rok: 21. rujna 2018.

Predviđeni datumi obrane:
 1. rok: 26.2. - 2.3. 2018.
 2. rok (izvanredni): 2.7. 2018.
 3. rok: 24.9. - 28.9. 2018.

Predsjednik Povjerenstva:

Izv. prof. dr. sc. Branko Bauer

SADRŽAJ

POPIS SLIKA	III
POPIS TABLICA.....	IV
POPIS OZNAKA	V
POPIS KRATICA	VII
SAŽETAK.....	VIII
SUMMARY	IX
1. UVOD.....	1
2. POSTUPAK BUŠENJA KOSTIJU	2
2.1. Trenutno stanje u području bušenja kostiju	2
2.2. Faktori koji utječu na razvoj topline	3
2.3. Sile rezanja kod bušenja.....	5
2.4. Izrada smjernica za bušenje u medicinske svrhe	7
3. UMJETNE NEURONSKE MREŽE	8
3.1. Biološki i umjetni neuron.....	8
3.2. Model statičke neuronske mreže.....	10
3.3. Unaprijedna i povratna faza učenja.....	12
4. EKSPERIMENTALNI POSTAV, MJERNA OPREMA I ISPITNI UZORCI.....	14
4.1. CNC sustav	15
4.2. Konstrukcija stroja	16
4.3. Mjerni sustav.....	17
4.4. Ispitni uzorci	18
5. ANALIZA PODATAKA.....	19
5.1. Ulazni podaci	19
5.2. Slučaj u kojem je korištena značajka $Max(F_z)$	23
5.3. Slučaj u kojem je korištena značajka $Max(F_R)$	24
5.4. Slučaj u kojem su korištene značajke $Max(F_z)$ i $Max(F_R)$	26
5.5. Slučaj u kojem je korištena značajka $Max(I_z)$	27
5.6. Slučaj u kojem je korištena značajka $Max(I_{GV})$	28
5.7. Slučaj u kojem su korištene značajke $Max(I_z)$ i $Max(I_{GV})$	29
5.8. Slučaj u kojem su korištene sve značajke sila i struja.....	31
6. ZAKLJUČAK.....	33
LITERATURA.....	34
PRILOZI.....	37

POPIS SLIKA

Slika 2.1. Postupci predbušenja, bušenja, proširivanja provrta i izrada navoja [17].....	4
Slika 2.2. rezanja kod bušenja [1]	6
Slika 3.1. Pojednostavljeni prikaz biološkog neurona [2].....	8
Slika 4.1. Ispitni postav koji se koristio za dobivanje ulaznih podataka [1]	14
Slika 4.2. Elementi sustava ispitnog postava [1]	15
Slika 4.3. Radni prostor ispitnog stroja [1].....	16
Slika 4.4. Mjerno računalo s korisničkim sučeljima [1].....	17
Slika 4.5. Senzor za mjerenje temperature kortikalisa [1].....	18
Slika 4.6. Ispitni uzorak nakon bušenja [1].....	18
Slika 5.1. Grafički prikaz UK kod značajke $Max(F_z)$ pri $\eta = 0.005$, $\alpha = 0$, $nskrivenih = 3$	23
Slika 5.2. Grafički prikaz UK kod značajke $Max(F_z)$ pri $\eta = 0.025$, $\alpha = 0$, $nskrivenih = 2$	24
Slika 5.3. Grafički prikaz UK kod značajke $Max(F_R)$ pri $\eta = 0.075$, $\alpha = 0$, $nskrivenih = 3$	25
Slika 5.4. Grafički prikaz UK kod značajke $Max(F_R)$ pri $\eta = 0.005$, $\alpha = 0$, $nskrivenih = 3$	25
Slika 5.5. Grafički prikaz UK kod značajki sila pri $\eta = 0.1$, $\alpha = 0$, $nskrivenih = 3$	26
Slika 5.6. Grafički prikaz UK kod značajke $Max(I_z)$ pri $\eta = 0.075$, $\alpha = 0$, $nskrivenih = 3$	27
Slika 5.7. Grafički prikaz UK kod značajke $Max(I_z)$ pri $\eta = 0.05$, $\alpha = 0$, $nskrivenih = 3$	28
Slika 5.8. Grafički prikaz UK kod značajke $Max(I_{GV})$ pri $\eta = 0.025$, $\alpha = 0,01$, $nskrivenih = 3$	29
Slika 5.9. Grafički prikaz UK kod značajki struja pri $\eta = 0.025$, $\alpha = 0.01$, $nskrivenih = 3$	30
Slika 5.10. Grafički prikaz UK kod značajki struja pri $\eta = 0.01$, $\alpha = 0$, $nskrivenih = 3$	30
Slika 5.11. Grafički prikaz UK kod svih značajki pri $\eta = 0.025$, $\alpha = 0$, $nskrivenih = 5$	31
Slika 5.12. Grafički prikaz UK kod svih značajki pri $\eta = 0.025$, $\alpha = 0,05$, $nskrivenih = 3$	32

POPIS TABLICA

Tablica 1. Opis parametara.....	19
Tablica 2. Podaci za učenje	21
Tablica 3. Podaci za testiranje.....	22

POPIS OZNAKA

Oznaka	Jedinica	Opis
f	mm/okr	posmak svrdla
F_a	N	aksijalna sila bušenja
F_c	N	glavna sila rezanja
F_{cp}	N	glavna sila rezanja poprečne oštrice
F_f	N	posmična sila
F_{fp}	N	posmična sila poprečne oštrice
F_p	N	natražna sila
F_R	N	rezultantna sila rezanja
F_t	N	sila trenja
F_z	N	komponenta rezultantne sile rezanja u smjeru z osi
I	-	broj neurona ulaznog sloja mreže
I_{GV}	A	jakost struje glavnog motora
I_z	A	jakost struje posmičnog motora z osi
J	-	broj neurona sakrivenog sloja mreže
K	-	broj neurona izlaznog sloja mreže
K_p	-	pojačanje sustava
net	-	vrijednost funkcije sume
net_{Ok}	-	vrijednost funkcije sume k-og neurona izlaznog sloja
O_k	-	k-ti izlaz neuronske mreže
UK	%	uspješnost klasifikacije
$UK_{testiranja}$	%	uspješnost klasifikacije kod skupa za testiranje
$UK_{učenja}$	%	uspješnost klasifikacije kod skupa za učenje
v_c	m/min	brzina rezanja
v_{ji}	-	težinski koeficijent veze između j-og neurona sakrivenog sloja i i-tog neurona ulaznog sloja
w_{kj}	-	težinski koeficijent veze između k-og neurona izlaznog sloja i j-tog neurona sakrivenog sloja
y	-	vrijednost izlaza neurona
y_j	-	vrijednost izlaza j-og neurona sakrivenog sloja
Z_i	-	i-ti ulaz neuronske mreže
α	-	vrijednost momentuma
δ_{Ok}	-	parametar algoritma povratnog prostiranja pogreške izlaznog sloja
η	-	koeficijent brzine učenja
ϑ	-	parametar učenja (težinski koeficijent)
$\vartheta(n)$	-	trenutna vrijednost parametra učenja

POPIS KRATICA

Kratice	Opis
CNC	Računalno numeričko upravljanje (Computer Numerical Control)
EMC	Vrsta otvorenog CNC upravljačkog sustava (Enhanced Machine Controller)
INGPOS	Inteligentni nadzor glavnog pogona obradnih sustava

SAŽETAK

Bušenje kostiju danas je jedan od uobičajenih zahvata u modernoj medicini. Međutim, ne postoji dovoljan broj istraživanja kako bi se moglo precizno odrediti trošenje svrdla i temperatura kosti koja se razvija tijekom zahvata. Primjena istrošenih svrdla ili preveliki unos topline mogu izazvati postoperativne komplikacije. U ovom radu analizirat će se primjena signala sila rezanja i struja pogonskih motora osi bušilice na mogućnost klasifikacije temperature kosti. Iz snimljenih signala struja i sila izdvojit će se niz značajki procesa. Primjenom umjetne neuronske mreže analizirat će se iskoristivost značajki u procjeni temperature bušenja.

Ključne riječi: termička osteonekroza, sile rezanja, struje pogonskih motora bušilice, statička neuronska mreža

SUMMARY

Bone drilling is one of the common procedures in modern medicine. However, there is insufficient research that has been done to accurately determine wear level and bone temperature generated during this procedure. Worn drill usage or excessive heat development can cause postoperative complications. This work will analyze the application of cutting force signals and currents of the drill motors in bone temperature classification. Process features will be extracted from the recorded current and force signals. The utilization of features in the classification of drilling temperature will be analyzed using artificial neural network.

