

# 금형의 절삭가공에서 표면 거칠기 예측 수식의 유사-실험 데이터 활용을 위한 인공지능망 구축에 대한 연구

김지우<sup>1,3</sup> · 이준한<sup>3</sup> · 이동원<sup>2,3</sup> · 김종선<sup>3</sup> · 김종수<sup>3†</sup>

고려대학교 기계공학과<sup>1</sup>

인하대학교 기계공학과<sup>2</sup>

한국생산기술연구원 디지털생산부문<sup>3†</sup>

## A Study on the Establishment of Artificial Neural Networks for the Use of Similar-Experimental Transition Data of Surface Roughness Prediction Equation in Mold Machining

Ji-Woo Kim<sup>1,3</sup> · Jun-Han Lee<sup>3</sup> · Dong-Won Lee<sup>2,3</sup> · Jong-Sun Kim<sup>3</sup> · Jong-Su Kim<sup>3†</sup>

Dept. of Mechanical Eng., Korea Univ.<sup>1</sup>

Dept. of Mechanical Eng., Inha Univ.<sup>2</sup>

Korea Inst. of Industrial Technology<sup>3,†</sup>

(Received March 19, 2024 / Revised March 22, 2024 / Accepted March 31, 2024)

**Abstract:** Surface roughness is one of the quality factors of molds that significantly influences the quality and performance of the final product, so it should be carefully considered during mold processing. To achieve the targeted surface roughness in mold machining, it typically relies on the utilization of cutting models for predicting cutting forces and experimental studies to optimize machining conditions. Because it is difficult to intuitively deduce the correlation between cutting variables and actual surface roughness, experiments are necessary in various machining conditions to adapt to changing machining environments. Furthermore, in micro-machining environments like in this study, various factors such as the difficulty of detecting micro-cutting signals, the lack of established standard models for predicting micro-cutting forces, and increased machining costs make it challenging to secure surface roughness through interpretation models and experiments. Moreover, although the trend of utilizing artificial intelligence in industries is increasing, there exist limitations in applying the technology due to the extensive time, manpower, and costs involved in collecting high-quality data for constructing artificial neural networks. In this study, to overcome these limitations and supplement experimental data necessary for AI learning, a neural network conversion model was proposed to convert surface roughness prediction equations into experimental data. Then, by using the converted formula data as similar-experimental data along with actual experimental data, an artificial neural network model for predicting surface roughness was constructed. The predicted surface roughness data obtained through the proposed method was compared and analyzed against actual surface roughness data. As a result, the prediction model incorporating similar-experimental data achieved an accuracy improvement of over 36% compared to models using only experimental data. The surface roughness prediction model with similar-experimental data is expected to replace labor-intensive and costly activities of collecting experimental data in various machining environments.

**Key Words:** Artificial neural network, Mathematical model, Milling, Mold, Surface roughness

### 1. 서론

산업 현장에서 제품을 제조하는 단가를 낮추기 위한 노력의 일환으로 금형을 이용한 대량 생산에 초점을 맞추고 있다.<sup>1)</sup> 이와 더불어 활발한 경제 활

† 교신저자: jskimgloria@kitech.re.kr

\* 본 논문에 대한 저작권은 저자들에게 있으며 CC BY-NC-SA를 만족하는 조건으로 이용할 수 있습니다.

동으로 생활 수준이 크게 높아진 환경에 따라 고객이 요구하는 제품의 품질에 대한 기준도 함께 상향 평준화되었으며, 이는 저렴한 생산 단가로부터 최상의 품질을 달성하여야 한다는 것을 의미한다. 고객이 제품을 사용함에 있어 피부로 직접 느껴지는 제품의 표면거칠기는 고객의 제품 만족도 판단에 지대한 영향을 주는 항목이며, 제품의 품질을 결정하는 가장 중요한 요소로 가공에 큰 노력을 기울여야 하는 부분이다.<sup>2)</sup>

금형을 통한 가공된 제품은 금형의 표면거칠기에 따라 제품의 최종 표면거칠기가 결정되며, 이는 금형의 표면거칠기가 곧 제품의 표면거칠기라는 것을 의미한다. 절삭 가공을 통해 제작된 금형은 목표된 표면거칠기를 달성하기 위해서 일반적으로 절삭 모델 활용을 통한 예측과 실험적 연구를 통해 가공 조건 최적화에 의존하는 실정이다.<sup>3)</sup> 이러한 방법은 실제 표면거칠기와 절삭 변수의 상관관계를 직관적으로 유추하기 어려우며 다양한 가공 환경에 대응한 수많은 실험을 필요로 한다.<sup>4)</sup> 더 나아가 본 연구와 같이 마이크로 가공 환경에서는 미세 절삭력 예측 모델의 미정립과 가공 소요 경비의 증가와 같은 여러 요인이 목표된 표면거칠기를 달성하는 데 어려움을 주고 있다. 이러한 한계를 극복하기 위해 최근 인공지능을 접목한 가공 조건 예측<sup>5)</sup>을 시도하고 있지만, 구축된 인공지능의 성능을 좌우하는 양질의 학습 데이터를 수집하는데 많은 인력과 비용이 소요됨에 따라 기술 적용에 많은 한계가 있는 실정이다.

