

PRIMJENA NEURONSKIH MREŽA U PROCJENJIVANJU KVALITETE OBRADIVANE POVRŠINE

Goran Šimunović, Tomislav Šarić, Roberto Lujčić

Izvorni znanstveni članak

Površinska hrapavost se često uzima kao pokazatelj kvalitete obrađivanih radnih predmeta. Postizanje željene kvalitete površine od velike je važnosti za obavljanje funkcije proizvoda. U radu je promatran utjecaj obrađivanog materijala, alata, dubine rezanja, posmaka i brzine rezanja na hrapavost obrađivane površine. Prikupljeni rezultati eksperimentalnih istraživanja, na radnom predmetu „razvodnik uređaja za ronjenje“, poslužili su za procjenjivanje površinske hrapavosti primjenom neuronskih mreža. Analizirane su različite neuronske mreže širenja unazad, te je izabrana mreža s najmanjom razinom RMS (eng. Root Mean Square) greške. Procjena površinske hrapavosti koju daje model, može olakšati rad manje iskusnim tehnologima i na taj način skratiti vrijeme tehnološke pripreme proizvodnje.

Ključne riječi: kvaliteta površine, umjetna inteligencija, neuronske mreže

Surface quality prediction by artificial-neural-networks

Original scientific paper

Surface roughness is often taken as an important indicator of the quality of machined parts. Achieving the desired surface quality is of great importance for the product function. In this paper, influence of material, type of tool, cutting depth, feed rate and cutting speed on surface roughness is observed. Collected results of experimental research are utilized for surface roughness prediction using neural networks. Various structures of a back-propagation neural network have been analyzed and the network with the minimum RMS error has been selected. Evaluation of surface roughness obtained by neural networks model can help to less experienced technologists and therefore production preparation technological time can be shorter.

Keywords: surface quality, artificial intelligence, neural networks

1 Introduction Uvod

Postizanje optimalne kvalitete proizvoda, niskih troškova proizvodnje, poštivanje rokova isporuke, racionalnije upravljanje materijalnim i informacijskim tokovima u proizvodnom sustavu, uz sve izraženije pritiske globalizacije i rastuću konkurenciju na tržištu koje zahtijeva male serije i raznolikost proizvoda, teško je ostvarivo bez novih znanstvenih pristupa i primjene suvremenih informacijskih tehnologija u pripremi proizvodnje, kao i u samoj proizvodnji.

Stalnim inovacijama proizvoda, inovacijama u pripremi proizvodnje i proizvodnom procesu, podizanjem razine organizacije pripreme i proizvodnje, upravljanja proizvodnjom i kvalitetom, itd. pokušava se utjecati na skraćanje vremena razvoja novih proizvoda i njihovu konkurentnost na tržištu, a transfer novih tehnoloških znanja u vlastite proizvodne sustave i inventivnost zaposlenih u pripremi i proizvodnji od presudnog su značaja. Primjena računalskih sustava, naročito sustava temeljenih na umjetnoj inteligenciji, utjecala je da se godinama stjecana pojedinačna znanja i iskustva djelatnika u odjelima pripreme proizvodnje, objedine i učine na razini poduzeća općedostupnim, te iskoriste za ekspertno zaključivanje, procjenjivanje i optimiranje pripremnih i proizvodnih aktivnosti.

S ciljem skraćanja vremena i smanjenja troškova obrade pojedini autori provode optimizaciju parametara obrade [1, 2, 3]. Pri tome u obzir uzimaju veliki broj ograničenja kao što su sila rezanja, snaga stroja, postojanost alata, temperatura u zoni rezanja, itd. Isti se ciljevi pokušavaju ostvariti kontinuiranim poboljšanjem uvjeta rezanja, odnosno razvojem i primjenom on-line inteligentnog sustava za monitoring i optimizaciju uvjeta rezanja temeljenog na genetičkim algoritmima [4, 5]. U postupcima optimiranja režima obrade često se uz GA (eng. Genetic Algorithm) kombiniraju i neuronske mreže (NN) [6-9]. Izabrani režimi obrade kasnije utječu na kvalitetu obrađivane površine. Bolja kvaliteta obrađivane površine


pozitivno utječe na tribološka svojstva, dinamičku izdržljivost, otpornost na koroziju i estetiku, ali istovremeno podiže troškove proizvodnje. Iz tog se razloga problemom procjene hrapavosti obrađivanih površina bave mnogi autori [10, 11]. Za procjenu hrapavosti primjenjuju se različite tehnike: višestruka regresija [12, 13], matematičko modeliranje [14], ekspertni sustavi [15] i neuronske mreže [16-20].