Key words: thermal osteonecrosis, cutting forces, drill motor currents, static neural network

1. UVOD

Bušenje kostiju postalo je uobičajen zahvat u ortopediji i traumatologiji. Tijekom zahvata dolazi do značajnog oslobađanja topline koja može negativno utjecati na uspješnost zahvata. Toplina se oslobađa zbog trenja između reznog alata i kosti, a porast temperature iznad 55 °C u trajanju kraćem od 30 s dovodi do nekroze koštanog tkiva. Stoga je potrebno posvetiti posebnu pažnju unosu topline kako bi se spriječio nastanak nekroze.

Nekroza koštanog tkiva do koje dolazi uslijed izlaganja povišenim temperaturama je jedan od najutjecajnijih čimbenika kod cijeljenja kosti. Ona uzrokuje gubitak čvrstog kontakta između kosti, odnosno frakturnih ulomaka i osteosintetskog sredstva korištenog za fiksaciju. Vrlo često kod prijeloma donjih ekstremiteta zbog opterećenja uzrokovanog tjelesnom masom dolazi do loma osteosintetskog sredstva [1].

Postoji više faktora koji utječu na povećanje trenja, a samim time i povećanje topline. Neki od tih faktora su: istrošenost reznog alata, brzina rezanja, posmak, fizikalno-kemijske karakteristike kosti te neadekvatna primjena sredstva za hlađenje i ispiranje.

Kako bi se uspješno kontrolirao unos topline potrebno je provesti veliki broj analiza, te ispitati u kojoj mjeri svaki parametar utječe na oslobađanje topline. Cilj ovog rada je analiza utjecaja sila rezanja i struja pogonskih motora osi bušilice na temperaturu. Iz navedenih signala izdvojiti će se značajke istrošenosti svrdla i temperature bušenja koje će se zatim analizirati primjenom algoritma računalne inteligencije. Konkretno, koristit će se statička troslojna perceptronska neuronska mreža koja će biti kreirana u programskom paketu Matlab.

2. POSTUPAK BUŠENJA KOSTIJU

2.1. Trenutno stanje u području bušenja kostiju

Bušenje kostiju je u novije vrijeme postalo uobičajen postupak u koštano-zglobnoj kirurgiji i stomatologiju. Broj zahvata bušenja kostiju postaje sve veći, a prema Alamu et al [3] u SAD-u se godišnje izvrši preko 300 000 artroplastika zgloba koljena. Značajnija istraživanja vezana za sprječavanje termičke osteonekroze kod bušenja započinju u drugoj polovici 20. st. Bušenje kostiju kompleksan je proces koji zahtjeva brojna testiranja i analize kako bi se došlo do podataka koji su od velikog značaja za buduće zahvate. Najvažnija značajka je razvijena toplina koja nepovoljno utječe na uspješnost zahvata. Kost je kompleksno biološko tkivo s nehomogenom strukturom što rezultira složenim mehaničkim i termičkim svojstvima.


Prilikom obrade odvajanjem čestica dolazi do kidanja intermolekularnih veza zbog naprezanja u kosti što čini primarni izvor topline [4]. Sekundarni izvori topline vezani su uz različite oblike trenja: trenje između odvojenih čestica i prednje površine alata, trenje između stražnje površine alata i obrađene površine te trenje između tijela svrdla i unutarnje stijenke provrta. Zanimljivo mali dio oslobođenja topline odvodi se krvlju zbog niskog protoka (2-3 ml/100mg) i brze koagulacije krvi te okluzije krvnih žila [5]. Zbog strukture kosti efekt odvođenja topline preko odvojenih čestica je slabije izražen u odnosu na obradu metalnih materijala [5,6]. Koeficijent provođenja topline kosti nizak je (prosječno $0,56 \pm 0,039$ W/mK) pa je i to jedan od faktora koji utječe na značajniji porast temperature.

Termička svojstva kosti još uvijek nisu detaljno istražena. Stoga se provode istraživanja biokemijskih procesa koji nastaju u koštanom tkivu tijekom i nakon izlaganja povišenim temperaturama. Analiziraju se specifični toplinski kapacitet, koeficijent toplinske vodljivosti s obzirom na smjer, vrstu, starost i karakteristike kosti. Međutim, tijekom brojnih istraživanja došlo se do različitih zaključaka. Pojedina istraživanja daju zaključak o termičkoj anizotropnosti [7, 8] dok druga govore da je kost termički izotropna [9] odnosno da su sva svojstva u svim smjerovima jednaka. Oprečni podaci dobivaju se kod definiranja granične vrijednosti temperature i vremena izlaganja kosti temperaturi nakon kojeg će doći do značajnog termičkog oštećenja. Dobiveni rezultati potvrđuju da se porastom temperature smanjuje potrebno vrijeme izlaganja nakon kojeg dolazi do termičke osteonekroze. Hillery i Shuaib [11] zaključuju da do značajnijih oštećenja dolazi kod temperature od 55 °C i vremena

izlaganja dužem od 30 s. Lundskog zaključuje da je granična temperatura 50 °C uz vrijeme izlaganja od 30 s. S obzirom na navedeno, ne postoji jedinstven zaključak o graničnoj temperaturi.

2.2. Faktori koji utječu na razvoj topline

Postoji niz faktora koji utječu na razvoj topline prilikom bušenja, a neki od njih su: dizajn svrdla, geometrija oštrica, parametri obrade te istrošenost [12]. Dizajn svrdla obuhvaća vrstu, broj i nagib žljebova, promjer svrdla te geometriju oštrica i vršnog kuta. Zadaća žljebova je odvođenje čestica obrađivanog materijala. Također, smanjuju silu trenja u zoni rezanja do koje dolazi uslijed utjecaja odvojenih čestica. Ako odvojene čestice ostanu u provrtu tijekom bušenja, dolazi do povećanja trenja, a samim time i temperature. Svrdla s helikoidnim žljebovima pokazala su se efikasnija od onih s ravnim žljebovima. Najčešće se koriste svrdla s dvije oštrice dok kut uspona mora biti što veći zbog bržeg odvođenja čestica [11]. Svrdla s tri žlijeba unatoč kraćem trajanju buđenja nisu pokazala poboljšanja u smislu smanjenja razvijene topline [12]. Zbog manjeg trenja između čestica i prednje površine alata te bržeg odvođenja odvojenih čestica predlaže se korištenje svrdla s većim pozitivnim prednjim kutom. Predlaže se i veći iznos kuta na stražnjoj površini kako bi se smanjio utjecaj trenja između alata i obrađene površine [13]. Ne postoji jedinstven podatak koliki bi trebao biti kut vrha medicinskih svrdla. Njegov se iznos najčešće kreće u intervalu između 90⁰ i 120⁰ budući da niže vrijednosti mogu uzrokovati ekscentričnu formu provrta [14] dok više vrijednosti mogu uzrokovati veća naprezanja u alatu [15]. Promjer svrdla također je jedan od bitnih faktora koji utječe na temperaturu kosti tijekom bušenja. U nekim istraživanjima zaključuje se da je odnos eksponencijalan [14, 16]. Porastom promjera povećava se i kontaktna površina između svrdla i kosti što pridonosi povećanju trenja odnosno povećanju temperature. S obzirom na okolnosti zahvata, preporučuje se primjena najmanjeg mogućeg promjera svrdla kako temperatura ne bi previše rasla. Predbušenje može značajno pomoći ako je potreban veći promjer provrta. Na slici 2.1. je prikazan tok izrade provrta s navojem.



Slika 2.1. Postupci predbušenja, bušenja, proširivanja provrta i izrada navoja [17]

Idući značajni faktor su parametri obrade. Oni moraju biti usklađeni kako bi obrada bila što efikasnija. Ispravan odabir brzine rezanja i posmaka značajno utječe na smanjenje temperature bušenja. Istraživanja su pokazala da su maksimalni iznosi temperature kod klasičnog bušenja u proporcionalnoj vezi s brzinom rezanja. Međutim, porastom brzine rezanja njihov odnos prestaje biti linearan, odnosno nakon postizanja maksimuma, temperatura se porastom brzine rezanja smanjuje [8, 18,19]. Kod visokobrzinske obrade temperatura koja se stvara je niža od obrade klasičnom brzinom rezanja [20]. S druge strane posmična brzina proporcionalno je vezana uz aksijalnu silu, a obrnuto proporcionalno uz temperaturu kosti. Ako se poveća posmična brzina, smanjuje se vrijeme bušenja te temperatura ostaje niža [14, 16, 19]. Uslijed prevelike sile može doći do mehaničkog oštećenja svrdla.

Dubina bušenja također ima značajan utjecaj na razvijenu temperaturu. Očekivano, s povećanjem dubine postupak dulje traje pa samim time raste i temperatura kosti. Vanjski dio kosti je najtvrdi te o njegovoj debljini ovisi trajanje i iznos vršne temperature bušenja. To je potvrdilo istraživanje Eriksona i Albrektssona [21] u kojem je mjerena temperatura kod bušenja psećih, zećjih i ljudskih bedrenih kostiju. Maksimalna temperatura kod bušenja ljudske kosti je iznosila 89 °C pri srednjoj debljini kortikalisa od 6,5 mm, kod pseće 56 °C pri debljini od 3,5 mm te kod zeće 40 °C pri debljini od 1,5 mm.