본 연구에서는 이러한 한계를 극복하고자 표면거칠기 예측 수식을 유사-실험 데이터로 전환하는 인공지능을 구축하는 이전 연구<sup>6)</sup>에서 더 나아가, 전환된 유사-실험 데이터를 학습에 활용해 부족한 양질의 실험 데이터를 보완하는 방법을 제안하였다. 또한 유사-실험 데이터를 활용한 인공지능 모델의 정확도를 평가하고자 실험 데이터만을 이용한 인공지능 모델을 함께 구축하여 비교 평가를 진행하였다.

## 2. 금형 절삭가공 실험 데이터 수집

### 2.1. 금형 절삭가공 실험 데이터 수집

금형 절삭 가공 실험 데이터 수집을 위해 STAVAX 강 시편을 선정하여 Fig. 1과 같은 Roders 사의 3축 고속 정밀 가공기 RXP 801 Z2를 사용해 가공하였으며<sup>6)</sup>, 0.2 mm의 직경의 2날 CBN Ball End Mill을 공구로 사

용하였다.<sup>7,9)</sup> Mist typed의 절삭유와 함께 Fig. 2와 같이 패턴 방향인 x 방향으로 Table 1의 조건을 조합하여 9가지 Case를 만든 후 1가지 Case당 하나의 공구를 사용하여 총 9개 공구를 통해 각각 가공하였다.<sup>7,8)</sup>



Fig. 1 High-speed precision machining 3-axis cnc machining center (RXP 801 Z2, rodgers)

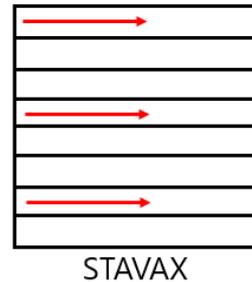


Fig. 2 Pattern & processing direction

Table 1 Machining conditions

Inclination Angle [°]	Spindle speed [RPM]	Axial Depth of Cut [ac, mm]	Feed rate [mm/min]	Radial Depth of Cut [ap, mm]
0	42,000	0.006	320	0.002
			560	0.0035
			800	0.005



Fig. 3 Olympus OLS5100 3D measuring laser microscope

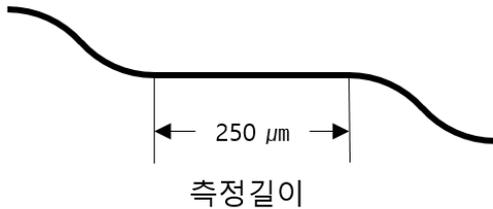


Fig. 4 Line surface roughness

가공된 STAVAX 시편은 Fig. 3와 같은 Olympus 사 3차원 공초점 레이저 현미경을 사용하여 1개의 Case마다 총 9개 Point time에 대해 표면 거칠기를 분석하였으며, 총 81개 데이터를 확보하였다. 각 Point time<sup>6)</sup>은 패턴의 평균 구간에 Fig. 4과 같이 약 250 μm 길이의 3개 Line의 거칠기를 측정하였다.<sup>7,8)</sup>

### 2.2. 금형 절삭가공 이론 모형 데이터 수집

이론 모형 데이터 수집은 가공된 시편의 표면거칠기를 예측하기 위한 이론 수식으로 response surfaced method에 따라 유도된 response surface equation 식(1)<sup>10)</sup>을 사용하였으며, Table 2를 통해 변수별 가공 요소<sup>10)</sup>를 나타내었다. Table 1과 같이 조합된 가공 조건을 적용하여 시편의 표면거칠기를 계산하였으며 유사-실험 데이터 전환 인공신경망 구축을 위한 데이터 셋으로 사용된다.

$$\begin{aligned}
 R_a = & 1.35355 + 0.0874799\phi + 0.000887986S \\
 & - 0.101501f_y + 7.92503f_x - 6.14303t \\
 & - 0.00320667\phi^2 - 1.20701 \times 10^{-7}S^2 \\
 & + 0.00122325f_y^2 + 9.91836f_x^2 + 10.5552t^2 \\
 & + 8.53234 \times 10^{-6}\phi S - 9.68995 \times 10^{-4}\phi f_y \\
 & + 0.1357\phi f_x + 0.00848098\phi t + 3.41726 \\
 & \times 10^{-5}Sf_y - 0.00576076Sf_x - 2.94529 \times 10^{-4}St \\
 & - 0.101860f_yf_x + 0.0719970f_yt - 12.5766f_xt
 \end{aligned} \quad (1)$$

Table 2 Variables equation

Variable	Factor
$\phi$	Inclination Angle
$S$	Spindle speed
$t$	Axial Depth of Cut
$f_x$	Radial Depth of Cut
$f_y$	Feed rate

이와 더불어 가공 순서에 따른 표면거칠기 변화를 학습에 활용하고자 가공 지시서 기반 위치 변수를 유도한 식(2)<sup>6)</sup>을 사용하였다.

$$\text{Point Time} = \left(\frac{15}{f_y} \times 60 \times r\right) + \left(\left(\frac{15}{f_x} - 1\right) \times \frac{15}{f_y} \times 60 \times c\right) \quad (2)$$

식(2)의 변수  $r$ 과  $c$ 의 값은 Fig. 5에 따라 Point 별 지정 값<sup>6)</sup>으로 계산되며 유사-실험 데이터 전환 인공신경망 구축을 위한 데이터 셋으로 사용된다.