U spomenutim radovima zaključci uglavnom potvrđuju opravdanost primjene umjetne inteligencije za rješavanje konkretnih tehnoloških problema. U višedimenzionalnim problemima u kojima je teško ili gotovo nemoguće uspostaviti matematičku ovisnost ulaznih i izlaznih varijabli, značajnu primjenu svakako imaju neuronske mreže. Međutim, bez obzira koji je osnovni smisao (cilj) primjene neuronskih mreža, rijetki autori govore o unaprjeđenju kroz integraciju prethodno istrenirane neuronske mreže u informacijski sustav, u okviru kojeg bi se rezultati koje neuronska mreža daje mogli višestruko iskoristiti. Upravo se problemom predviđanja hrapavosti površine radnih predmeta primjenom neuronskih mreža bavi ovaj rad.

2 Definicija problema i cilja istraživanja The problem and investigating goal definition

Promatra li se obrada odvajanjem čestica, mnogo je utjecajnih faktora na hrapavost obrađivane površine. Utjecajni faktori bi se mogli razvrstati u nekoliko skupina: faktori određeni radnim predmetom (kemijski sastav, mehanička svojstva, stanje površine,...), faktori određeni izabranim strojem (stabilnost, radne karakteristike, preciznost,...), faktori određeni izabranim alatom (vrsta materijala alata, geometrija alata, stanje rezne površine,...), faktori određeni izabranim režimima obrade (dubina rezanja, posmak i brzina rezanja) i faktori određeni sredstvom za hlađenje i podmazivanje (kemijski sastav, viskoznost, način i položaj hlađenja,...).

Tijekom realizacije količinski velike narudžbe, na probnoj seriji je promatran utjecaj nekih od spomenutih



Slika 1 Razvodnik uređaja za ronjenje
Figure 1 Part of the device for diving

faktora na površinsku hrapavost. Naime, u pogonima poduzeća Đuro Đaković u Slavanskom Brodu planiralo se izraditi ukupno 12000 komada "razvodnika uređaja za ronjenje" (slika 1). U probnoj seriji od 250 komada za naknadna ispitivanja u eksploatacijskim uvjetima, radni se predmet izrađivao iz čelika 25CrMo4 (C4730), ali uz suglasnost naručitelja koristio se i zamjenski materijal čelik 42CrMo4.V (C4732.4). Na probnoj su seriji varirani alati (reznice pločice: TCMT 090204-PF; VBMT 110304-PF) i parametri obrade (posmak: 0,08; 0,12; 0,15; 0,2 mm/okr; dubina rezanja: 0,8, 1,0; 1,2; 1,5 mm; broj okretaja: 1800; 2000; 2200; 2500 okr/min). Želja je bila tehnološkom operacijom tokarenja ispuniti zahtjev površinske hrapavosti 0,8 μm na površini ø40h5. Polazni je materijal bila šipka punog presjeka promjera ø50 mm. Za promatranu operaciju tokarenja izabrana je CNC tokarilica proizvođača "Knuth", tip: Proton 460. Nakon provedene operacije tokarenja slijedila je kontrola i mjerenje hrapavosti na promatranj površini. Podaci su dobiveni djelomičnim faktorskim planom pokusa (faktori na različitim razinama) s dva ponavljanja. Hrapavost je mjerena na udaljenosti 20 mm od jednog i drugog čela radnog predmeta na temperaturi radne okoline 23±1 °C.

