

# Klasifikacija tvrdoće obratka kod bušenja kamena primjenom signala vibracija

---

Šlankovič, Matej

Master's thesis / Diplomski rad

2023

*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:235:570663>

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

*Download date / Datum preuzimanja:* **2024-09-07**

*Repository / Repozitorij:*

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



SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# DIPLOMSKI RAD

**Matej Šlankovič**

Zagreb, 2023.

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# DIPLOMSKI RAD

Mentor:

Prof. dr. sc. Danko Brezak, dipl. ing.

Student:

Matej Šlankovič

Zagreb, 2023.

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i prijašnjeg obrazovanja uz pomoć navedene literature.

*Od srca se zahvaljujem mentoru prof. dr. sc. Danku Brezaku na dostupnosti, pomoći te korisnim savjetima tijekom izrade rada.*

*Neizmjerno se zahvaljujem obitelji, djevojci Lari i svim prijateljima na pruženoj potpori i strpljenju tijekom studiranja.*

Matej Šlankovič



SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite  
Povjerenstvo za diplomske ispite studija strojarstva za smjerove:  
Proizvodno inženjerstvo, inženjerstvo materijala, industrijsko inženjerstvo i menadžment,  
mehatronika i robotika, autonomni sustavi i računalna inteligencija

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa: 602 - 04 / 23 - 6 / 1	
Ur.broj: 15 - 23 -	

## DIPLOMSKI ZADATAK

Student: **Matej Šlankovič** JMBAG: 0035212814

Naslov rada na hrvatskom jeziku: **Klasifikacija tvrdoće obratka kod bušenja kamena primjenom signala vibracija**

Naslov rada na engleskom jeziku: **Workpiece hardness classification using vibration signals in stone drilling**

Opis zadatka:

Kamen je izrazito heterogen i anizotropni materijal karakteriziran svojim mineralnim sastavom, teksturom i strukturom. Varijacije fizikalno-kemijskih svojstava različitih vrsta kamena imaju značajnog utjecaja na dinamiku obradnog procesa. Pritom je tvrdoća jedno od najznačajnijih svojstava kamena s direktnim utjecajem na sile rezanja. Varijacije tvrdoće u zoni rezanja često utječu na povećanu dinamiku trošenja reznog alata, a time, posljedično, mogu utjecati i na lom alata i/ili obratka. Stoga je određivanje tvrdoće za vrijeme obrade kamena i sličnih izrazito nehomogenih materijala istovremeno izazovan zadatak, ali i nužan segment nadzora obradnih sustava i procesa.

Posebnost ovog rada je analiza signala vibracija u klasifikaciji tvrdoće kamenih obradaka bušenih novodizajniranim svrdlima s kanalom za ispuhivanje, a čija je primjena u laboratorijskim uvjetima pokazala značajno manje sile rezanja, vibracije i intenzitet trošenja rezne oštrice.

U radu je potrebno:

1. Izraditi programsku podršku za obradu snimljenih signala vibracija i izdvajanje značajki.
2. Izraditi programsku podršku za neuronsku mrežu koja će biti primijenjena u klasifikaciji tvrdoće kamenih obradaka.
3. Izvršiti detaljnu analizu utjecaja svih značajki procesa i njihovih kombinacija na kvalitetu procjene tvrdoće.
4. Izvesti zaključke rada.

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

Zadatak zadan:

4. svibnja 2023.

Datum predaje rada:

6. srpnja 2023.

Predviđeni datumi obrane:

17. – 21. srpnja 2023.

Zadatak zadao:

  
Prof.dr.sc. Danko Brezak

Predsjednik Povjerenstva:

  
Prof. dr. sc. Ivica Garašić

**SADRŽAJ**

Sadržaj.....	I
Popis slika .....	III
Popis tablica .....	IV
Popis oznaka.....	V
Sažetak .....	VII
Summary .....	VIII
1. Uvod.....	1
2. Nadzor procesa bušenja kamena .....	4
2.1. Vrste nadzora .....	4
2.2. Indirektni nadzor obradnih procesa – vrste signala.....	8
2.2.1. Jakost električnih struja motora .....	8
2.2.2. Sile rezanje i moment glavnog vretena.....	9
2.2.3. Akustična emisija .....	9
2.2.4. Vibracije pri bušenju .....	9
2.3. Nadzor tvrdoće .....	10
2.3.1. Model sustava za indirektni nadzor tvrdoće .....	10
2.3.2. Unaprjeđenja eksperimenta.....	12
3. Opis eksperimenta .....	15
3.1. Eksperimentalni postav .....	15
3.1.2. Ispitni stroj .....	15
3.1.3. Mjerna oprema .....	18
3.2. Vrste kamenih uzoraka .....	21
3.3. Mjerenje, obrada signala i izdvajanje značajki .....	22
3.4. Neuronska mreža s radijalnim baznim funkcijama .....	26
3.4.1. Struktura mreže i matematički model.....	26
3.4.2. Učenje i testiranje mreže.....	29

---

3.4.3. Podaci za učenje i testiranje mreže .....	32
4. Klasifikacija tvrdoće kamena .....	34
4.1. Prvi korak klasifikacije tvrdoće kamena .....	34
4.2. Međukorak klasifikacije tvrdoće .....	36
4.3. Drugi korak klasifikacije .....	37
5. Zaključak .....	41
Literatura .....	42

**POPIS SLIKA**

<b>Slika 1.1.</b> CNC obradni centar proizvođača Okuma [2].....	1
<b>Slika 1.2.</b> Podjela obradnih procesa [1].....	2
<b>Slika 1.3.</b> Dijelovi spiralnog svrdla [3] .....	2
<b>Slika 2.1.</b> Uobičajeno nadzirane veličine pojedinih dijelova obradnog sustava [4].....	6
<b>Slika 2.2.</b> Udjeli pojedinih mehanizama trošenja u ukupnom trošenju u ovisnosti o temperaturi [7] .....	7
<b>Slika 2.3.</b> Trošenje alata tijekom njegova radnog vijeka [8] .....	7
<b>Slika 2.4.</b> Model indirektnog nadzora obradnog procesa [3] .....	11
<b>Slika 2.5.</b> Svrdlo s kanalom za ispuhivanje, shematski (lijevo) i stvarni (desno) prikaz [7] ..	12
<b>Slika 2.6.</b> Usporedba potrošenosti spiralnog svrdla i spiralnog svrdla s kanalom za ispuhivanje [7] .....	13
<b>Slika 2.7.</b> Oštrice na kraju eksperimenta, svrdlo s kanalom za ispuhivanje (lijevo) i konvencionalno svrdlo (desno) [7] .....	13
<b>Slika 3.1.</b> Eksperimentalni postav [3].....	15
<b>Slika 3.2.</b> Elementi ispitnog stroja [3] .....	16
<b>Slika 3.3.</b> Modul glavnog prigona [3] .....	17
<b>Slika 3.4.</b> Upravljački sustav ispitnog postava [3] .....	18
<b>Slika 3.5.</b> Položaj senzora na ispitnom stroju [3] .....	19
<b>Slika 3.6.</b> Tok signala mjernog sustava [3].....	19
<b>Slika 3.7.</b> Korisničko sučelje programskog paketa LabView [3] .....	20
<b>Slika 3.8.</b> Primjer imena datoteke generiranog programskim paketom LabView [3] .....	21
<b>Slika 3.9.</b> Izmjerene vrijednosti tvrdoće u ovisnosti o broju mjerenja [3] .....	22
<b>Slika 3.10.</b> Vizualni prikaz kombinacija parametara korištenih u eksperimentu [3].....	23
<b>Slika 3.11.</b> Tok određivanja stupnja istrošenosti alata [3,7] .....	24
<b>Slika 3.12.</b> Struktura RBF neuronske mreže [3].....	27
<b>Slika 3.13.</b> Podjela podataka na skupove za učenje i testiranje [3] .....	33



## POPIS TABLICA

Tablica 2.1. Srednje vrijednosti aksijalnih sila ( $F_z$ ) [7].....	14
Tablica 2.2. Srednje vrijednosti jakosti struja pogonskog motora osi Z ( $I_z$ ) [7].....	14
Tablica 2.3. Srednje vrijednosti jakosti struja pogonskog motora glavnog vretena ( $I_{gv}$ ) [7].	14
Tablica 3.1. Tehničke karakteristike ispitnog stroja [3].....	16
Tablica 3.2. Pregled mehaničkih svojstva ispitnih kamenih uzoraka [3].....	21
Tablica 4.1. Kombinacije značajki korištenih u prvom koraku klasifikacije [3].....	34
Tablica 4.2. Najuspješniji rezultati svakog frekvencijskog pojasa nakon prvog koraka klasifikacije .....	35
Tablica 4.3. Ukupan broj izdvojenih jedinstvenih značajki iz svih kombinacija značajki za svaki postavljeni prag uspješnosti.....	37
Tablica 4.4. Kombinacije značajki korištenih u drugom koraku klasifikacije [3].....	37
Tablica 4.5. Rezultati uspješnosti klasifikacije tvrdoće nakon drugog koraka s obzirom na UK > 55 % u prvome koraku.....	38
Tablica 4.6. Rezultati uspješnosti klasifikacije tvrdoće nakon drugog koraka s obzirom na UK > 60 % u prvome koraku.....	39
Tablica 4.7. Rezultati uspješnosti klasifikacije tvrdoće nakon drugog koraka s obzirom na UK > 65 % u prvome koraku.....	39
Tablica 4.8. Rezultati uspješnosti klasifikacije tvrdoće nakon drugog koraka s obzirom na UK > 70 % u prvome koraku.....	40
Tablica 4.9. Rezultati uspješnosti klasifikacije tvrdoće nakon drugog koraka s obzirom na UK > 75 % u prvome koraku.....	40

## POPIS OZNAKA

Oznaka	Jedinica	Opis
$C$	-	matrica težinskih faktora RBF mreže
$c_j$	-	$j$ -i vektor težinskih faktora RBF mreže
$c_{jw}$	-	težinski faktor RBF mreže, koji povezuje $j$ -i neuron skrivenog sloja i $w$ -ti neuron izlaznog sloja
$E(VIB_i)$	-	energija spektra signala vibracija u smjeru $i$ -te Kartezijeve koordinatne osi
$E(VIB_{XYZ})$	-	suma energije spektra signala vibracija Kartezijevih koordinatnih osi
$f$	Hz	frekvencija
$f_D$	Hz	donja granica frekvencijskog pojasa
$f_G$	Hz	gornja granica frekvencijskog pojasa
$F_Z$	N	sila rezanja u smjeru $Z$ osi
$H$	-	matrica učenja RBF mreže
$H_{ij}$	-	elementi matrice učenja RBF mreže
$h(\bullet)$	-	aktivacijska funkcija
$H^+$	-	Moore-Penroseov pseudoinverz matrice
$HK$	MPa	tvrdća po Knoop-u
$I_{GV}$	A	jakost električne struje motora glavnog vretena
$I_Z$	A	jakost električne struje posmičnog motora $Z$ osi
$K$	-	broj neurona sakrivenog sloja RBF mreže
$L$	-	broj ulaznih neurona RBF mreže
$M$	-	broj izlaznih neurona RBF mreže
$O$	-	matrica izlaza RBF mreže
$O_w$	-	vrijednost $w$ -tog izlaznog neurona RBF mreže
$r_{ij}$	-	Mahalanobisova udaljenost između $i$ -tih elemenata ulaznih neurona i elemenata $j$ -tog vektora centra
$S_i$	-	$i$ -ti stupanj istrošenosti
$T_i$	-	rezultat klasifikacije $i$ -te testne skupine

---

$\mathbf{t}_j$	-	$L$ -dimenzionalni vektor centra $j$ -tog neurona sakrivenog sloja RBF mreže
$UK$	-	uspješnost klasifikacije
$VB$	mm	širina potrošenosti stražnje površine alata
$v_c$	m/min	brzina rezanja
$\mathbf{x}$	-	ulazni vektor RBF mreže
$z_{pg}$	-	$g$ -ta komponenta $p$ -tog uzorka $j$ -te grupe
$X, Y, Z$	-	osi Kartezijevog pravokutnog koordinatnog sustava
$XYZ_{SUM}$		suma značajki svih Kartezijevih osi
$\sigma_g$	-	vrijednost fiktivnog ili stvarnog maksimalno udaljenog uzorka
$\Sigma_j$	-	kovarijantna matrica $j$ -og vektora centra

## **SAŽETAK**

Kroz rad se istražuje mogućnost primjene neuronske mreže s radijalnim baznim funkcijama za klasifikaciju tvrdoće kamena na temelju signala vibracija snimljenih pri obradi bušenjem. U prvom dijelu rada iznosi se značaj i vrste nadzora obradnih procesa, što je dodatno prošireno dubljim pregledom karakteristika signala snimanih tijekom indirektnog nadzora. Na kraju teorijskog dijela, analizirani su model obradnog sustava s modulom za indirektni nadzor tvrdoće kamena i novodizajnirano svrdlo s kanalom za ispuhivanje. Nakon teorijskog dijela, detaljno je prikazan provedeni eksperiment. Redom su opisani: eksperimentalni postav, korištene vrste kamenih uzoraka, mjerenje i obrada signala, te izdvajanje značajki. Zatim je iznesena struktura, matematički model i principi rada neuronske mreže s radijalnim baznim funkcijama. Naposljetku su prikazani rezultati provedenog eksperimenta te je iznesen konačan zaključak o primjenjivosti mreže za klasifikaciju tvrdoće.

Ključne riječi: bušenje, indirektni nadzor, klasifikacija tvrdoće kamena, neuronske mreže

**SUMMARY**

The paper explores the possibility of applying the radial basis function neural network for the stone hardness classification based on vibration signals measured during drilling process. In the first part of the paper, the importance and types of monitoring of machining processes are presented. Which is additionally expanded by a deeper overview of indirectly monitored signals. At the end of the theoretical part, the model of machining system with the module for indirect stone hardness monitoring and the newly designed drill bit with a channel that allows the flow of cutting fluids were analyzed. After the theoretical part, the conducted experiment is thoroughly described in the following order: the experimental setup, used types of stone samples, measurement and processing of signals, and feature extraction. Subsequently followed by explanation of the structure, mathematical model and operating principles of the radial basis function neural network. Final chapter presents the results of conducted experiment and concluding remarks of applicability of neural network for hardness classification.