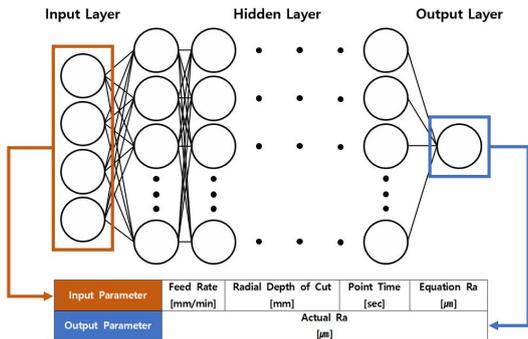
<b>PT.1</b>	<b>PT.2</b>	<b>PT.3</b>
$r: 0$	$r: 0.5$	$r: 1$
$c: 0$	$c: 0$	$c: 0$
<b>PT.4</b>	<b>PT.5</b>	<b>PT.6</b>
$r: 0$	$r: 0.5$	$r: 1$
$c: 0.5$	$c: 0.5$	$c: 0.5$
<b>PT.7</b>	<b>PT.8</b>	<b>PT.9</b>
$r: 0$	$r: 0.5$	$r: 1$
$c: 1$	$c: 1$	$c: 1$

Fig. 5 The values of r & c for point time equation

## 3. 유사-실험 데이터 전환 모델 구축

### 3.1. 유사-실험 데이터 전환 모델 학습

이론 식을 통해 계산된 금형의 표면거칠기 결과를 유사-실험 데이터로 전환하기 위한 인공신경망 모델을 구축하였다. 인공신경망 모델의 학습에 Fig. 6과 같이 Feed rate, Radial Depth of Cut의 가공 조건과 Point time<sup>6)</sup>, Equation Ra<sup>10)</sup> 계산 값이 입력 변수로 사용되었으며 금형 절삭가공 실험으로 수집한 실제 표면거칠기를 사용하였다.



**Fig. 6** Input and output parameters for convert model (Theoretical model to Experiment)

총 81개의 데이터는 8:1:1 비율에 맞추어 각각 학습(Train), 검증(Validation), 테스트(Test) 데이터 셋으로 구성하였다. 전체 실험 데이터 중에서 무작위로 선택된 64개 조건을 학습 데이터로 사용하였으며 학습 데이터로 사용되지 않은 데이터 중 8개 조건을 임의로 선정해 검증 데이터로 사용하였다. 마지막으로 최종 모델의 성능 평가를 위한 테스트 데이터는 나머지 9개 조건을 사용하였으며 이후 구축되는 모든 모델의 성능을 평가하는 테스트 데이터로 사용하기 위해 Table 3과 같이 저장되었다.

하이퍼밴드(Hyper-band)<sup>11)</sup> 방법으로 Table 4과 같은 하이퍼 파라미터(hyper parameter)의 탐색 범위로 탐색을 진행하였으며<sup>12,13)</sup>, 그 결과 Table 5와 같은 최적의 하이퍼 파라미터를 추출하였다.

**Table 3** Used test data

No	Feed rate	Radial Depth of Cut	Point time
1	320	0.0035	12050.758928571
2	320	0.005	8437.5
3	560	0.002	12051.964285714
4	560	0.0035	3444.681122
5	560	0.005	0
6	560	0.005	2410.714286
7	800	0.0035	2410.151786
8	800	0.0035	4820.303571
9	800	0.005	3374.4375

**Table 4** Search range of hyper parameters

Factor	Value
Optimizer	Adams <sup>14)</sup>
Learning rate	0.0001~0.01 [step size 0.001]
Number of hidden layers	1~5 [step size 1]
Max neuron	1~10 [step size 1]
Activation	Elu (hidden layers) <sup>15)</sup> Linear (output layer)
Weight initializer	He normal (hidden layers) Glorot normal (output layer)
Drop number per hidden layer	0.0~0.4 [step size 0.1]
Epochs	~3000
ETC	L2 normalization Batch normalization

**Table 5** Search result of hyper parameters for convert model

Factor	Value
Learning rate	0.0074
Number of hidden layers	3
Number of neurons per hidden layer	[6, 4, 4]
Drop number per hidden layer	[0.0, 0.0, 0.1] (hidden layers)
Epochs	506

### 3.2. 유사실험 데이터 전환 모델의 성능 평가

구축된 유사-실험 데이터 전환 모델의 성능을 평가하기 위해 Table 3의 테스트 데이터의 가공 조건을 입력 변수로 도출된 표면거칠기 예측값을 테스트 데이터의 실제 금형 표면거칠기 값과 비교하여 Fig. 7와 같은 결과를 확인하였다.