Hlađenje je najznačajniji faktor koji smanjuje temperaturu kod bušenja. Sredstvo za hlađenje ima trostruku ulogu: hlađenje, ispiranje odnosno odvođenje odvojenih čestica te podmazivanje. Zbog navedenih karakteristika sustav hlađenja izuzetno je bitan za smanjenje trošenja alata te odvođenje topline i smanjenje temperature kosti. Sustavi hlađenja mogu se podijeliti u dvije skupine: sustavi unutarnjeg hlađenja, kod kojih rashladna tekućina prolazi kroz svrdlo i sustavi vanjskog hlađenja [22, 23]. Sustavi unutarnjeg hlađenja mogu biti otvorenog i zatvorenog tipa. Kod otvorenog tipa rashladna tekućina nakon prolaska kroz svrdlo izlazi na prednjoj površini oštrice, dok kod zatvorenog tipa rashladna tekućina cirkulira u zatvorenom krugu. U medicinskim primjenama još uvijek nedostaju analize koje bi ispitale različite uvjete i vrste hlađenja.

Istrošenost svrdla je još jedan od faktora koji utječe na maksimalnu temperaturu bušenja. Kod istrošenih svrdla povećat će se trenje i produljiti trajanje zahvata. Rezultat će biti više generirane topline i viša temperatura. Medicinska svrdla troše se uslijed mehaničkih, kemijskih i toplinskih utjecaja. Postupci sterilizacije i kontinuiranog korištenja neprestano se izmjenjuju što značajno doprinosi istrošenosti. Mathews i Hirsh [24] zaključili su da stupanj istrošenosti ima značajan utjecaj na maksimalnu temperaturu. Zaključak su donijeli nakon što su usporedili temperature generirane novim svrdlom s onima koje su nastale korištenjem istrošenih svrdla koja su izbušila više od 200 provrta.

Porast temperature i potencijalnu nekrozu kosti može uzrokovati i neadekvatna pozicija i gibanje svrdla. Nadalje, sve navedeno može uzrokovati neadekvatnu geometriju provrta i porast sila što može dovesti do loma vrha ili oštrice alata. Ako dođe do loma vrha ili oštrice alata, nastat će mehanička oštećenja tkiva što znači zahtjevan postoperativni tijek liječenja.

2.3. Sile rezanja kod bušenja

Tijekom bušenja na svrdlo djeluju različite sile rezanja. Te sile prikazane su na slici 2.2. U idealnim uvjetima sile rezanja na svakoj su oštrici jednake budući da se pretpostavlja da je poprečni presjek odvojene čestice jednak [1].



Slika 2.2. rezanja kod bušenja [1]

Sile koje se javljaju kod bušenja [1]:

- sile na glavnim oštricama:
 - dvije jednake i suprotno usmjerene glavne sile rezanja $F_c/2$,
 - dvije jednake i istog smjera posmične sile $F_f/2$,
 - dvije jednake i suprotno usmjerene natražne sile $F_p/2$;
- sile na poprečnoj oštrici:
 - dvije jednake i suprotno usmjerene glavne sile rezanja poprečne oštrice $F_{cp}/2$,
 - posmična sila poprečne oštrice F_{fp} ;
- sile trenja $F_t/2$ uzrokovane trenjem svrdla obrađene površine i odvojenih čestica.

Aksijalna sila određena je rezultantom svih vertikalnih komponenti, odnosno:

$$F_a = F_f + F_{fp} + F_t$$

2.4. Izrada smjernica za bušenje u medicinske svrhe

Singh et al [25] proveli su istraživanje u Velikoj Britaniji na uzorku od 40 bolnica. Zabrinjavajući je podatak da 75% bolnica nije imalo nikakvih smjernica u kontroli i održavanju medicinskih svrdla. Ostale bolnice imale su smjernice vezane uz identifikaciju i označavanje istrošenih svrdla. Osam bolnica pridržavalo se uputa i provodilo neku vrstu kontrole. 45% svih bolnica koristilo je isključivo svrdla za jednokratnu upotrebu. Autori ukazuju na nedostatak konsenzusa po pitanju kontrole istrošenosti i učestalu primjenu istrošenih svrdla. Budući da se dinamika procesa bušenja u industriji često razlikuje od one u medicinske svrhe potrebno je ispitati mogu li rješenja u industriji zadovoljiti potrebe bušenja u medicinske svrhe.


U koštano-zglobnoj kirurgiji primjenjuju se bušilice niskog stupnja automatizacije bez protočnog hlađenja svrdla što znači da se hlađenje najčešće obavlja zalijevanjem površine kosti i tijela svrdla izvan kosti. Efekt hlađenja je ovim pristupom ograničen zbog niske toplinske vodljivosti kosti. Razvojem tehnologije pojavila se potreba za uvođenjem poluautomatskih ili potpuno automatiziranih bušilica koje bi omogućile brži i kvalitetniji operativni zahvat. Za ostvarenje je potrebno realizirati nova istraživanja koja bi upotpunila dosadašnja znanja.

3. UMJETNE NEURONSKE MREŽE

3.1. Biološki i umjetni neuron

Neuronska mreža je mreža koja se sastoji od više međusobno povezanih neurona koji zbog načina povezivanja imaju mogućnost obrađivanja informacija. Umjetne neuronske mreže nastale su iz niza pokušaja modeliranja biofiziologije mozga čovjeka. To podrazumijeva kreiranje modela koji može procesirati informacije analogno aktivnostima mozga čovjeka. Aktivnost neurona se može modelirati kao zbroj otežanih ulaza neurona, a to znači da aktivnost neurona ovisi o broju ulaza, intenzitetu veza i o pragu osjetljivosti. Prije nego što neuron ispali puls signali moraju biti dovoljno jaki da prijeđu prag osjetljivosti.

Biološki neuron se sastoji od tijela, aksona i dendrita koji okružuju tijelo neurona. Akson je oblika tanke cjevčice čiji je jedan kraj povezan na tijelo neurona dok se drugi kraj dijeli na niz grana. Krajevi grana završavaju zadebljanjima koji su uvijek u kontaktu s tijelom preko dendrita, direktno ili preko aksona. Sinapsa je mali razmak između završetka aksona prethodnog neurona i dendrita ili tijela sljedećeg neurona. Akson jednog neurona formira sinaptičke veze s ostalim neuronima. Impulsi putuju kroz akson do sinapsi odakle se različito otežani signali šalju kroz dendrite na tijelo drugih neurona. Neuron će poslati impuls tek ako je njegova uzbuda veća od praga osjetljivosti [2].



Slika 3.1. Pojednostavljeni prikaz biološkog neurona [2]

S druge strane, umjetni neuron je model koji je napravljen s ciljem simulacije biološkog neurona. Sve dijelove biološkog neurona bilo je potrebno zamijeniti drugim elementima pa tako sumator i aktivacijska funkcija zamjenjuju tijelo biološkog neurona, a ulazi u sumator zamjenjuju dendrite. Osjetljivost koja je potrebna da bi se ispalio impuls zamijenjena je aktivacijskom funkcijom. Sinaptičke veze između neurona se simuliraju uvođenjem težinskih faktora. Prema navedenom, može se zaključiti da između mozga i računala postoje određene sličnosti. Oba sustava koriste električne signale, imaju veliki broj jednostavnih elemenata te izvode određene funkcije. Međutim postoje bitne razlike kod rješavanja problema. Računalo može izvršiti veliki broj jednostavnih operacija, ali se proces računanja odvija u sekvencama što znači da se iduća sekvenca izvrši tek kada je prethodna gotova što bitno usporava proces. Iduća razlika je stupanj pogreške. Mozak daje bolje aproksimacije i zaključke iako ponekad ulazi nisu potpuni ili korektni dok je kod računala izuzetno bitno da su ulazi savršeno ispravni. Dok su ulazi savršeni i program ispravan kod računalnog procesiranja podataka neće se pojaviti greške.


