



PREDIKTIVNO MODELOVANJE HRAPAVOSTI POVRŠINE PRI OBRADI GLODA-NJEM LEGURE TITANIJUMA Ti-6Al-4V UZ UPOTREBU MAŠINSKOG UČENJA

PREDICTIVE MODELING OF SURFACE ROUGHNESS DURING MILLING OF TITANIUM ALLOY Ti-6Al-4V USING MACHINE LEARNING

Mile Đurić, Borislav Savković, *Fakultet tehničkih nauka, Novi Sad*

Oblast – MAŠINSTVO

Kratak sadržaj – *Analiziranje uticaja ulaznih faktora na izlaznu veličinu (hrapavost), modelovanje optimalne kombinacije faktora u cilju postizanja bolje hrapavosti obrađene površine.*

Ključne reči: Taguchi, hrapavost, Minitab, MATLAB, modelovanje, neuronske mreže, glodanje

Abstract - *Analyzing the influence of input factors on the output value (roughness), modeling the optimal combination of factors in order to achieve a better roughness of the processed surface.*

Keywords: Taguchi, roughness, Minitab, MATLAB, modelling, neural network, milling

1. UVOD

Eksperimentalni deo rada predstavlja jedan deo istraživanja koji je izveden u Laboratoriji za mašine alatke i CIM sisteme Mašinskog fakulteta u Istočnom Sarajevu. Naglasak istraživanja bio je na analizi uticaja širine faktora na rezultate planiranih eksperimenta.

Ukupno su izvedena četiri eksperimenta, koja su obuhvatila obradu glodanjem legure titanijuma, uz četiri faktora, svaki sa tri nivoa. Promatrani faktori su uključivali brzinu rezanja, dubinu rezanja, pomak, te uticaj sredstva za hlađenje i podmazivanje. U eksperimentima je varirana različita širina faktora brzine rezanja, dubine rezanja i pomak po zubu glodala, dok je izlazna veličina, odnosno srednja aritmetička hrapavost, merena na površini nastaloj nakon obrade čeonom ili obimnom stranom alata.

Eksperimentalni rezultati predstavljeni u ovom radu čine jedan od četiri izlaza dobijena u okviru pomenutog istraživanja. Ispitivanja su izvršena na glodalici Emco Concept Mill 250, dok je za merenje izlazne veličine (hrapavosti) korišten Mitutoyo surftest SJ210 uređaj. Materijal nad kojim je izvršeno ispitivanje je legura titanijuma Ti-6Al-4V.

Početne stranice ovog rada su posvećene neuronskim mrežama i osnovama glodanja, dok epilog ovog rada predstavlja analize eksperimentalnih rezultata koje su izvršene u Excelu, Minitab-u i MATLAB-u.

NAPOMENA:

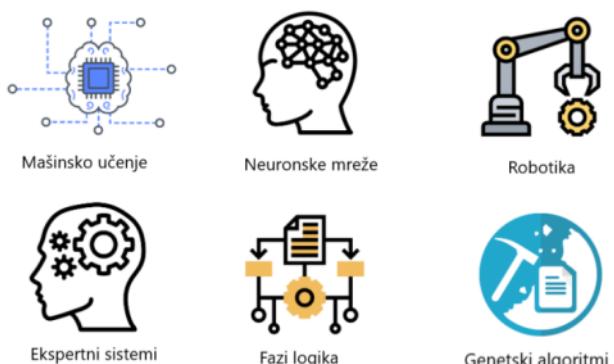
Ovaj rad proistekao je iz master rada čiji mentor je bio dr Borislav Savković, vanr. prof.

2. NEURONSKE MREŽE

Veštačka inteligencija predstavlja spoj konvencionalne nauke, psihologije i fiziologije, u cilju stvaranja sistema koji bi se mogao smatrati „inteligentnim“. Ona se često povezuje sa konceptom znanja, ali se procenjuje da nervni sistem čoveka još uvek daleko ispred veštačke inteligencije.

Neuronske mreže se mogu definisati kao sistem sastavljen od više jednostavnih procesora (jedinica), u kojem svaka od jedinica ima lokalnu memoriju u kojoj pamti podatke koje obrađuje. Ove jedinice su povezane komunikacionim kanalima (vezama) i preko njih se razmenjuju podaci koji su pretežno numerički. Negde se neuronska mreža može definisati kao model mašinskog učenja dizajniran da oponaša funkciju i strukturu ljudskog mozga.