Dobiveni podaci iskorišteni su za postavljanje procesnog modela za procjenu hrapavosti površine temeljenog na primjeni neuronskih mreža. Neuronske su mreže izabrane za postavljanje modela jer je znanje o problemu dostupno u obliku skupa diskretnih vrijednosti elementa vektora stanja i izlaznih veličina iz procesa. Naravno, uz ovaj pristup primijenjen u radu, bilo bi interesantno promatrati i uspoređivati rezultate koje bi dao višeregresijski model.

3 Procjena kvalitete obrađivane površine primjenom neuronske mreže "širenja unazad"

Evaluation of the surface quality by the application of the back-propagation neural network


3.1 Izbor vrste neuronske mreže – opći model

Selection of the type of neural network - general model

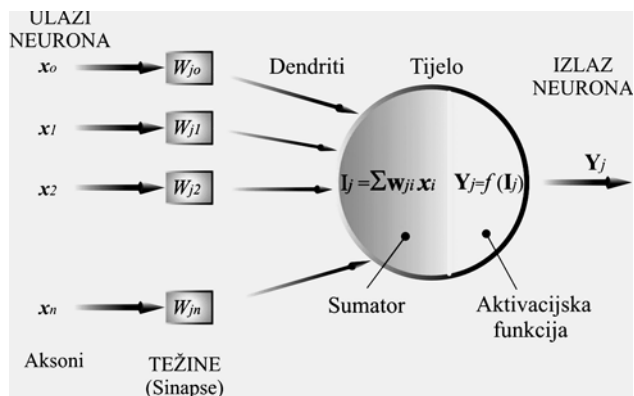
Promatrano istraživanje pripada problemima s kontinuiranim vrijednostima ulaza i izlaza, odnosno skupini problema predviđanja, te je stoga primijenjena mreža "širenja unazad" (eng. Back-Propagation Network). Na slici 2 je prikazana struktura mreže širenja unazad s jednim skrivenim slojem (skrivenih slojeva može biti i više), a na slici 3 struktura umjetnog neurona.

Tijekom procesa učenja cilj je omogućiti brzo konvergiranje i smanjiti globalnu grešku danu izrazom (1).

$$E = 0,5 \cdot \sum (d_k - x_k)^2 \tag{1}$$



Slika 2 Struktura mreže širenja unazad
Figure 2 Structure of a back-propagation network



Slika 3 Model strukture neurona
Figure 3 Model of a neuron structure

Globalna se greška kod ove vrste mreže širi unazad kroz mrežu sve do ulaznog sloja pri čemu se prema željenim vrijednostima izlaza neuronske mreže podešavaju težine veza u mreži. Povećanje ili smanjenje trenutnih vrijednosti težina $w_{ji}^{[s]}$ utječe na opadanje globalne greške.

Primjenom pravila gradijentnog opadanja može se izraziti prirast težina veza u mreži $\Delta w_{ji}^{[s]}$:

$$\Delta w_{ji}^{[s]} = -\alpha \cdot \left(\frac{\partial E}{\partial w_{ji}^{[s]}} \right) \tag{2}$$

gdje je α koeficijent učenja.

Tablica 1 Varijable s vrijednostima protezanja za predloženi model istraživanja
Table 1 Domain of the variables for the proposed investigating model

Rb.	Naziv varijable	Donja vrijednost	Gornja vrijednost
1.	vrsta materijala	1	2
2.	vrsta alata (pločica tvrdog metala)	1	2
3.	dubine rezanja, mm	0,8	1,5
4.	posmaka, mm/o	0,08	0,2
5.	broj okretaja (brzine rezanja), o/min	1800	2500

Derivacije u gornjem izrazu mogu se izračunati kao:

$$\frac{\partial E}{\partial w_{ji}^{[s]}} = \left(\frac{\partial E}{\partial I_j^{[s]}} \right) \cdot \left(\frac{\partial I_j^{[s]}}{\partial w_{ji}^{[s]}} \right) = -e_j^{[s]} \cdot x_i^{[s-1]} \quad (3)$$

