

NADZOR OBRABE ORODJA ZA ZUNANJE STRUŽENJE NA PODLAGI TERMOGRAFIJE IN KONVOLUCIJSKE NEVRONSKE MREŽE

David POTOČNIK¹, Nika BRILI¹, Mirko FICKO¹, Simon KLANČNIK¹

¹Fakulteta za strojništvo, Univerza v Mariboru

IZVLEČEK

Proces struženja je v industriji zelo razširjen postopek odrezavanja. Vsakršna optimizacija tega procesa lahko pomembno vpliva na izboljšanje kakovosti izdelkov, racionalizacijo stroškov ali zmanjšanje neželenih dogodkov. S samodejnim nadzorom stružnih orodij lahko zmanjšamo stroške, povečamo učinkovitost in zmanjšamo število neželenih dogodkov, ki se pojavijo med obdelavo (izmet, lom orodja, ...). V primeru posamične ali maloserijske proizvodnje, nadzor obrabe opravlja operater stroja, vendar je tako določanje obrabe orodja prepuščeno subjektivni presoji in zahteva poseg v proces. Predstavljena rešitev ta problem odpravi s samodejnim nadzorom stanja rezalnega orodja. Za nadzor procesa je bila uporabljena IR kamera, ki zajame tudi termografsko stanje. Kamera je bila ustrezno zaščitena in nameščena tik ob stružnem nožu, kar omogoča spremljanje obdelave iz neposredne bližine. Med eksperimentom so bili nastavljeni konstantni rezalni parametri za struženje obdelovanca (nizko legirano jeklo z oznako 1.7225 oz. 42CrMo4) brez uporabe hladilnega sredstva. Z različno obrabljenimi stružnimi ploščicami je bila med procesom struženja ustvarjena podatkovna baza z več kot 6.000 slikami. Z uporabo konvolucijske nevronske mreže (CNN) je bil razvit model za napovedovanje obrabe in poškodb rezalnega orodja. Model na podlagi zajete termografske slike med procesom struženja samodejno določi stanje rezalnega orodja (brez, majhna, velika obraba). Dosežena točnost klasifikacije je bila 99,55 %, kar potrjuje ustreznost predlagane metode. Tovrsten sistem omogoča takojšnje ukrepanje v primeru obrabe ali zloma orodja, ne glede na znanje in usposobljenost operaterja.

1 UVOD


V času tehnološke dobe, ki jo poznamo pod pojmom Industrija 4.0 poteka intenziven razvoj na področju izboljšav CNC strojev, ki so vedno bolj zmogljivi, saj omogočajo obdelavo različnih operacij na enem stroju (npr. stružnice z gnanimi orodji in Y-osjo omogočajo operacije rezkanja obdelovanca). Kljub temu pa tudi najsodobnejši stroji, ki so namenjeni posamični in maloserijski proizvodnji, ne omogočajo tega, da bi delovali avtonomno, brez nadzora človeka.

Pri avtomatizaciji CNC-obdelovalnih strojev v smislu avtonomnega vršenja obdelave brez prisotnosti operaterja je zelo pomembno pravočasno zaznavanje obrabe rezalnega roba orodja. S tem se prepreči slab vpliv obrabe orodja na kvaliteto obdelane površine in poškodbe obdelovanca [1, 2] ali obdelovalnega stroja, do katerih lahko pride pri katastrofalni obrabi rezalnega orodja [3]. Stanje rezalnega orodja ne vpliva zgolj na lastnosti obdelovancev (geometrijske, površinske in strukturne), ampak tudi na količino izmeta in zastojev v proizvodnji