Keywords: drilling, indirect monitoring, stone hardness classification, neural networks


## 1. UVOD

Još od pamtivijeka, ljudi nastoje olakšati procese obrade kojekakvim alatima i oruđima. Prve inačice modernih alata, drvene bušilice s kamenim svrdlima, pojavljuju se u drevnom Egiptu 4000 godina prije Krista. Od vremena drevnog Egipta pa sve do danas tehnologija obrade konstantno napreduje i razvija se. Jednom od najvažnijih inovacija smatra se tehnologija numeričkog upravljanja, tj. računalnog numeričkog upravljanja (engl. computer numerical control, CNC) i direktnog numeričkog upravljanja (engl. direct numerical control, DNC) obradnim sustavima. Primjenom CNC i DNC tehnologija upravljanja obradnim sustavima postiže se izuzetna preciznost i uniformnost serije proizvoda, zbog čega navedene tehnologije predstavljaju neizostavni dio velike većine proizvodnih pogona [1]. Slika 1.1 prikazuje jednu od mnogobrojnih inačica CNC obradnog centra.



**Slika 1.1.** CNC obradni centar proizvođača Okuma [2]

Obradni procesi mogu se podijeliti na tradicionalne (obrada odvajanjem čestica) i netradicionalne. Kod tradicionalnih procesa, alat prodire do predodređene dubine u obradak i odvaja čestice s njegove površine. Konačan oblik proizvoda postiže se u ovisnosti o relativnim gibanjima između alata i obratka. Tradicionalni procesi zahtijevaju alat veće tvrdoće nego obrađivani materijal, a kod netradicionalnih procesa to nije uvjet, dapače, većinom nema kontakta između alata i stroja. Netradicionalni procesi koriste elektrokemijske, termalne i druge metode temeljene na eroziji [1]. Kompletna podjela obradnih procesa prikazana je na slici 1.2.



Slika 1.2. Podjela obradnih procesa [1]

Od niza navedenih procesa, u ovome je radu korišten postupaka obrade bušenjem. Bušenje je tradicionalni kontinuirani obradni proces koji služi za izrađivanje i proširivanje provrta. Svrdo (alat za bušenje) ima konačan broj reznih oštrica, najčešće tri, pri čemu su najčešće dvije rezne i jedna poprečna oštrica. Pri obradi bušenjem razlikujemo dvije vrste gibanja, kontinuirana rotacija svrdla (glavno) i kontinuirano translacijsko (posmično) gibanje. Tijekom bušenja najvažniji parametri obrade su: brzina rezanja, posmak, te dubina obrade. Također prilikom bušenja poželjna je upotreba SHIP-a, odnosno sredstva za hlađenje, ispiranje i podmazivanje, u svrhu redukcije trošenja i zagrijavanja alata. Postoje razne izvedbe svrdla za obradu bušenjem, no u praksi najčešće se koristi spiralno svrdlo [1,3]. Izgled spiralnog svrdla te njegovi dijelovi prikazani su na slici 1.3.



Slika 1.3. Dijelovi spiralnog svrdla [3]

Tijekom eksploatacije reznog alata dolazi do stalnog porasta stupnja istrošenosti njegovih reznih oštrica, a što uzrokuje neželjene vibracije alata i niz potencijalno ozbiljnih oštećenja alata, obratka i/ili stroja. Navedeno dovodi do pada kvalitete proizvodnje, a u najgorem slučaju i zastoja. Stoga se u moderne obradne sustave uvode nadzorni sustavi koji omogućuju prepoznavanje navedenih problema u ranoj fazi nastanka. Detekcija problema temelji se na analizi slika alata ili procesnih signala kao što su: sile rezanja, vibracije, akustične emisije, temperature i sličnima. Procesne varijable izdvojene iz navedenih signala procesa su u direktnoj korelaciji sa stanjem alata i režimima obradnog procesa. Tijekom nadzora, kontinuirano se prikupljaju analogni signali iz procesa pomoću raznovrsnih senzora. Zatim se prikupljeni analogni signali pretvaraju u digitalne signale iz kojih se generiraju značajke koje se dalje evaluiraju najčešće pomoću metoda umjetne inteligencije. O krajnjem rezultatu obavještava se operater stroja ili numerički kontroler koji izvršava potrebnu korekciju obradnog procesa [4].

Cilj ovog diplomskog rada je istražiti mogućnosti klasifikacije tvrdoće kamena korištenjem procesnih varijabli izdvojenih iz signala vibracija, a koji su snimljeni pri obradi bušenjem primjenom novodizajniranog svrdla s kanalom za ispuhivanje. Rad se sastoji od ukupno pet poglavlja. Prvo poglavlje daje kratki uvod u obradne procese i nadzor istih. Drugo poglavlje detaljno opisuje nadzor obradnih procesa s naglaskom na indirektni nadzor. U trećem poglavlju opisan je provedeni eksperiment, odnosno korišteni postav i kameni uzorci, postupak snimanja i obrade signala te korištena neuronska mreža primijenjena u klasifikacije tvrdoće. Kroz četvrto poglavlje raspravljani su dobiveni rezultati eksperimenta, dok su u petom poglavlju izneseni zaključci doneseni na temelju dobivenih rezultata.



## 2. NADZOR PROCESA BUŠENJA KAMENA

Kroz ovo poglavlje detaljno se opisuje proces nadzora obradnog procesa bušenja. Na početku su opisane vrste nadzora i nadziranih parametara procesa. Također opisan je utjecaj vrste materijala na promatrane parametre procesa. Zatim je dan kratki pregled indirektnih metoda nadzora, pritom je stavljen naglasak na nadzor vibracija prilikom procesa bušenja. Na kraju je dodatno objašnjen postupak nadzora tvrdoće.

### 2.1. Vrste nadzora


Sustav za nadzor procesa može se klasificirati prema tri kategorije, a to su:

- način prikupljanja podataka:
  - direktni
  - indirektni
  
- broj različitih mjernih sustava:
  - jednosenzorski
  - višesenzorski
  
- mjesto smještanja na obradni stroj:
  - interni
  - eksterni

U modernim nadzornim sustavima praktički je nemoguće pronaći jednosenzorski sustav s obzirom da je to tehnologija korištena u samim počecima nadzornih procesa koja nije pokazala pouzdane rezultate. Nadalje, s obzirom na smještaj samih senzora, za nadzor se najčešće koriste eksterno smješteni vizijski sustavi i senzori. Problem internog smještaja mjernog sustava leži u dohvaćanju podataka, odnosno potrebno je imati direktan pristup upravljačkoj jedinici. Također interni mjerni sustav ne bilježi samo stanje alata već i informacije o dinamici stroja. Stoga je pri upotrebi internih mjernih sustava potrebno voditi računa o šumovima u snimljenim signalima. Prednost korištenja internih sustava je što oni dolaze ugrađeni u stroj, te nije potrebno nadodavati komponente na konstrukciju stroja čime bi se mogla umanjiti njegova funkcionalnost. U eksperimentalnim sustavima, puno češće se koriste eksterni mjerni sustavi koji se postavljaju na postojeću konstrukciju obradnog centra. Naspram internih mjernih sustava, prednost eksternih sustava je mogućnost njihove relativno jednostavne zamjene, nadogradnje ili uklanjanje komponente ukoliko je s vremena na vrijeme to potrebno učiniti [3].


Općenito se podrazumijeva korištenje višesenzorskih sustava, a mjesto smještaja najčešće ovisi da li su senzori tvornički ili naknadno ugrađeni u sustav. Stoga se može reći kako je glavna podjela ona prema načinu prikupljanja podataka. Korištenjem direktnih metoda nadzora, moguće je dobiti izravnu informaciju o stanju reznih oštrica alata. Direktne metode za određivanje stanja oštrice koriste laserske, optičke i ultrazvučne senzore ili vizijske sustave. Korištenje navedenih sustava nije moguće osim dok stroj nije izvan pogona zbog korištenja znatnih količina SHIP-a prilikom bušenja te velike količine odvojenih čestica. Osim što navedeni faktori ometaju rad mjerne opreme, također potrebno je štiti mjernu opremu od istih. Zaštita mjerne opreme predstavlja dodatan problem i znatno povećava cijenu sustava u okolini kao što je industrijski pogon. Iz navedenog slijedi da je mjerenja moguće obaviti samo između dva ciklusa obrade. Stoga će znatna oštećenja alata unutar samoga ciklusa obrade biti otkrivena prekasno [3-5].

Indirektne metode su znatno ekonomičnije, te omogućuju prikupljanje podataka o stanju oštrica i uvjeta procesa u stvarnom vremenu tijekom obrade („on-line“ nadzor) čime se zapravo omogućuje pravovremena promjena režima obrade ili zaustavljanje obradnog procesa. Umjesto izravnih informacija, indirektne metode pružaju informacije o parametrima kao što su sile rezanja, vibracije, jakost električne struje pogonskih motora stroja, temperature u zoni obrade i sličnima, a koji se mogu dovesti u korelaciju s određenim stanjem alata, obratka ili stroja. Nedostatak indirektnih metoda bi bio način prikupljanja podataka, te potrebni dodatni računalni resursi za obradu svih prikupljenih podataka. Slika 2.1 prikazuje tipične mjerene parametre izmjerene direktnim i indirektnim metodama, na pojedinim dijelovima obradnog sustava. Za nadzor obradnih sustava četiri su najprimjenjivnije grupe senzora: senzori sile/momenta, akcelometri, senzori akustične emisije, te senzori snage i jakosti električne struje pogonskih motora [3-5].



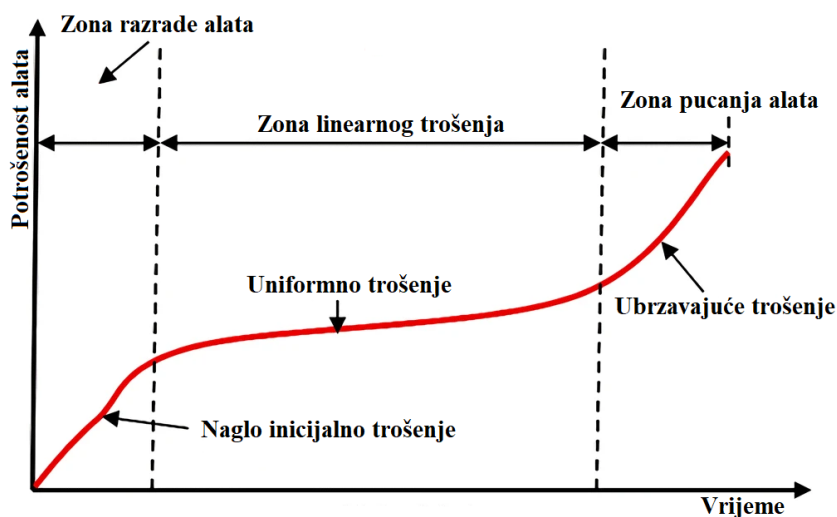
**Slika 2.1.** Uobičajeno nadzirane veličine pojedinih dijelova obradnog sustava [4]

U navedenoj literaturi, najčešće se spominje primjena nadzornog sustava za nadzor trošenja i sprječavanje loma alata. Tri glavna uzroka trošenja alata su: abrazija između alata i obratka, adhezija odvojenih čestica, te difuzijsko trošenje. Abrazijsko trošenje nastaje uslijed kontakta između alata i obratka. Izraženije je kod nižih temperatura, te nedovoljnog i/ili neadekvatnog podmazivanja alata uslijed obrade. Tijekom obrade pri nižim temperaturama, može doći do naljepljivanja odvojenih čestica s alata ili obratka na reznu oštricu. S daljnjom obradom dolazi do otkidanja naljepka, a zajedno sa njime i dijela rezne oštrice. Taj proces naziva se adhezijsko trošenje alata. Osim temperature, na adheziju utječu tlak između alata i obratka, te razina hrapavosti kontaktnih površina. Pritom viša razina hrapavosti znatno povećava mogućnost pojave adhezije. Difuzijsko trošenje najčešće se susreće pri obradama visokim brzinama, uslijed porasta temperature, te pri korištenju alata izrađenoga od tvrdoga metala i keramike. Uzrokovano je kemijskim opterećenjima koja se povećavaju shodno porastu temperature, te afinitetom materijala alata prema materijalu obratka. Najefektivnije se suzbija korištenjem različitih vrsta površinskih prevlaka. Osim navedenih vrsta trošenja, postoje još manje zastupljene sljedeće vrste trošenja: oksidacijsko trošenje, plastična deformacija rezne oštrice i trošenje uslijed umora materijala [3,6]. Prema slici 2.2, vidljivo je kako pri niskim temperaturama prevladava trošenje uslijed adhezije i abrazije. Dok s porastom temperature utjecaj adhezije slabi, a javlja se difuzijsko i oksidacijsko trošenje.



**Slika 2.2.** Udjeli pojedinih mehanizama trošenja u ukupnom trošenju u ovisnosti o temperaturi [7]

Trošenje alata tijekom njegova radnog vijeka može se podijeliti u tri faze, kao što je prikazano na slici 2.3. U prvoj fazi (faza razrade alata) dolazi do naglog inicijalnog trošenja alata. Zatim dolazi do stabilizacije trošenja, a posljedica toga je uniformno trošenja alata tijekom znatnog dijela radnog vijeka što je vidljivo u zoni linearnog porasta krivulje trošenja. Pred kraj radnog vijeka dolazi do sve većeg ubrzavanja trošenja i to sve dok ne dođe do loma alata ili razine istrošenosti koja čini alat neupotrebljivim [6,8].



