

Mesterséges intelligencia módszereivel támogatott prediktív modell létrehozása mikromarási folyamathoz

Artificial intelligence supported predictive model development related to micro milling process

TAKÁCS Márton¹, PhD, egyetemi docens, ADIZUE Ugonna Loveday², PhD hallgató, BALÁZS Barnabás Zoltán³, PhD, adjunktus

^{1,2,3} Budapesti Műszaki és Gazdaságtudományi Egyetem, Gépészmérnöki Kar, Gyártástudomány és -technológia Tanszék, H-1111 Budapest, Műegyetem rakpart 3., Tel.: +36 1 463 2515,

¹takacs.marton@gpk.bme.hu, ²ugonna.adizue@edu.bme.hu, ³balazs.barnabas.zoltan@gpk.bme.hu, www.manuf.bme.hu

Abstract

Nowadays, there is a growing demand for the production of miniature parts, which requires the continuous development of micromachining processes. Within the framework of Industry 4.0, automated manufacturing processes play an essential role. The efficiency can be significantly improved by application of artificial intelligence based prediction. The aim of the present research is to create a predictive model that provides an estimation of the conditions of the micro milling process, primarily the active cutting force component.

Keywords: cutting, micro-milling, ANN, active force component, predictive model

Kivonat

Napjainkban egyre nagyobb igény mutatkozik a miniatűr alkatrészek előállítása iránt, ami a mikromegmunkálási eljárások folyamatos fejlesztését igényli. Az Ipar 4.0 keretrendszerén belül fontos szerepet kapnak az automatizált gyártási eljárások, amik a mesterséges intelligencia alapú előrejelzésekre támaszkodva a korábbiakhoz képest hatékonyabban működhetnek. Jelen kutatás célja olyan prediktív modell létrehozása, ami a mikromarási folyamat körülményeire, elsősorban az aktív forgácsoló erőkomponensre ad becslést.

Kulcsszavak: forgácsolás, mikromarás, mesterséges neurális hálózat, aktív forgácsolási erőkomponens, előrejelző modell

1. BEVEZETÉS

Napjainkban a komplex, 3D-s miniatűr alkatrészek iránti igény jelentős növekedést mutat az ipar számos területén [1]. Az egyik legfontosabb alkalmazási területet a mikrofröccsöntő szerszámok előállítása jelenti, ami leghatékonyabban mikromarással valósítható meg. Ennél az eljárásnál számos egyedi körülményt is figyelembe kell venni a mérethatás miatt (pl. erőteljes sorjaképződés, viszonylag nagy éllekerékítési sugár, minimális forgácsvastagság fontossága). Ennek részeként a forgácsoló erőkomponensek szerepe is felértékelődik a viszonylag nagy mértékű szerszámkihajlás miatt, de az erők mérése jelenti a folyamatfelügyelet egyik alapját, jól jelzik a szerszám pillanatnyi állapotát, ami hatással van a megmunkált felület minőségére is, valamint kapcsolatban vannak a forgácsolási hőmérséklettel is. Mindezek alapján az erők pillanatnyi körülményektől függő ismerete elsődleges fontosságú, valós gyártási környezetben azonban – a legtöbb esetben – nincs lehetőség ezek közvetlen mérésére. A mesterséges intelligencia módszerein alapuló modellek alkalmazásával az erőkomponensek becsülhetők különböző forgácsleválasztási eljárások esetén [2,3]. Az ipar számára fontos, átlagosnál keményebb anyagok (>50 HRC) hatékony mikromarása az egyedi sajátosságok mellett további kihívásokkal szolgál.

A kutatás célja forgácsolási kísérletek során mért adatok alapján egy olyan, a mesterséges intelligencia módszerein alapuló prediktív modell létrehozása, aminek segítségével a megmunkálás jellemzői (erőterhelés, minőség, éltartam) becsülhetők AISI H13 típusú acél mikromarása esetén. Jelen cikkben az aktív forgácsoló erőkomponensre (F_a) vonatkozó eredmények kerülnek bemutatásra.

2. KÍSÉRLETI KÖRÜLMÉNYEK


Az ANN alapú prediktív erőmodell megalkotásához szisztematikus kísérletsorozatot terveztünk és hajtottunk végre az 1. táblázatban szereplő paraméterek valamennyi lehetséges kombinációjával, ami összesen 48 kísérletet jelent. A kísérletek sorszámozásánál első szinten az élenkénti előtolás 8 értéke változott növekvő sorrendben az egyes fogásmélységek mindig állandó értéke mellett. Ennek megfelelően az 1. számú kísérlet paraméterei: $v_c=90$ m/min, $a_p=25$ μm , $f_z=1$ μm , a 2. számú kísérleté: $v_c=90$ m/min, $a_p=25$ μm , $f_z=2$ μm , az utolsó, 48. számú kísérleté pedig: $v_c=90$ m/min, $a_p=150$ μm , $f_z=14$ μm .