실제 표면거칠기 값(Actual Ra) 대비 이론식 예측값(Theoretical Ra)의 오차는 최대 1604 μm, 평균 961.5 μm의 값을 나타낸다. 그러나 구축된 유사-실험 데이터 전환 인공신경망을 통한 예측값(Predicted Ra)은 최대 39.7 μm, 평균 9.2 μm의 오차를 보이며 99% 이상의 정확도 향상을 확인하였다. 인공신경망의 성능을 평가하기 위해 표면거칠기 예측값(Predicted Ra)에 대한 RMSE(root mean square error)로 Ra 0.01311 mm 값이 산출되었으며, 이론식(Theoretical Ra)의 RMSE Ra 1.0537 mm에서 98.75%의 정확도 향상을 확인하였다.

구축된 인공신경망 모델을 통한 가공 환경의 차이에 의한 이론식의 예측 오차 보정과 정확도 향상을 확인하여 유사-실험 데이터 전환의

가능함을 판단한 후 5절에서 유사-실험 데이터를 활용하는 인공지능망 모델의 학습을 위해 유사-실험 데이터 전환 모델로 사용하였다.

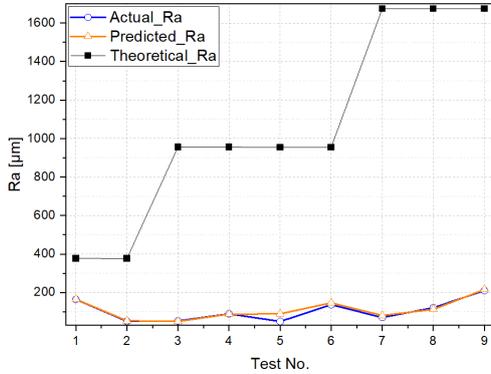


Fig. 7 Result of surface roughness for covert model

#### 4. 실제 실험 데이터를 이용한 표면거칠기 예측 모델 구축

##### 4.1. 실제 실험 데이터 활용 금형 표면거칠기 예측 모델 학습

유사-실험 전환 데이터를 이용한 표면거칠기 예측 모델을 구축하기 전 비교군으로 이용하기 위한 실제 실험 데이터를 통한 예측 모델을 구축하였다. 인공지능망 학습에는 Fig. 8와 같이 입력 파라미터로 Feed rate, Radial Depth of Cut, Point time 3가지의 변수와 출력 파라미터 Experimental Ra 1가지 변수가 사용되었다.

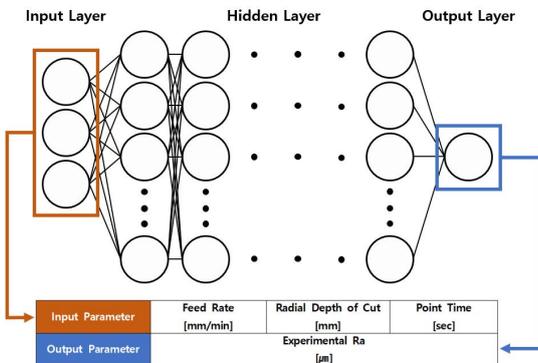


Fig. 8 Input and output parameters for experimental model

모델 구축에 사용된 데이터는 실제 금형의 표면거칠기 실험을 통해 수집한 81개 조건의 데이터로 8:1:1 비율의 학습, 검증, 테스트 랜덤 데이터 셋 분류를 진행하였다.

최종 성능 평가를 위해 공통으로 할당된 9개 조건의 테스트 데이터를 분리하였으며 총 데이터의 80%에 해당하는 64개의 데이터를 인공지능망 모델의 학습 데이터로 사용하였다. 최종적으로 남은 8개의 데이터는 인공지능망 학습 중 검증을 위한 데이터로 사용하였다.

실험 데이터를 이용한 표면거칠기 예측을 위해 인공지능망 모델의 구조는 Table 4와 동일한 하이퍼 밴드 방법을 사용하여 탐색을 진행하였으며, Table 6와 같이 하이퍼 파라미터가 선정되었다. 분류된 데이터 셋을 통하여 입력 변수와 출력 변수 사이의 관계를 학습시키고 표면거칠기 예측 모델을 구축하였다.<sup>12,13)</sup>

Table 6 Search result of hyper parameters for experimental model

Factor	Value
Learning rate	0.0097
Number of hidden layers	3
Number of neurons per hidden layer	[7, 7, 6]
Drop number per hidden layer	[0.0, 0.2, 0.2] (hidden layers)
Epochs	451

##### 4.2. 실제 실험 데이터 활용 금형 표면거칠기 예측 모델 성능 평가

구축된 예측 모델의 성능을 평가하기 위해 학습에 사용되지 않은 Table 3에 나타난 테스트 데이터를 사용하였다. 테스트 데이터의 공정 조건을 인공지능망의 입력 변수로 적용하여 금형의 표면거칠기 예측 값을 Fig. 9과 같이 나타내었다.