Neuronske mreže se oslanjaju na podatke o obuci da bi naučile i poboljšale svoju tačnost tokom vremena. Međutim, kada se ovi algoritmi učenja primene na odgovrajući način, oni postaju moćni alati u računarskoj nauci i veštačkoj inteligenciji, omogućavajući nam da klasifikujemo i grupišemo podatke velikom brzinom. Zadaci kao što su prepoznavanju govora ili slike mogu trajati nekoliko minuta u odnosu na značajno veće vreme koje je potrebno za identifikaciju od strane ljudi. Jedna od najpoznatijih neuronskih mreža je Google-ov algoritam za pretragu.



Slika 1. Podela veštačke inteligencije

ISTORIJAT NEURONSKIH MREŽA

Neuronske mreže se prvi put pominju početkom četrdesetih godina 20-og veka. Najpre su se neurofilozov Veren MekKuloh i logičar Valter Pitsa dotakli ove teme u članku pod nazivom „A Logical Calculus of Ideas

Immanent in Nervous Activity“ koji je objavljen 1943. godine. Ovaj članak je poslužio kao osnova za dalji razvoj neuronskih mreža i u mnogim istraživačim i naučnim radovima se ovaj rad citira.

Početkom pedesetih godina Marvin Minski je konstruisao neuroračunar pod nazivom „Snark“. Ovaj računar je mogao da podešava težinske koeficijente, ali nije uspeo da ostvari značajnije rezultate. Frenk Rozenblat i Čarls Vigtmann su 1958. godine razvili računar „Mark“, koji je mnogo bolje funkcionisao u odnosu na „Snark“ računar. Frank Rozenblat je zaslужan za otkriće jednoslojne neuronske mreže, poznatije kao perceptron.

Jedan od najzaslužnijih ljudi koji je doprineo populizaciji neuronskih mreža bio je poznati fizičar Džon Hopfield koji je sredinom 80-tih u svome radu ispravio paralelu između neuronskih mreža i odeđenih fizičkih veličina. Bark Kosko je u svojoj knjizi “Neural Networks and Fuzzy Systems” dokazao da neuronske mreže i fazi logiku opisuju isti skup problema.

Početkom devedesetih godina prošlog veka, neuronske mreže su počele da se izučavaju kao predmet na nekoliko prestižnih univerziteta širom SAD. Od tada kreće intezivan rast i razvoj neuronskih mreža koji ima tendenciju da se nastavi daleko u budućnosti.

Smatra se da će neuronske mreže u budućnosti biti dominantna oblast primene veštačke inteligencije u odnosu na ostale oblasti.

PODELA NEURONSKIH MREŽA

Neuronske mreže se mogu podeliti prema različitim kriterijumima. Osnovna podela neuronskih mreža je na biološke i veštačke neuronske mreže.

Biološke neuronske mreže (BNN)

Neurone možemo definisati kao nosioce informacija koji koriste električne impuse i hemijske signale za prenos informacija. Nervna stanica predstavlja osnovnu jedinicu ljudskog mozga, a ujedno i najsloženiju jedinicu ljudskog organizma. Neuroni prenose informacije u različite delove mozga i nervni sistem. Dakle, sve što mislimo, osećamo i kasnije činimo je sve zbog rada neurona.

Ukratko, možemo zaključiti da biološki neuroni komuniciraju jedni sa drugima tako što šalju hemikalije, zvane neurotransmiteri, preko malog prostora, nazvanog sinapsa, između aksona i dendrita susednih neurona.

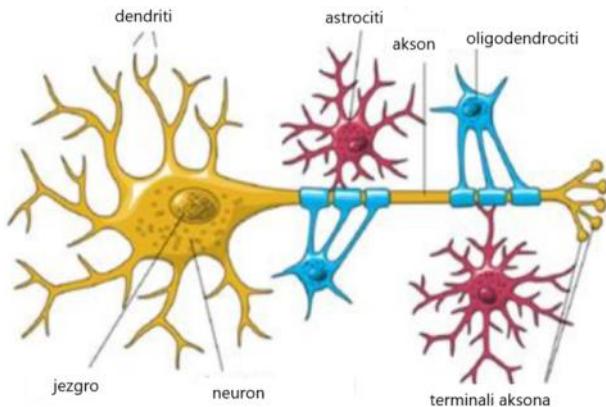
Dendriti primaju poruke od drugih ćelija. Neuroni, odnosno njihov električni impuls putuje duž aksona. Aksoni prenose poruke od tela ćelije ka drugim neuronima, žlezdama ili mišićima. Terminali aksona formiraju veze sa drugim ćelijama. Svaki čovek u nervnom sistemu ima oko 10^{11} neurona. Razlikujemo više od 100 različitih vrsta neurona koji se raspoređuju prema definisanom rasporedu. Svaki neuron je povezan sa oko 10^4 drugih neurona.