Vrijednost prirasta težina veza u mreži $\Delta w_{ji}^{[s]}$ sada glasi:

$$\Delta w_{ji}^{[s]} = \alpha \cdot e_j^{[s]} \cdot x_i^{[s-1]} \quad (4)$$

gdje je α koeficijent učenja, $x_j^{[s]}$ predstavlja izlazno stanje j -tog neurona u s -tom sloju, a parametar $e_j^{[s]}$ koji predstavlja grešku i prolazi unazad kroz sve slojeve mreže definira se kao:

$$e_j^{[s]} = \frac{-\partial E}{\partial I_j^{[s]}} \quad (5)$$

Stopa učenja nastoji se držati na niskoj razini da bi se izbjegla divergencija (odstupanje), ali istovremeno ovako niska razina koeficijenta učenja za posljedicu može imati veoma sporo učenje. Ovi suprotni zahtjevi riješeni su uvođenjem vrijednosti momentum u izraz (4):

$$\Delta w_{ji}^{[s]} = \alpha \cdot e_j^{[s]} \cdot x_i^{[s-1]} + \text{momentum} \cdot \Delta w_{ji}^{[s]} \quad (6)$$

Osvježavanje težina veza u mreži može se provoditi za svaki vektor učenja posebno ili kumulativno što znatno povećava brzinu učenja (konvergiranja).

Dakle, cilj procesa učenja u neuronskoj mreži je postići što manju razinu greške između izlaza dobivenih učenjem mreže i stvarnih (željenih) rezultata. Ovo se ostvaruje podešavanjem težina neurona, a prihvaćanjem funkcije cilja, koja je u nastavku definirana kroz minimalizaciju sume kvadrata grešaka.

Opći oblik vektora modela pogodnog za ulaz u neuronsku mrežu je sljedeći:

$$X_i = \{x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}\} \Rightarrow Y_o = \{y_{o1}, y_{o2}, y_{o3}, \dots, y_{on}\} \quad (7)$$

gdje vektor $X_i = \{x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}\}$ predstavlja ulazne varijable, a vektor $Y_o = \{y_{o1}, y_{o2}, y_{o3}, \dots, y_{on}\}$ izlazne varijable.

3.2

Primjena neuronske mreže širenja unazad kod procjene površinske hrapavosti

Application of the back-propagation network in evaluations of surface roughness

Za promatrani problem vektor modela ima jednu izlaznu varijablu-hrapavost površine. Ulazne su varijable sljedeće: vrsta materijala, vrsta alata (pločica tvrdog metala), dubine rezanja, posmaka i brzine rezanja (tablica 1).

Kao kriterij za ocjenu mreže prihvaćena je RMS greška definirana izrazom:

$$RMS = \sqrt{MS} = \sqrt{\frac{\sum_{n=1}^N (d_n - y_n)^2}{N}} \quad (8)$$

gdje je:

MS - srednje kvadratno odstupanje

N - broj parova ulazno-izlaznih vrijednosti skupa za učenje

y_n - n -ti izlaz neuronske mreže

d_n - željena vrijednost n -tog izlaza neuronske mreže.

Za učenje mreže primijenjeno je Delta pravilo. Ovo pravilo učenja naziva se i Widrow/Hoff-ovo pravilo ili pravilo najmanjih srednjih kvadrata, a postalo je jedno od osnovnih u procesu učenja kod većine neuronskih mreža.

Izrazom (9) dana je formula za Delta pravilo:

$$\Delta w_{ji} = \alpha \cdot y_{cj} \cdot \varepsilon_i \quad (9)$$

gdje je Δw_{ji} vrijednost razlike težina neurona j prema neuronu i ostvarene u dva koraka (k -tom i $k-1$), matematički opisano izrazom (10):

$$\Delta w_{ji} = \Delta w_{ji}^k - \Delta w_{ji}^{k-1} \quad (10)$$

α je koeficijent učenja, y_{cj} je vrijednost izlaza neurona j izračunatog prema prijenosnoj funkciji, ε_i je greška dana kao:

$$\varepsilon_i = y_{ci} - y_{di} \quad (11)$$


gdje je y_{di} stvarni (željeni) izlaz. Vrlo rijetko se greška dana izrazom (11) vraća u mrežu, već se koriste drugi oblici greške, ovisno o vrsti mreže.

