

# A minőség és a termelékenység optimalizálása mikromarásnál gépi tanulás alapú prediktív modellek alkalmazásával

## Optimisation of quality and productivity in the micromilling process through machine learning predictive models

ELLY Ogutu Isaya<sup>1</sup>, TAKÁCS Márton<sup>1</sup>

<sup>1</sup>Budapesti Műszaki és Gazdaságtudományi Egyetem, Gépészmérnöki Kar, Gyártástudomány és -technológia Tanszék; Tel.: +36 1 4633176; E-mail: takacs.marton@gpk.bme.hu; Honlap: www.manuf.bme.hu

### Abstract

*The paper presents a multi-objective optimization method for the micro-milling process, aiming at the simultaneous optimization of average surface roughness ( $R_a$ ) and material removal rate (MRR). The method employs an ANFIS predictive model and a swarm intelligence-based optimization algorithm to determine the optimal cutting parameters, supporting the integration of the micro-milling process into an Industry 4.0 environment.*

**Keywords:** Micro-milling, Multi-objective optimization, Surface roughness ( $R_a$ ), Material removal rate (MRR), ANFIS (Adaptive Neuro-Fuzzy Inference System)

### Kivonat

*A cikk egy többcélú optimalizálási módszert mutat be a mikromarási folyamat számára az átlagos felületi érdesség ( $R_a$ ) és az anyagleválasztási sebesség (MRR) egyidejű optimalizálására. A módszer az ANFIS prediktív modellt és egy rajntelligencia-alapú optimalizáló algoritmust alkalmaz az optimális forgácsolási paraméterek meghatározására, támogatva a mikromarási folyamat Ipar 4.0 környezetbe történő integrációját.*

**Kulcsszavak:** Micro-milling, Multi-objective optimization, Surface roughness ( $R_a$ ), Material removal rate (MRR), ANFIS (Adaptive Neuro-Fuzzy Inference System)

## 1. BEVEZETÉS

A magas termékminőség az egyik legfontosabb mutatója a hatékony mikromechanikai folyamatoknak. A felületi minőség kiemelt jelentőségű, különösen akkor, amikor funkcionális felületekkel rendelkező miniatürizált termékekről van szó. A felületi minőség nemcsak esztétikai értéket ad a terméknek, hanem meghatározza annak tribológiai működését is [1]. A gyártóvállalatok célja a minőségi miniatürizált termékek nagy termelékenységgel történő előállítása. Ez biztosítja a vevői igények kielégítését és a költséghatékonyságot. Ez azonban nem mindig valósul meg. A kialakuló felületi minőség és az anyagleválasztási sebesség számos megmunkálási tényezőtől függ, amelyeket folyamatosan felügyelni és szabályozni kell. Ezek a tényezők magukban foglalják a forgácsolási paramétereket, a szerszámgeometriát és a megmunkálási környezetet, amik gyakran egymással ellentétes módon befolyásolják az anyagleválasztási sebességet (MRR – Material Removal Rate) és a felületi minőség ( $R_a$ ) értékét [2], valamint más jellemzőket, például a szerszámkopást is. Az MRR növelése általában a szerszám élettartamának csökkenésével és a felületi minőség romlásával jár, ahogyan azt Miranda és munkatársai is kimutatták [3]. Ezek az ellentmondó hatások a mikromarás során fellépő forgácsképződés összetett jellegéből erednek, amelyet a mérhető jelensége is befolyásol, és kompromisszumos megoldásokat tesznek szükségessé [4].

Jelen kutatás célja egy mesterséges intelligencián alapuló optimalizálási keretrendszer kidolgozása a szakirodalomban elérhető adatok esetében, amelyben a felületi érdességre és az anyagleválasztási sebességre vonatkozó prediktív gépi tanulási modellek szolgálnak célfüggvényként egy metaheurisztikus optimalizáló algoritmusban. Ennek segítségével meghatározhatóak az optimális forgácsolási paraméterek – így a forgácsoló sebesség, a fogásmélység és az előtolás –, valamint elérhető egy megfelelő egyensúly az MRR és az  $R_a$  között.


A munka nemcsak az optimális paramétereket mutatja be, hanem ismerteti a gépi tanulási modellek fejlesztését és azok optimalizáló algoritmusba történő integrálását is.