Prednosti BNN:

- Sinapse predstavljaju element za obradu ulaza,
- U stanju je da obrađuje veoma složene paralelne ulaze.

Nedostaci BNN:

- Ne postoji kontrolni mehanizam,
- Brzina obrade je spora jer je složena.



Slika 2. Struktura biološke neuronske mreže

Veštačke neuronske mreže (ANN)

Veštačka neuronska mreža je efikasan računarski sistem čiji je osnovni zadatak i namena preslikana iz analogije bioloških neuronskih mreža. ANN se takođe nazivaju „veštački neuronski sistemi“, ili „paralelno distribuirani sistemi za obradu“, ili „konekcionistički sistemi“. ANN dobija veliku kolekciju jedinica koje su međusobno povezane na neki način da bi se omogućila komunikacija između jedinica. Ove jedinice, koje se takođe nazivaju čvorovi ili neuroni, su jednostavnvi procesori koji rade paralelno. Svaki neuron je povezan sa drugim neuronom preko odgovarajuće veze. Svaka veza između neurona je povezana, odnosno definisana sa težinom koja ima informacije o ulaznom signalu. Ovo predstavlja najkorisniju informaciju za neurone za rešavanje određenog problema jer težina obično uzbudjuje ili zaustavlja signal koji se prenosi. Svaki neuron ima unutrašnje stanje, koje se naziva aktivacionim signalom. Izlazni signali, koji nastaju kombinovanjem ulaznih signala i aktivacionog pravila, mogu se poslati drugim jedinicama.

Veštačke neuronske mreže se sastoje od slojeva čvorova, koji sadrže ulazni sloj, jedan ili više skrivenih slojeva i izlazni sloj. Svaki čvor, ili veštački neuron, povezuje se sa drugim i ima povezanu težinu i prag. Ako je izlaz bilo kog pojedinačnog čvora iznad navedene granične vrednosti, taj čvor se aktivira i šalje podatke sledećem sloju mreže. U suprotnom, nikakvi podaci se ne prosleđuju na sledeći sloj mreže. U cilju povećanja sposobnosti rešavanja problema, možemo povećati broj skrivenih slojeva i broj neurona u bilo kom datom sloju, kao i broj putanja između neurona.

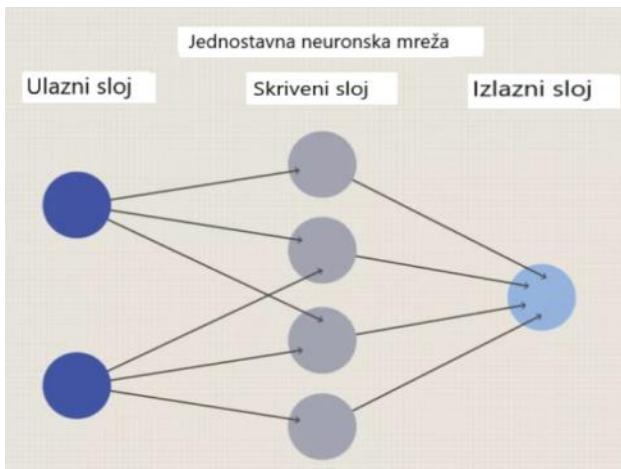
Razlikujemo tri tipa slojeva (čvorova) unutar neuronske mreže:

1.Ulazni sloj: Ovo je sloj koji prima korisnički unos. U većini slučajeva imamo samo jedan ulazni sloj u mreži. Prethodno obrađujemo tekst, slike, audio, video i druge tipove podataka da bismo dobili njihov numerički prikaz. Kasnije, prosleđujemo ovu brojevnu reprezentaciju kao informaciju svakom neuronu ulaznog sloja. Svaki neuron zatim primenjuje unapred definisanu nelinearnu matematičku funkciju za izračunavanje izlaza.