실제 실험 데이터를 활용한 인공지능망 모델의 표면거칠기 예측값(Predicted Ra)을 실제 표면거칠기 실험값(Actual Ra)과 비교하여 최대 55.5 μm, 평균 19.49 μm의 오차를 확인하였다. 이를 토대로 계산된 RMSE 값은 Ra 0.02664 mm로 산출되었으며 상관계수는 0.7585로 확인할 수 있었다. 이는 본 연구에서와 같은 마이크로 가공 환경에서 무시할 수 없는 수준의 오차를 보이며 실제값과의 선형관계가 미미하다는 것을 확인할 수 있었다.

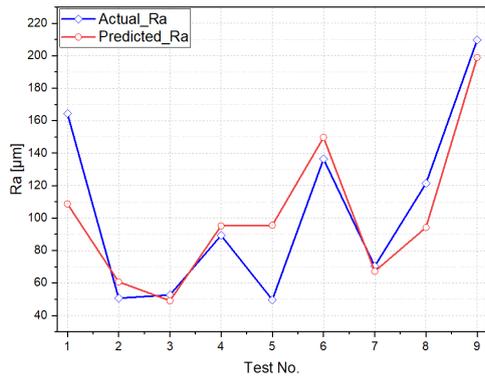


Fig. 9 Result of surface roughness for experimental model

## 5. 유사실험 전환 데이터를 이용한 표면거칠기 예측 모델 구축

### 5.1. 실험 데이터 보완을 위한 유사-실험 데이터 생성

실제 금형의 표면거칠기 실험을 통해 추출한 81개 조건의 데이터의 범위를 확장시켜 금형 절삭가공에서의 품질 예측을 진행하고자 유사-실험 데이터 전환 모델을 사용하였다. 유사-실험 전환 데이터를 생성하기 위해 Table 7과 같이 기존 공정 조건 범위 내에서 기존과 상이한 새로운 3,006개의 공정 조건을 선정하고, 표면거칠기 예측 수식을 통해 이론 예측 결과를 추출하였으며 3절에서 구축된 데이터 전환 모델을 통해 유사-실험 데이터로 전환하였다. 유사-실험 데이터는 기존 공정 조건의 실험 데이터와 함께 표면거칠기 예측 모델 학습에 사용되었다.

Table 7 Machining condition for similar - experimental transition data

Machining Condition	Value
Feed rate	320, 330, 340 ... 800
Radial Depth of Cut	0.002, 0.0025, 0.003 ... 0.005
Point time	1, 2, 3 ... 9

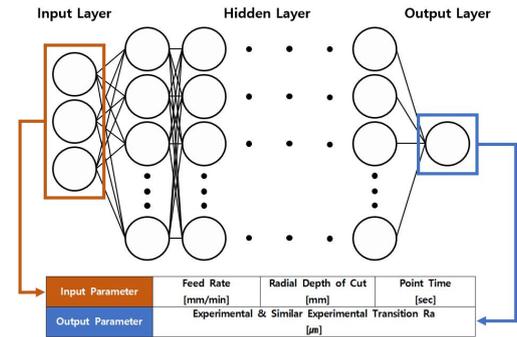


Fig. 10 Input and output parameters for similar-experimental transition model

### 5.2. 유사-실험 전환 데이터 활용 금형 표면거칠기 예측 모델 학습

실험 데이터와 유사-실험 전환 모델로 생성된 데이터를 표면거칠기를 예측 인공신경망 구축을 위한 학습에 사용하였다. 인공신경망 모델 학습에 사용된 입력 파라미터는 Fig. 10와 같이 Feed rate, Radial Depth of Cut, Point time 3가지 입력 변수가 사용되었으며, 출력 파라미터로 실험 Ra와 유사-실험 Ra가 사용되었다.

총 3,087개의 공정 조건의 데이터 중 테스트 데이터는 316개 조건으로, 실험 데이터 단일 사용 예측 모델과의 비교를 위해 공통 테스트 데이터인 지정된 9개의 가공 조건을 포함하였다. 테스트 데이터를 제외한 데이터 중 80%인 2,217개의 조건을 인공신경망 학습에 사용하였으며, 최종적으로 나머지 554개의 조건은 검증 데이터로 할당되었다.

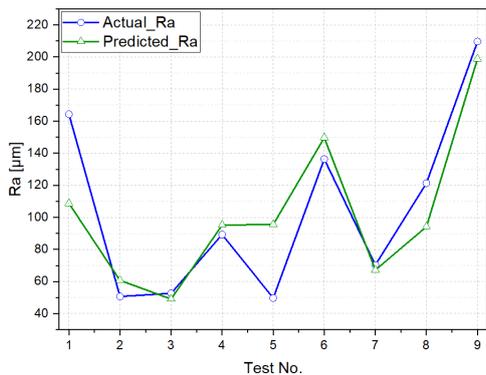
표면거칠기 예측을 위한 인공신경망 모델의 구조를 탐색하기 위해 Table 4와 동일한 하이퍼밴드 방법을 사용하여 Table 8과 같은 최적의 하이퍼 파라미터를 추출하였다. 그리고 해당 인공신경망 모델에 학습 데이터를 사용하여 입력 변수와 출력 변수 사이의 관계를 학습시키고 표면거칠기 예측 모델을 구축하였다.