[4]. V splošnem velja, da se o tem odloča operater stroja na podlagi strokovnega, neformalnega znanja (občutek, osebna presoja in izkušnje) glede na več faktorjev, kot so na primer: oblika in barva odrezkov, kvaliteta površine, vibracije, zvočne emisije, temperature [3, 5]. Z željo po izboljšanju tovrstnega določanja stanja obrabe rezalnega orodja je v pričujočem članku predstavljen način avtomatizacije CNC-strojev na višjo raven avtonomnosti v sklopu Industrije 4.0. Predstavljen je sistem za samodejni nadzor obrabe orodja v procesu zunanega struženja, ki temelji na zajemu termografskih slik in modela z uporabo konvolucijske nevronske mreže (ang. *Convolutional Neural Network* – CNN). Zaradi medsebojne povezanosti oz. soodvisnosti med temperaturo in obrabo rezalnega orodja je ena izmed možnih metod nadzora obdelovalnega procesa metoda termografije.


2 DOLOČANJE STANJA REZALNEGA ORODJA

Dokazano je, da se obraba proste ploskve povečuje s časom obdelave [6]. Obstajajo priporočila (standard ASTM), kako meriti dobo trajanja orodja na podlagi velikosti obrabe proste ploskve oz. širine obrabljenega roba (oznaka VB). V primeru enakomerne obrabe, je ta lahko do $VB = 0,3 \text{ mm}$, v primeru neenakomerne pa lahko lokalno največja obraba znaša $0,6 \text{ mm}$ [3, 7]. Pomen obrabe proste ploskve prikazuje Slika 1.



Slika 1: Prikaz obrabe proste ploskve (oznaka VB) na rezalnem orodju (v_f - smer podajalne hitrosti)

Pomanjkljivost takšnega kriterija obrabe, ki ne upošteva geometrije orodja, je v svojih delih izpostavilo več avtorjev [3]. V poglobljeni študiji o učinkih obrabe orodja je Niaki leta 2017 predstavil posredno metodo za določanje obrabe orodja. Zaradi obrabe orodja se spreminja skupna višina orodja, zato pride do odstopanj dimenzij obdelovanca (Slika 2).



Slika 2: Vpliv obrabe rezalnega orodja na odstopanje premera obdelovanca (r_1 – dejanski polmer obdelovanca, r_2 – polmer obdelovanca, kadar orodje ni obrabljeno)

V raziskavi je po vsakem rezu izmeril premer obdelovanca na treh mestih in ugotavljal odstopanje dejanske vrednosti od pričakovane

(ΔD). Dokazal je povezavo med ΔD in obrabo proste ploskve VB [8]. Metoda je potrjena s primerjavo predvidene obrabe proste ploskve VB in izmerjenega odstopanja premera obdelovanca ΔD pri sedmih različnih podajalnih hitrostih.

V svoji raziskavi smo kvaliteto rezalnega orodja določili po dveh metodah:

1. **Z meritvami:** po Niakijevi metodi [8]. Metoda je primerna iz več razlogov:
 - stružna ploščica lahko ostane ves čas v držalu,
 - meritve so hitre in samo za kratek čas prekinejo delovni proces,
 - edina potrebna dodatna oprema je umerjeni mikrometer (ugodna rešitev),
 - metoda je primerna za večje število meritev, saj ni časovno potratna.
2. **Izkustveno:** Kvaliteto stanja rezalnega orodja določi izkušen strokovnjak. Algoritem bo nadomeščal strokovnjaka pri odločitvah, zato želimo, da sprejema odločitve enako kot strokovnjak (ekspert), ki na podlagi izkušenj poveže vse vplivne faktorje obrabe.

3 RAZVOJ SISTEMA ZA NADZOR OBRABE ORODJA ZA ZUNANJE STRUŽENJE

Raziskava in razvoj sistema sta bila v grobem razdeljena na dva sklopa, in sicer:

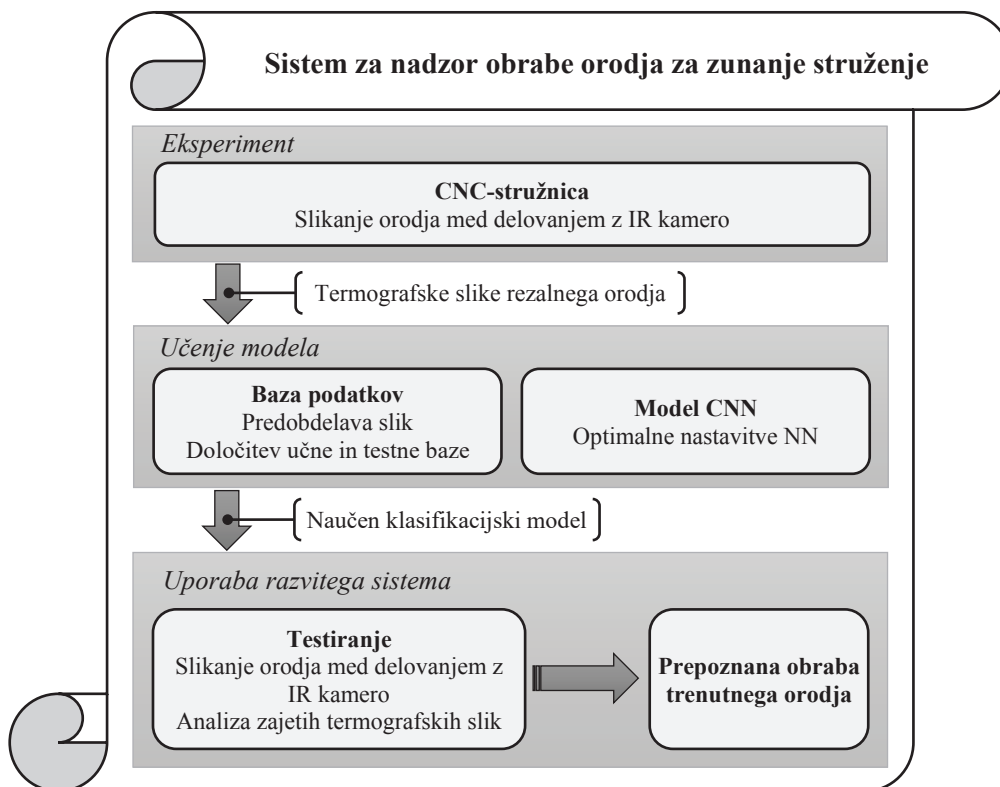
- eksperimentalni del na obdelovalnem stroju in
- obdelava pridobljenih podatkov, učenje ter testiranje modela CNN.

Celoten postopek vzpostavitve modela nadzora orodij od zajema podatkov (termografskih slik rezalnih orodij) do uporabe naučenega modela je prikazan na Sliki 3.

3.1 Eksperimentalni del

Eksperimentalni del raziskave je bil namenjen pridobitvi baze podatkov, v sklopu katerega sta bila zadana dva cilja:

- zajem termografskih slik med obdelovalnim procesom (struženjem) iz neposredne bližine rezalnega orodja,
- pridobitev zadostne količine slik za različna stanja obrabe rezalnega orodja.




Slika 3: Shematski prikaz inteligentnega sistema za nadzor obrabe in poškodb rezalnih orodij z uporabo termografije

Strojna oprema

Za zajem termografskih slik je bila uporabljena infrardeča (IR) kamera FLIR E5, ki ima frekvenco zajema 9 slik na sekundo (9 Hz) in ločljivost 120×90 slikovnih točk. Zaradi časovnih izgub in zamikov ob prenosu slik na računalnik je bilo število slik prepolovljeno (zajem 4,5 slike/s oz. 1 slika vsake 0,222 s) [9]. Uporabljene so bile naslednje nastavitve IR kamere: mavrična shema, brez črt, emisivnost $\varepsilon = 0,60$.