2.Skriveni sloj: Ovaj sloj se nalazi između ulaznog i izlaznog sloja. Ovde se izvode svi neophodni matematički složeni proračuni. Ovde neuronske mreže

uče da rešavaju zadate probleme. U neuronskoj mreži može postojati jedan ili više skrivenih slojeva. Neuroni u skrivenom sloju primaju svoje ulaze ili od neurona ulaznog sloja ili od neurona prethodno skrivenog sloja. Svaki neuron zatim prosleđuje ulaz drugoj nelinearnoj funkciji i nakon toga šalje izlaz neuronima sledećeg sloja.

3.Izlazni sloj: Ovaj sloj se isporučuje nakon nekoliko transformacija i optimizacija. Imamo samo jedan izlazni sloj u mreži koji označava logički završetak neuronske mreže. Konačni rezultat možemo imati kao jednostavnu binarnu klasifikaciju koja označava jednu od dve klase ili možemo imati višeklasne klasifikacije. Takođe možemo koristiti konačni rezultat kao predviđenu vrednost.



Slika 3. Struktura neuronske mreže

Prilikom opisivanja neurona, razlikujemo tri osnovna elementa:

1.Sinapse- predstavljaju skup linija od kojih se svaka karakteriše svojom jačinom i težinom. Efikasnost sinapse se izražava kroz sinaptičku težinu. Ulagani signal x_i se prilikom ulaza u sinapsu povezuje sa neuronom tako što se njegova vrednost pomnoži sa težinskim koeficijentom w_{ij} . U zavisnost od toga da li je težina pozitivna ili negativna vrednost, razlikujemo dva slučaja: a) u slučaju pozitivne vrednosti sinapse je pobuđujuća, b) u slučaju negativne vrednosti sinapsa je inhibitorna.

2.Sabirač- Ovaj element se označava sa Σ_i i on predstavlja sumu ulaznih signala. Na izlazu sabirača se dobija linearna kombinacija ulaza.

3.Aktivaciona funkcija- Preko ovog elementa dobijamo izlaz iz neurona na osnovu predhodnog izlaza kojeg smo dobili na izlazu sabirača. Vrednost izlaznog signala iz neurona je ograničena na neke konačne vrednosti, kao što su zatvoreni intervali. Neki od najčešće korišćenih skupova aktivacionih funkcija su binarne, linearne i hiperboličke sigmoidne aktivacione funkcije.

Prednosti ANN:

- Sposobnost učenja bez obzira na vrstu podataka (linearni ili nelinearni),
- ANN je veoma primenljiv i daje dobre rezultate pri predviđanju finansijskih, tržišnih promena.

Nedostaci ANN:

- Najjednostavnija arhitektura otežava predviđanje o tome kako će se mreža ponašati u budućnosti,
- Ova mreža zavisi od hardvera.

Podela veštačkih neuronskih mreža:

1. Feedforward i Feedback neuronska mreža
2. RBF neuronska mreža
3. Rekurentna neuronska mreža (RNN)
4. Konvolucionna neuronska mreža (CNN)
5. Mreža dugoročne memorije (LSTM)
6. Model od sekvene do sekvene
7. Modularne neuronske mreže

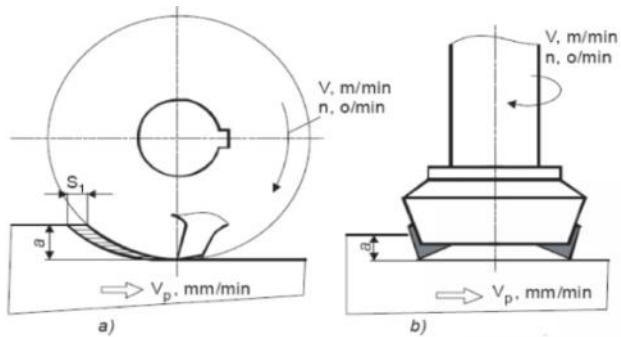
3. OSNOVE GLODANJA

Glodalica je vrsta maštine koja uklanja materijal sa radnog predmeta pri čemu glodalno vrši glavno kružno kretanje, dok obradak izvodi pomoćno pravolinjsko kretanje. To je vrsta procesa obrade u kojoj se glodalno koje ima više reznih ivica koristi za uklanjanje materijala sa radnog predmeta. Ova mašina alatka čini oko 85% svih procesa uklanjanja materijala.

