

# Nadzor nad obrabljanjem orodja med procesom čelnega rezkanja z globokim zloženim samokodirnikom

VanThien Nguyen – VietHung Nguyen\* – VanTrinh Pham  
Tehniška univerza v Hanoju, VietNam

Rutinsko zbiranje podatkov o obratovanju sistemov je pomembno za analiziranje, diagnosticiranje in napovedovanje potencialnih težav v kontekstu razvoja industrije 4.0. Upoštevanje obrabljanja orodja med obdelavo kovin z odrezavanjem ima pomembno vlogo pri izboljševanju kakovosti izdelkov in produktivnosti v proizvodni industriji. Z nadzorom rezalnega orodja je mogoče identificirati stanja obrabe orodja in to je področje zanimanja mnogih raziskovalcev. Glavni cilj pričujoče študije je bil zasnovati globoko nevronska mrežo (DLN) za identifikacijo stanj obrabe orodja pri operacijah čelnega rezkanja železove litine za zagotavljanje zanesljivosti in stabilnosti procesa odrezavanja.

Na podlagi zbranih podatkov o vibracijah je bil podrobno preučen model DLN za napovedovanje stanj obrabe orodja pri obdelavi kovin z odrezavanjem. V raziskavi je bila uporabljena metoda učenja DLN na osnovi podatkov za doseganje visoke stopnje točnosti, ki potrjuje uspešnost napovedi. DLN, ki je bila uporabljena za klasifikacijo obrabe orodja, je bila oblikovana z združitvijo zloženega samokodirnika (SAE) in klasifikatorja softmax. V tem modelu DLN so bile s SAE izločene visokonivojske značilke kompleksnega signala vibracij v povezavi z obrabljanjem orodja, nato pa je bil uporabljen klasifikator softmax za točno identifikacijo vzorcev značilk.

Zasnovan je bil dvoslojni SAE za učinkovito izločanje pomembnih značilk, ki imajo vlogo vhodov za klasifikator softmax pri učenju in testiranju. Klasifikacijska točnost je pri vseh preizkušancih znašala 100 %. Sledi sklep, da so SAE z nenadzorovanimi algoritmi učenja primerna rešitev za izločanje značilk obrabe orodja. Klasifikator softmax z aktivacijsko funkcijo je bil uporabljen kot klasifikacijski sloj v arhitekturi DLN za ocenjevanje verjetnosti vzorcev, rezultat pa je bila 100-odstotna točnost. Značilke, pridobljene s SAE, so bile uporabljene tudi v modelih s plitkim klasifikatorjem, kot sta klasifikator z usmerjeno nevronska mrežo (FNN) in klasifikator z algoritmom k-najbližjih sosedov (k-NN). Izkazalo se je, da je značilke mogoče uporabiti v poljubnem klasifikacijskem modelu za doseganje klasifikacijske točnosti vsaj 65 %. Za učenje modelov klasifikatorjev je bila uporabljena samo polovica vzorcev značilk, kar dokazuje sposobnost SAE za izločanje značilk. Učenje modela DLN traja 0,3072 sekunde z optimiziranimi fazami gradnje DLN za pridobivanje rezultatov s popolno klasifikacijsko točnostjo za arhitekturo DLN. Čas učenja je daljši kot pri modelu klasifikatorja z algoritmom k-NN, kjer učenje traja le 0,1098 s. Na osnovi teh rezultatov je mogoče izraziti veliko gotovost v primernost DLN za diagnostiko na področju vzdrževanja v strojništvu, denimo pri odkrivanju napak v ležajih ali zobnikih.

Originalne podatke o vibracijah iz procesa čelnega rezkanja v časovni domeni je treba za učinkovito delovanje pred vnosom v DLN prestaviti v frekvenčno domeno s hitro Fourierjevo transformacijo (FFT). Opisana arhitektura DLN ni bila uporabljena za zaznavanje drugih stanj rezalnega orodja v procesu čelnega rezkanja, kot je zlom ali iztek obstojnosti orodja, zato bo to ena od možnih tem za nadaljnje raziskave.

Glavni prispevki študije so: (1) pridobitev signala vibracij iz procesa čelnega rezkanja s senzorji in predobdelava podatkov; (2) izločitev visokonivojskih značilk vibracijskega signala v povezavi s stanji obrabe orodja; (3) klasifikacija stanj obrabe orodja s prepoznavanjem vzorcev. Naštete tri faze so vdela v arhitekturi DLN za identifikacijo obrabljanja orodja, ki bo uporabna v industrijski proizvodnji.

**Ključne besede:** čelno rezkanje, obraba orodja, zloženi samokodirnik (SAE), globoke nevronske mreže (DLN), železova litina, identifikacija, softmax