**Slika 2.3.** Trošenje alata tijekom njegova radnog vijeka [8]

Nadzor obradnog procesa kod obrade homogenih materijala znatno je jednostavniji proces zbog relativno nepromijenjenih fizikalno-mehaničkih svojstava obratka. No to nije slučaj kod heterogenih i anizotropnih materijala kao što su kamen ili različiti kompoziti. Provedena je nekolicina eksperimenata u kojima je zaključeno kako upravo kod takvih, heterogenih

materijala dolazi do povećanoga trošenja alata uslijed nepoznavanja navedenih svojstava i njima neprilagođenih režima obrade. Zbog toga je potreba za nadzorom tvrdoće materijala obratka, kao jednog od najvažnijih parametara o kojemu ovisi dinamika trošenja alata, kod istih još veća, kako bi se pravovremeno mogle izvršiti korekcije parametara obrade. U literaturi je moguće pronaći istraživanja u kojima je već dokazana korelacija između tvrdoće kamena i jakosti električne struje pogona servomotora, tvrdoće kamena i posmaka alata pri konstantnoj aksijalnoj sili, korelacija između tlačne čvrstoće kamena, aksijalne sile i posmaka alata te ostale korelacije. Također, istraživanja provedena još u 2010-oj godini pokazuju značajan međusobni utjecaj istrošenosti alata na klasifikaciju tvrdoće obratka, u smislu da s povećanjem istrošenosti alata dolazi do povećanja parametara procesa na temelju kojih se zatim mogu donijeti pogrešni zaključci o tvrdoći. Važno je napomenuti kako indirektnim nadzorom nije moguće odrediti vrijednost tvrdoće materijala, već s obzirom na snimljene značajke procesa i poznate tvrdoće uzoraka moguće je klasificirati tvrdoću obratka ili odrediti da li je došlo do promjene, odnosno njezinog porasta ili smanjenja [9]. Detalji o samom nadzoru tvrdoće izloženi su u poglavlju 2.3. Nadzor tvrdoće.

## **2.2. Indirektni nadzor obradnih procesa – vrste signala**

Kao što je već prethodno rečeno, najčešći snimani signali primijenjeni u indirektnim metodama nadzora su: sile i momenti, jakost električnih struja, akustična emisija (AE) i vibracije.

### **2.2.1. Jakost električnih struja motora**

Jakost električne struje mjeri se na motoru glavnog vretena ili motorima posmičnih prigona. Brojna istraživanja su već pokazala jako dobru povezanost između vrijednosti jakosti električne struje s istrošenosti alata, loma alata, kolizijom alata, te tvrdoćom obratka. Pritom za detekciju loma alata dovoljno je koristiti samo jedan senzor, dok je za ostale parametre je potreban višesenzorski pristup. Za mjerenje struja najčešće se koriste analogni senzori temeljeni na Hallovom efektu. Hallov efekt je pojava pri kojoj se u metalnoj ili poluvodičkoj jezgri priključenoj u krug istosmjerne struje, uslijed djelovanja magnetskog polja i Lorentzove sile, stvara napon i struja. Važno je napomenuti kako su pri obradi malim svrdlima, potrebne su vrlo male struje za odvajanje čestica materijala. Stoga je potrebno koristiti pojačala signala kako bi se i dalje dobili pouzdani rezultati [3,4,10,11].

### **2.2.2. Sile rezanje i moment glavnog vretena**

Silama rezanja moguće je odrediti stanje alata, kvalitetu obrađene površine te režime obrade. Pritom se u nadzoru mogu koristiti tri vrste sila rezanja: glavna, posmična i natražna silu. Više o samim silama koje se javljaju u procesu obrade bušenjem može se pronaći u doktorskom radu [3]. S obzirom na provedena istraživanja, literatura preporučuje primjenu aksijalne posmične sile u postupcima nadzora obradnog procesa bušenjem. Dokazano je kako mjerenjem samo aksijalne sile, uslijed premale osjetljivosti, dobivaju se neupotrebljivi podaci u industrijskoj okolini. Stoga je za ostvarivanje pouzdanih rezultata potrebno mjeriti i moment glavnoga vretena zajedno s aksijalnom silom rezanja. Međutim, valja napomenuti kako će navedena kombinacija dati pouzdane rezultate samo prilikom obrade materijala s relativno homogenom tvrdoćom. Ukoliko se održavaju aksijalne sile na konstantnima vrijednostima, moguće je odrediti tvrdoću obrađivanog kamena pomoću posmične brzine. Sile rezanja i momenti glavnog vretena najčešće se mjere pomoću piezoelektričnih senzora [3,4,11].

### **2.2.3. Akustična emisija**

Akustična emisija može se definirati kao elastični valovi koji se prenose alatom i konstrukcijom koja ga veže uz stroj. Valovi nastaju uslijed naglog izbijanja energije iz obratka ili alata uslijed npr. trenja između obratka te prednje i stražnje površine alata, plastične deformacije u obratku, otkidanja čestica alata, formiranja pukotine u alatu i slične pojave tijekom obrade. Mjerenjem akustične emisije dobivaju se veoma pouzdani rezultati o lomu alata jer pritom dolazi do pojave signala vrlo visokih amplituda. Za mjerenje akustične emisije, najčešće se koriste piezoelektrični senzori sa širokim mjernim područjima (otprilike 50 kHz do 2 MHz) [3,4,11].

### **2.2.4. Vibracije pri bušenju**

Uslijed obrade bušenjem postoji više uzroka pojave vibracija, a neke od njih su: kontakt između obratka i alata, rotacija vretena i trošenje alata. Iz toga slijedi da sukladno promjenama na alatu ili režimima obrade dolazi do promjene amplitude i frekvencije signala vibracija. Istraživanjima je pokazano kako signali vibracija najviše ovise o materijalu obratka, parametrima obrade i konstrukciji stroja. Na materijal obratka nije moguće utjecati, dok se na konstrukciji stroja mogu napraviti preinake kako bi se što više smanjile vibracije, no njih nikada neće biti moguće skroz eliminirati. Iz toga razloga, potrebno je što bolje prilagoditi režime obrade kako bi se maksimalno smanjile vibracije. Prema konferencijskom zborniku [12], dokazano je kako kod nekih materijala, primjerice titanija i njegovih legura, posmak alata ima najveći utjecaj na aksijalne sile, momente i vibracije tijekom obrade bušenjem. Što je volumen odvojene čestice

u vremenu veći potrebna je veća sila rezanja i veće su površine u kontaktu. S većim površinama u kontaktu javljaju se veći udari, te zbog toga s porastom posmaka alata dolazi do povećanja vibracija. Logički, a i eksperimentalno, može se zaključiti kako istrošenost alata također znatno utječe na pojavu vibracija. Kada je alat potrošen, veća je rezna površina u zahvatu, čime se pojavljuju veće sile trenja, a sukladno tome i veće vibracije (proporcionalan odnos). Iz svega navedenoga može se donijeti zaključak kako bilokakav nadzor pomoću signala vibracija može biti dosta nezgodan i dovesti do pogrešnih rezultata. Signali vibracija mogu se relativno jednostavno izmjeriti, a najčešće se mjere pomoću akcelerometra u područjima frekvencije do 10 kHz [3,4,11-14].

### **2.3. Nadzor tvrdoće**

Prema provedenim eksperimentima, klasifikacija tvrdoće obratka primjenom značajki izdvojenih iz signala vibracija postigla je najbolje rezultate [3]. U nastavku su opisani potrebni podsustavi za provedbu indirektnog nadzora tvrdoće. Također je prikazan primjer modela indirektnog nadzora obradnog procesa, a u konačnici su opisana i unaprjeđenja u provedenom eksperimentu u smislu primjene novodizajniranog svrdla za bušenje kamena.

#### **2.3.1. Model sustava za indirektni nadzor tvrdoće**

Kako bi se omogućila dinamička korekcija procesa na temelju informacija prikupljenih indirektnim nadzorom, sustav nužno mora sadržavati sljedeće podsustave:

- podsustav za indirektno mjerenje
- podsustav za prihvata i obradu signala
- podsustav paralelnog procesiranja značajki
- podsustav za učenje i adaptaciju strukture.

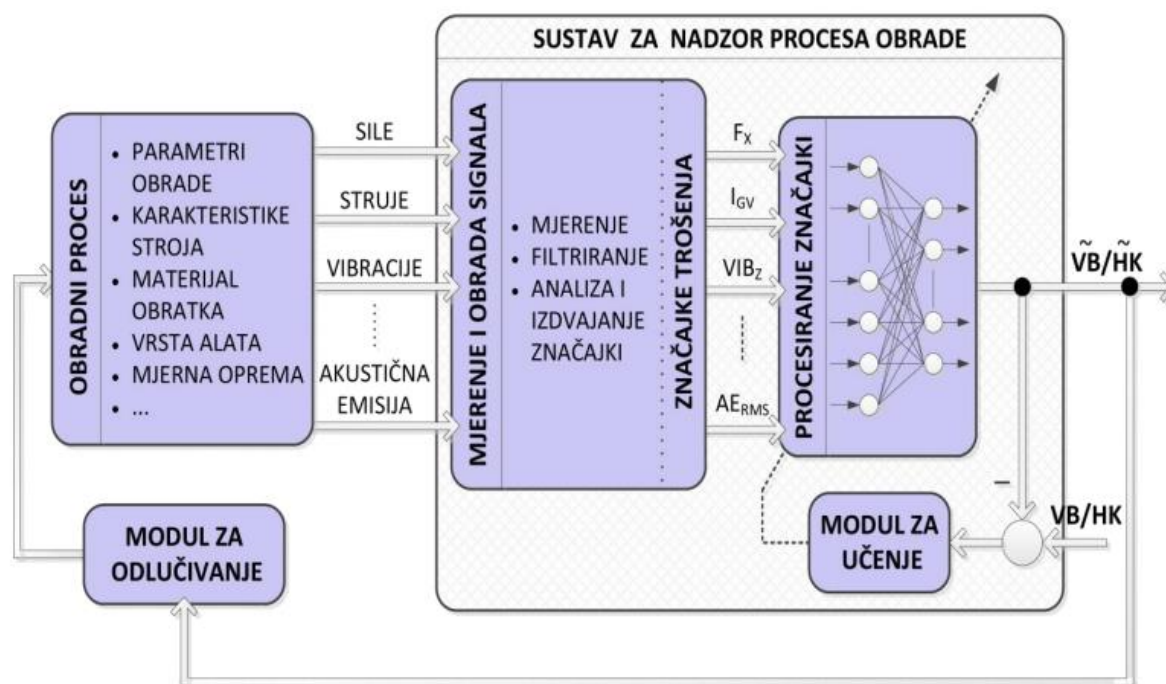
Podsustav za indirektno mjerenje prikuplja informacije iz procesa u obliku analognih signala, koji se šalju u podsustav za prihvata i obradu signala gdje se signali filtriraju i iz njih zatim izdvajaju adekvatne značajke procesa. Pritom značajke procesa mogu biti izdvojene iz vremenskog, frekvencijskog i vremensko-frekvencijskog područja. U ovome su radu značajke iz signala vibracija izdvojene iz frekvencijskog područja primjenom Fourierove transformacije. u frekvencijsko područje. Općenito, u frekvencijskom području moguće je izdvojiti sljedeće značajke signala:

- dominantne amplitude/snage spektra
- spektralnu gustoću snage cijelog spektra

- spektralnu gustoću snage u pojedinim segmentima signala
- frekvenciju najveće amplitude spektra
- ukupnu snagu signala u okolini frekvencije najveće amplitude spektra.

Na temelju izdvojenih značajki, podsustav za paralelno procesiranje značajki određuju aktualno stanje procesa i alata, odnosno u ovome slučaju provodi klasifikaciju tvrdoće obratka. Nakon što su dobiveni rezultati klasifikacije, podsustav za adaptaciju vrši korekcije režima obrade. Valja imati na umu da ukoliko sustav ima samo mogućnost nadzora procesa obrade bez dinamičke korekcije procesa, iz njegove strukture izostati će modul za odlučivanje. Primjer modela sustava s indirektnim nadzorom tvrdoće i dinamičkom korekcijom procesa, prikazan je na slici 2.4. Pritom oznaka  $VB$  označava širinu potrošenosti stražnje površine alata, a  $HK$  označava tvrdoću prema Knoop-u [3].

Tijekom indirektnog nadzora procesa obrade prikupljaju se ogromne količine podataka koje je potrebno obraditi u kratkom vremenu. Stoga se obrada podataka vrši pomoću algoritama umjetne inteligencije, a najčešće se upotrebljavaju umjetne neuronske mreže. Umjetnim neuronskim mrežama potreban je podsustav za učenje kako bi na temelju naučenih korelacija stanja i značajki procesa, dalje mogle provoditi klasifikacije nepoznatih stanja na temelju snimljenih značajki [3].