A kísérleti megmunkáláshoz VHTC 130 típusú öttengelyes mikromegmunkáló központot alkalmaztunk. A forgácsolási tesztekhez (1. ábra) szerszámként 500 μm átmérőjű kétélű, bevonatos keményfém mikromarót, munkadarabként pedig edzett állapotú, 50 HRC keménységű AISI H13-as melegalakító szerszámacélt használtunk. A folyamat közben fellépő erők vizsgálatára egy Kistler 9257A típusú háromkomponensű erőmérő cella szolgált egy Kistler 5080A töltéserősítővel és egy NI 4431 adatgyűjtővel kombinálva. Az adatok rögzítéséről egy LabVIEW környezetben fejlesztett program gondoskodott.

Mikromarási kísérletek paraméterei

1. táblázat

Paraméterek	v_c (m/min)	a_p (μm)	f_z (μm)	Anyag	Marási stratégia
Értékek	90	25, 50, 75, 100, 125, 150	1, 2, 4, 6, 8, 10, 12, 14	AISI H13	Horonymarás



1. ábra. A mikromarási kísérlet környezete a mérőrendszerrel, valamint a munkadarab az erőmérési irányokkal és az alkalmazott szerszám

A kísérletek során az eredő forgácsolási erő három komponensét rögzítettük (F_x , F_y és F_z), ezek közül a szerszám tengelyére merőleges két komponens (F_x és F_y) vektoriális összegzéséből adódik az 1. ábrán is feltüntetett aktív forgácsoló erőkomponens (F_a), ami a mikroméretű marószerszám viszonylag jelentős szerszámdeformációjáért is felelős. Jelen kutatás ennek az erőkomponensnek a becslését célozza.

3. ANN ALAPÚ ELŐREJELZŐ MODELL

Az előrejelző erőmodell megalkotásához a MATLAB szoftvert használtuk. Ezen belül – a kínákozó lehetőségek széles tárházából – a mesterséges neurális hálózat (ANN, artificial neural network) alapú többrétegű (vagyis MLP, multi layer perceptron) előrecsatolt hibavisszaterjesztéses (FFB, Feedforward Backpropagation) algoritmust alkalmaztunk 10 neuronnal a rejtett és 2 neuronnal (aktív forgácsoló erőkomponens és átlagos érdesség) a kimeneti rétegen. A bemeneti paraméterek a forgácsoló sebesség (v_c), az élenkénti előtolás (f_z) és a fogásmélység (a_p) voltak. A rejtett réteg esetében szigmoid, a kimeneti rétegnél pedig lineáris aktivációs függvényt választottunk.

A modell létrehozása során felügyelt tanítás valósult meg, tehát az optimális súlyok és az eltolás meghatározására a kísérletek bemeneti-kimeneti adatképeit használtuk. A kísérletek során rögzített adathalmazból 10 mérési eredményt elkülönítettünk az utólagos ellenőrzés számára, a fennmaradó 38 eredmény pedig véletlenszerűen felosztásra került 70:15:15 arányban a betanításhoz, a validációhoz és a teszteléshez. A kísérleti eredmények pontos felosztása a 2. táblázatban látható. A hálózat betanítását a Levenberg-Marquardt algoritmust (LM) meghívó TRAINLM függvénnyel hajtottuk végre. Ez a betanító