## 2. FORRÁSDATOK

A jelen munkában felhasznált adatok Natarajan és munkatársai [2] kutatásából származnak. A kísérleteket egy háromtengelyes, egyedi építésű mikromaró gépen végezték, amelynek főorsófordulatszama 60 000–80 000 fordulat/perc tartományban volt. A megmunkált munkadarab egy  $60 \times 40 \times 16 \text{ mm}^3$  méretű alumínium tömb volt, amelyet 1 mm átmérőjű keményfém maróval munkáltak meg.

A vizsgált forgácsolási paraméterek három szinten kerültek meghatározásra a következők szerint: forgácsoló sebesség ( $v_c$ ) (189, 220, 251 m/min), axiális fogásmélység ( $a_p$ ) (10, 25, 40  $\mu\text{m}$ ), valamint előtolási sebesség ( $v_f$ ) (0,2; 0,5; 0,8  $\mu\text{m/s}$ ). A válaszparaméterek az  $R_a$  és az MRR voltak. Az  $R_a$  értékét 4 mm-es mintavételi hosszban mérték Mitutoyo SJ-400 felületi érdességmérő készülékkel. Az MRR értékét a forgácsolási paraméterekből számították.

A kísérlettervezés során teljes faktoriális tervet alkalmaztak, amely 27 kísérleti futást eredményezett. További négy futást végeztek a modell validálására. Az 1. ábra a kísérleti elrendezést mutatja be.



1. ábra. Az adatok forrásául szolgáló kísérleti elrendezés [2]

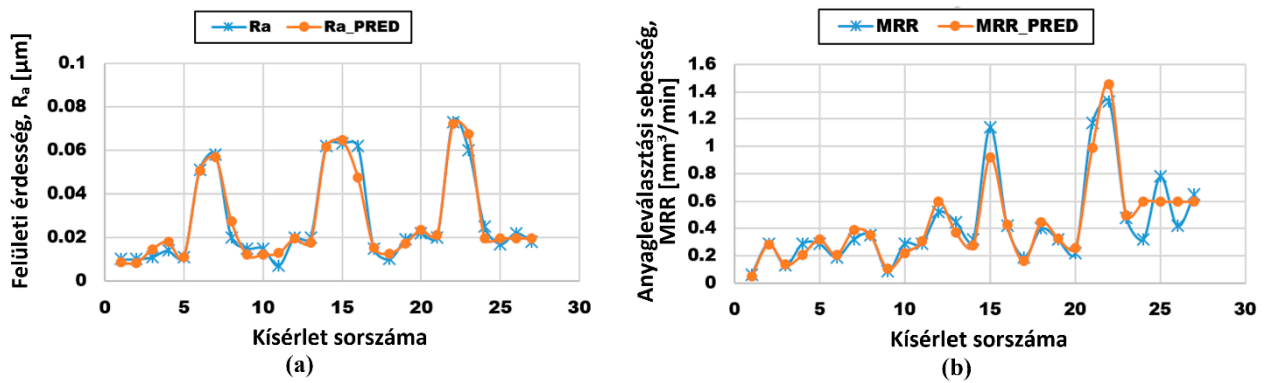
## 3. ANFIS-MODELL FEJLESZTÉSE

Az ANFIS-modelleket MATLAB R2023b környezetben fejlesztettük. A tanítási folyamat felügyelt módon történt és 27 – különböző paraméterkombinációjú – mikromarási kísérletből származó adathalmazt használt fel. Több ANFIS modell került betanításra a következő hiperparaméterek variálásával: a tagsági függvények (MF) száma és típusa a bemeneti paraméterek (általánosított haranggörbe, Gauss-, háromszög- és trapéz függvények), valamint a kimeneti paraméterek (konstans és lineáris függvények) részére, a tanítási algoritmusok (visszaterjesztés és hibrid módszer – legkisebb négyzetes becslés és gradiens módszer kombinációja), az epochok száma, valamint a fuzzy következtetési rendszerek típusa (Sugeno és Mamdani). A legjobb modell a determinációs együttható ( $R^2$ ) és az átlagos négyzetes hiba négyzetgyöke (RMSE) értékei alapján került kiválasztásra.