Prema rasporedu reznih elemenata alata, možemo razlikovati dva osnovna postupka obrade glodanjem:

1. Obimno glodanje,

2. Čeono glodanje.



Slika 4. Osnovne operacije glodanja: a) obimno, b) čeono

Kod čeonog glodanja, sečenja se vrši prvenstveno sa krajnjim uglovima glodala. Čeono glodanje se koristi za sečenje ravnih površina na radnim predmetima ili za sečenje udubljena sa ravnim dnom. Kod obimnog glodanja, sečenje se vrši prvenstveno duž obima glodala, tako da poprečni presek površine koja se obrađuje dobija oblik glodala. U ovom slučaju može se videti kako se sečiva glodalica izvlače materijal iz radnog komada. Obimno glodanje je pogodno za glodanje dubokih otvora, navoja i zubaca zupčanika. Prema smeru međusobnih kretanja alata i predmeta obrade razlikujemo istosmerno i suprotnosmerno glodanje.

Alati za obradu glodanjem – glodalici spadaju u grupu višesečnih alata cilindričnog oblika sa reznim elementima raspoređenim po obimu ili čeonoj površini. Prema vrsti i obliku glodala koja se koristi pri obradi glodanjem, proizvodni zahvati se mogu izvoditi sa jednim od sledećih tipova glodala: valjkastim glodalima, čeonim glodalima, vretenastim glodalima, koturastim glodalim.

4. REALIZACIJA EKSPERIMENTA

Kao ulaz u eksperiment, posmatrali su se sledeća četiri faktori pri čeonom glodanju obradka: brzina rezanja,

dubina rezanja, pomak po zubu i sredstvo za hlađenje i podmazivanje. Svaki od ovih faktora je variran na tri nivoa. Izlaznu veličinu predstavlja hrapavost obrađene površine koja je izmerena pomoću Mitutoyo surftest SJ210 uređaja za merenje hrapavosti. Emco Concept Mill 250 predstavlja obradni vertikalni centar sa najnovijom tehnologijom servo pogona. Ova mašina raspolaze sa snagom od 7 kW, magacinom sa kapacitetom od 20 alata sa brzim dvostrukim griperom. Idealan za obradu čelika i aluminijuma. Za obradu na ovoj mašini korištena je legura Ti-6Al-4V.

Tagučijev metod

Na osnovu Tagučijevog plana eksperimenta izabran je Tagučijev L27 (3^4) ortogonalni niz, iz čega sledi da je izvršeno 27 merenja pri čemu su varirana 4 kontrolna faktora na 3 nivoa.

Naziv faktora	Nivo	1	2	3
	Oznaka			
Brzina	A	30	60	90
Pomak	B	0.05	0.12	0.2
Dubina	C	0.3	0.6	0.8
SHP	D	Emulzija (1)	Suho (2)	Turbina (3)

Tabela 1. Nivoi faktora eksperimenta

Nakon postavljanja plana eksperimenta i merenja rezultata, usledila je analiza dobijenih rezultata. Analiza varijacije (ANOVA) predstavlja niz koraka na osnovu kojih se analiziraju i simuliraju rezultati dobijeni eksperimentom.

Faktor	Stepen slobode	Suma kvadrata	Varijacije	F-test
	DF	S	V	F
A	2	0.065352	0.032676	4.547
B	2	2.449294	1.224647	170.398
C	2	0.477064	0.238532	33.189
D	2	0.670	0.334766	46.580

Tabela 2. ANOVA tabela

Vrednost F-testa za sva četiri faktora je ≥ 1 što znači da su sve vrednosti signifikantne. Na osnovu ove tabele dolazimo do zaključka da najveći uticaj na izlazne rezultate ima pomak, dok najmanji uticaj ima brzina. Procentualno učešće svakog od faktora, kao i greške na izlazne rezultate eksperimenta je sledeće:

$$P_A = \frac{S_A}{S_T} * 100\% = 1.72405 \% \quad - \text{brzina}$$

$$P_B = \frac{S_B}{S_T} * 100\% = 64.6148 \% \quad - \text{pomak}$$

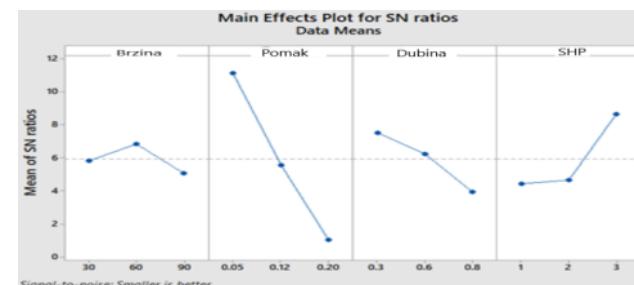
$$P_C = \frac{S_C}{S_T} * 100\% = 12.58542 \% \quad - \text{dubina}$$

$$P_D = \frac{S_D}{S_T} * 100\% = 17.66294 \% \quad - \text{SHP}$$

$$P_E = \frac{S_E}{S_T} * 100\% = 3.412791 \% \quad - \text{greška}$$

Minitab

Minitab je softverski alat za analizu podataka, statistiku i poboljšanje procesa koji koriste organizacije širom sveta za poboljšanje kvaliteta i smanjenje troškova. Minitab alate koriste inženjeri kvaliteta i statističari da pomognu u rešavanju problema iz stvarnog sveta. Minitab pruža korisnicima alate za obavljanje statističke analize, uključujući testiranje hipoteza, regresionu analizu i ANOVA. Pored toga, Minitab pruža različite grafičke alate koji pomažu korisnicima da vizuelizuju podatke. Da bi se uverili u tačnost rezultat dobijenih računanjem preko Taguči i ANOVA formula u Excel-u, poslužit ćemo se alatima koje poseduje Minitab.



Slika 5. Uticaj faktora na SN odnos

Na osnovu ovog grafika zaključujemo da se optimalne vrednosti SN odnosa dobiju kada su faktori na sledećim nivoima:

- brzina = 60 (drugi nivo)

•pomak = 0.05 (prvi nivo)

•dubina = 0.3 (prvi nivo)

•SHP = 3 (treći nivo)

Analiza varijacije za signal/šum odnos nam prikazuje p-vrednost za svaki od naših faktora, kao i za kombinacije prvog faktora sa ostalima.

Ako je:

r-vrednost < 0.05 - faktor je signifikantan.

r-vrednost > 0.05 - faktor nije signifikantan

Dolazimo do zaključka da je pomak signifikantan u slučaju kada nam je faktor poverenja 95%. Prilikom analiza sa upotreboom niže vrednosti faktora poverenja, signifikantnost su pokazali i ostali faktori.

Analysis of Variance for SN ratios									
Source	DF	Seq SS	Adj SS	Adj MS	F	P			
Brzina	2	14.387	14.387	7.193	1.68	0.263			
Pomak	2	464.562	464.562	232.281	54.29	0.000			
Dubina	2	59.478	59.478	29.739	6.95	0.027			
SHP	2	101.648	101.648	50.824	11.05	0.007			
Brzina*Pomak	4	5.649	5.649	1.412	0.33	0.849			
Brzina*Dubina	4	3.657	3.657	0.914	0.21	0.921			
Brzina*SHP	4	2.174	2.174	0.544	0.13	0.967			
Residual Error	6	25.673	25.673	4.279					
Total	26	677.325							

Slika 6. Analiza varijacije

Prema uticaju na izlazne rezultate eksperimenta, faktori se prema važnosti mogu poredati prema sledećem rasporedu:

Response Table for Signal to Noise Ratios
Smaller is better

Level	Brzina	Pomak	Dubina	SHP
1	5.835	11.175	7.558	4.435
2	6.857	5.560	6.244	4.669
3	5.076	1.034	3.966	8.665
Delta	1.782	10.141	3.593	4.230
Rank	4	1	3	2

Slika 7. Rangiranje faktora prema uticajnosti na izlaz

Očitavanjem vrednosti sa grafika možemo zaključiti da vrednost hrapavosti raste sa porastom vrednosti pomaka, dubine i brzine, dok opada sa povećanjem vrednosti SHP.