Slika 2.4. Model indirektnog nadzora obradnog procesa [3]



### 2.3.2. Unaprjeđenja eksperimenta

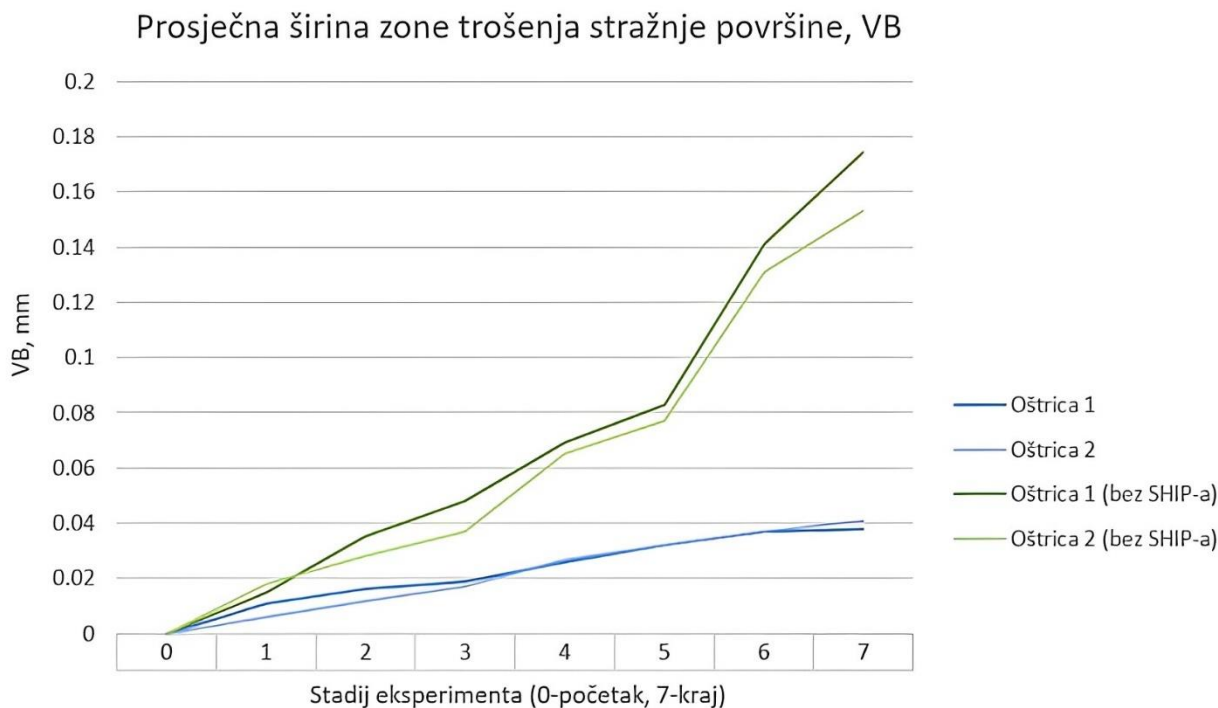
U priloženoj literaturi [3] prikazana je analiza primjene signala vibracija u klasifikaciji tvrdoće obratka prilikom bušenja kamena klasičnim svrdlom koji se koristi u industrijskoj praksi, kao što je prikazano na slici 1.3. U radu [7] prikazano je i ispitano novodizajnirano svrdlo s kanalom za ispuhivanje koji prolazi duž svrdla. Već je spomenut utjecaj SHIP-a na trošenje i zagrijavanje svrdla pri radu, a novi tip svrdla potvrdio je to u laboratorijskim uvjetima. Prema dobivenim rezultatima, svrdlo je pokazalo značajno manje trošenje, sile rezanja i vibracije pri radu. U eksperimentu s klasičnim svrdlom [3], pokazani su jako dobri rezultati klasifikacije tvrdoće kamena. Stoga je u ovome radu napravljena klasifikacija tvrdoće na temelju vibracija snimljenih prilikom obrade kamena svrdlom s kanalom za ispuhivanje, u pokušaju reprodukcije istih ili boljih rezultata [3,7].

Slika 2.5 prikazuje svrdlo s kanalom za ispuhivanje. Shematski prikaz svrdla vidljiv je na lijevoj strani slike, a desna strana prikazuje stvarni prikaz svrdla. Svrdlo sadrži dva kanala, uzdužni (plavi) kroz cijelo svrdlo putem kojega se dovodi SHIP i hladi alat iz središta. Drugi kanal je poprečni (crveni), koji služi za izlaz SHIP-a iz alata i odvođenje odvojenih čestica kamena s reznih oštrica [7].




**Slika 2.5.** Svrdlo s kanalom za ispuhivanje, shematski (lijevo) i stvarni (desno) prikaz [7]

Svrdlo s kanalom za ispuhivanje pokazalo je u laboratorijskim uvjetima izvanredne rezultate. Prilikom provedbe eksperimenta kroz kanal se dovodio komprimirani zrak. Na slici 2.6, prikazani su iznosi prosječne širine zone trošenja na stražnjim površinama oštrica ( $VB$ ) prilikom korištenja konvencionalnoga i novog tipa svrdla. Graf pokazuje da je prosječna širina zone trošenja na novodizajniranom svrdlu u zadnjem stadiju eksperimenta (7) bila više od četiri puta manja. To znači da je prosječna širina zone trošenja smanjena za više od 400% u odnosu na konvencionalno svrdlo (bez upotrebe SHIP-a). S obzirom da je teško predočiti razliku u trošenju samo na temelju brojeva, slika 2.7 prikazuje izgled oštrica na kraju eksperimenta [7].



**Slika 2.6.** Usporedba potrošenosti spiralnog svrdla i spiralnog svrdla s kanalom za ispuhivanje [7]



**Slika 2.7.** Oštrice na kraju eksperimenta, svrdlo s kanalom za ispuhivanje (lijevo) i konvencionalno svrdlo (desno) [7]

Znatno poboljšanje je vidljivo i na temelju parametara snimljenih indirektnom metodom nadzora. U tablici 2.1, može se vidjeti kako su se aritmetičke aksijalne sile ( $\bar{F}_z$ ) smanjile između 3,5 i 10 puta ovisno o ispitnom uzorku. Nadalje, tablica 2.2 prikazuje smanjenje prosječnih jakosti struja na pogonskom motoru osi Z ( $\bar{I}_z$ ) koje su manje u slučaju korištenja SHIP-a za

otprilike 2-6 puta ovisno o ispitivanom uzorku. Za kraj, prosječne jakosti struja na pogonskom motoru glavnog vretena ( $\overline{I_{gv}}$ ) također su znatno manje (otprilike 1,5-3 puta), a vrijednosti su prikazane u tablici 2.3. U radu [8] vidljivi su detaljni podaci eksperimenta iz kojih se mogu postići i dodatni zaključci da se sa stupnjem istrošenosti alata kod konvencionalnih svrdla vrijednosti jakosti struja i aksijalne sile mijenjaju nelinearno i naglo rastu, a kod svrdla s kanalom za ispuhivanje se mijenjaju relativno linearno uz slabi prirast [7].

Tablica 2.1. Srednje vrijednosti aksijalnih sila ( $\overline{F_z}$ ) [7]

Ispitni uzorak	$\overline{F_z}$ sa SHIP-om, N	$\overline{F_z}$ bez SHIP-a, N
K1	36,1	357,1
K2	70,6	254
K3	51,9	301,1

Tablica 2.2. Srednje vrijednosti jakosti struja pogonskog motora osi Z ( $\overline{I_z}$ ) [7]

Ispitni uzorak	$\overline{I_z}$ sa SHIP-om, A	$\overline{I_z}$ bez SHIP-a, A
K1	0,16	0,97
K2	0,35	0,68
K3	0,25	0,8

Tablica 2.3. Srednje vrijednosti jakosti struja pogonskog motora glavnog vretena ( $\overline{I_{gv}}$ ) [7]

Ispitni uzorak	$\overline{I_{gv}}$ sa SHIP-om, A	$\overline{I_{gv}}$ bez SHIP-a, A
K1	0,34	0,92
K2	0,52	0,8
K3	0,39	0,9

Iako novi tip svrdla daje izvrsne rezultate, veliku manu predstavlja sama izrada svrdla. Naime teško je precizno izraditi uzdužni kanal po sredini svrdla, što je posebno izraženo kod dugačkih svrdla manjeg promjera, obzirom da što je manji promjer svrdla to su uže dopuštene tolerancije za pogrešku. S druge strane, i malo odstupanje se na dugim svrdlima vrlo brzo akumulira u prekomjernu pogrešku [7].

### 3. OPIS EKSPERIMENTA

#### 3.1. Eksperimentalni postav


Eksperiment je proveden u Laboratoriju za alatne strojeve, Fakulteta strojarstva i brodogradnje u Zagrebu. Eksperimentalni postav prikazan na slici 3.1, sastoji se od postava za pripremu uzoraka, ispitnog postava i mjernog sustava [3].



**Slika 3.1.** Eksperimentalni postav [3]

#### 3.1.2. Ispitni stroj

Bušenje je provedeno na troosnoj glodalici prikazanoj na slici 3.2. Glodalica se sastoji od zavarene konstrukcije na koju su ugrađene kotrljajuće vodilice za ostvarivanje posmičnih gibanja. Pomični stol ostvaruje gibanje obratka po  $X$  osi, a gibanje po  $Y$  i  $Z$  osi ostvaruje alat. Na osnovnu konstrukciju stroja zavarena je vodilica putem koje se ostvaruje gibanje po osi  $Y$ , a po vodilici se giba vodilica putem koje se ostvaruje gibanje po osi  $Z$ , a na kojoj je pričvršćen motor glavnog vretena s prihvatom alata i alat [3].



1. Posmični prigon X osi
2. Posmični prigon Y osi
3. Posmični prigon Z osi
4. Glavni motor
5. Zavarena konstrukcija
6. Stezna naprava za uzorke

**Slika 3.2.** Elementi ispitnog stroja [3]

Posmične osi izvedene su primjenom kugličnih navojnih vretena proizvođača *HIWIN* pogonjenih sinkronim servomotorima s permanentnim magnetima proizvođača *Mecapion Ltd.* Servomotori posjeduju inkrementalne enkodere koji šalju povratnu informaciju o brzini i poziciji pogona [3]. Tehničke karakteristike ispitnog stroja nalaze se u tablici 3.1.

Tablica 3.1. Tehničke karakteristike ispitnog stroja [3]

Hod osi	<i>X</i>	350 mm
	<i>Y</i>	450 mm
	<i>Z</i>	55 mm
Korak navojnog vretena osi	<i>X, Y, Z</i>	5 mm
Maksimalna posmična brzina osi	<i>X, Y, Z</i>	15 m/min
	<i>C</i>	+/- 360°
Nazivna učestalost vrtnje GV	3000 min <sup>-1</sup>	
Maksimalna učestalost vrtnje GV	5000 min <sup>-1</sup>	

Osim konstrukcije stroja, za potrebe eksperimenta izrađen je modul glavnog prigona s ciljem osiguravanja točnog stezanja i centriranja alata. Modul ima mogućnost protočnog hlađenja, te predviđena mjesta za stezanje raznovrsnih senzora na vrhu modula u blizini prednjeg ležaja. Konstruirani modul s označenim komponentama prikazan je na slici 3.3 [3].




**Slika 3.3.** Modul glavnog prigona [3]

Upravljanje glodalicom izvršeno je pomoću CNC upravljačkog sustava otvorene arhitekture EMC2 (engl. enhanced machine controller). EMC2 integriran je u numerički upravljano (engl. numerical control, NC) računalo, a potrebno napajanje, servo regulatori i ulazno-izlazno sklopovlje smješteni su u elektro-ormar [3]. Na slici 3.4 s lijeve strane nalazi se elektro-ormar, a s desne NC računalo.

Navedeni upravljački sustav osim regulatora motora osi, sadrži sklopovlje za prilagodbu upravljačkih i mjernih signala. Također omogućuje kontrolu SHIP-a, podmazivanje i izmjenu alata. NC računalo omogućuje istovremeno upravljanje alatnim strojem, snimanje i obradu signala te izvršavanje algoritama računalne inteligencije.

Za prihvatanje snimljenih signala potrebno je koristiti akvizicijske kartice. U eksperimentu su korištene dvije akvizicijske kartice koje posjeduju analogno i digitalno izlazno/ulazno sučelje. Jedna kartica namijenjena je za akviziciju signala srednjih frekvencija (do 100 kHz), a druga za akviziciju signala visokih frekvencija (do 10 MHz) [3].





**Slika 3.4.** Upravljački sustav ispitnog postava [3]

### 3.1.3. Mjerna oprema


Eksperimentalni postav korišten je ujedno za mjerenje i nadzor parametara koji su izvan obuhvata ovoga rada. Stoga osim senzora vibracija, mjerni sustav sadrži senzore sila i akustičnih emisija, te industrijsku kameru. Smještaj senzora na ispitnom stroju prikazan je na slici 3.5. Osim prethodno navedenog NC računala, tijekom eksperimenta korišteno je dodatno računalo, opremljeno prijenosnom modularnom stanicom, kao poslužitelj za udaljeno nadgledanje eksperimenta i izvršavanje mjerne aplikacije. Udaljeno računalo korišteno je za snimanje stanja rezne oštrice kamerama, te prikupljanje signala sila rezanja i početka snimanja signala [3].

Signali vibracija snimani su pomoću tro-komponentnog piezo-električnog akcelerometra tijekom prve dvije sekunde obrade, mjereno od trenutka kontakta obje oštrice alata s obratkom. Snimanje je trajalo samo dvije sekunde zbog ograničenja akvizicijskog sustava u prikupljanju i memoriranju velike količine podataka. Pouzdano mjerno područje akcelerometra iznosi 0,5 – 5000 Hz, a vibracije su snimane u smjeru  $X$ ,  $Y$  i  $Z$  osi s frekvencijom uzorkovanja od 100 kHz. Tok i vrste prikupljenih signala mjernog postava u cijelosti prikazani su na slici 3.6 [3,9].





Korisničko sučelje za nadzor i upravljanje procesom predstavlja LabView programski paket postavljen na mjernom računalo. LabView omogućava upravljanje parametrima obrade, snimanje signala procesa obrade, verifikaciju rezultata i generiranje mjernih datoteka. Prozor korisničkog sučelja prikazan je na slici 3.7 [3].



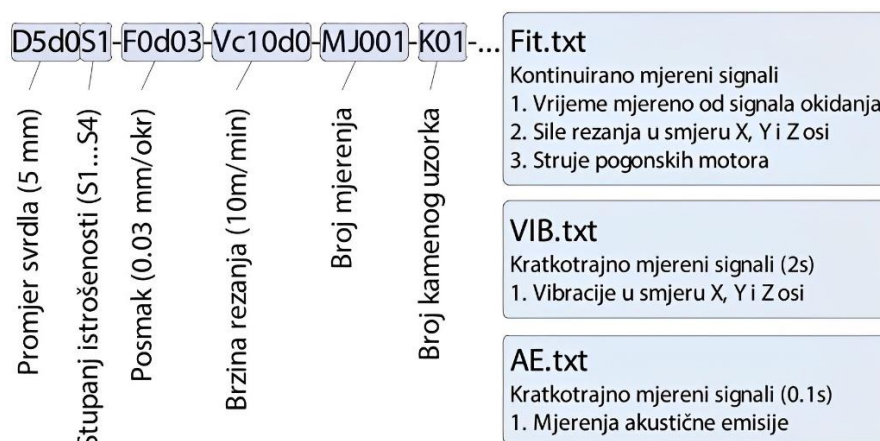
- |                                 |  |
|---------------------------------|--|
| 1. Parametri eksperimenta       | 4. Signali vibracija                       |
| 2. Trenutne vrijednosti signala | 5. Signali sila rezanja                    |
| 3. Signal akustične emisije     | 6. Signali jakosti struja pogonskih motora |

Slika 3.7. Korisničko sučelje programskog paketa LabView [3]

Navedeno sučelje omogućuje grafički prikaz snimljenih signala mjernog sustava i unos slijedećih parametara bitnih za eksperiment:

- parametri obrade
- broj ispitnog kamenog uzorka
- broj ponavljanja ciklusa bušenja
- promjer i stupanj istrošenosti svrdla.