**Table 8** Search result of hyper parameters for similar-experimental model

Factor	Value
Learning rate	0.0043
Number of hidden layers	3
Number of neurons per hidden layer	[8, 8, 3]
Drop number per hidden layer	[0.0, 0.0, 0.2] (hidden layers)
Epochs	306

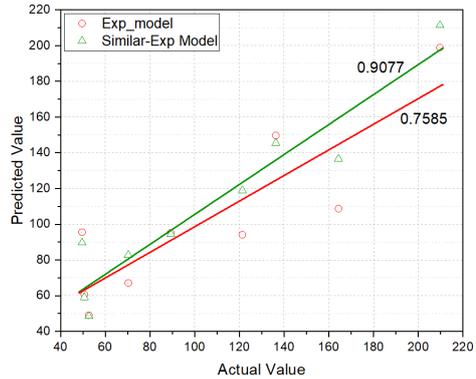
### 5.3. 유사-실험 전환 데이터 활용 금형 표면거칠기 예측 모델 성능 평가

유사-실험 전환 데이터를 활용하여 구축한 표면거칠기 예측 모델의 성능을 평가하기 위해 학습에 사용되지 않은 Table 3의 테스트 데이터를 사용하였다. 테스트 데이터의 공정 조건을 학습이 완료된 모델에 입력하여 표면거칠기를 예측하였다. 그리고 해당 예측값(Predicted Ra)을 실제 표면거칠기 값(Actual Ra)과 비교하여 정확도를 평가하여 Fig. 11과 같이 나타내었다. 유사-실험 전환 데이터를 활용한 예측 모델의 금형 표면거칠기 예측 값(Predicted Ra)은 실제 가공된 금형의 표면거칠기(Actual Ra)와 비교하여 최대 40  $\mu\text{m}$ , 평균 12.3  $\mu\text{m}$ 의 오차를 확인할 수 있었다. 이를 토대로 계산된 RMSE 값은 Ra 0.01741 mm로 산출되었으며 상관계수는 0.9077로 확인할 수 있었다.



**Fig. 11** Result of surface roughness for similar-experimental model

결과적으로 Fig. 12과 같이 실제 실험 데이터만을 사용한 모델(Exp\_model)의 상관계수 0.7585에서 유사-실험 데이터를 활용한 모델 (Similar-Exp Model)의 상관계수 0.9077로 큰 폭으로 향상되어 예측 값과 실제 값의 선형 관계가 더욱이 일치한다는 것을 확인할 수 있었다.



**Fig. 12** Line fitting for predicted value of each model

더 나아가 실제 실험 데이터 학습 모델의 예측 오차 값(EXP Ra)과 유사-실험 데이터 활용 모델의 예측 오차 값(Similar EXP Ra)을 실제 실험 표면거칠기(Actual Ra)와 비교하여 Fig. 13에 나타내었다.

실제 실험 데이터만을 사용하여 구축한 모델의 RMSE 값 Ra 0.02664 mm 대비 유사-실험 데이터 활용 모델의 RMSE 값은 Ra 0.01741 mm로 본 연구와 같이 마이크로 가공에서 무시할 수 없는 수준인 36%의 유의미한 정확도 향상을 확인할 수 있었다. 이를 통해 유사-실험 데이터 전환 모델을 활용하여 인적자원과 비용, 시간적 손해가 큰 실험 데이터 수집 과정을 유사-실험 데이터로 보완하여 표면거칠기 예측 모델을 구축한다면 실험 데이터만을 이용해 구축된 모델과 비교하여 오차 감소, 정확도 향상, 선형관계 향상을 확인할 수 있었다.