Neuronske mreže

Za obučavanje, realizaciju neuronske mreže korišćen je računarski program MATLAB R2016a koji je zasnovan na matematičkom konceptu matrica. Ovaj program poseduje širok opseg metoda neuronskih mreža kao i veliki broj algoritama za učenje. Pored toga, raspolaže i sa alatima za vizuelizaciju, simulaciju i realizaciju. Od ukupno 27 različitih kombinacija režima obrade koji su korišćeni prilikom eksperimenta, svih 27 je korišteno za obučavanje (treniranje) neuronske mreže dok je nasumično izabranih pet iskorišteno za testiranje neuronske mreže.

Broj eksperimenta	A	B	C	D	Ra srednje
3	30	0.05	0.8	3	0.280333
8	30	0.2	0.6	1	1.263667
13	60	0.12	0.3	2	0.487667
18	60	0.2	0.8	2	1.085667
23	90	0.12	0.6	3	0.437667

Tabela 3. Nasumično izabrani režimi za testiranje

Nakon analize rezultata dobijenih primenom neuronske mreže dolazimo do zaključka da je primetno odstupanje dobijeno samo u jednom slučaju treniranja mreže (odstupanje veće od 10%), dok su za ostala 4 slučaja odstupanja u dozvoljenim granicama. Ukupno prosečno odstupanje iznosi oko 5%.

Broj eksper.	A	B	C	D	Ra očekivano	Ra nakon treninga	Razlika u %
3	30	0.05	0.8	3	0.2803	0.2912	3.73
8	30	0.2	0.6	1	1.2636	1.2097	4.46
13	60	0.12	0.3	2	0.4876	0.4888	0.2
18	60	0.2	0.8	2	1.0856	0.9248	17,39
23	90	0.12	0.6	3	0.4376	0.4335	0.9

Tabela 4. Očekivane i dobijene izlazne vrednosti

9. ZAKLJUČAK

Vrednosti F-testa do kojih smo došli na kraju proračuna korišćenjem Tagučijeve metode nam pokazuju uticajnost (signifikantnost) svih faktora na izlaznu veličinu (hrapavost). Na osnovu ovih rezultata dolazimo do

zaključka da najveći uticaj na izlazne rezultate ima pomak, dok najmanji uticaj ima brzina.

Analiza podataka kroz Minitab je na neki način predstavljala proveru rezultata do kojih smo predhodno došli pri obradi podataka u Excel-u.

Rezultati koje smo dobili nakon treniranja neuronske mreže nisu u potpunosti zadovoljni naša očekivanja (jedan slučaj odstupa previše), što nam govori da treniranje ovakve mreže zahteva veću količinu ulaznih podataka kako bi se mreža dovoljno istrenirala.

10. LITERATURA

- [1] Ugochi, D., Yimin, Z., Kranthi, K.D., (2018). *Unsupervised Learning Based On Artificial Neural Network: A Review*, International Conference on Cyborg and Bionic Systems, pp. 323-327.
- [2] Tlhabadira, I., Daniyan, I.A., Machaka, R., Machio, C., Masu, L., VanStaden, L.R., (2019). *Modelling and optimization of surface roughness during AISI P20 milling process using Taguchi method*, The International Journal of Advanced Manufacturing Technology, pp.3707-3718.
- [3] Kovač, P., (2011). *Metode planiranja i obrade eksperimenta*, Fakultet tehničkih nauka.
- [4] Canakci, A., Erdemir, F., Varol, T., Patir, A., (2013). *Determining the effect of process parameters on particle size in mechanical milling using the Taguchi method: Measurement and analysis*, Elsevier; Measurment 46, pp. 3532-3540.
- [5] Mao, H., Jiao, L., Gao, S., Yi, J., Peng, Z., Liu, Z., Yan, P., Wang, X., (2016). *Surface quality evaluation in meso-scale end-milling operation based on fractal theory and the Taguchi method*, International Journal Advanced Manufacturing Technology 91, pp. 657-665.

Kratka biografija:



Mile Đurić rođen je u Bijeljini, 1999. godine. Diplomirao na Fakultetu tehničkih nauka u Novom Sadu, oblast Mašinstvo –Proizvodno mašinstvo.

Kontakt: djuric.mile99@gmail.com



Borislav Savković rođen je u Novom Sadu 1982. god. Doktorirao je na Fakultetu tehničkih nauka 2015. god., a od 2021 je u zvanju vanrednog profesora na Fakultetu tehničkih nauka. Oblast interesovanja su procesi obrade skidanjem materijala, simulacije kao i ekološko tehnološki sistemi.