Po završetku ciklusa mjerenja generirane su tri datoteke sa snimljenim signalima. Imena datoteka su automatski generirana prema uzorku prikazanom na slici 3.8 [3].



Slika 3.8. Primjer imena datoteke generiranog programskim paketom LabView [3]

### 3.2. Vrste kamenih uzoraka


U svrhu postizanja što općenitijih zaključaka istraživanja, pri izboru ispitnog kamena nastojale su se odabrati vrste kamena sa što većom razlikom u mehaničkim svojstvima. Za potrebe eksperimenta svakom kamenu je dodijeljena oznaka, a odabrani su: Sivac Konavoski ( $K_1$ ), Mironja ( $K_2$ ) i Sivec ( $K_3$ ). Sva tri kamena spadaju u mramore prema sistematizaciji arhitektonsko-građevnog kamena. Svojstva pojedinog kamena nalaze se u tablici 3.2. Valja napomenuti kako je tvrdoća izmjerena metodom po Knoop-u na Fakultetu strojarstva i brodogradnje, u Laboratoriju za ispitivanje mehaničkih svojstava [3].

Tablica 3.2. Pregled mehaničkih svojstva ispitnih kamenih uzoraka [3]

Vrsta kamena	$K_1$	$K_2$	$K_3$
Tlačna čvrstoća ( $P_{pros.}$ ), MPa	136,8	169	162,10
Upijanje vode ( $\vartheta$ ), %	2,08	0,07	0,1067
Gustoća ( $\rho$ ), kg/m <sup>3</sup>	2570	2690	2850
Poroznost ( $P$ ), %	5,2	0,2	0,877
Tvrdoća, MPa	1815	1620	2605

U eksperimentu su korišteni ispitni uzorci dimenzija 200x90x30 mm. Ispitni uzorci su pripremljeni na način da su prvo izrezani grubi komadi iz većih komada kamena. Zatim su na postavu za pripremu uzorka (dio eksperimentalnog postava), korištenjem dijamantnog brusa raznih granulacija, fino polirani kako bi se moglo provesti određivanje tvrdoće [3].


Uređaji za mjerenje tvrdoće uobičajeno su namijenjeni za male ispitne uzorke, a zbog nehomogenosti kamena i velikog broja ponavljanja bušenja u eksperimentu su korišteni veliki uzorci. Stoga je kao dio eksperimentalnog postava, izrađena stanica za mjerenje tvrdoće koja može zaprimiti uzorke iznad navedenih dimenzija. Tvrdoća je određivana prema normi HRN EN 14205:2003. Ispitivanje je izvedeno ukupno 120 puta po ispitnom uzorku, uz korištenu silu od 5N i vrijeme držanja opterećenja od 10 s. Pritom je ukupno vrijeme trajanja jednog ciklusa mjerenja tvrdoće iznosilo 40 s. Zbog heterogenog i anizotropnog svojstva kamena postojala je znatna varijacija rezultata, a konačna tvrdoća je određena aritmetičkom sredinom. Izmjerene vrijednosti tvrdoće u ovisnosti o broju mjerenja prikazane su na slici 3.9 [3].



Slika 3.9. Izmjerene vrijednosti tvrdoće u ovisnosti o broju mjerenja [3]

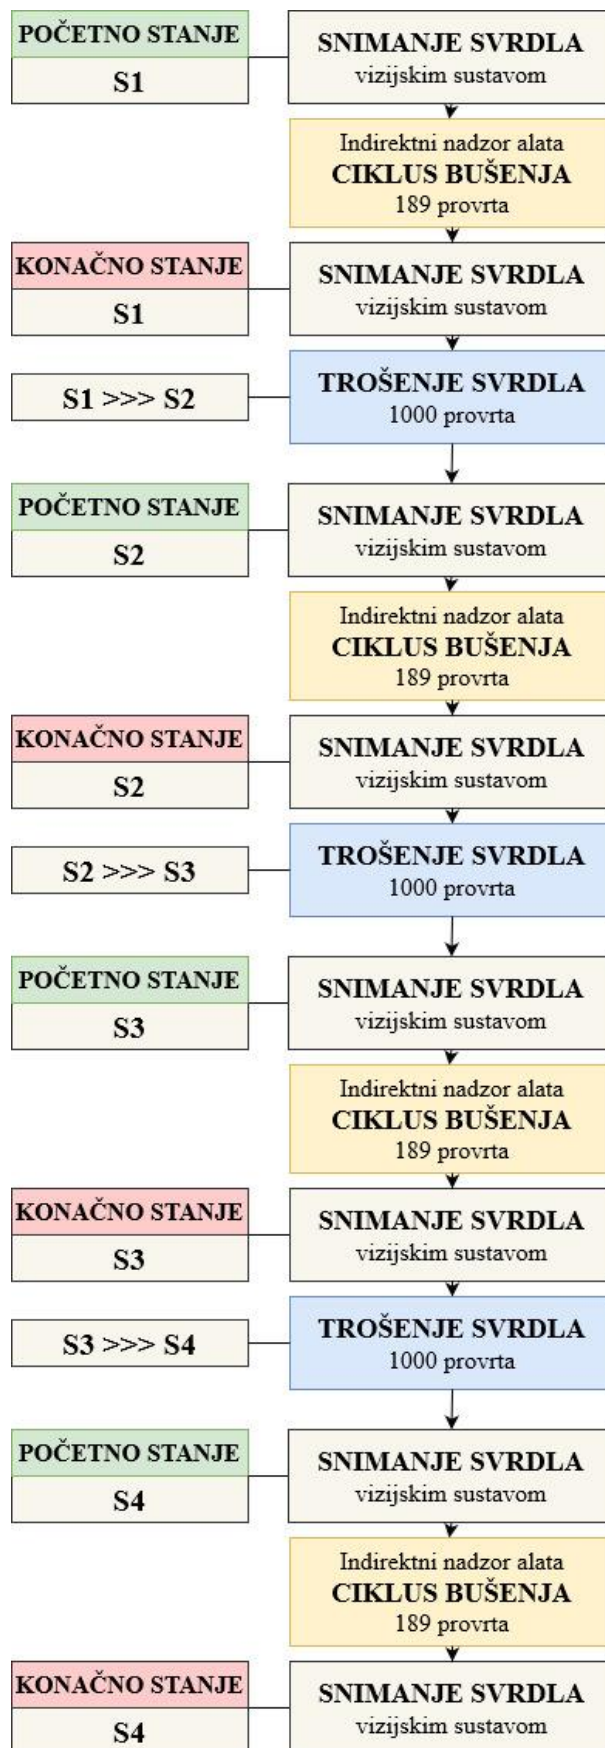
### 3.3. Mjerenje, obrada signala i izdvajanje značajki

Varijabilni parametri eksperimenta bili su vrste kamenih uzoraka, posmak, brzina rezanja, te stupanj istrošenosti svrdla. Svaki kamen ( $K_1$ ,  $K_2$ ,  $K_3$ ) obrađen je s 9 kombinacija brzine rezanja i posmaka pri svakom stupnju istrošenosti alata ( $S_1$ ,  $S_2$ ,  $S_3$ ,  $S_4$ ), što ukupno iznosi 108 kombinacija ponavljanja. Nadalje, mjerenja za svaku kombinaciju ponovljena su 7 puta naizmjenično kako bi se dobio što veći broj i raznolikost ulaznih podataka za neuronsku mrežu. To znači da je tijekom eksperimenta provedeno ukupno 756 mjerenja. Vrijednosti posmaka i brzina rezanja određene su na temelju prethodno izvršenih probnih mjerenja. Slika 3.10 daje vizualni prikaz korištenih kombinacija parametara tijekom eksperimenta [7].



**Slika 3.10.** Vizualni prikaz kombinacija parametara korištenih u eksperimentu [3]

Eksperiment je proveden na slijedeći način. Na početku je vizijskim sustavom snimljeno inicijalno stanje oštrice. Zatim je odrađeno 189 bušenja prema prethodno navedenom principu (9 kombinacija posmaka i brzine rezanja u kombinaciji s tri vrste kamena uz sedam naizmjenice ponavljajućih mjerenja za svaku kombinaciju). Tijekom bušenja indirektnim sustavom nadzora snimljeni su signali vibracija, jakosti struja, akustične emisije i sila. Nakon ciklusa bušenja ponovno je snimljeno svrdlo vizijskim sustavom kako bi se odredila zona istrošenosti između početnog i konačnog stanja reznih oštrica. Nakon provedenih mjerenja napravljeno je dodatnih 1000 provrta bez snimanja podataka kako bi se svrdlo istrošilo i time postigao drugi, viši stupanj istrošenosti. Cijeli opisani proces ponovljen je četiri puta, a prikazan je na slici 3.11 [7].



Slika 3.11. Tok određivanja stupnja istrošenosti alata [3,7]



Snimljeni signali vibracija u vremenskom području transformirani su korištenjem brze Fourierove transformacije (engl. Fast Fourier transform, FFT) u frekvencijsko područje. Zatim su iz signala u frekvencijskom području izdvojene značajke za koje se pretpostavilo da su u direktnoj korelaciji s tvrdoćom obratka [3].

Nakon primjene FFT, dobivene su snage frekvencijskog spektra signala vibracija za svaku od osi ( $X$ ,  $Y$ ,  $Z$ ) zasebno. Na temelju dobivenih snaga, izračunate su energije spektra signala koje ujedno predstavljaju izdvojene značajke iz signala vibracija. Energije su izračunate za različite frekvencijske pojaseve unutar radnog područja senzora (0,5 – 5000 Hz), prema sljedećim integralima:

$$E(VIB_X) = \int_{f_D}^{f_G} VIB_X(f) df , \quad (3.1)$$

$$E(VIB_Y) = \int_{f_D}^{f_G} VIB_Y(f) df , \quad (3.2)$$

$$E(VIB_Z) = \int_{f_D}^{f_G} VIB_Z(f) df , \quad (3.3)$$

pri čemu  $f_D$  i  $f_G$  predstavljaju gornju i donju granicu frekvencijskog pojasa. Prethodno su definirana 23 frekvencijska pojasa prema kojima su izdvojene značajke vibracija, a to su: 5, 10, 20, 30, ..., 90, 100, 200, ..., 900, 1000, 1500, 2500 i 5000 Hz. Iako je mjerno područje senzora od 0,5 do 5000 Hz, značajke su izdvojene iz područja 5 – 5000 Hz. To bi značilo da su za frekvencijski pojas od 1000 Hz, granice  $[f_D, f_G]$  izgledale na sljedeći način: [5, 1005], [1005, 2005], [2005, 3005], [3005, 4005], [4005, 5000]. Iz navedenog je odmah vidljivo kako zadnji raspon nije nužno odgovarao veličini frekvencijskog pojasa, nego je uobičajeno bio manji. Za svaki raspon frekvencijskog pojasa izdvojene su značajke signala vibracija snimljenih u sve tri ortogonalne osi. Također, uvedena je dodatna značajka, suma energija spektra  $E(VIB_{XYZ})$ , koja predstavlja zbroj osnovnih značajki, prema formuli [3,9]:

$$E(VIB_{XYZ}) = E(VIB_X) + E(VIB_Y) + E(VIB_Z) . \quad (3.4)$$


### 3.4. Neuronska mreža s radijalnim baznim funkcijama

Neuronska mreža s radijalnim baznim funkcijama (engl. radial basis function neural network, RBF NN) prvi puta se spominje krajem 80-ih godina, a tijekom vremena je znatno unaprjeđena i prilagođena rješavanju klasifikacijskih i regresijskih problema. Glavna prednost RBF mreža naspram višeslojnih perceptronskih mreža leži u brzini učenja koje se odvija u jednom koraku, te mogućnosti jednostavne adaptacije strukture. S druge strane RBF mreže zahtijevaju veću pažnju na pripremi podataka, odnosno njihovom grupiranju [15].

#### 3.4.1. Struktura mreže i matematički model

RBF NN pripadaju skupini unaprijednih ili statičkih (engl. feed-forward) neuronskih mreža. Mreža se uvijek sastoji od tri sloja: ulaznog, skrivenog i izlaznog (struktura prikazana na slici 3.12). Ulazni sloj mreže određen je problemom, a definiran je s  $L$  ulaznih neurona. Svaka od izdvojenih značajki predstavljena je jednim ulaznim neuronom. Izlazni sloj sadrži  $M$  izlaznih neurona koji su određeni rješavanjem problemom, a svaki izlazni neuron predstavlja jednu klasifikacijsku skupinu. Broj neurona skrivenog sloja  $K$  određen je od strane učitelja u fazi učenja, gdje  $K$  ovisi o broju grupa u koje su smješteni podaci za učenje. Neuroni skrivenog sloja opisani su pomoću  $L$ -dimenzionalnog vektora centara ( $t_j$ ) i odabranom aktivacijskom funkcijom. Djelovanjem vektora težinskih faktora ( $c_j$ ) na neurone skrivenog sloja, dobivaju se vrijednosti izlaznih neurona. Iz navedenog slijedi da se RBF mrežom preslikava  $L$ -dimenzionalni ulazni vektor na  $M$ -dimenzionalni izlazni vektor [15].

Struktura skrivenog sloja zajedno s težinskim faktorima predstavlja glavni dio RBF mreže s obzirom da o njima ovisi kvaliteta odziva i generalizacijska svojstva mreže. Ukoliko svaki vektor neurona ulaznog sloja čini jednu grupu, odnosno, ako je broj skrivenih neurona jednak broju vektora ulaznih neurona, tada će svaki vektor ulaznih neurona činiti jedan vektor centara što je vidljivo na slici 3.12. Češća je praksa grupiranje ulaznih podataka u podgrupe, s obzirom da se pri učenju može koristiti i tisuće podataka, a rad s matricama te veličine može biti izrazito nezgodan i problematičan. Također, grupiranjem podataka se znatno povećavaju generalizacijska svojstva mreže jer se testni podaci, koji bi se našli između dva susjedna neurona, ovim putem točnije klasificiraju s obzirom da je prostor klasifikacijske grupe adekvatnije određen. U slučaju korištenja podgrupa, centri grupe se računaju aritmetičkom sredinom svih članova grupe [15].