Za većinu stvarnih problema koriste se različite stope učenja za različite slojeve s niskom razinom stope učenja za izlazni sloj. Uobičajeno je da se stopa učenja postavi na vrijednost bilo gdje u intervalu između 0,05 i 0,5, te se tijekom procesa učenja smanjuje. Prilikom korištenja algoritma Delta pravila učenja, važno je istaći da se korišteni podaci iz skupa za učenje odabiru slučajno. U protivnom se mogu očekivati vrlo često oscilacije i greške u konvergiranju rezultata.

Prijenosna funkcija korištena u ovom istraživanju je Sigmoidna funkcija koja se izračunava prema izrazu (12).

$$Izlaz_i = \frac{1}{1 + e^{-G \cdot ulaz_i}} \quad (12)$$

gdje je G - prirast funkcije, a izračunava se kao $G=1/T$. T je prag funkcije. Ova funkcija se često koristi pri kreiranju i istraživanju neuronskih mreža. Graf funkcije je kontinuirano monoton, a prikazan je na slici 4. Kao što se vidi sa slike, vrijednosti ove prijenosne funkcije kreću se u intervalu $[0, 1]$.



Slika 4 Prikaz Sigmoidne prijenosne funkcije
Figure 4 Graph of a Sigmoid transfer function

3.3 Ostvareni rezultati Obtained results

Istraživanje primjene mreže "širenja unazad" provedeno je za definirani model podataka. Mijenjanjem atributa istraživane su različite arhitekture neuronskih mreža. Atributi mreže koja daje najmanju RMS grešku prikazani su u tablici 2. Ova arhitektura mreže generirala je

izlaz mreže s razinom RMS greške 4,69 % u fazi učenja, odnosno 4,93 % u fazi validacije.

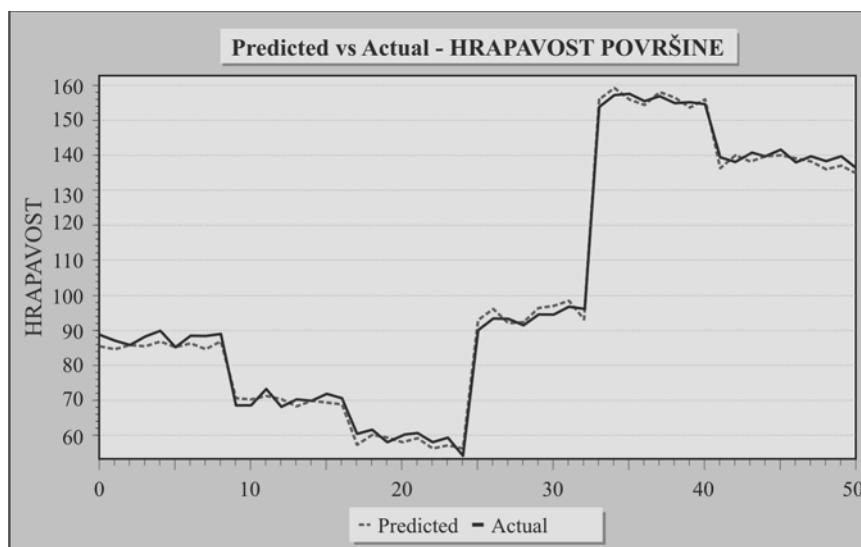
Dakle, neuronska mreža čiji su atributi navedeni u tablici 2 najbolje aproksimira rezultate dobivene eksperimentalnim istraživanjem. Slika 5 daje grafički prikaz rezultata koje daje ova struktura mreže u odnosu na eksperimentalne vrijednosti.

Naknadno je provedeno i istraživanje značaja pojedinih varijabli za model neuronske mreže, a s ciljem moguće redukcije njihovog broja. U odnosu na definiranu strukturu neuronske mreže koja je imala najnižu razinu greške (tablica 2) slijedio je proces kod kojega promatran reducirani podatkovni model koji je sadržavao 4 ulazne i 1 izlaznu varijablu. Mreža je učena s reduciranim podatkovnim modelom, te su potom analizirani dobiveni rezultati. Dobiveni rezultati u ovom procesu, ukazuju da je za svaki korak (s reduciranim modelom za jednu varijablu) dobivena veća RMS greška nego što je imao početni model. Dakle, može se zaključiti da bi izbacivanje bilo koje varijable iz modela značilo povećavanje greške.