Težinski faktori u umjetnom neuronu zamjenjuju sinapse odnosno povezuju izlaze neurona (aksone) s ulazima sumatora (dendriti). Mogu biti pozitivni ili negativni brojevi, a kod složenijih mreža težinski faktor može biti i funkcija koja s obzirom na uvjete mijenja vrijednost. Aktivacijske funkcije mogu biti linearne (izlaz sumatora množi se s nekim faktorom odnosno pojačanjem) i nelinearne (funkcije praga osjetljivosti, sigmoidalne, hiperbolične i harmoničke funkcije). Kod nelinearnih aktivacijskih funkcija izlaz sumatora se prevodi na izlaz neurona preko nelinearnog pojačanja, te na izlazu daje jedinicu ako je izlaz sumatora veći od nekog zadanog broja (praga osjetljivosti). Ako izlaz sumatora ne prijeđe iznos praga osjetljivosti na izlazu neurona će ostati nula. Neuronske mreže mogu biti jednoslojne ili višeslojne. Sloj neuronske mreže se sastoji od skupa neurona koji su paralelno složeni. Višeslojne mreže se uobičajeno sastoje od tri dijela: ulaznog sloja, izlaznog sloja i skrivenih slojeva. Ako je tok signala mreže samo u jednom smjeru onda se takve mreže nazivaju unaprijednim neuronskim mrežama. S druge strane, ako postoji barem jedna povratna petlja onda govorimo o povratnim neuronskim mrežama.

Učenje neuronskih mreža može se izvršiti na dva načina: supervizorno (uz nadzor) i nesupervizorno (bez nadzora). Supervizorno učenje je način učenja kod kojeg vanjski učitelj promatra ponašanje mreže korigirajući istu dok ne dobije željeno ponašanje. Na početku se usvaja određena struktura mreže (broj ulaza, broj neurona, broj slojeva, broj izlaza te broj težina) dok se početne težine stvaranju uz pomoć generatora slučajnih brojeva. Nakon što je

usvojena određena struktura, na ulaz se dovodi skup ulaznih vrijednosti na koje mreža daje odgovarajući skup izlaznih vrijednosti. Skup izlaznih vrijednosti uspoređuje se sa željenim skupom izlaznih podataka pri čemu se dobiva razlika odnosno greška koja služi za računanje novih težina. Postupak se ponavlja iteracijski dok pogreška ne bude manja od željenog iznosa. S druge strane, kod nesupervizornog učenja neuronsku mrežu ne nadgleda vanjski učitelj nego se neuronska mreža sama organizira. Nakon što se na ulaz mreže dovede skup ulaznih vrijednosti, mreža se samoorganizira podešavanjem težina po unaprijed definiranom algoritmu. Kod ovog načina nije predvidivo koji će neuron postati aktivirani za odabrani skup ulaznih vrijednosti. Postoji cijeli niz različitih algoritama učenja, a neki od poznatijih su: generalizirano delta pravilo, povratno propagiranje, Grossbergovo (Hebbianovo) učenje, primjena Lyapunovih funkcija, optimalno učenje, statičko i adaptivno učenje.

3.2. Model statičke neuronske mreže

Model statičke neuronske mreže sastoji se od standardnih modela statičkog neurona koji je prikazan na slici 3.2.




Slika 3.2. Model statičkog neurona

Model statičkog neurona sastoji se od ulaza ($u_1, u_2 \dots u_{n-1}, 1$) i težina (w_1, w_2, w_{j-1}, w_j) koji se sumiraju u sumatoru. Suma prolazi kroz aktivacijsku funkciju iz koje se dobiva konačan izlaz iz neurona. Kako bi se proces učenja mogao izvršiti potrebno je dodati poseban ulaz jedinične vrijednosti (BIAS). Najčešća aktivacijska funkcija je nelinearna bipolarna sigmoidalna funkcija čiji izraz je dan u 3.1. U ovom radu će se kao aktivacijska funkcija koristiti upravo nelinearna bipolarna sigmoidalna funkcija. Navedena aktivacijska funkcija je globalnog karaktera i prikazuje dobre rezultate kada se koristi u učenju dinamičkih sustava.

$$y = \frac{2}{1+e^{-net}} - 1 \quad (3.1)$$

Shema strukture mreže koja će se koristiti u radu je prikazana na slici 3.3.



Slika 3.3. Shema strukture statičke neuronske mreže [2]

Ulazi u mrežu su označeni sa Z_i , izlazi iz mreže s O_k , dok su stvarni izlazi označeni sa d_k . Mreža se sastoji od 3 sloja: ulaznog, sakrivenog i izlaznog sloja. Iako se može koristiti više sakrivenih slojeva ovdje će jedan biti dovoljan. Svi slojevi mreže su u potpunosti umreženi,

odnosno svaki neuron promatranog sloja (osim BIAS-a) vezan je sa svakim neuronom prethodnog sloja. Ulazni sloj je sa sakrivenim slojem vezan vezama koje su opterećene težinama v_{ji} . Isto tako, sakriveni sloj vezan je s izlaznim slojem vezama koje su opterećene težinama w_{kj} . Kao što je prikazano na slici 3.3. učenje se odvija u dvije faze, a to su unaprijedna i povratna.

3.3. Unaprijedna i povratna faza učenja

Kod unaprijedne faze učenja mreža iz vrijednosti svih ulaza Z izračunava izlaze O . Početne vrijednosti težinskih faktora v i w odredit će se generatorom slučajnih brojeva budući da mreža treba konkretne vrijednosti težinskih faktora kako bi ih u svakom novom koraku mogla korigirati u ovisnosti o dobivenim uvjetima. Funkcija sume net neurona skrivenog sloja se dobiva pomoću izraza

$$net_{Hj} = \sum_{i=1}^I v_{ji} Z_i, \quad j = 1, 2, \dots, J - 1, \quad i = 1, 2, \dots, I, \quad (3.2)$$

pri čemu je I broj ulaznih neurona + 1, a J broj skrivenih neurona + 1 (BIAS). Kod izlaznog sloja izraz je sličan

$$net_{Ok} = \sum_{j=1}^J w_{kj} y_j, \quad k = 1, 2, \dots, K, \quad (3.3)$$

pri čemu je K broj izlaza mreže. Aktivacijska funkcija izlaznog sloja će biti linearna funkcija pa će vrijediti izraz 3.4. K_p označava nagib linearne funkcije te će se koristiti $K_p = 1$.

$$O_k = K_p net_{Ok}, \quad k = 1, 2, \dots, K. \quad (3.4)$$

Nakon izvršenja unaprijedne faze slijedi povratna faza u kojoj se mijenjaju težinski faktori na temelju izračunate pogreške učenja. Cijeli postupak ponavlja se dok greška ne padne ispod unaprijed zadane vrijednosti. Da bi se pogreška smanjivala potrebno je koristiti gradijent pogreške te uvesti η , odnosno koeficijent brzine učenja. Koeficijent brzine učenja omogućuje promjenu težinskih koeficijenata u smjeru najstrmijeg pada pogreške. Njega određuje učitelj i mreža postiže najbolje rezultate ako je između 10^{-3} i 10. Promjena parametara težinskih koeficijenata ϑ se definira izrazom

$$\Delta\vartheta = -\eta \nabla E(\vartheta). \quad (3.5)$$

Međutim, najveći nedostatak ovakvog izračuna pogreške je veliki broj potrebnih koraka učenja. Kako bi se smanjio uvode se različite modifikacije osnovnog algoritma. Jedna od njih je uvođenje momentuma kojeg predlaže Zurada [2]. Taj izraz glasi

$$\Delta\vartheta = -\eta\nabla E(\vartheta(n)) + \alpha\Delta\vartheta(n-1), \quad (3.6)$$

pri čemu (n) označava trenutnu promjenu parametra učenja, a (n-1) prethodnu promjenu parametra učenja. Kao i koeficijent brzine učenja vrijednost koeficijenta momentuma određuje učitelj pri čemu se najčešće uzima vrijednost između 0.1 i 0.9. Promjena parametara učenja odvija se od izlaznog prema ulaznom sloju mreže što znači da će se v_{ji} računati tek nakon što bude izračunat w_{kj} . Konačni algoritam za izračun promjene težina izlaznog sloja dobiva se izvodom iz promjene pogreške učenja preko gradijenta greške, a glasi

$$w_{kj}(n+1) = w_{kj}(n) + \eta\delta_{ok}y_j + \alpha\Delta w_{kj}(n-1). \quad (3.7)$$

Nakon što se promjene težine izlaznog sloja mogu se izračunati sve težine sakrivenog sloja. Izraz se može dobiti preko sličnog izvoda

$$v_{ji}(n+1) = v_{ji}(n) + \frac{1}{2}\eta(1-y_j^2)Z_i(\sum_{k=1}^K \delta_{ok}w_{kj}) + \alpha\Delta v_{ji}(n-1). \quad (3.8)$$

Izračunom koeficijenta težina v_{ji} mreža je promijenila sve težine (u slučaju jednog sakrivenog sloja) te se cijeli postupak ponavlja ispočetka. Postupak se prekida nakon određenog broja koraka učenja ili nakon što pogreška mreže padne ispod unaprijed zadane vrijednosti. Budući da je u ovom radu potrebno klasificirati temperaturu kosti kod obrade bušenjem, koristit će se konačan broj koraka. Naime, potrebno je analizirati utjecaj određenih parametara na procjenu temperature, te se neće definirati željena pogreška budući da mreža možda neće moći u svakom slučaju omogućiti željenu grešku. Iz tog razloga, konačan broj koraka iznosi 100 000.