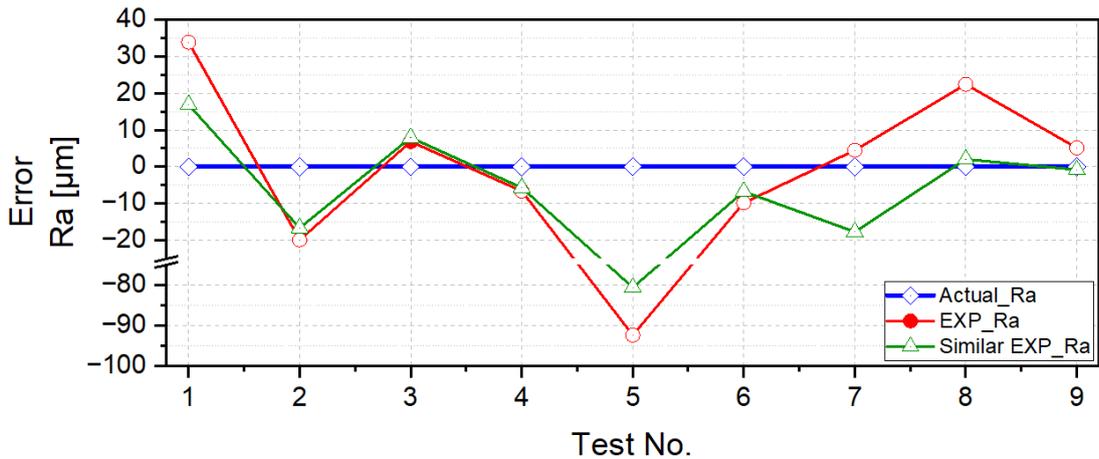


Fig. 13 Error compared to the actual surface roughness of each prediction

### 6. 결론

본 연구에서는 금형의 절삭가공에서 표면거칠기를 예측하는 이론 식을 통하여 금형의 표면거칠기 데이터를 확보하였으며, 이론식으로 도출한 표면거칠기를 실제 실험 데이터로 보완하기 위한 유사-실험 데이터 전환 모델을 구축하였다. 이를 활용하여 총 81개 실제 실험 데이터 이외의 가공조건에 대한 총 3,006개의 유사-실험 데이터를 확보하여 총합 3,087개의 데이터를 인공지능망 학습에 사용하였다. 해당 인공지능망을 통해 금형의 표면거칠기의 품질을 예측하는 모델을 구축하고 실제 실험 데이터를 학습에 사용한 모델 대비 성능을 평가하였으며 다음과 같은 결과를 확보할 수 있었다.

- 1) 제한된 실험 데이터를 이론 식과 인공지능망을 통한 유사-실험 데이터로 전환하는 모델을 구축한다면 Ra 0.01311 mm의 RMSE를 보이는 신뢰성 높은 유사-실험 데이터가 생성되는 것을 확인할 수 있었다.
- 2) 유사-실험 데이터로 전환된 가공조건과 표면거칠기 값을 학습에 활용한 인공지능망을 구축한 결과 실제 실험값과 비교하여 Ra 0.01741 mm의 RMSE를 나타내었으며 상관계수는 0.9077로 확인할 수 있었으며, 실제 금형의 절삭가공 실험을 통해 측정된 표면거칠기와 매우 유사한 수준의 값으로 전환되는 것을 확인할 수 있었다.
- 3) 실제 실험 데이터만을 학습에 활용한 인공지능망 모델을 구축한 결과 실제 실험값과 비교하여 Ra 0.02664 mm의 RMSE가 산출되었으며 상관계수는 0.7585로 확인할 수 있었다.
- 4) 유사-실험 데이터를 학습에 활용한 인공지능망은 실제 실험 데이터만을 학습에 활용한 인공지능망 모델과 비교하여 36%의 정확도 향상을 보여주었으며 예측 값과 실제 값의 선형관계의 일치도가 향상된 것을 확인할 수 있었다.

인공지능 학습에 사용되는 데이터가 구축된 모델의 예측 정확도에 지대한 영향을 미치기 때문에 양질의 데이터를 확보하는 것이 매우 중요한 일이다. 하지만 절삭가공을 통한 데이터 수집은 매우 많은 시간과 인력을 필요로 하기 때문에 실제 산업 현장에서 인공지능망을 적용하는 데 한계가 존재한다. 본 연구에서는 유사-실험 데이터 전환 모델 구축을 통한 이론식의 유사-실험 데이터 전환 연구<sup>6)</sup>에서 더 나아가 이론 식 기반 유사-실험 데이터의 실제 실험 데이터 보완을 통한 금형의 표면거칠기 예측 인공지능망 모델을 구축 및 평가하였다. 위 결과에 따라, 유사-실험 데이터를 통한 인공지능망 구축은 신뢰성 있는 실험 데이터 보완이 가능함을 확인할 수 있었으며, 이론 식을 활용한 유사-실험 데이터 전환을 통해 부족한 실험 데이터를 보완함으로써 데이터 수집에 소모되

는 인적자원과 시간적 손실에 대한 비용을 큰 폭으로 절감할 수 있으며, 적은 실험 데이터로 높은 정확도의 예측 모델을 구축할 수 있어 실제 산업현장에 적용함에 있어 부족함이 없을 것으로 판단된다. 더 나아가 표면거칠기 예측에 국한되지 않고 가공 제품의 전반적인 품질 예측에 활용되는 등 실제 산업 현장에서 다양한 변수에 의한 품질 예측의 어려움을 보다 효율적이고 정확하게 예측할 수 있을 것으로 판단된다.

## 후기

본 연구는 2023년도 산업통상자원부의 소재부품 산업기술개발기반구축사업의 ‘글로벌 시장 진출을 위한 차세대 자동차용 R100, Ra 200nm급 디지털 라이트닝 초미세 Light Guide 모듈 금형성형기술 개발 (No. 20019131, KM230100)’ 과제의 지원을 받아 연구되었습니다.