Testiranje izdvojenog modela pokazalo se učinkovitim, jer su predviđanja površinske hrapavosti, na seriji koja je uslijedila, uglavnom poštovala dopuštenu granicu odstupanja od 5 % (slika 6 - odstupanja površinske hrapavosti mjerene na slučajnim uzorcima iz serije).

Tablica 2 Atributi neuronske mreže s najmanjom RMS greškom
Table 2 Neural network attributes with the lowest RMS error

Rb.	Naslov atributa	Usvojeno obilježje
1.	Ulazni broj neurona	5
2.	Izlazni broj neurona	1
3.	Broj skrivenih neurona	5
4.	Pravilo učenja	Delta pravilo
5.	Prijenosna funkcija	Sigmoidna
6.	Veličina epohe	10
7.	Maksimalni broj epoha za učenje	65000
8.	Broj epoha učenja između testova	200
9.	Broj pokušaja	40
10.	Stopa učenja	0,2; 0,05; 0,1; 0,8
11.	Momentum	0,2; 0,05; 0,1; 0,9
12.	RMSE u fazi učenja	0,0469
13.	RMSE u fazi validacije	0,0493
14.	Faktor korelacije	0,9896



Slika 5 Prikaz stvarnih i predviđenih vrijednosti koje daje NM za hrapavost površine
Figure 5 Presentation of actual and predicted values given by NN for the surface roughness



Slika 6 Odstupanje površinske hrapavosti na radnim predmetima
Figure 6 Deviation of the actual from predicted value of surface roughness

4

Zaključak

Conclusion

U radu su opisani rezultati primjene neuronskih mreža u procjenjivanju površinske hrapavosti obrađivanog radnog predmeta. Model predikcije temeljen na neuronskim mrežama daje rezultate s greškom koja je manja od 5 % što je u granicama rezultata (1,33 %-10 %) ostvarenih u istraživanjima objavljenim u citiranim radovima.

Ova greška potvrđuje prihvatljivost modela i opravdanost primjene dobivene mreže u praksi. Istrenirana mreža pretpostavka je za generiranje programskog koda koji će omogućiti da se unosom ulaznih parametara u kratkom vremenu dobiju izlazne vrijednosti površinske hrapavosti. Naučena mreža se može samostalno koristiti ili se može integrirati u ERP (eng. Enterprise Resource Planning) sustav i na taj način ubrzati ili potvrditi izbor režima obrade, te skratiti vrijeme tehnološke pripreme proizvodnje mladim i manje iskusnim inženjerima.

U nastavku istraživanja cilj je i nadalje prikupljati realne podatke iz proizvodnje i time proširivati podatkovni uzorak. Za očekivati je da će nakon učenja i treniranja mreža davati još bolje rezultate, odnosno nižu grešku. Cilj je provesti i optimalizaciju parametara obrade. U optimalizacijski postupak će biti uključeni GA, te bi se kombiniranom primjenom NN i GA trebali dobiti optimalni parametri na osnovi ulaznih podataka iz ERP sustava.

5

Literatura

Reference

- [1] Singh, G.; Choudhary, A. K.; Karunakaran, K. P.; Tiwari, M. K. An evolutionary approach for multi-pass turning operations. *Proceedings of the Institution of Mechanical Engineers Part B-Journal of Engineering Manufacture*. 220(2), 2(2006), str. 145-162.
- [2] Sardinas, R. Q.; Santana, M. R.; Brindis, E. A. Genetic algorithm-based multi-objective optimization of cutting parameters in turning processes. *Engineering Applications of Artificial Intelligence*. 19(2), 3(2006), str.127-133.
- [3] Jurković, Z.; Cukor, G.; Meštrović, T. Determination of optimal cutting parameters to improve surface roughness based on different optimization approaches // AMST'08 Advanced Manufacturing Systems and Technology / Kuljanić, Elso (ur.). Udine: CISM, 2008. str. 105-110.
- [4] Cus, F.; Balic, J. Optimization of cutting process by GA approach. *Robotics And Computer-Integrated Manufacturing*. 19(1-2), 2-4(2003), str. 113-121.
- [5] Cus, F.; Milfelner, M.; Balic, J. An intelligent system for monitoring and optimization of ball-end milling process. *Journal of Materials Processing Technology*. 175(1-3), 6(2006), str. 90-97.
- [6] Tansel, I. N.; Ozcelik, B.; Bao, W. Y.; Chen, P.; Rincon, D.; Yang, S. Y.; Yenilmez, A. Selection of optimal cutting conditions by using GONNS. *International Journal of Machine Tools & Manufacture*. 46(1), 1(2006), str. 26-35.