Kamera mora zajemati slike med samim procesom obdelave, zato jo je bilo treba zaščititi pred vročimi ostružki. V ta namen je bila izdelana škatla iz polimetilmetakrilata (PMMA). Ker PMMA ne prepušča IR žarkov, smo pred objektivom na škatli naredili luknjo in vanjo pritrdili namensko IR okence, ki je obstojno in hkrati prepušča IR žarke (Slika 4). Škatla z IR kamero je bila nameščena na revolver tik ob stružni nož, na bližnjem orodnem mestu v revolverju. Oddaljenost IR kamere od mesta obdelave je bila manj kot 10 cm, poleg tega se je kamera premikala skupaj z rezalno ploščico. S tem smo zagotovili ponovljivost zajema slik.



Slika 4: Namestitev IR kamere tik ob stružnem nožu in zaščita za kamero

Ekspiriment je bil izveden na CNC-stružnici Okuma LC30. Parametre obdelave, ki so predstavljeni v Tabeli 1, smo določili v skladu s priporočili proizvajalca orodja glede na material obdelovanca (nizko legirano jeklo z oznako

1.7225). Začetni premer obdelovanca je bil $\varnothing 60$ mm, dolžina obdelave pa 100 mm.

Tabela 1: Rezalni parametri obdelave

Parametri obdelave	Vrednost
Hlajenje	Brez
Rezalna hitrost	100 m/min
Podajalna hitrost	200 mm/min
Globina reza	0,25 mm (0,5 mm na premer)

Za rezalno orodje smo uporabili držalo z oznako CKJNL2525M16 proizvajalca Canela in rezalno ploščico z oznako KNUX160410L11 (prevleka CVD z oznako QP1025, 2 rezalna roba) proizvajalca Sanstone.

3.2 Podatkovna baza slik

Za uspešno učenje modela CNN smo predvideli, da potrebujemo vsaj 1.000 slik za vsak razred obrabe rezalnih ploščic. Vse vrste obrabe smo združili v 3 klasifikacijske razrede [9], pri čemer vsak razred sestavlja podatkovna baza z več kot 2.000 slikami (Slika 5), zraven pa so zapisane tudi vrednosti odstopanja premera obdelovanca. Podrobnejši podatki o definiranju razredov obrabe orodja so predstavljeni v poglavju 4. Za nadaljnjo uporabo sistema je namreč pomembno, da omogoča zajem velikega števila slik v relativno kratkem času. Le z dovolj veliko bazo podatkov je mogoče učinkovito razširiti model tudi na druga orodja, materiale itd.

Vrsta obrabe rezalnega orodja ni bila predmet te raziskave, ampak primernost uporabe rezalnega orodja za nadaljnje struženje.



Slika 5: Razdelitev termografskih slik po razredih obrabe

3.3 Konvolucijska nevronska mreža (CNN)

V fazi razvoja modela smo uporabili obstoječi model Inception V3, ki temelji na konvolucijski nevronske mreži. Optimalno arhitekturo in vrednosti filtrov tega modela so več let razvijali znanstveniki Szegedy in drugi [10].

Spreminjanje parametrov CNN ni bil predmet naše raziskave, ampak smo uporabili že razvito mrežo in jo zgolj dodatno naučili prepoznave slik iz naše baze. Pri tem je bilo treba naučiti le nekaj zadnjih plasti nevronske mreže (t. i. prenosno učenje, ang. *Transfer Learning*), ki služijo za klasifikacijo slik v posamezne razrede obrabe.

Za namene učenja modela CNN je bilo treba ustvariti učno in testno množico slik. Za testno množico smo določili enako število slik v vseh klasifikacijskih razredih, da so tako rezultati med seboj lažje primerljivi. Delež slik v testni množici je približno 10 % vseh slik v posameznem razredu obrabe in znaša 220 slik.