## 참고문헌

- 1) Kim, S. G., Lee, S. I., Ryu, G. Y., Shin, M. S., “Design of Data Analysis System for Supporting the Collaboration of Mold Manufacturing SMEs”, Industrial Engineering & Management Systems, 1889-1895, 2019.
- 2) Lee, J. H., Lee, J. K., Kawk, J. S., “Development and Evaluation of a Non-linearity Predictive Surface Roughness Model for Non-contact Finishing Products”, Transactions of the Korean Society of Mechanical Engineers, Vol. 46:9, 835-841, 2022.
- 3) Ryu, S. H., Lee, H. S., Chu, C. N., “Surface Roughness Prediction in Finish Machining with a Flat End Mill”, Korean Society for Precision Engineering, 166-171, 1998.
- 4) Chun, S. H., “A Study on the Application of ANN for Surface Roughness Prediction in Side Milling AL6061-T4 by Endmill”, Journal of the Korean Society of Manufacturing Process Engineers, Vol. 20:5, 55-60, 2021.
- 5) Oh, S. C., “Prediction of Machining Performance using ANN and Training using ACO”, Journal of the Korean Society of Manufacturing Process Engineers, Vol. 16:6, 125-132, 2017.
- 6) Kim, J. W., Lee, D. W., Kim, J. S., Kim, J. S., “A Study on the Construction of an Artificial Neural Network for the Experimental Model Transition of Surface Roughness Prediction Results based on Theoretical Models in Mold Machining”, Design & Manufacturing, Vol. 17:4, 1-7, 2023.
- 7) Lee, D. W., Lee, H. H., Kim, J. S., Kim, J. S., “A Study on the Surface Roughness Analysis by Cutting Condition in Machining of STAVAX mold for Vehicle Light Guide”, Korean Society of Mechanical Technology, Vol. 24:6, 1106-1112, 2022.
- 8) Lee, D. W., Lee, H. H., Kim, J. S., Kim, J. S., “A study on surface roughness depending on cutting direction and cutting fluid type during micro-milling on STAVAX steel”, Design & Manufacturing, Vol. 17:2, 22-26, 2023.
- 9) Kim, J. S., “A study on the surface roughness of STD11 material according to the helix angle of ball endmill”, Design & Manufacturing, vol. 17:1, 33-39, 2023.
- 10) Hossain, M. S. J., Ahmad, N. “Artificial intelligence based surface roughness prediction modeling for three dimensional end milling”. Int. J. Adv. Sci. Technol., Vol. 45:8, 1-18. 2012.
- 11) Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., Talwalkar, A., Hyperband: “A novel bandit-based approach to hyper-parameter optimization”, J. Mach. Learn. Res. Vol. 18, 6765 - 6816. 2017.
- 12) Lee, J. H., Kim, J. S., “A study on the construction of the quality prediction model by artificial neural intelligence through integrated learning of CAE-based data and experimental data in the injection molding process”, Design & Manufacturing, Vol. 15:4, 24-31, 2021.
- 13) Lee, J. H., Kim, J. S., “A study on the accuracy of multi-task learning structure artificial neural network applicable to multi-quality prediction in injection molding process”, Design & Manufacturing, Vol. 16:3, 1-8, 2022.
- 14) Kingma, D. P., Ba, J., Adam: “A method for

stochastic optimization”., arXiv, 2014.

- 15) Kim, D. H., Kim, J. N., Kim, J. I., “Elastic exponential linear units for convolutional neural networks, Neurocomputing”, Vol. 406, 253-266, 2020.

### 저자 소개

#### 김 지 우 (Ji-Woo Kim)



- 2024년 2월: 국립한국교통대학교 기계공학과 (공학사)
- 2024년 3월~현재: 고려대학교 기계공학과 석사과정
- 2023년 7월~현재: 한국생산기술연구원 지능화뿌리기술연구소 디지털생산부문, 근로연수생

< 관심분야 >  
정밀가공, 최적설계, 금형

#### 이 준 한 (Jun-Han Lee)



- 2022년 8월: 단국대학교 기계공학과 (공학박사)
- 2015년 3월~2022년 8월: 한국생산기술연구원 금형성형연구부문, 학연협동과정생
- 2022년 9월~2023년 8월: ㈜이몰디노 솔루션 팀, Domain expert
- 2023년 9월~현재: 한국생산기술연구원 지능화뿌리기술연구소 디지털생산부문, 포스트닥터

< 관심분야 >  
사출성형, 유동해석, 금형

#### 이 동 원 (Dong-Won Lee)



- 2017년 8월: 인하대학교 기계공학과 (공학석사)
- 2017년 9월~현재: 인하대학교 기계공학과 박사과정
- 2015년 3월~현재: 한국생산기술연구원 지능화뿌리기술연구소 디지털생산부문, 학연협동과정생

< 관심분야 >  
정밀가공, 금형, CAE

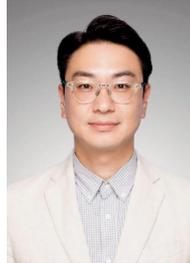
#### 김 종 선 (Jong-Sun Kim)



- 2005년 8월: 단국대학교 기계공학과 (공학박사)
- 2006년 3월~현재: 한국생산기술연구원 지능화뿌리기술연구소 디지털생산부문, 수석연구원

< 관심분야 >  
사출성형 및 금형, 유동해석

#### 김 종 수 (Jong-Su Kim)



- 2012년 2월: KAIST 기계공학과 (공학박사)
- 2012년 3월~2019년 1월: 삼성전자 MASK 개발팀, 책임연구원
- 2019년 1월~현재: 한국생산기술연구원 지능화뿌리기술연구소 디지털생산부문, 수석연구원

< 관심분야 >  
정밀가공, 금형, 자동차