- [7] Jain, R. K.; Jain, V. K. Optimum selection of machining conditions in abrasive flow machining using neural network. *Journal of Materials Processing Technology*. 108(1), 12(2000), str. 62-67.
- [8] Zuperl, U.; Cus, F.; Mursec, B.; Ploj, T. A hybrid analytical-neural network approach to the determination of optimal cutting conditions. *Journal of Materials Processing Technology*. 157-58(Special Issue SI), 12(2004), str. 82-90.
- [9] Zuperl, U.; Cus, F. Optimization of cutting conditions during cutting by using neural networks. *Robotics and Computer-Integrated Manufacturing*. 19(1-2), 2-4(2003), str. 189-199.
- [10] Ozel, T.; Karpat, Y. Predictive modelling of surface roughness and tool wear in hard turning using regression and neural networks. *International Journal of Machine Tools & Manufacture*. 45(4-5), 4(2005), str. 467-479.
- [11] Chen Lu. Study on prediction of surface quality in machining process. *Journal of materials processing technology* 205 (2008), str. 439-450.
- [12] Wang, X. F.; Feng, C. X. Development of empirical models for surface roughness prediction in finish turning. *Int J Adv Manuf Technol* 20(5)2002, str. 348-356.
- [13] Naveen, Sait A.; Aravindan, S.; Noorul Haq, A. Influence of machining parameters on surface roughness of GFRP pipes, *Advances in Production Engineering & Management* 4, 1-2(2009), str. 47-58.
- [14] Grzesik, W. A revised model for predicting surface roughness in turning. *Wear* (1996)194, str. 143-148.
- [15] Abburi, N. R.; Dixit, U. S. A knowledge-based system for the prediction of surface roughness in turning process, *Robotics and Computer-Integrated Manufacturing* 22 (2006), str. 363-372.
- [16] Bernie, P.; Huang, Joseph C.; Chenb, Ye Lib. Artificial-neural-networks-based surface roughness Pokayoke system for end-milling operations, *Neurocomputing* 71 (2008), str. 544-549.
- [17] Bajić, D.; Gjeldum, N.; Veža, I. Examination and Modeling of the Influence of Cutting Parameters on the Surface Roughness in Face Milling // AMST'08 Advanced Manufacturing Systems and Technology / Kuljanić, Elso (ur.). Udine: CISM, 2008. str. 123-133.
- [18] Durmus, K. Prediction and control of surface roughness in CNC lathe using artificial neural network. *Journal of materials processing technology* 209(7) (2009), str. 3125-3137.
- [18] Hasan, O.; Tuncay, E.; Fehmi, E. Prediction of minimum surface roughness in end milling mold parts using neural network and genetic algorithm, *Materials and Design* 27 (2006), str. 735-744.
- [20] Bajić, D.; Lela, B.; Cukor, G. Examination and Modelling of the Influence of Cutting Parameters on the Cutting Force and the Surface Roughness in Longitudinal Turning. *Journal of Mechanical Engineering* 54 (2008)5, str. 322-333.

Adresa autora
Authors' address

prof. dr. sc. Goran Šimunović,
prof. dr. sc. Tomislav Šarić
prof. dr. sc. Roberto Lujčić
Sveučilište J. J. Strossmayera u Osijeku
Strojarski fakultet u Slavonskom Brodu
Trg Ivane Brlić-Mažuranić 2
35000 Slavonski Brod
e-mail: gsimun@sfsb.hr