Slika 3.12. Struktura RBF neuronske mreže [3]

Prilikom korištenja ovog tipa mreža, aktivacijske funkcije moraju biti odabrane iz skupine radijalnih baznih funkcija prema kojima, uostalom, mreža i nosi ime. Glavna karakteristika radijalnih baznih funkcija je da su monotono rastuće ili padajuće obzirom na svoje središte. Upravo to svojstvo, prema Micchellijevom teoremu da je prva derivacija aktivacijske funkcije u potpunosti monotona, osigurava regularnost matrice vrijednosti radijalnih baznih funkcija ( $\mathbf{H}$ ). Ukoliko nije osigurana regularnost matrice  $\mathbf{H}$ , znači da nije moguće odrediti inverz iste, što u konačnici znači da se ne mogu izračunati težinski parametri, a time je učenje mreže onemogućeno. Jedna od najčešće korištenih radijalno baznih funkcija je Gaussova aktivacijska funkcija koja je također korištena u ovome radu [15].

U nastavku slijedi matematički model mreže koji započinje krajnjom relacijom, a zatim su definirane varijable korištene u istoj [16].

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



pri čemu  $O_w$  predstavlja element  $w$ -tog izlaznog neurona koji ovisi o: svim elementima ulaznog vektora ( $\mathbf{x}$ )  $i$ -tog koraka, aktivacijskoj funkciji  $h(\bullet)$ , Mahalanobisovoj udaljenosti ( $r_{ij}$ ) između  $i$ -tih elemenata ulaznih neurona i elemenata  $j$ -tog centra, težinskom faktoru  $c_{jw}$  koji povezuje  $j$ -i neuron skrivenog i  $w$ -ti neuron izlaznog sloja, broju neurona sakrivenog sloja  $K$ , broju izlaznih neurona  $M$  i broju ulaznih neurona  $L$ . Nadalje, Gaussova aktivacijska funkcija ima sljedeći oblik:

$$h(r_{ij}) = H_{ij} = e^{-\frac{1}{2}r_{ij}^2}, \quad (3.6)$$

gdje  $H_{ij}$  predstavlja element matrice  $\mathbf{H}$ . Mahalanobisova udaljenost definirana je kao udaljenost između svih uzoraka za učenje i centara neurona sakrivenog sloja svih razmatranih klasifikacijskih skupina. Stoga se vrijednost kvadratne Mahalanobisove udaljenosti računa prema jednadžbi:

$$r_{ij}^2 = (\mathbf{x}_i - \mathbf{t}_j)^T \boldsymbol{\Sigma}_j^{-1} (\mathbf{x}_i - \mathbf{t}_j). \quad (3.7)$$

$\boldsymbol{\Sigma}_j$  je kovarijantna matrica koja je definirana na temelju grupe uzoraka koji su korišteni za izračun  $j$ -og vektora centara skrivenog neurona, a pripadaju određenoj klasifikacijskoj skupini. Drugim riječima, svaka klasifikacijska skupina će imati broj kovarijantnih matrica koji je jednak broju podgrupa koji se nalazi unutar te iste klasifikacijske skupine. Svakom vektoru centara skrivenog sloja pridružuje se vlastita kovarijantna matrica. Kovarijantna matrica ima sve elemente izvan glavne dijagonale jednake nuli, odnosno vrijedi:

$$\boldsymbol{\Sigma}_j = \begin{bmatrix} \sigma_1^2 & 0 & 0 & 0 \\ 0 & \sigma_2^2 & 0 & 0 \\ 0 & 0 & \ddots & 0 \\ 0 & 0 & 0 & \sigma_L^2 \end{bmatrix}. \quad (3.8)$$

$\sigma_g$  ( $g = 1, \dots, L$ ) predstavlja vrijednosti maksimalnog udaljenog uzorka razmatrane grupe od centra te iste grupe po svim dimenzijama, a određuju se prema izrazu

$$\sigma_g \Big|_j = \max\{\|z_{pg} - t_g\|\}_j, \quad p = 1, \dots, n; \quad g = 1, \dots, L; \quad j = 1, \dots, K \quad (3.9)$$

Pritom je  $z_{pg}$   $g$ -ta komponenta  $p$ -tog uzorka  $j$ -e grupe u koju je svrstano  $n$  uzoraka, a  $t_g$   $g$ -ta komponenta vektora centra  $j$ -og neurona skrivenog sloja. S obzirom na strukturu matrice, kovarijantna matrica može biti singularna samo ako je minimalno jedna vrijednost na glavnoj dijagonali jednaka nuli. Kako bi se i dalje u tome slučaju omogućila invertibilnost matrice, nula elemente potrebno je zamijeniti proizvoljnom malom vrijednošću (naprimjer  $10^{-6}$ ) koja neće imati utjecaj na konačni rezultat.

Početni izraz (3.5) može se zapisati u matričnom obliku i tada glasi:

$$\mathbf{O} = \mathbf{H} \mathbf{C}, \quad (3.10)$$

pri čemu je  $\mathbf{O}$  matrica izlaza dimenzija  $L \times M$ ,  $\mathbf{H}$  matrica vrijednosti radijalnih baznih funkcija (matrica učenja) dimenzija  $L \times K$ , a  $\mathbf{C}$  matrica težinskih faktora dimenzija  $K \times M$ . Prebacivanjem matrice  $\mathbf{H}$  na lijevu stranu, odnosno množenjem prethodnog izraza s inverzom matrice  $\mathbf{H}$  s lijeve strane, slijedi jednadžba za izračun matrice težinskih faktora:

$$\mathbf{C} = \mathbf{H}^{-1} \mathbf{O}. \quad (3.11)$$

Iznad izvedena formula vrijedi samo u slučaju kada je matrica  $\mathbf{H}$  kvadratna matrica. Ukoliko se radi o pravokutnoj matrici, potrebno je koristiti pseudoinverz pa jednadžba 3.11 postaje

$$\mathbf{C} = \mathbf{H}^+ \mathbf{O}. \quad (3.12)$$

Moore-Penroseov pseudoinverz pravokutne matrice računa se prema izrazu:

$$\mathbf{H}^+ = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T. \quad (3.13)$$

### 3.4.2. Učenje i testiranje mreže

Tijekom učenja potrebno je postići što bolja generalizacijska svojstva mreže, odnosno odrediti strukturu mreže za što kvalitetniji odziv za bilo koju kombinaciju ulaznih vrijednosti iz skupine podataka za učenje i testiranje. Stoga je potrebno odabrati dovoljan broj uzoraka za učenje koji kvalitetno opisuju prostor učenja, što bi značilo da na granicama klasifikacijskih skupina se nalazi veći broj uzoraka s obzirom da su to uobičajeno problematična područja. Konačna struktura mreže se temelji na rezultatima ostvarenima u fazi testiranja [15].

RBF mreže spadaju u skupinu mreža koje uče metodom učenja s učiteljem (engl. supervised learning). Struktura mreže određuje se na temelju unaprijed poznatih ulaznih vektora i njima pridruženih izlaznih vektora. Iako RBF mreža uči u jednom koraku, određivanje parametara mreže u fazi učenja nerijetko zahtjeva nekoliko iteracija. Naime potrebno je odrediti raspodjelu uzoraka pojedinih klasifikacijskih skupina u niz podgrupa. Raspodjela uzoraka u podgrupe obično zahtjeva više ponavljanja, jer ovisno o uzorcima u podgrupi se mijenja vektor centara pa je potrebno više iteracija kako bi se smjestili uzorci na granicama podgrupa. Tijekom postupka učenja potrebno je odrediti sljedeće parametre [15]:

- $K$   $L$ -dimenzionalnih vektora centara  $t_j$  neurona sakrivenog sloja
- $K \times L \times L$  dimenzionalnih kovarijantnih matrica  $\Sigma_j$  neurona sakrivenog sloja
- $K \times M$  dimenzionalne matrice težinskih faktora  $C$  izlaznog sloja.

Učenje se provodi u šest koraka [15]:

1. Za početak se odrede klasifikacijske značajke, a prema njima i skupine. Zatim se uzorci za učenje razvrstaju po definiranim klasifikacijskim skupinama.
2. Svaka klasifikacijska skupina se dodatno razdijeli na niz podgrupa primjenom proizvoljno odabrane metode grupiranja (naprimjer metoda  $k$ -središnjih vrijednosti, engl.  $k$ -means clustering).
3. Kada su formirane podgrupe, za svaku pojedinačno izračuna se vrijednost centra i kovarijantne matrice  $\Sigma_j$  korištenjem izraza 3.8 i 3.9.
4. Prema izrazu 3.7 računaju se Mahalanobisove udaljenosti između svih uzoraka za klasifikaciju bez obzira u koju skupinu pripadaju i vektora centara neurona sakrivenog sloja. Ukoliko se na glavnoj dijagonali kovarijantne matrice nalazi nul-element nužno ga je zamijeniti s proizvoljno odabranom malom vrijednošću kako bi se osigurala regularnost matrice (naprimjer  $10^{-6}$ ).
5. Na temelju prethodno izračunatih Mahalanobisovih udaljenosti, računaju se vrijednosti aktivacijskih funkcija (izraz 3.6), odnosno elementi matrice učenja  $H$ .
6. Težinski faktori koji povezuju izlazni i sakriveni sloj (matrica  $C$ ) računaju se pomoću izraza 3.11 ili 3.12 ovisno o svojstvima matrice  $H$ , korištenjem matrice izlaza  $O$  te matrice  $H$  izračunate u koraku prije.

Važno je napomenuti da se jednom određeni vektori centara, kovarijantne matrice, te matrica težinskih faktora više ne mijenjaju. Prema tome, oni čine bazu znanja neuronske mreže o učenom problemu [16].

Jednom kada je postupak učenja završen, naknadno korištenje mreže se provodi u četiri jednostavna koraka [15]:

1. Ponovi se izračun Mahalanobisovih, ovoga puta između svih uzoraka i centara neurona sakrivenog sloja određenih pri učenju.
2. Na temelju izračunanih Mahalanobisovih udaljenosti, odredi se nova matrica vrijednosti radijalnih baznih funkcija  $H$ .
3. Prema izrazu 3.10 odredi se izlazni vektor pojedinog uzorka.
4. Uzorku se određuje pripadnost klasifikacijskoj skupini na osnovi najveće vrijednosti izlaznog neurona, odnosno maksimalne vrijednosti izlaznog vektora.

#### 3.4.2.1. *Određivanje podgrupa klasifikacijskih skupina*

Osim pravilno odabranih i pripremljenih uzoraka za učenje, uspješnost učenja mreže znatno ovisi o odabiru broja i položaja centara neurona sakrivenog sloja. Ukoliko se odredi prevelik broj sakrivenih neurona, odnosno prevelika struktura sakrivenog sloja, produžuje se vrijeme učenja i postoji mogućnost pojave pretreniranosti mreže (engl. overfitting). Pretreniranost mreže, kao i premali broj sakrivenih neurona, uzrokuje loša generalizacijska svojstva mreže. Loša generalizacijska svojstva uobičajeno su najizraženija na granicama klasifikacijskih skupina ili mjestima njihovog preklapanja. Nadalje, o broj centara i njihovom razmještaju ovisi stupanj pokrivenosti prostora pojedinih klasifikacijskih skupina što je u korelaciji s kvalitetom dobivenih rezultata. Broj i položaj centara se određuje individualno za svaki rješavani problem [16].

Prema navedenom, može se zaključiti kako nije pouzdano koristiti slučajan odabir centara s obzirom da se na taj način ne postiže adekvatan razmještaj u prostoru, a praksa je također to i potvrdila. Stoga je u ovome radu korištena metoda grupiranja uzoraka s obzirom na njihov razmještaj u prostoru. Na početku učenja potrebno je definirati koeficijent učenja ( $\beta$ ) na temelju kojega se vrši grupiranje. Smanjenjem vrijednosti koeficijenta učenja dolazi do povećanja broja centara i smanjenja broja uzoraka unutar grupa, a povećanjem koeficijenta učenja postiže se suprotan efekt. Postupak određivanja centara naspram proizvoljne vrijednosti koeficijenta  $\beta$  podijeljen je u šest koraka [16]:

1. Prvi uzorak postavlja se za centar prve grupe.
2. Između centra i preostalih uzoraka klasifikacijske skupine izračunaju se Euklidijske udaljenosti.

3. Ukoliko je izračunata udaljenost uzorka od centra grupe, manja od vrijednosti koeficijenta  $\beta$ , uzorak se svrstava u razmatranu grupu. U protivnom, uzorak ostaje nesvrstan.
4. Nakon što se provjere udaljenosti svih uzoraka, ponovo se računa centar grupe. Centar grupe računa se na temelju aritmetičke sredine svih uzoraka svrstanih u grupu po svakoj dimenziji zasebno.
5. S novo izračunatom vrijednošću centra ponavljaju se koraci 2-4, iz čega slijedi konačan broj uzoraka promatrane grupe i centar grupe.
6. Svrstani uzorci ne ulaze u proračun ostalih centara. Prvi nesvrstani uzorak postavlja se za centar druge grupe i ponavlja se algoritam počevši od drugog koraka. Algoritam se ponavlja dok svi uzorci nisu svrstani u grupu.