4. EKSPERIMENTALNI POSTAV, MJERNA OPREMA I ISPITNI UZORCI


Za uspješnu provedbu istraživanja potrebno je povezati više različitih sustava u jedinstvenu cjelinu kako bi se omogućilo dobivanje točnih podataka koji će se dalje analizirati. To su prepoznali proizvođači alatnih strojeva i CNC upravljačkih sustava te se počinju sve više koristiti otvoreni upravljački sustavi. Takvi sustavi su fleksibilni u softverskom i hardverskom smislu te standardizirani u smislu integracije s drugim upravljačkim sustavima. Uspješna primjena cjelovitog sustava uvjetovana je mogućnostima integracije većeg broja različitih mjernih sustava s postojećim CNC upravljačkim sustavom stroja. To znači veći broj senzora i softverskih modula za obradu signala koje je potrebno povezati s CNC sustavom.

Ispitni postav na kojem je provedeno prikupljanje podataka zasnovan je na upravljačkom sustavu otvorene upravljačke arhitekture, razvijen zajedničkim naporima Katedre za alatne strojeve i Katedre za strojarску automatiku pri FSB-u u sklopu tehnologijskog projekta „INGPOS inteligentni nadzor glavnog pogona obradnih sustava“ [1]. Sustav za ispitivanje prilagođen je istraživanju bušenja kosti te je dodan niz eksternih mjernih uređaja za odgovarajuća mjerenja.



Slika 4.1. Ispitni postav koji se koristio za dobivanje ulaznih podataka [1]

4.1. CNC sustav



- a) Ožičenje CNC upravljačkog sustava - pogled srijeda
 b) Ožičenje CNC upravljačkog sustava - pogled s boka
 c) NC pult

1. NC Računalo
2. Napajanja logičkih krugova
3. Napajanje NC računala
4. Napajanje servo regulatora
5. Servo regulatori pogonskih motora
6. Logički krugovi
7. Sklopovlje za pretvorbu signala
8. Sigurnosni relej
9. Sklopke za pojedinačno iskapčanje servo regulatora
10. Konektori za spajanje pogonskih motora (napajanje i enkoder), referentnih i graničnih prekidača
11. Konektori sučelja za povezivanje s vanjskim sustavima

Slika 4.2. Elementi sustava ispitnog postava [1]

Upravljački sustav sastoji se od NC računala s instaliranim EMC2 sustavom koje je zajedno s pripadajućim sustavima napajanja, servo regulatorima pogonskih motora i ostalim ulazno- izlaznim sklopovljem smješteno u elektro-ormar [1].

Posmičnim motorima upravlja se po principu kaskadne regulacije s regulacijskim petljama po momentu, brzini i poziciji. Regulacijska petlja po poziciji izvodi se u sklopu NC računala, dok se preostali dio odvija u sklopu ugrađenih servo regulatora. Povratna veza pozicije i brzine gibanja za svaki motor izvedena je inkrementalnim enkoderima [1].

Osim regulatora posmičnih progona, ugrađen je niz sklopova za prilagodbu upravljačkih i mjernih signala, te logičkih sklopova i konektora za kontrolu SHIP-a,


podmazivanje izmjenu alata i sl. Napajanje servo regulatora i NC računala izvedeno je odvojenim transformatorima. Napajanje logičkih krugova i istosmjernih trošila izvedeno je iz dva zasebna stabilizirana izvora istosmjernog napona.

Regulacija pogonskih motora po brzini i momentu izvedena je digitalnim servo regulatorima tvrtke Advanced Motion Control, Inc. (AMC) predviđenim za upravljanje sinkronim motorima s permanentnim magnetom ili istosmjernim motorima s nezavisnom uzbudom [1].

NC računalo se temelji na PC konfiguraciji koje se sastoji od dva četverojezrena procesora AMD Opteron 2346HE, 8 GB ECC RAM memorije, matične ploče ASUS KFN32-D. Ovakva konfiguracija omogućava upravljanje svim alatnim strojevima te obradu signala i izvršavanje naprednih algoritama računalne inteligencije.

4.2. Konstrukcija stroja

Osnova ispitnog stroja je mala tro-osna glodalica, čiji su posmični prigoni izvedeni kliznim vodilicama i kugličnim navojnim vretenima, dok je glavni prigon izveden izravnim prijenosom momenta glavnog motora na svrdlo putem odgovarajuće stezne glave [1].



a) Radni prostor stroja

1. Posmični prigon X osi
2. Posmični prigon Y osi
3. Posmični prigon Z osi
4. Glavni motor
5. Infracrvena grijalica
6. Stezna naprava
7. Senzor sila (tro-komponentni)
8. Senzor vibracija (tro-komponentni)

b) Detaljni prikaz ugrađenih senzora

9. Senzor akustične emisije
10. Industrijska kamera s telecentričnim objektivom i rasvjetom
11. Termopar kortikalisa
12. Termoparovi okoliša
13. Termopar medularnog kanala
14. Ispitno svrdlo
15. Ispitna kost

Slika 4.3. Radni prostor ispitnog stroja [1]

Oko stroja nalazi se limeno kućište s dvostrukim stijenkama kako bi se osigurali stalni temperaturni uvjeti. Stroj je opremljen nizom senzora za direktni i indirektni nadzor alata. Za pogon glavnog i posmičnih prigona koristili su se sinkroni servo motori s permanentnim magnetima.

4.3. Mjerni sustav

Za istraživanje je korišteno više različitih mjernih sustava kako bi se sakupilo što više podataka. Na slici 4.4. prikazano je mjerno računalo.




Slika 4.4. Mjerno računalo s korisničkim sučeljima [1]

U prostor stroja ugrađeni su senzori za mjerenje sila rezanja, vibracija i akustične emisije, industrijska kamera te termoparovi za mjerenje temperature kortikalisa, okoliša i modularnog kanala. Signali jakosti struje su dobiveni iz odabranih servo-regulatora u sklopu CNC upravljačkog sustava [1].

Sile rezanja i jakosti struje svih motora također su snimane i u sklopu vanjskog mjernog računala. Razlog je sinkronizacija signala sa signalom temperature kortikalisa. Signali sila rezanja prikupljali su se pomoću piezo-električnog tro-komponentno senzora sila (tip 9257B) i odgovarajućeg nabojnog pojačala (tip 5017B) proizvođača Kistler Holding AG. Senzor sila je montiran na radni stol.

Za mjerenje temperature korišten je termopar K tipa. Termopar je smješten u posebno izrađeno kućište koje se sastoji iz dva međusobno spojena cilindrična dijela različitih promjera.



Slika 4.5. Senzor za mjerenje temperature kortikalisa [1]

4.4. Ispitni uzorci

Za dobivanje podataka korištene su goveđe kosti. Debljina kortikalisa kod goveđih kostiju je veća od svinjskih kosti. To je omogućilo dulje snimanje obradnog procesa što omogućava provođenje većeg broja ispitivanja na istom uzorku.

Tijekom skladištenja kosti su zamrznute na temperaturu ispod $-10\text{ }^{\circ}\text{C}$ kako bi se zadržala termodinamička svojstva. Pokusi na istoj kosti nikad nisu trajali dulje od 2 h zbog mogućeg gubitka vlage isušivanjem [1].



Slika 4.6. Ispitni uzorak nakon bušenja [1]

5. ANALIZA PODATAKA

5.1. Ulazni podaci

Za ulazne podatke postojale su 2 skupine podataka te se svaka skupina sastojala od 40 skupova podataka. Svaki skup podataka sastojao se od značajki koje su prikazane u Tablici 1.