Mind az MRR, mind az  $R_a$  esetében a legjobb modellek a forgácsoló sebességhez 4 darab (Gauss-típusú), az előtoláshoz 2, valamint a fogásmélységhez szintén 2 tagsági függvényt alkalmaztak. Ezek Sugeno-típusú modellek voltak, hibrid betanítási algoritmussal. A felületi érdességre ( $R_a$ ) vonatkozó modell a tanító adatokon  $R^2 = 0,96$  és  $\text{RMSE} = 0,004$  értékeket mutatott, míg az MRR-modell esetében az értékelési paraméterek értékei  $R^2 = 0,9$  és  $\text{RMSE} = 0,101$  voltak. A 2. ábra a modellek illeszkedési diagramjait (paritásdiagramjait) mutatja a tanító adatokon. Ezekből a statisztikai mutatókból megállapítható, hogy a modellek nagy pontosságúak.

A modellek teljesítményét a betanításhoz nem alkalmazott adatokon is ellenőriztük egy négy kísérleti futásból álló validációs adathalmaz segítségével. A modellek jó teljesítményt mutattak a validációs adatokon is: az  $R_a$ -modell megőrizte a kedvező statisztikai mutatókat ( $R^2 = 0,9$ ;  $\text{RMSE} = 0,004$ ), míg az MRR-modell

esetében  $R^2 = 0,82$  és  $RMSE = 0,52$  adódott. A 3. ábra a modellek validációs adatokon nyújtott teljesítményét foglalja össze.



2. ábra. A betanított modellek által szolgáltatott értékek (PRED) és a mérési eredmények illeszkedése a betanításban részt vett adatok esetében



3. ábra. A betanított modellek által szolgáltatott értékek (PRED) és a mérési eredmények illeszkedése a betanításban részt nem vett – validációs – adatok esetében

#### 4. TERMÉKMINŐSÉG ÉS MEGMUNKÁLÁSI SEBESSÉG OPTIMALIZÁLÁSA

A felületi minőség javítása és az anyagleválasztási sebesség maximalizálása érdekében többcélú részecske-raj-optimalizálást (PSO) alkalmaztunk. Az algoritmus a madarak rajának táplálékkeresés közbeni összehangolt mozgását (optimális megoldáskeresését) utánozza. Minden egyed (részecskét) a pozíciója és a sebessége jellemez, amik minden keresési lépés (iteráció) után frissítésre és a raj többi tagjával megosztásra kerülnek. A raj legjobb pozíciója tekinthető az optimalizálási probléma globális megoldásának.

A jelen munkában egy többcélú PSO-algoritmust készült, amit a MATLAB R2023b környezetben futtattunk. A kifejlesztett ANFIS-modellek egy többcélú függvénybe (1. egyenlet) kerültek integrálásra, ami a részecskék pozíciójának frissítésére szolgált az optimalizálási folyamat során. Az iterációk maximális számát 1000-ban határoztuk meg, míg a raj méretét 500-ban. Emellett az algoritmus kognitív és szociális paraméterei rendre 1,5 és 2,0 értéket vettek fel, a nem-dominált megoldások tárat pedig 50 elemben korlátoztuk.

$$\text{Min} (f(Ra, -MRR)) \tag{1}$$

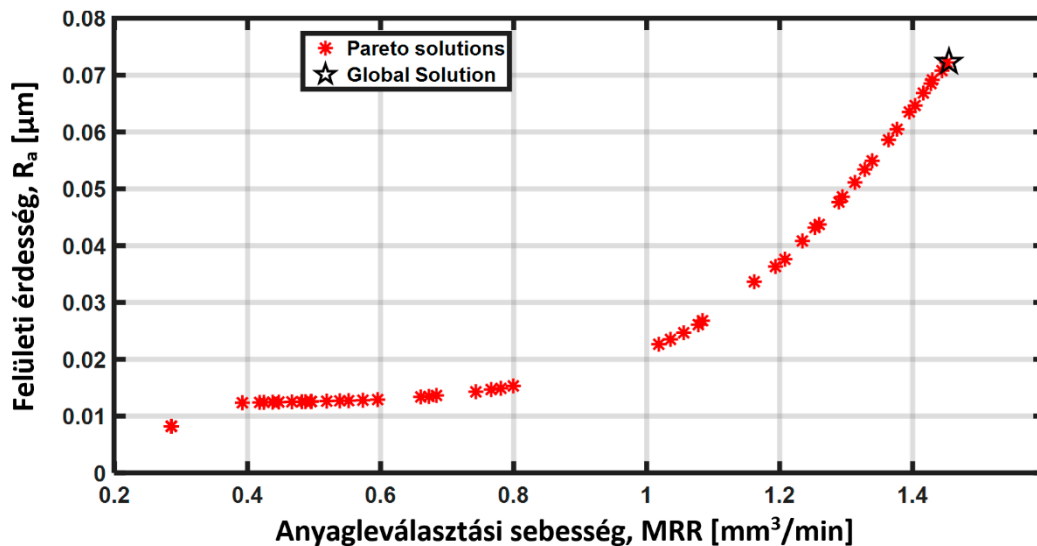
Korlátozások:

$$0,2 \mu \frac{m}{s} \leq v_f \leq 0,8 \mu m/s$$

$$189 \text{ m/min} \leq v_c \leq 252 \text{ m/min}$$

$$10 \mu m \leq a_p \leq 40 \mu m$$

A 4. ábra az optimalizálási folyamat eredményeként kapott Pareto-frontot mutatja. Az elért optimális MRR és  $R_a$  értékek rendre  $1,46 \text{ mm}^3/\text{min}$  és  $0,07 \mu m$  voltak,  $221,28 \text{ m/min}$  optimális forgácsoló sebesség,  $40 \mu m$  fogásmélység és  $0,8 \mu m/s$  előtolási sebesség mellett. Ezek az optimális értékek a 687. iterációban adódtak.



4. ábra. A PSO-alapú többcélú optimalizálás kétdimenziós Pareto-frontja

## 5. KÖVETKEZTETÉSEK

A kutatás célja gépi tanulás alapú prediktív modellek és egy optimalizálási keretrendszer kidolgozása volt az  $R_a$  és az MRR előrejelzésére és a forgácsolási paraméterek optimalizálására mikroméretű marás esetén. A kifejlesztett ANFIS-modellek robusztusnak bizonyultak, amit a teljesítménymutatók ( $R^2$  és RMSE) kedvező értékei is alátámasztanak mind a tanítási, mind a validációs fázisban. A modellek jó teljesítménye a validációs adathalmazon azt jelzi, hogy alkalmasak lehetnek az  $R_a$  és az MRR üzemi körülmények közötti előrejelzésére.

A jövőbeni kutatásoknak figyelembe kellene venniük olyan tényezők hatását is, mint a szerszámkopás, a rezgések, a szerszám ütése, valamint a mikromarási erők, amelyeket ebben a munkában nem vizsgáltunk, ugyanakkor jelentős hatással vannak az  $R_a$  és az MRR értékére. Ez hozzájárulhat pontosabb és robusztusabb modellek fejlesztéséhez a mikromarási folyamat előrejelzésére és optimalizálására.

## KÖSZÖNETNYILVÁNÍTÁS

A jelen cikkben ismertetett, a Budapesti Műszaki és Gazdaságtudományi Egyetemen végzett kutatást részben a Nemzeti Kutatási, Fejlesztési és Innovációs Hivatal (NKFIH) finanszírozta a következő projektek keretében: OTKA SNN\_23\_146940 (Mesterséges intelligencia alapú prediktív modellek alkalmazhatóságának alapvető vizsgálata korszerű megmunkálási eljárásokkal történő gyártás minőségének javítása céljából), valamint 2021-1.2.4-TÉT-2021-00054 (Mikromegmunkálás gépi tanulással támogatott folyamatfelügyelete az Ipar 4.0 keretén belül).

## IRODALMI HIVATKOZÁSOK

- [1] Surface Fabricated by Micro-Milling and Wet Micro-Blasting,” *Journal of Tribology*, vol. 144, no. 9, p. 091201, Sep. 2022, DOI: 10.1115/1.4053318.
- [2] U. Natarajan, Pr. Periyanan, and S. H. Yang, “Multiple-response optimization for micro-endmilling process using response surface methodology,” *Int J Adv Manuf Technol*, vol. 56, no. 1–4, pp. 177–185, Sep. 2011, DOI: 10.1007/s00170-011-3156-2.
- [3] M. Miranda, D. Serje, J. Pacheco, and J. Bris, “Tool edge radius wear and material removal rate performance charts for titanium micro-milling,” *Int. J. Precis. Eng. Manuf.*, vol. 19, no. 1, pp. 79–84, Jan. 2018, DOI: 10.1007/s12541-018-0009-z.
- [4] F. B. De Oliveira, A. R. Rodrigues, R. T. Coelho, and A. F. De Souza, “Size effect and minimum chip thickness in micromilling,” *International Journal of Machine Tools and Manufacture*, vol. 89, pp. 39–54, Feb. 2015, DOI: 10.1016/j.ijmactools.2014.11.001.