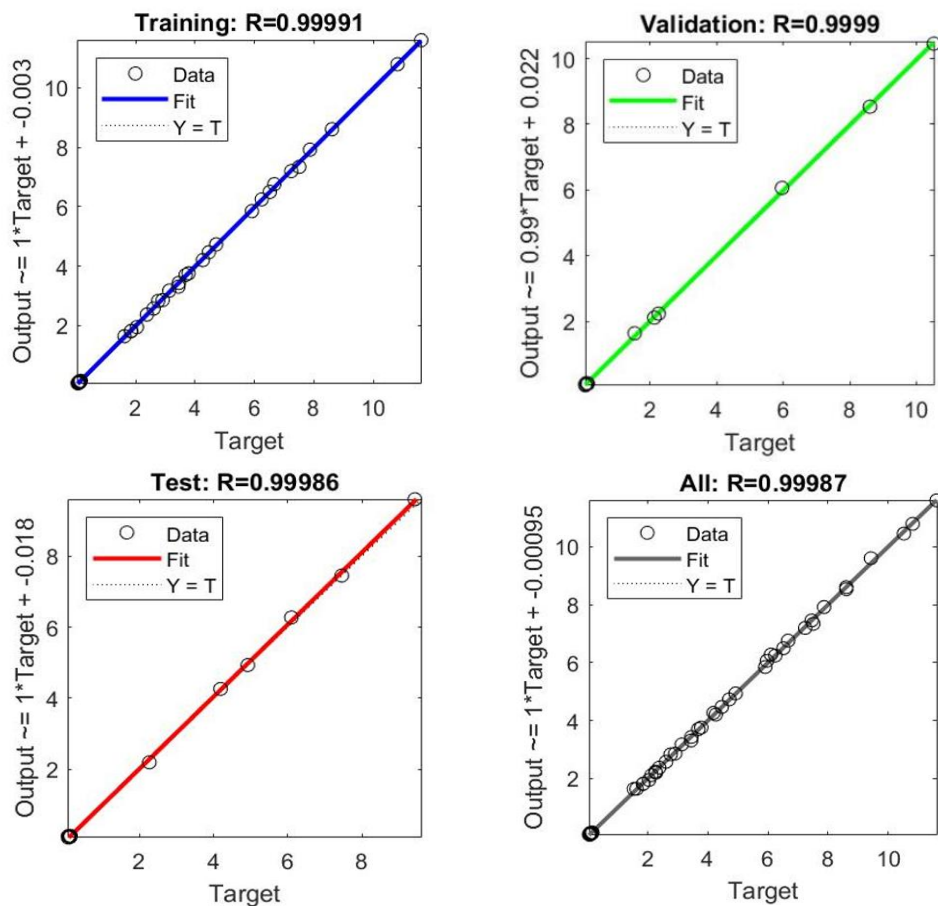
függvény az egyik leggyorsabb hibavisszaterjesztéses algoritmus.

A létrehozott modell becslési teljesítményének az értékelésére az átlagos négyzetes eltérés (MSE, mean squared error), az átlagos négyzetes eltérés négyzetgyöke (RMSE, root mean squared error) és a korrelációs együttható (R) szolgált. Az első két mérőszámnál a minimalizálás, a harmadiknál pedig a maximalizálás, tehát az 1-hez minél közelebbi érték elérése a cél.

4. EREDMÉNYEK

Az előrejelző modell betanításának az eredményét a 2. ábra diagramjai mutatják a tanítási, a validációs és a tesztelési fázisra vonatkozóan. Látható, hogy mindhárom adathalmaznál, valamint a teljes betanítási folyamat esetén is az R-érték 0.999 feletti, ami rendkívül erős egyezést jelent az aktív forgácsoló erőkomponens kísérletek során mért, valamint a mesterséges neurális hálózat segítségével becsült értékei között. A létrehozott ANN alapú előrejelző modell eredményeit a 2. táblázat foglalja össze. Megállapítható, hogy a modell előrejelzési hatékonyságának az ellenőrzését célzó, 10 kísérleti eredményen alapuló, a már betanított modell segítségével végzett utólagos teszt is rendkívül nagy R-értéket eredményezett.

Az aktív forgácsoló erőkomponens mért és becsült értékeinek az összehasonlítása mind a tanítás, mind pedig az utólagos ellenőrzés esetén a 3. ábra diagramjain látható. Az utólagos ellenőrzés eredményeit bemutató diagram vízszintes tengelyén az erre a célra ténylegesen felhasznált kísérletek sorszámai szerepelnek. Ezeknek a kísérleteknek az eredményei nem képezték részét a modell betanításának.