Tablica 1. Opis parametara

Oznaka	Opis
f	Posmak u mm/okr
v_c	Brzina rezanja u m/min
$Max(F_z)$	Prosjek 10% najvećih vrijednosti sile F_z pri čemu je z os u smjeru posmaka
$Max(F_R)$	Prosjek 10% najvećih vrijednosti sile F_R pri čemu R označava rezultantu
$Max(I_z)$	Prosjek 10% najvećih apsolutnih vrijednosti struje I_z pri čemu je z os u smjeru posmaka
$Max(I_{gv})$	Prosjek 10% najvećih vrijednosti struje I_{GV} pri čemu GV označava glavno vreteno
T_{max}	Najviša temperatura

Prva skupina je skupina za učenje što znači da su podaci iz te skupine ulazili u neuronsku mrežu i na temelju njih je mreža izračunavala težinske faktore. Mreža je na temelju težinskih faktora izračunavala kolika je uspješnost klasifikacije učenja ($UK_{učenja}$) nakon svakog koraka i to je bilo grafički prikazano na kraju učenja. Nakon svakog koraka učenja mreža je u zasebnom potprogramu provela samo unaprijednu fazu na podacima iz druge skupine, odnosno podacima za testiranje iz čega se dobila uspješnost klasifikacije testiranja ($UK_{testiranja}$) koja je također bila grafički prikazana. Dakle, prva skupina (podaci za učenje) služili su za podešavanje težinskih faktora dok se druga skupina (podaci za testiranje) koristila za određivanje uspješnosti klasifikacije i podaci ove skupine nisu se koristiti za izmjenu težinskih faktora. Postojale su dvije skupine vezane uz maksimalnu temperaturu. Granična temperatura je iznosila 55 °C pa se prva klasifikacijska skupina sastojala od uzoraka čija je maksimalna temperatura manja od 55 °C dok su u drugoj skupini uzorci s maksimalnom temperaturom većom od 55 °C. Uspješnost klasifikacije u obje skupine se dobivala preko identičnog izlaza:

$$UK = \frac{\text{broj ispravno klasificiranih uzoraka}}{\text{ukupan broj uzoraka u skupini}} \cdot 100\%. \quad (5.1)$$

Broj ispravno klasificiranih uzoraka označava broj uzoraka kod kojih se rezultat mreže uvrstio u istu skupinu temperature u kojoj se nalazila izmjerena temperatura što znači da su dobiveni težinski faktori dali ispravno rješenje za taj uzorak.

Filtrirani podaci su prikazani u tablicama 2 i 3. Kako bi mreža mogla koristiti podatke prvo ih je potrebno normalizirati. Nakon normalizacije podaci su uvršteni u neuronsku mrežu.

Tablica 2. Podaci za učenje


Redni broj	f	v_c	$Max(Fz)$	$Max(Fr)$	$Max(Iz)$	$Max(I_{GV})$	T_{max}
1	0.05	30	150.9080	151.7204	0.325798	0.192548	58.290
2	0.05	30	164.2688	165.4540	0.379005	0.197556	58.162
3	0.05	30	158.9970	160.2864	0.341311	0.197086	59.010
4	0.05	30	151.4944	152.4977	0.316665	0.191960	59.187
5	0.05	30	166.5632	167.6671	0.353925	0.197174	59.328
6	0.05	50	160.0119	161.3565	0.345223	0.189120	56.634
7	0.05	50	158.6826	159.6717	0.341879	0.172621	53.863
8	0.05	50	156.8563	157.8151	0.331214	0.184522	60.512
9	0.05	50	166.3807	167.5493	0.361088	0.186300	48.009
10	0.05	50	164.3691	165.2757	0.333572	0.182656	51.821
11	0.10	30	231.4981	233.0469	0.526674	0.332939	50.582
12	0.10	30	224.0376	225.7956	0.530072	0.306330	52.547
13	0.10	30	219.6137	221.1152	0.483203	0.298093	51.333
14	0.10	30	186.9382	187.9646	0.446735	0.280872	51.832
15	0.10	30	251.2624	252.9305	0.537693	0.289811	50.250
16	0.10	50	244.1175	245.7339	0.549020	0.292555	49.598
17	0.10	50	245.5919	247.2419	0.542484	0.284909	48.190
18	0.10	50	223.0998	224.6598	0.496489	0.286390	49.848
19	0.10	50	217.2064	218.7809	0.473149	0.375859	54.069
20	0.10	50	278.0109	280.0208	0.629174	0.296754	47.710
21	0.05	30	149.0983	150.1393	0.296289	0.198082	63.591
22	0.05	30	184.5087	185.9890	0.357808	0.236893	62.157
23	0.05	30	169.5773	170.1865	0.344458	0.212788	61.157
24	0.05	30	152.2746	153.4841	0.292163	0.208146	69.557
25	0.05	30	160.3353	160.6168	0.368803	0.264191	73.646
26	0.05	50	169.0822	170.3957	0.348332	0.203079	58.256
27	0.05	50	159.4669	159.9851	0.304466	0.201103	61.777
28	0.05	50	193.7190	195.3912	0.417887	0.218808	62.954
29	0.05	50	173.9148	175.4057	0.334128	0.214923	61.967
30	0.05	50	173.9488	175.0591	0.350071	0.192704	53.983
31	0.10	30	264.9966	267.2152	0.568536	0.311829	58.018
32	0.10	30	349.7629	351.0201	0.760698	0.314380	56.025
33	0.10	30	347.0237	349.4527	0.775781	0.324506	53.769
34	0.10	30	338.1470	340.7249	0.715316	0.365841	61.561
35	0.10	30	393.8466	396.5035	0.842169	0.331315	54.662
36	0.10	50	357.6234	358.9162	0.768110	0.312241	56.893
37	0.10	50	295.5491	296.6079	0.723641	0.285107	51.575
38	0.10	50	355.6842	356.9286	0.784848	0.288783	49.769
39	0.10	50	376.6167	379.2561	0.822101	0.517628	65.351
40	0.10	50	329.1463	331.4048	0.707498	0.298246	54.803

Tablica 3. Podaci za testiranje


Redni broj	f	v_c	$Max(Fz)$	$Max(Fr)$	$Max(Iz)$	$Max(I_{GV})$	T_{max}
1	0.05	30	137.7059	138.8033	0.314910	0.191698	59.576
2	0.05	30	174.5141	175.5441	0.386546	0.215154	59.117
3	0.05	30	168.9169	170.2018	0.371630	0.203784	52.749
4	0.05	30	178.5591	179.6274	0.411549	0.191598	56.356
5	0.05	30	170.9439	171.9171	0.375234	0.200108	62.787
6	0.05	50	153.9945	154.9197	0.323240	0.189986	53.930
7	0.05	50	157.8387	158.9985	0.335734	0.174152	51.222
8	0.05	50	142.3618	143.4115	0.302951	0.182878	56.655
9	0.05	50	160.2797	161.1886	0.332713	0.186652	49.797
10	0.05	50	163.9706	165.0144	0.337664	0.187789	51.255
11	0.10	30	221.289	222.8251	0.481764	0.359046	54.643
12	0.10	30	219.6147	221.2826	0.496489	0.330079	56.178
13	0.10	30	212.2946	213.5956	0.451027	0.280971	50.860
14	0.10	30	285.4527	287.4233	0.644955	0.301547	49.163
15	0.10	30	244.3800	245.8555	0.522840	0.299601	50.556
16	0.10	50	278.9056	280.6485	0.621423	0.291821	48.108
17	0.10	50	239.6167	240.9443	0.522718	0.277539	48.949
18	0.10	50	286.0391	287.9534	0.620009	0.289387	46.492
19	0.10	50	239.4428	241.1427	0.515827	0.298051	50.640
20	0.10	50	228.4131	229.9632	0.519243	0.330098	51.011
21	0.05	30	160.7968	161.6298	0.322858	0.207601	70.353
22	0.05	30	172.6920	174.0690	0.350211	0.223561	70.038
23	0.05	30	155.6034	156.9012	0.298151	0.203495	58.294
24	0.05	30	202.5487	203.9262	0.408183	0.225598	58.410
25	0.05	30	184.7069	186.5891	0.399533	0.237827	66.234
26	0.05	50	145.8960	146.9568	0.264583	0.175148	53.917
27	0.05	50	172.2093	172.8839	0.338268	0.203157	58.334
28	0.05	50	167.1950	168.4050	0.326900	0.188221	56.018
29	0.05	50	156.7952	157.6745	0.302523	0.188119	59.557
30	0.05	50	157.4522	158.7998	0.287616	0.186980	57.997
31	0.10	30	342.2267	344.3431	0.783394	0.333643	59.355
32	0.10	30	290.3617	292.4240	0.729251	0.324416	55.044
33	0.10	30	355.7834	358.3832	0.848443	0.322659	50.239
34	0.10	30	378.0460	380.7307	0.825946	0.369216	57.470
35	0.10	30	335.1497	337.4714	0.742844	0.384079	64.753
36	0.10	50	318.8120	321.3868	0.675619	0.305096	55.191
37	0.10	50	328.7464	330.7897	0.728966	0.288362	48.638
38	0.10	50	312.2871	313.3802	0.683391	0.325008	54.682
39	0.10	50	323.4871	325.7398	0.746589	0.306988	49.653
40	0.10	50	452.3062	455.3321	1.051152	0.343602	55.882

5.2. Slučaj u kojem je korištena značajka $Max(F_z)$

Za početak, trebalo je vidjeti koje su mogućnosti uspješnosti klasifikacije ako se koristi samo značajka $Max(F_z)$. Uz silu, ostali ulazni podaci u mrežu bili su posmak i brzina rezanja. Provedeno je učenje i testiranje sa 17 različitih kombinacija parametara η , α i broja skrivenih neurona. Kod izbora parametara neuronske mreže težilo se da uspješnost klasifikacije bude što veća. Na slikama 5.1. i 5.2. nalaze se grafički prikazi pri parametrima $\eta = 0.005$, $\alpha = 0$, $n_{skrivениh} = 3$ te $\eta = 0.025$, $\alpha = 0$, $n_{skrivениh} = 2$. Na apscisi nalazi se broj koraka (ograničen na 100 000), a na ordinati se nalazi UK. Crvenom bojom prikazan je $UK_{testiranja}$ dok je plavo označen $UK_{učenja}$.