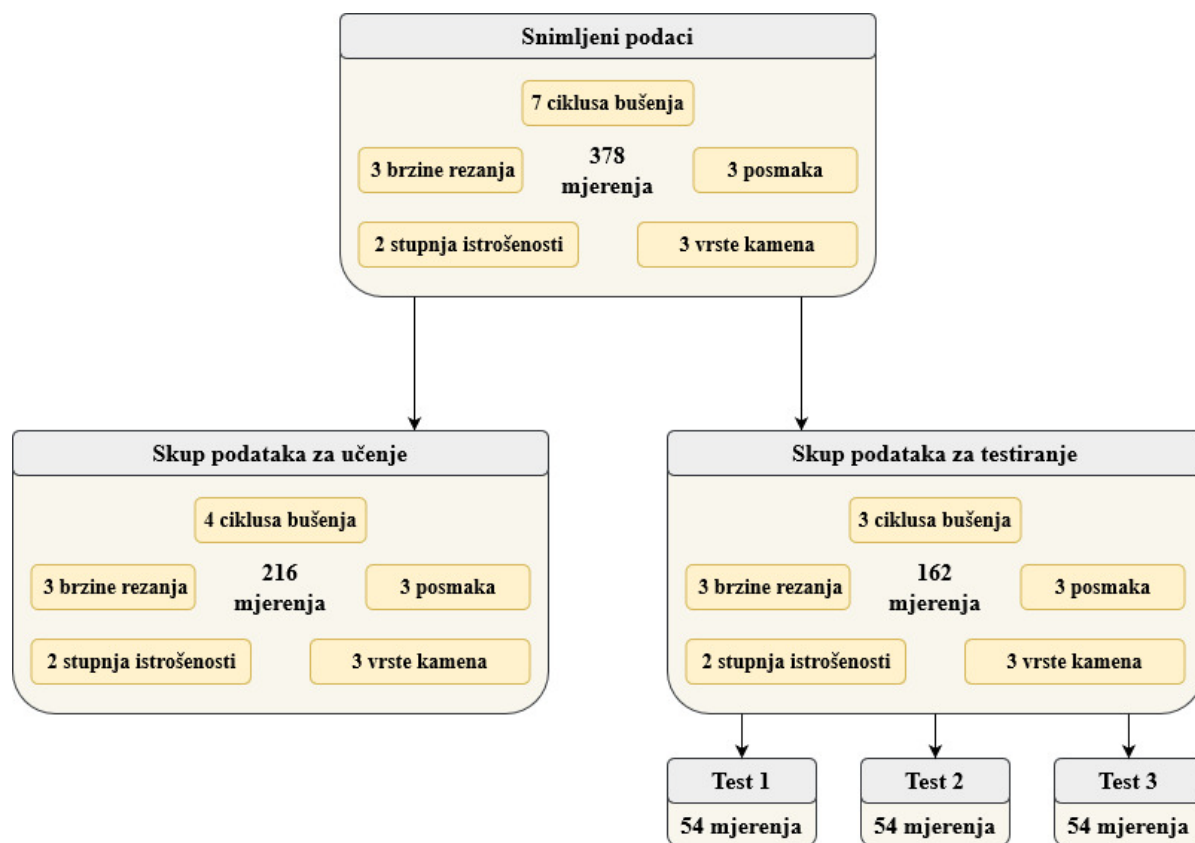
Kao što je već rečeno, opisanom metodom moguće je vrlo lako mijenjati strukturu skrivenog sloja mreže. Promjenom vrijednosti koeficijenta učenja unutar nekoliko iteracija pronalazi se oblik strukture sa zadovoljavajućim generalizacijskim svojstvima [16].

### **3.4.3. Podaci za učenje i testiranje mreže**

U provedenom je eksperimentu na raspolaganju bilo 756 različitih mjerenja. Odnosno provedena je obrada s 9 kombinacija režima obrade na 3 različite vrste kamena za 4 različita stupnja istrošenost, a svaka obrada je ponovljena 7 puta. Pritom, zbog premalih razlika u istrošenosti alata novodizajniranog svrdla, podaci izmjereni za stupanj istrošenosti 2 i 3 nisu korišteni u učenju i testiranju mreže. Korištenjem svih podataka ne bi se vidio utjecaj istrošenosti alata s obzirom na preuske raspone trošenja pojedinog stupnja. Prema tome za klasifikaciju su korišteni podaci iz 378 mjerenja koji su podijeljeni u dva skupa podataka [3,7]:

- Skup podataka za učenje mreže
- Skup podataka za testiranje mreže

Pritom za učenje mreže su korišteni podaci iz 216 mjerenja, a za testiranje mreže preostalih 162. S obzirom da je provedeno 7 ponavljanja mjerenja za svaku kombinaciju parametara obrade, podaci izmjereni u četiri mjerenja izdvojeni za učenje, a podaci iz preostala tri mjerenja su korišteni u testiranju mreže. Testni podaci dodatno su bili nasumično podijeljeni u tri grupe kako bi se ubrzalo testiranje i usput olakšala analiza varijacija rezultata. Drugim riječima, svaka grupa sadržavala je podatke iz 54 mjerenja [3]. Potpuna podjela podataka po skupovima prikazana je na slici 3.13.



Slika 3.13. Podjela podataka na skupove za učenje i testiranje [3]

## 4. KLASIFIKACIJA TVRDOĆE KAMENA

Klasifikacija tvrdoće kamena izvršena je u dva koraka pomoću neuronske mreže s radijalnim baznim funkcijama. Broj ulaza neuronske mreže je varirao, dok je broj izlaza uvijek iznosio tri s obzirom da je uzorak mogao biti svrstan samo u jednu od tri vrste kamena korištenih u obradi bušenjem. Uzorak je svrstan pod vrstu kamena, čiji neuron je poprimio najveću vrijednost na izlazu iz neuronske mreže.

### 4.1. Prvi korak klasifikacije tvrdoće kamena

U prvom koraku provedena je klasifikacija na temelju svake od izdvojenih značajki energije vibracija za svaku od 23 širine frekvencijskog pojasa zasebno. Naprimjer, za os  $X$  u frekvencijskom pojasu širine 5 Hz provedena je zasebna klasifikacija za svaki od 999 frekvencijskih pojaseva, tj. vrijednosti energija tih pojaseva. Kod kombinacije značajki, npr.  $XY$ , postupak je bio identičan uz dodatni ulaz u mrežu s pripadajućim značajkama signala vibracija iz  $Y$  smjera. Dodatne ulaze neuronske mreže činili su posmak i brzina obrade pri kojima su snimljen signali vibracija. Tablica 4.1 prikazuje kombinacije značajki temeljem kojih je provedena klasifikacija, uz pripadajući broj ulaza neuronske mreže.

Tablica 4.1. Kombinacije značajki korištenih u prvom koraku klasifikacije [3]

Kombinacija značajki	Ulazi u neuronsku mrežu			Ukupan broj ulaza u mrežu
	$vc$	$f$		
$X$	$vc$	$f$	$E(VIB_X)$	3
$Y$	$vc$	$f$	$E(VIB_Y)$	3
$Z$	$vc$	$f$	$E(VIB_Z)$	3
$XY$	$vc$	$f$	$E(VIB_X), E(VIB_Y)$	4
$YZ$	$vc$	$f$	$E(VIB_Y), E(VIB_Z)$	4
$XZ$	$vc$	$f$	$E(VIB_X), E(VIB_Z)$	4
$XYZ$	$vc$	$f$	$E(VIB_X), E(VIB_Y), E(VIB_Z)$	5
$XYZ_{SUM}$	$vc$	$f$	$E(VIB_{XYZ})$	3
$XYZ + XYZ_{SUM}$	$vc$	$f$	$E(VIB_X), E(VIB_Y), E(VIB_Z), E(VIB_{XYZ})$	6

Nakon provedene klasifikacije analizirani su rezultati svih navedenih kombinacija značajki u 23 širine frekvencijskog pojasa. Dobiveni rezultati su već u prvom koraku bili zadovoljavajući,

budući da je nekolicina značajki imala uspješnost klasifikacije preko 80%. U tablici 4.2 prikazani su najuspješniji rezultati svake od 23 širine frekvencijskog pojasa neovisno o ulaznoj kombinaciji značajki. Iz prikazanih rezultata je vidljivo kako je većina najboljih rezultata postignuta kombinacijom značajki koje su pripadale signalima vibracija sve tri osi (*XYZ*). U pravilu su niže vrijednosti frekvencije postizale bolju uspješnost klasifikacije kroz sve širine frekvencijskog pojasa. Također je iz tablice, vidljivo kako su uži frekvencijski pojasevi većinom ostvarili nešto bolje rezultate nego široki. Uspješnost klasifikacije (*UK*) uzima u obzir uspješnost klasifikacije uzoraka iz sva tri test skupa, a definirana je izrazom:

$$UK = \frac{\text{Broj točno klasificiranih uzoraka}}{\text{Ukupan broj uzoraka}} \cdot 100 \text{ [\%]}$$

Tablica 4.2. Najuspješniji rezultati svakog frekvencijskog pojasa nakon prvog koraka klasifikacije

Kombinacija značajki	Frekvencijski pojas, Hz			Uspješnost klasifikacije ( <i>UK</i> ), %
	Širina	$f_D$	$f_G$	
<i>XYZ + XYZ<sub>SUM</sub></i>	5	110	115	77,78
<i>XYZ</i>	10	105	115	82,10
<i>XY</i>	20	125	145	79,01
<i>XYZ + XYZ<sub>SUM</sub></i>	30	95	125	79,63
<i>YZ</i>	40	125	165	80,25
<i>YZ</i>	50	105	155	84,57
<i>XYZ</i>	60	185	245	79,01
<i>XYZ + XYZ<sub>SUM</sub></i>	70	75	145	81,48
<i>XYZ + XYZ<sub>SUM</sub></i>	80	85	165	80,86
<i>XY</i>	90	95	185	76,54
<i>XYZ</i>	100	505	605	75,31
<i>XYZ</i>	200	1805	2005	78,40
<i>XZ</i>	300	1505	1805	74,07
<i>XYZ</i>	400	5	405	74,69
<i>XYZ</i>	500	5	505	76,54
<i>XYZ</i>	600	1205	1805	75,92



<i>XYZ</i>	700	705	1405	72,22
<i>XYZ</i>	800	805	1605	72,22
<i>XYZ + XYZ<sub>SUM</sub></i>	900	5	905	74,69
<i>XY</i>	1000	5	1005	72,22
<i>XYZ</i>	1500	5	1505	77,16
<i>XYZ</i>	2500	2505	5000	70,99
<i>XYZ</i>	5000	5	5000	72,22

#### 4.2. Međukorak klasifikacije tvrdoće

U međukoraku su pripremljeni ulazi neuronske mreže koji su korišteni u drugom koraku klasifikacije. Drugi korak klasifikacije proveden je na temelju pet različitih pragova uspješnosti prvoga koraka. Definirani pragovi uspješnosti iznosili su: 55 %, 60 %, 65 %, 70 % i 75 %.

Za početak izdvojene su sve značajke koje su zadovoljile pragove uspješnosti bez obzira na širinu frekvencijskog pojasa pojedine kombinacije značajki. Među izdvojenim značajkama mogle su se pronaći dvije ili više značajke koje su iz različitih širina frekvencijskih pojasa, ali pokrivaju iste frekvencije. Odnosno postoji ponavljanje ulaznih podataka što nikako nije dopušteno, inače su rezultati nevaljani. Naprimjer, ako je značajka 10-15 Hz u frekvencijskom pojasu 5 Hz ostvarila zadovoljavajući rezultat, a pritom je i značajka 5-105 Hz u frekvencijskom pojasu 100 Hz također ostvarila zadovoljavajući rezultat. Obje značajke su izdvojene, ali kako ne bi došlo do ponavljanja podataka uzeta je u obzir samo značajka užeg frekvencijskog pojasa što je u ovome slučaju 5 Hz. Tablica 4.3 prikazuje ukupan broj jedinstvenih značajki izdvojenih za svaku kombinaciju značajki svakoga praga uspješnosti.

Na temelju tablice moguće je dodatno analizirati rezultate prvog kruga. Vidljivo je kako su značajke pojedinačnih osi ostvarile dosta lošije rezultate nego kada su kombinirane osi. Također, može se primijetiti kako je zapravo mali broj značajki ostvario uspješnost veću od 75 %. Zbog toga se tablica 4.2 može na prvu činiti malo zavaravajuća s obzirom da su prikazani rezultati s *UK* preko 80 %. Iz zadnja tri stupca tablice 4.3 može se protumačiti kako suma značajki ne ostvaruje očekivane rezultate, te u kombinaciji s kombinacijom značajki *XYZ* zapravo smanjuje *UK*.

Tablica 4.3. Ukupan broj izdvojenih jedinstvenih značajki iz svih kombinacija značajki za svaki postavljeni prag uspješnosti

	$X$	$Y$	$Z$	$XY$	$YZ$	$XZ$	$XYZ$	$XYZ_{SUM}$	$XYZ + XYZ_{SUM}$
55 %	45	40	47	157	200	185	287	83	264
60 %	8	11	14	65	97	84	142	24	138
65 %	1	4	2	18	32	35	69	9	54
70 %	0	1	1	11	13	12	28	3	23
75 %	0	0	0	3	4	3	9	0	6

### 4.3. Drugi korak klasifikacije

Kroz odjeljak detaljno su prikazani i analizirani konačni rezultati klasifikacije tvrdoće. Kao što je već rečeno, značajke izdvojene i analizirane u međukoraku korištene su kao ulazi neuronske mreže drugog koraka. Tablica 4.4 prikazuje opći zapis ulaza korištenih za pojedine kombinacije značajki, a ukupan broj ulaza ovisno o pragu uspješnosti se može izračunati na temelju tablice 4.3.