3.4 Kriteriji za vrednotenje klasifikacije

Kriterije uspešnosti klasifikacije smo izračunali s pomočjo kontingenčne matrike (ang. *Confusion Matrix*), ki prikazuje razvrstitev slik v razrede glede na dejansko stanje in glede na klasifikacijo modela. Matrika ima v stolpcih zapisane pravilne vrednosti, v vrsticah pa vrednosti, ki jih je določil model (ali ravno obratno). Pravilne napovedi klasifikatorja ležijo na diagonali matrike, napačne pa izven te. Ovrednotenje rezultatov je prikazano v Tabeli 2 na primeru kontingenčne matrike za štirirazredni kvalifikacijski problem (indeks j označuje posamezni razred). Rezultati v kontingenčni matriki so označeni z naslednjimi oznakami [8]:

- TP – resnično pozitivni (ang. *True Positive*),
- FP – lažno pozitivni (ang. *False Positive*),
- TN – resnično negativni (ang. *True Negative*),
- FN – lažno negativni (ang. *False Negative*).

Tabela 2: Kontingenčna matrika

		Dejansko			
		Razred 1	Razred 2	...	Razred j
Razvrstitev	Razred 1	TP	FP	FP	FP
	Razred 2	FN	TN	TN	TN
	...	FN	TN	TN	TN
	Razred j	FN	TN	TN	TN

Izračunali smo naslednje kriterije uspešnosti klasifikacije [9]:

- *Priklic* ali *občutljivost* (ang. *Recall*), ki se določi za vsak razred posebej in se izračuna kot razmerje med pravilno klasificiranimi pozitivnimi primeri in vsemi resnično pozitivnimi primeri. Predstavlja pravilno razvrščene slike v posameznem dejanskem razredu obrabe (stolpec v kontingenčni matriki).

$$R = \frac{\text{št. pravih razvrstitev v j razredu}}{\text{št. dejanskih primerov v j razredu}} = \frac{TP}{TP + FN} \quad (1)$$

- *Natančnost* (ang. *Precision*), ki se določi za vsak razred posebej in se izračuna kot razmerje med pravilno klasificiranimi pozitivnimi primeri in vsemi klasificiranimi pozitivnimi primeri. Predstavlja pravilno razvrščene slike v posameznem klasificiranem razredu obrabe (vrstica v kontingenčni matriki).

$$P = \frac{\text{št. pravih razvrstitev v j razred}}{\text{št. vseh razvrstitev v j razred}} = \frac{TP}{TP + FP} \quad (2)$$

- *Točnost* ali *klasifikacijska točnost* (ang. *Accuracy*) se izračuna kot razmerje med

pravilno klasificiranimi primeri in številom vseh primerov (ne glede na razred obrabe).

$$A = \frac{\text{št. vseh pravih klasifikacij}}{\text{št. vseh klasifikacij}} = \frac{\sum_{i=1}^j TP_i}{\text{št. vseh klasifikacij}} \quad (3)$$

4 REZULTATI IN DISKUSIJA

Razrede obrabe orodja smo definirali glede na vrsto obdelave in uporabe v industriji. Primernost obrabljenega orodja je namreč odvisna od vrste obdelovalnega materiala in zahtev izdelka (tolerančno polje, hrapavost) [9]. Splošno pravilo razvrstitve razredov glede na primernost uporabe rezalne ploščice prikazuje Tabela 3.

Tabela 3: Primernost orodja glede na vrsto obdelave

Vrsta obrabe	Primernost uporabe ploščice	
	Grobo struženje	Fino struženje
Brez obrabe	DA	DA
Majhna	DA	NE
Velika	NE	NE

Učenje CNN modela smo izvajali v 5.000 ponovitvah. Rezultati klasifikacije so zapisani v Tabeli 4. Klasifikacijska točnost s 3 kategorijami obrabe rezalnega orodja znaša 99,55 %, kar je odličen rezultat in potrjuje možnost uporabe metode v realnem procesu. Zgolj 3 slike od 660 so bile klasificirane napačno. Model CNN se je napačno odločal pri klasifikaciji med prvima dvema razredoma obrabe (brez, majhna obraba).

Vse slike za orodje z veliko obrabo so bile pravilno prepoznane, kar je bistvena prednost za uporabo modela v industriji, kjer so za delovni proces najbolj kritični ravno nenadni zlomi orodja.