Slika 5.1. Grafički prikaz UK kod značajke $Max(F_z)$ pri $\eta = 0.005$, $\alpha = 0$, $n_{skrivениh} = 3$



Slika 5.2. Grafički prikaz UK kod značajke $Max(F_z)$ pri $\eta = 0.025$, $\alpha = 0$, $n_{skrivjenih} = 2$


Uspješnost klasifikacije primjenom značajke $Max(F_z)$ pokazala se relativno niskom. $UK_{učenja}$ uglavnom je bio između 70 i 80% što je uspješnije od $UK_{testiranja}$. S druge strane, u većini slučajeva $UK_{testiranja}$ je već nakon par stotina koraka pao na 47.5% i tu bi ostao dok se ne izvrši svih 100 000 koraka. Međutim, u dva slučaja mreža je dala $UK_{testiranja}$ od 65% na većem intervalu. Jedan od tih slučajeva je prikazan na slici 5.1. gdje se može vidjeti da je do 44 000. koraka mreža postizala $UK_{testiranja}$ od 67.5%. Nakon toga najvjerojatnije je uslijedila pretreniranost te su rezultati koje je mreža postizala bili daleko niži. Na slici 5.2. prikazana je jedna od neuspješnih kombinacija parametara mreže. Ovim mjerenjem može se zaključiti da primjena značajke $Max(F_z)$ bez kombinacije s ostalim značajkama procesa neće biti dovoljna u klasifikaciji temperature kosti.

5.3. Slučaj u kojem je korištena značajka $Max(F_R)$


Sila F_R određena je preko sljedećeg izraza

$$F_R = \sqrt{F_x^2 + F_y^2 + F_z^2}. \quad (5.2)$$

Rezultati koji su dobiveni primjenom značajke $Max(F_R)$ malo su bolji od rezultata postignutih značajkom $Max(F_z)$ međutim i dalje je uspješnost klasifikacije relativno niska što je prikazano na slikama 5.3. i 5.4.



Slika 5.3. Grafički prikaz UK kod značajke $Max(F_R)$ pri $\eta = 0.075$, $\alpha = 0$, $n_{skrivjenih} = 3$




Slika 5.4. Grafički prikaz UK kod značajke $Max(F_R)$ pri $\eta = 0.005$, $\alpha = 0$, $n_{skrivjenih} = 3$

$UK_{učenja}$ je uglavnom bio između 70 i 80%. U većini slučajeva $UK_{testiranja}$ je već nakon par stotina koraka postizao vrijednosti od 47.5% i tu bi ostao dok se ne izvrši svih 100 000 koraka. U tri slučaja mreža je postigla $UK_{testiranja}$ veći od 60% na većem intervalu. Jedan od

tih slučajeva je prikazan na slici 5.3. gdje se može vidjeti da je do 38 000. koraka mreža postizala $UK_{testiranja}$ između 62.5 i 67.5%. Nakon toga najvjerojatnije je uslijedila pretreniranost te su rezultati poprimili niže vrijednosti. Na slici 5.4. je prikazana jedna od neuspješnih kombinacija parametara. Ovim mjerenjem može se zaključiti da niti značajka $Max(F_R)$ neće postići dobre rezultate kod procjene temperature.

5.4. Slučaj u kojem su korištene značajke $Max(F_z)$ i $Max(F_R)$

Rezultati koji su postignuti ako su ulazne podatke predstavljale značajke $Max(F_z)$ i $Max(F_R)$ su slični prethodnim rezultatima. Dakle, $UK_{učenja}$ je varirao između 70 i 80% dok je $UK_{testiranja}$ u većini slučajeva poprimao vrijednost od 47.5% nakon prvih nekoliko stotina koraka. Najbolji rezultat koji odstupa od ostalih rezultata prikazan je na slici 5.5.




Slika 5.5. Graficki prikaz UK kod značajki sila pri $\eta = 0.1$, $\alpha = 0$, $n_{skriventh} = 3$


$UK_{učenja}$ je brzo dostigao vrijednost 77.5% dok je $UK_{testiranja}$ u prvih nekoliko stotina koraka postizao vrijednosti od 67.5%, a ubrzo i vrijednost 47.5%. Nakon gotovo 50 000 koraka UK testiranja počinje postizati više vrijednosti te se zaustavlja na 67.5%. S obzirom na to da je kod većine ispitivanja korištenjem ovih značajki $UK_{testiranja}$ brzo padao na 47.5% može se pretpostaviti da je postotak od 67.5% bliži slučajnosti nego pravilu. To znači da sile nisu dovoljno dobar izvor informacija za kvalitetnu klasifikaciju temperature. Međutim postoji mogućnost da bi veći broj mjerenja možda postigao bolje rezultate.

5.5. Slučaj u kojem je korištena značajka $Max(I_z)$

Izlazni rezultati mreže kod primjene signala struja su bolji od onih koji se dobiju korištenjem signala sila. Međutim, i dalje postoji veliki broj parametara neuronske mreže kod kojih će mreža nakon malog broja koraka postići konstantnu vrijednost od 47.5%. Dva grafička prikaza u kojima je korištena značajka $Max(I_z)$ nalaze se na slikama 5.6. i 5.7.



Slika 5.6. Grafički prikaz UK kod značajke $Max(I_z)$ pri $\eta = 0.075$, $\alpha = 0$, $n_{skrivenih} = 3$




Slika 5.7. Grafčki prikaz UK kod značajke $Max(I_z)$ pri $\eta = 0.05$, $\alpha = 0$, $n_{skrivnih} = 3$

UK_{ucenja} je postizao vrijednosti između 70 i 80% što znači da je mreža dobro namjestila težinske koeficijente za prvu skupinu podataka. Na slici 5.6 može se vidjeti da nakon $UK_{testiranja}$ postiže konstantnu vrijednost od 67,5% (osim na intervalu između 58 000. i 75 000. koraka) što ide u prilog dobrom rezultatu. Veće oscilacije prikazane su na slici 5.7. Kod ove kombinacije parametara mreže $UK_{testiranja}$ je postizao rezultate od 30% pa sve do 75%.

5.6. Slučaj u kojem je korištena značajka $Max(I_{GV})$

Kao i kod prethodnih značajki i kod maksimalnih vrijednosti signala struje glavnog vretena $Max(I_{GV})$ postoje kombinacije parametara koje na izlazu daju loša rješenja, odnosno nakon nekoliko stotina koraka dolazi do pada $UK_{testiranja}$ na vrijednost 47.5%. Ukupan broj tih kombinacija je 6 što znači manje od pola ukupnog broja korištenih kombinacija parametara neuronske mreže. S obzirom na navedeno, primjena značajke $Max(I_{GV})$ postiže dobre rezultate, a jedan od boljih rezultata predočen je na slici 5.8.




Slika 5.8. Grafički prikaz UK kod značajke $Max(I_{GV})$ pri $\eta = 0.025$, $\alpha = 0.01$ $n_{skrivnih} = 3$


Nakon 9000 koraka mreža je došla do vrijednosti $UK_{testiranja}$ od 82.5% što je relativno dobar rezultat, iako je interval broja koraka u kojem je postignuta navedena vrijednost vrlo uzak. Unatoč tome što je uspješnost klasifikacije nakon toga počela padati, vrijednost nije padala ispod 67.5%. Uzrok pada može biti pretreniranost, te mreža više nije sposobna dobro generalizirati.

5.7. Slučaj u kojem su korištene značajke $Max(I_z)$ i $Max(I_{GV})$

Rezultat koji su postigle značajke obiju struja uspješniji je od rezultata koje je dobiven samo primjenom značajke $Max(I_{GV})$. Neuronska mreža je samo u 4 od 17 različitih kombinacija parametara neuronske mreže postigla loše rezultate što je također dobar pokazatelj. Izlazi koje je postigla mreža prikazani su na slikama 5.9. i 5.10.



Slika 5.9. Grafički prikaz UK kod značajki struja pri $\eta = 0.025$, $\alpha = 0.01$, $n_{skrivnih} = 3$




Slika 5.10. Grafički prikaz UK kod značajki struja pri $\eta = 0.01$, $\alpha = 0$, $n_{skrivnih} = 3$

Na prethodnim slikama može se vidjeti da $UK_{učenja}$ nakon relativno malog broja koraka postiže vrijednost od 80%. $UK_{testiranja}$ također je došao do relativno visoke vrijednosti. Na slikama se može vidjeti da prelazi vrijednost od 70% (u kratkim intervalima koraka čak i


80%) što je vrlo dobro ako se uzme u obzir da su za ulaz uzeti samo signali struja. Signali struja su definitivno postigli bolje izlaze u odnosu na signale sile.