Tablica 4.4. Kombinacije značajki korištenih u drugom koraku klasifikacije [3]

Kombinacija značajki	Ulazi u neuronsku mrežu			Ukupan broj ulaza u mrežu
$X$	$v_C$	$f$	$E(VIB_X)_1 \dots E(VIB_X)_n$	$2 + n$
$Y$	$v_C$	$f$	$E(VIB_Y)_1 \dots E(VIB_Y)_n$	$2 + n$
$Z$	$v_C$	$f$	$E(VIB_Z)_1 \dots E(VIB_Z)_n$	$2 + n$
$XY$	$v_C$	$f$	$E(VIB_X)_1 \dots E(VIB_X)_n, E(VIB_Y)_1 \dots E(VIB_Y)_n$	$2 + 2n$
$YZ$	$v_C$	$f$	$E(VIB_Y)_1 \dots E(VIB_Y)_n, E(VIB_Z)_1 \dots E(VIB_Z)_n$	$2 + 2n$
$XZ$	$v_C$	$f$	$E(VIB_X)_1 \dots E(VIB_X)_n, E(VIB_Z)_1 \dots E(VIB_Z)_n$	$2 + 2n$
$XYZ$	$v_C$	$f$	$E(VIB_X)_1 \dots E(VIB_X)_n, E(VIB_Y)_1 \dots E(VIB_Y)_n, E(VIB_Z)_1 \dots E(VIB_Z)_n$	$2 + 3n$
$XYZ_{SUM}$	$v_C$	$f$	$E(VIB_{XYZ})_1 \dots E(VIB_{XYZ})_n$	$2 + n$
$XYZ + XYZ_{SUM}$	$v_C$	$f$	$E(VIB_X)_1 \dots E(VIB_X)_n, E(VIB_Y)_1 \dots E(VIB_Y)_n, E(VIB_Z)_1 \dots E(VIB_Z)_n, E(VIB_{XYZ})_1 \dots E(VIB_{XYZ})_n$	$2 + 4n$

U tablicama 4.5, 4.6, 4.7, 4.8 i 4.9 prikazani su rezultati postignuti ovisno o izdvojenim značajkama prvog kruga koje su zadovoljile navedeni prag uspješnosti. S time da su u prva tri stupca prikazani rezultati svakoga testnog skupa uzoraka zasebno. Zatim slijedi stupac aritmetičke sredine (*UK*) prethodna tri stupca, a zadnja tri stupca prikazuju rezultate uspješnosti klasifikacije pojedine vrste kamena. U tablicama 4.8 i 4.9 pojavljuje se povlaka (-). Povlaka označava neprovedenu klasifikaciju zbog izostanka ulaznih značajki energije jer nisu zadovoljile postavljeni prag uspješnosti, što je uostalom vidljivo u tablici 4.3.

Analizom tablica moguće je zaključiti samo da su dobiveni rezultati izrazito nepredvidivi. Između istih kombinacija značajki u različitim tablicama postoje znatne varijacije u ostvarenim rezultatima. Do varijacija dolazi ponajviše zbog ukupnog broja ulaznih značajki, a najbolji rezultati su ostvareni pri korištenju najvećeg broja značajki što odgovara najmanjoj vrijednosti postavljenoga praga. Najbolji postignuti rezultat, bezobzira na postavljene pragove uspješnosti i kombinaciju značajki, iznosi visokih 90,74 %. Vidljiva je sličnost s rezultatima iz prvog kruga budući da najbolje rezultate opet ostvaruje kombinacija značajki po sve tri osi (*XYZ*). Iz rezultata klasifikacije dobivenih za pojedinu vrstu kamena, ponovo se može primijetiti znatna varijacija rezultata, ali se mogu primijetiti pojedini vrlo visoki postotci (i do 100 %). U svakoj tablici je naznačen redak koji je ostvario najbolji rezultat.

Tablica 4.5. Rezultati uspješnosti klasifikacije tvrdoće nakon drugog koraka s obzirom na *UK* > 55 % u prvome koraku

Kombinacija značajki	$T_1$ %	$T_2$ %	$T_3$ %	<i>UK</i> %	$K_1$ %	$K_2$ %	$K_3$ %
<i>X</i>	90,74	77,78	83,33	83,95	81,48	88,89	81,48
<i>Y</i>	81,48	81,48	70,37	77,78	74,07	79,63	79,63
<i>Z</i>	74,07	81,48	83,33	79,63	72,22	85,19	81,48
<i>XY</i>	90,74	88,89	75,93	85,19	83,33	94,44	77,78
<i>YZ</i>	87,04	83,33	87,04	85,80	75,93	94,44	87,04
<i>XZ</i>	88,89	83,33	92,59	88,27	79,63	100	85,19
<i>XYZ</i>	90,74	88,89	92,59	90,74	87,04	100	85,19
<i>XYZ<sub>SUM</sub></i>	88,89	85,19	90,74	88,27	79,63	92,59	92,59
<i>XYZ + XYZ<sub>SUM</sub></i>	87,04	90,74	88,89	88,88	83,33	96,30	87,04

Tablica 4.6. Rezultati uspješnosti klasifikacije tvrdoće nakon drugog koraka s obzirom na UK  
> 60 % u prvome koraku

Kombinacija značajki	$T_1$ %	$T_2$ %	$T_3$ %	UK %	$K_1$ %	$K_2$ %	$K_3$ %
$X$	88,89	83,33	87,04	86,42	85,19	92,59	81,48
$Y$	81,48	75,93	79,63	79,01	79,63	85,19	72,22
$Z$	77,78	85,19	81,48	81,48	81,48	79,63	83,33
$XY$	79,63	88,89	83,33	83,95	74,07	92,59	85,19
$YZ$	87,04	87,04	77,78	83,95	70,37	98,15	83,33
$XZ$	83,33	87,04	83,33	84,57	75,93	88,89	88,89
$XYZ$	85,19	92,59	88,89	88,89	79,63	92,59	94,44
$XYZ_{SUM}$	85,19	87,04	83,33	85,19	83,33	85,19	87,04
$XYZ + XYZ_{SUM}$	88,89	90,74	83,33	87,65	75,93	96,30	90,74

Tablica 4.7. Rezultati uspješnosti klasifikacije tvrdoće nakon drugog koraka s obzirom na UK  
> 65 % u prvome koraku

Kombinacija značajki	$T_1$ %	$T_2$ %	$T_3$ %	UK %	$K_1$ %	$K_2$ %	$K_3$ %
$X$	64,81	66,67	66,67	66,05	48,15	70,37	79,63
$Y$	74,07	68,52	68,52	70,37	61,11	88,89	61,11
$Z$	66,67	64,81	66,67	66,05	66,67	61,11	70,37
$XY$	83,33	83,33	83,33	83,33	70,37	87,04	92,59
$YZ$	83,33	85,19	77,78	82,10	79,63	75,93	90,74
$XZ$	87,04	92,59	85,19	88,27	77,78	94,44	92,59
$XYZ$	87,04	81,48	87,04	85,19	81,48	92,59	81,48
$XYZ_{SUM}$	77,78	94,44	85,19	85,80	81,48	88,89	87,04
$XYZ + XYZ_{SUM}$	81,48	92,59	77,78	83,95	68,52	92,59	90,74

Tablica 4.8. Rezultati uspješnosti klasifikacije tvrdoće nakon drugog koraka s obzirom na UK > 70 % u prvome koraku

Kombinacija značajki	$T_1$ %	$T_2$ %	$T_3$ %	UK %	$K_1$ %	$K_2$ %	$K_3$ %
$X$	-	-	-	-	-	-	-
$Y$	74,07	77,78	61,11	70,99	77,78	75,93	59,26
$Z$	70,37	77,78	70,37	72,84	57,41	83,33	77,78
$XY$	88,89	87,04	85,19	87,04	79,63	92,59	88,89
$YZ$	79,63	85,19	79,63	81,48	64,81	88,89	90,74
$XZ$	79,63	77,78	81,48	79,63	83,33	70,37	85,19
$XYZ$	88,89	90,74	75,93	85,19	83,33	83,33	88,89
$XYZ_{SUM}$	85,19	81,48	74,07	80,25	72,22	81,48	87,04
$XYZ + XYZ_{SUM}$	88,89	90,74	79,63	86,42	92,59	79,63	87,04

Tablica 4.9. Rezultati uspješnosti klasifikacije tvrdoće nakon drugog koraka s obzirom na UK > 75 % u prvome koraku

Kombinacija značajki	$T_1$ %	$T_2$ %	$T_3$ %	UK %	$K_1$ %	$K_2$ %	$K_3$ %
$X$	-	-	-	-	-	-	-
$Y$	-	-	-	-	-	-	-
$Z$	-	-	-	-	-	-	-
$XY$	75,93	85,19	70,37	77,16	77,78	72,22	81,48
$YZ$	87,04	90,74	85,19	87,65	85,19	88,89	88,89
$XZ$	88,89	81,48	74,07	81,48	72,22	94,44	77,78
$XYZ$	92,59	85,19	85,19	87,65	90,74	83,33	88,89
$XYZ_{SUM}$	-	-	-	-	-	-	-
$XYZ + XYZ_{SUM}$	81,48	79,63	75,93	79,01	72,22	75,93	88,89

## 5. ZAKLJUČAK

U modernim obradnim sustavima uvode se nadzorni sustavi kako bi se na vrijeme prepoznali problemi prekomjerne istrošenosti ili loma alata. Ako se problem prepozna dovoljno rano moguće je spriječiti pad kvalitete i zastoje u proizvodnji. Nadalje, u procesima obrade heterogenih i anizotropnih materijala, kod kojih se javljaju varijacije mehaničkih svojstava, moguće je vršiti nadzor tvrdoće obratka, što je korisno s obzirom da je dokazano kako upravo kod takvih materijala dolazi do izrazitog trošenja alata.

Zbog ekonomičnosti i mogućnosti prikupljanja podataka o stanju oštrice i uvjetima procesa u stvarnom vremenu tijekom rada, najprimjenjivnije su indirektno metode nadzora. Indirektno metode nadzora, najčešće prikupljaju podatke o silama i momentima, jakostima električne struje na prigonima, vibracijama i akustičnoj emisiji. Prema rezultatima već provedenih eksperimenata prikupljeni podaci se mogu dovesti u korelaciju s određenim režimima rada obradnog procesa, stanjem alata i tvrdoćom obratka.

U sklopu rada proveden je eksperiment kako bi se ustanovila mogućnost primjene signala vibracija u klasifikaciji tvrdoće kamena. Pritom su korišteni podaci koji su snimljeni pri obradi u kojoj je korišteno novodizajnirano svrdlo. Novodizajnirano svrdlo ima dva kanala, uzdužni kanal kroz cijelo svrdlo služi za dovod SHIP-a, a poprečni kanal pri vrhu svrdla služi za izlazak SHIP-a iz alata i podmazivanje oštrica. Tijekom eksperimenta kroz kanale je dovođen komprimirani zrak.

Već u prvom koraku klasifikacije tvrdoće obratka dobili su se zadovoljavajući rezultati. U drugome koraku su postignuti još bolji rezultati, koji bi se mogli svrstati u grupu izvanrednih. Općenito, najbolji rezultati su ostvareni korištenjem kombinacije značajki po sve tri osi (XYZ), a sveukupno najbolje ostvareni rezultat iznosi 90,74 %. Nadalje ako se promatraju rezultati uspješnosti klasifikacije pojedine vrste kamena, u dva navrata je ostvarena uspješnost klasifikacije od 100 %, a redovito je ista prelazila 90 %. Iako metoda pokazuje veliki potencijal, za ozbiljniju primjenu u industriji preporuča se provođenje dodatnih eksperimenata s obzirom da postoje znatne varijacije u rezultatima, kao i da metoda nije provjerena kod viših stupnjeva istrošenosti alata.

## LITERATURA

- [1] Abdel-Gawad El-Hofy H. *Fundamentals of Machining Processes: Conventional and Nonconventional processes*. 6nd ed. London: Taylor & Francis; 2014.
- [2] Slika CNC obradnog centra: <https://okuma.com/> , pristupljeno: 14.4.2023.
- [3] Klaić M. *Indirektni nadzor istrošenosti alata i tvrdoće obratka kod bušenja kamena* [doktorski rad]. Zagreb: Fakultet strojarstva i brodogradnje; 2018.
- [4] Li H., Chen Y. *Machining Process Monitoring*. In: Y. C. Nee A., editor. *Handbook of Manufacturing Engineering and Technology*. London: Springer; 2015., p. 941-981.
- [5] Wang L., X. Gao R. *Condition Monitoring and Control for Intelligent Manufacturing*. UK: Springer, 2006.
- [6] Landers G. R., Ulsoy A. G., Furness J. R. *Process Monitoring and Control of Machining Operations*. In: Nwokah D. I. O., Hurmuzlu Y., editors. *The Mechanical systems design handbook: modeling, measurement, and control*. USA: CRC Press; 2001.
- [7] Fuš H. *Utjecaj odvođenja čestica na aksijalnu silu pri bušenja kamena* [diplomski rad]. Zagreb: Fakultet strojarstva i brodogradnje; 2018.
- [8] Slika trošenje alata tokom njegova radnog vijeka: Chen SH., Luo ZR. *Study of using cutting chip color to the tool wear prediction*. The International Journal of Advanced Manufacturing Technology. 2020 July; 109:823-839. doi. 10.1007/s00170-020-05354-2.
- [9] Klaić M. et al. *On-line workpiece hardness monitoring in stone machining*. Transactions of FAMENA. 2020 Feb.; 43(4):43-53. doi. 10.21278/TOF.43404.
- [10] *Hallova pojava*: <http://struna.ihj.hr/naziv/hallova-pojava/8605/> , pristupljeno: 24.4.2023.
- [11] Rajendran A., Asokan G. *Real time monitoring of machining process and data gathering for digital twin optimization* [degreee project]. Stockholm: KTH Royal institute of technology: 2021.
- [12] Subramanian S. J. et al. *Study on Drilling Process Parameters*. Proceedings of International conference on newer engineering concepts and technology – ICONECT 2018, Vol. 6(7), Samayapuram, India, 2018.
- [13] Balaji M., Murthy B. S. N., Mohan Rao N. *Optimization of Cutting Parameters in Drilling of AISI 304 Stainless Steel Using Taguchi and ANOVA*. Procedia Technology. 2016 April; 25:1106-1113. doi. 10.1016/j.protcy.2016.08.217.

- 
- [14] Hoseinie S. H., Ataei M., Mikaeil R. *Comparison of Some Rock Hardness Scales Applied in Drillability Studies*. Arabian journal for science and engineering. 2012 July. 37:1451-1458. doi. 10.1016/j.protcy.2016.08.217.
- [15] Novaković B., Majetić D., Široki M. *Umjetne neuronske mreže*. Zagreb: Fakultet strojarstva i brodogradnje; 1998.
- [16] Brezak D. et al., *Tool Wear Monitoring Using Radial Basis Function Neural Network*, Proceedings of International Joint Conference on Neural Networks – IJCNN 2004, Vol. 3, Budapest, Hungary, 2004., p. 1859-1863.