Tabela 4: Kontingenčna matrika za klasifikacijo orodij v 3 razrede obrabe

RAZVRSTITEV	DEJANSKO			Skupaj	Natančnost
	Brez obrabe	Majhna obraba	Velika obraba		
Brez obrabe	218	1	0	219	99,5 %
Majhna obraba	2	219	0	221	99,1 %
Velika obraba	0	0	220	220	100,0 %
Skupaj	220	220	220		
Priklic	99,1 %	99,5 %	100,0 %		

- Število pravih razvrstitev: 657
- Število vseh slik: 660
- Točnost klasifikacije: 99,55 %

5 SKLEP

Spremljanje obrabe rezalnega orodja med obdelovalnim procesom je pomembno tako za kvaliteto končnega izdelka kot za optimizacijo stroškov proizvodnje. Zaradi nevarnih razmer v okolici odrezavanja (vroči ostružki) je nadzor orodja med obdelavo otežen. V sklopu raziskave smo poiskali rešitev za zaščito opreme in uspešno razvili metodo, ki omogoča spremljanje procesa v realnem času in v neposredni bližini.

Cilj je bil narediti klasifikacijski model CNN za napovedovanje obrabe in poškodb rezalnega orodja. Model na podlagi zajete termografske slike med procesom struženja samodejno določi stanje rezalnega orodja (trije razredi obrabe: brez, majhna, velika obraba). Na podlagi rezultatov klasifikacije in s stališča uporabnosti v industriji se je izkazalo, da je delitev orodij v 3 razrede obrabe smiselna. Rezultati so se izkazali kot zelo dobri, saj je klasifikacijska točnost za naključno testno množico termografskih slik ploščic znašala 99,55 %.

Viri:

- [1] D. M. D'Addona, D. Matarazzo, A. M. M. S. Ullah, and R. Teti, "Tool Wear Control through Cognitive Paradigms," *Procedia CIRP*, vol. 33, pp. 221-226, 2015/01/01/ 2015.
- [2] D. M. D'Addona and R. Teti, "Image Data Processing via Neural Networks for Tool Wear Prediction," *Procedia CIRP*, vol. 12, pp. 252-257, 2013/01/01/ 2013.
- [3] A. Siddhpura and R. Paurobally, "A review of flank wear prediction methods for tool condition monitoring in a turning process," *The International Journal of Advanced Manufacturing Technology*, vol. 65, no. 1, pp. 371-393, 2013/03/01 2013.
- [4] A. Antic, J. Hodolic, and M. Sokovic, "Development of a neural-networks tool-wear monitoring system for a turning process," *Strojnicki Vestnik*, vol. 52, pp. 763-776, 11/01 2006.
- [5] J. Kopač, "Cutting-Tool Wear during High-Speed Cutting," 2004, high speed cutting; cutting tools; tool wear; cutting tool materials; vol. 50, no. 4, p. 11, 2017-07-07 2004.
- [6] W. T. Kang, M. N. Derani, and M. Ratnam, "Effect of Vibration on Surface Roughness in Finish Turning: Simulation Study," *International Journal of Simulation Modelling*, vol. 19, pp. 595-606, 2020.
- [7] *Tool Life Testing with Single - Point Turning Tools*, ASME, 1985.
- [8] F. Akhavan Niaki and L. Mears, "A comprehensive study on the effects of tool wear on surface roughness, dimensional integrity and residual stress in turning IN718 hard-to-machine alloy," *Journal of Manufacturing Processes*, vol. 30, pp. 268-280, 2017/12/01/ 2017.
- [9] N. Brili, M. Ficko, and S. Klančnik, "Automatic Identification of Tool Wear Based on Thermography and a Convolutional Neural Network during the Turning Process," *Sensors-Basel*, vol. 21, no. 5, p. 1917, 2021.
- [10] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," 12/01 2015.