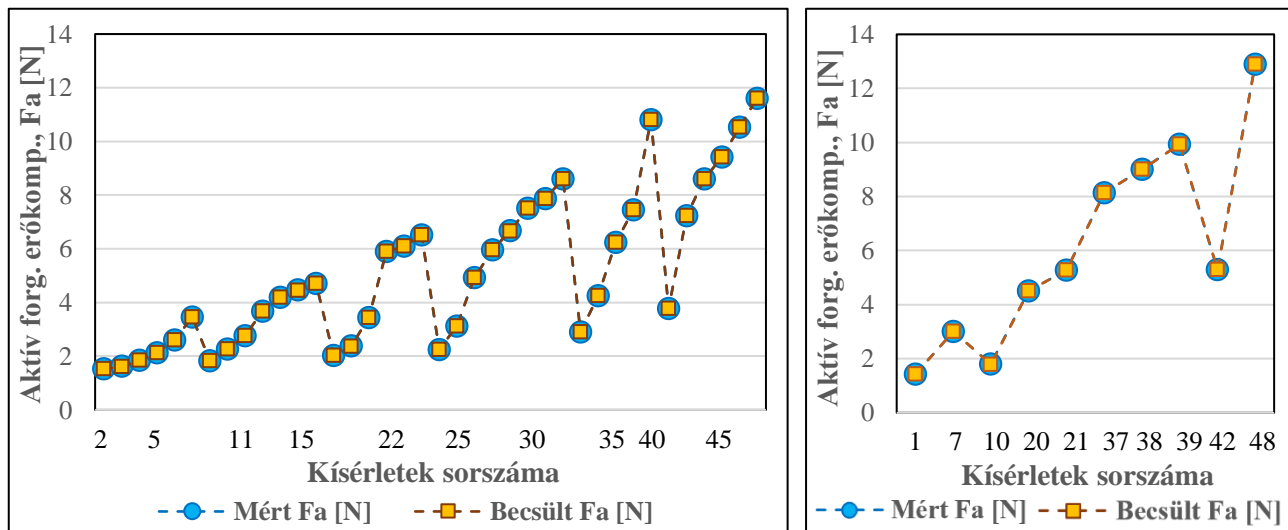


2. ábra. A betanított mesterséges neurális hálózat regressziós diagramjai

ANN modell eredményeinek összegzése

2. táblázat

	Kísérleti eredmények száma	MSE	RMSE	R
Tanítás	26	0,0018	0,0424	0,99991
Validáció	6	0,0029	0,0539	0,99990
Teszt	6	0,0066	0,0812	0,99986
Kiegészítő teszt	10	0,0312	0,1766	0,99987
Összesen	48			



3. ábra. Az aktív forgácsoló erőkomponens mért és becsült értékeinek összehasonlítása a betanítás és az utólagos ellenőrzés esetén

5. ÖSSZEFOGLALÁS

A kutatási munka célja a mikromarási technológia Ipar 4.0 keretrendszerébe történő integrálásának az elősegítése a folyamatra vonatkozó adatokat felhasználó mesterséges intelligencia alapú támogató rendszerek létrehozása által.

A kutatás jelen szakaszában AISI H13 típusú acélon végzett szisztematikus kísérletek eredményeinek a felhasználásával egy olyan mesterséges neurális hálózat alapú előrejelző modellt hoztunk létre, ami az adott forgácsolási paraméterek alapján tud becslést adni az aktív forgácsoló erőkomponensre mikromarás esetén. A modell tanítását, validálást, tesztelését, valamint utólagos, 10 konkrét mérési eredmény alapján végzett ellenőrzését a rendelkezésre álló kísérleti adathalmaz célzott megosztásával végeztük. Az elemzés alapján kijelenthető, hogy az előrejelző modell aktív forgácsoló erőkomponensre vonatkozó becslési jósága kiemelkedő (>99%) a vizsgált paramétertartományon belül.

A kutatással kapcsolatos jövőbeni eredmények segítségével lehetőség kínálkozik arra, hogy a szenzorokból érkező jelekből meghatározott pillanatnyi folyamatjellemzők alapján megmunkálás közben becsülhetővé és a forgácsolási paraméterek optimalizálásával kontrollálhatóvá válik a gyártmány minősége, valamint meghatározhatóvá a szerszám maradék hasznos éltartama. Az utóbbi egy olyan döntéstámogató rendszer alapját jelenti, ami segítségével a szerszámcsere ideális időpontja meghatározható. Mindezek további lépéseket jelentenek a selejtmentes gyártás megvalósításának az irányában.

KÖSZÖNETNYILVÁNÍTÁS

A kutatás a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott OTKA-K-132430 azonosító számú, Tranziens deformációs, termikus és tribológiai folyamatok kemény fémfelületek finomforgácsolásánál című, valamint az ED_18-2-2018-0006 azonosító számú, Kutatások az ipari digitalizáció által nyújtott potenciál minőségi kiaknázására tárgyú projektek keretében valósult meg. A szerzők köszönetet mondanak a Fraisa és Böhler cégek támogatásáért is.

IRODALMI HIVATKOZÁSOK

- [1] Boswell, B., Islam, M.N., Davies, I.J. *A review of micro-mechanical cutting*. Internation Journal of Advanced Manufacturing, 2018, 94, 789–806.
- [2] Makhfi, S.; Velasco, R.; Habak, M.; Haddouche, K.; Vantomme, P. *An optimized ANN approach for cutting forces prediction in AISI 52100 bearing steel hard turning*. Sci. Technol. 2013, 3, 24–32.
- [3] Imani, L., Henzaki, A.R., Hamzeloo, R., Davoodi B. *Modeling and optimizing of cutting force and surface roughness in milling process of Inconel 738 using hybrid ANN and GA*. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, 2020 Apr;234(5):920-32.