5.8. Slučaj u kojem su korištene sve značajke sila i struja

Kao i u prethodnim slučajevima, i ovdje postoje kombinacije parametara neuronske mreže kod kojih se dobivaju loši rezultati. Međutim, ukupno gledajući rezultati su dobri budući da većina $UK_{testiranja}$ oscilira oko visokih postotaka (70-80%). Na slikama 5.11. i 5.12. prikazani su $UK_{učenja}$ i $UK_{testiranja}$ kod parametara neuronske mreže $\eta = 0.025$, $\alpha = 0$ $n_{skrivenih} = 5$ te $\eta = 0.025$, $\alpha = 0,05$ $n_{skrivenih} = 3$.



Slika 5.11. Grafički prikaz UK kod svih značajki pri $\eta = 0.025$, $\alpha = 0$ $n_{skrivenih} = 5$



Slika 5.12. Grafički prikaz UK kod svih značajki pri $\eta = 0.025$, $\alpha = 0.05$ $n_{skrivjenih} = 3$

Iz prethodnih grafičkih prikaza može se vidjeti visok postotak $UK_{učenja}$ od 80-90%. $UK_{testiranja}$ ima dosta oscilacija budući da su sve značajke uključene u ulaz pa težinski faktori dosta osciliraju.

6. ZAKLJUČAK

Nakon provedenog učenja i testiranja različitih ulaznih značajki uz različite kombinacije parametara mreže dobiveno je mnoštvo različitih rezultata. Budući da su uzorci za učenje i testiranje relativno mali teško je sa sigurnošću dati točan zaključak. Za pouzdanija rješenja trebalo bi povećati uzorke te dodati treći uzorak koji bi se koristio za validaciju. Međutim, i s korištenim podacima moguće je dati konkretne zaključke. Parametre mreže nije moguće jednoznačno odrediti jer za svaku značajku drugačije kombinacije parametara postižu najbolje rezultate. Stoga je potrebno svaku značajku testirati sa što više različitih kombinacija kako bi se našla ona koja daje najvišu vrijednost UK .

Najbolji rezultati su dobiveni kod korištenja svih značajki kao ulaznih podataka. $UK_{testiranja}$ je pri određenim parametrima mreže postizao vrijednosti veće od 70% (u nekim slučajevima i više od 80%, ali na kratkim intervalima) što govori da postoji veza između sila i struja. To se moglo pretpostaviti i prije samog testiranja mreže budući da će porastom struje rasti i sila rezanja, a samim time trenje i temperatura kosti kod bušenja. Uzevši u obzir da su korištene samo dvije značajke uz pomoć kojih se dobio UK testiranja veći od 70% maksimalna temperatura bušenja se može relativno uspješno procijeniti iz signala struja i sila.

Kod testiranja svake značajke zasebno, može se zaključiti da su struje postigle bolji rezultat od sila. Rezultati $UK_{testiranja}$ koje su postigle sile vrlo često su završavali na vrijednosti od 47.5%. Samo na temelju sila bilo bi teško kvalitetno procijeniti temperaturu koju će poprimiti kost tijekom bušenja. Za najbolje rezultate je ipak potrebno koristiti obje značajke.

LITERATURA

- [1] Staroveški T.: *Modeliranje trošenja medicinskog svrdla*, Fakultet strojarstva i brodogradnje, Zagreb, 2013.
- [2] Novaković, B., Majetić, D., Široki, M.; *Umjetne neuronske mreže*, Fakultet strojarstva i brodogradnje, Zagreb, 1998.
- [3] K. Alam, A. V. Mitrofanov, V. V. Silberschmidt, Experimental investigations of forces and torque in conventional and ultrasonically-assisted drilling of cortical bone, *Medical Engineering & Physics*, Article in press, 2010.
- [4] Y. Huang, S. Y. Liang, Modelling of the cutting temperature distribution under the tool flank wear effect, *Journal of Mechanical Engineering Science*, Vol. 217, pp. 1195-1208, 2003.
- [5] S. Karmani, The thermal properties of bone and the effects of surgical intervention, *Current Orthopaedics*, Vol. 20, pp. 52-58, 2006.
- [6] R. Komanduri, Z. B. Hou, Thermal modelling of the metal cutting process - Part III: temperature rise distribution due to the combined effects of shear plane heat source and the tool-chip interface frictional heat source, *International Journal of Mechanical Sciences*, Vol. 43, pp. 89-107, 2001.
- [7] E.S. Zelenov, Experimental investigation of the thermophysical properties of compact bone, *Mechanics of Composite Materials*, Vol. 21, pp. 759-762, 1985.
- [8] M. B. Abouzgia, D. F. James, Temperature rise during drilling through bone, *The International Journal of Oral and Maxillofacial Implants*, Vol. 12, pp. 342-353, 1997.
- [9] J. Lundskog, Heat and bone tissue - An experimental investigation of the thermal properties of bone and threshold levels from thermal injury, *Scandinavian Journal of Plastic and Reconstructive Surgery*, Vol. 6, pp. 5-75, 1972.
- [10] M.T. Hillery, I. Shuaib, Temperature effects in the drilling of human and bovine bone, *Journal of Materials Processing Technology*, Vol. 92-93, pp. 302-308, 1999.
- [11] C. Natali, P. Ingle, J. Dowell, Orthopaedic bone drills—can they be improved?, *The Journal of Bone Joint Surgery*, Vol. 78-B, pp. 357-362, 1996.

- [12] N. Bertollo, H.R.M. Milne, L.P. Ellis, P.C. Stephens, R.M. Gillies, W.R. Walsh, A comparison of the thermal properties of 2- and 3-fluted drills and the effects on bone cell viability and screw pull-out strength in an bovine model, *Clinical Biomechanics*, Vol. 25, pp. 613-617, 2010.
- [13] G.E. Chacon, D.L. Bower, P.E. Larsen, E.A. McGlumphy, F.M. Beck, Heat Production by 3 Implant Drill Systems After Repeated Drilling and Sterilization, *Journal of Oral and Maxillofacial Surgery*, Vol 64, pp. 265-269, 2006.
- [14] G. Augustin, S. Davila, K. Mihoci, T. Udiljak, D. S. Vedrına, A. Antabak, Thermal osteonecrosis and bone drilling parameters revisited, *Archives of Orthopaedic and Trauma Surgery*, Vol. 128, pp. 71-77, 2007.
- [15] .E. Chacon, D.L. Bower, P.E. Larsen, E.A. McGlumphy, F.M. Beck, Heat Production by 3 Implant Drill Systems After Repeated Drilling and Sterilization, *Journal of Oral and Maxillofacial Surgery*, Vol 64, pp. 265-269, 2006.
- [16] V. Kalidindi, Optimization of drill design and coolant systems during dental implant surgery, *PhD thesis*, University of Kentucky, 2004.
- [17] <http://glidewell dental.com/education/inclusive-dental-implant-magazine/volume-3-issue-3/bone-quality-based-drilling-protocol-achieving-high-primary-stability/> (datum posjete: 26.1.2018.)
- [18] M. B. Abouzgia, J. M. Symington, Effect of drill speed on bone temperature, *International Journal of Oral and Maxillofacial Surgery*, Vol. 25, pp. 394-399, 1996.
- [19] Y. Reingewirtz, S. Szmukler-Moncler, B. Senger, Influence of different parameters on bone heating and drilling time in implantology, *Clinical Oral Implants Research*, Vol. 8, pp.189-197, 1997.
- [20] T. Udiljak, D. Ciglar, S. Škorić, Investigation into bone drilling and thermal bone necrosis, *Advances in Production Engineering & Management* , Vol. 2, pp. 103-112, 2007.
- [21] R. A. Eriksson, T. Albrektsson, 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.
- [22] B. Eyup, O. Babur, Effects of different cooling conditions on twist drill temperature, *The International Journal of Advanced Manufacturing Technology*, Vol. 34, pp. 867-877, 2007.

-
- [23] B. C. Sener, G. Dergin, B. Gursoy, E. Kelesoglu, I. Slih, Effects of irrigation temperature on heat control in vitro at different drilling depths, *Clinical Oral Implants Research*, Vol. 20, pp. 294-298, 2009.
- [24] L. S. Mathews, C. Hirsch, Temperature measured in human cortical bone when drilling, *The Journal of Bone Joint Surgery*, Vol. 54-A, pp. 297-308, 1972.
- [25] J. Singh, J.H. Davenport, D.J. Pegg, A national survey of instrument sharpening guidelines, *The Surgeon*, Vol. 8, pp. 136-139, 2010.

PRILOZI

I. CD-R disc