

TQM 형상 공작물의 선삭가공 시 심층신경망을 이용한 표면거칠기 예측모델 개발

Surface Roughness Prediction in Interrupted Turning of TQM-shaped Workpiece Using Deep Neural Network

이진영* · 이정희* · 객재섭* †

Jin-Young Lee*, Jung-Hee Lee* and Jae-Seob Kwak* †

(Received 06 April 2026, Revision received 19 May 2026, Accepted 19 May 2026)

초록 : 단속선삭 공정은 비대칭 또는 비원형 단면을 가진 복잡 형상 공작물의 가공에 널리 활용된다. 그러나 공구-공작물 간 접촉 상태가 주기적으로 변화함에 따라 절삭력 변동, 충격 하중 및 진동이 발생하여 표면 품질과 공정 안정성에 영향을 미친다. 따라서 단속선삭에서의 동적 거동과 주요 절삭변수의 상호작용을 이해하는 것은 신뢰성 있는 표면 품질 확보에 중요하다. 본 연구에서는 SCM440 소재의 단속선삭 가공에서 절삭 속도, 이송 속도, 절삭 깊이가 표면거칠기에 미치는 영향을 분석하였다. 또한 예측 정확도 향상을 위한 답러닝 기반 DNN 모델을 구축하였다. $L_9(3^3)$ 다구찌 실험을 통해 최적 절삭 조건은 절삭 속도 140 m/min, 이송 0.1 mm/rev, 절삭 깊이 1.0 mm로 도출되었다. DNN 모델은 R^2 가 0.984, RMSE는 0.145로 높은 예측 성능을 보였다. 제안된 예측모델은 단속선삭 공정의 품질 관리와 최적 절삭조건 선정에 효과적으로 활용할 수 있을 것으로 기대된다.

키워드 : SCM440, 단속선삭, 답러닝 기반 예측모델, 데이터 기반 예측

Abstract : Interrupted turning is widely used in the machining of complex workpieces with asymmetric geometries or non-circular cross-sections. However, the tool-workpiece contact changes periodically, which leads to fluctuations in cutting force, impact loads, and vibration. These effects can negatively affect surface quality and process stability. Therefore, understanding the dynamic behavior of interrupted turning and the interactions among major cutting parameters is essential for achieving reliable surface quality. In this study, the effects of cutting speed, feed rate, and depth of cut on surface roughness in the interrupted turning of SCM440 steel were analyzed. In addition, a deep learning-based deep neural network (DNN) model was developed to improve prediction accuracy. Based on an $L_9(3^3)$ Taguchi experimental design, the optimal cutting condition was identified as a cutting speed of 140 m/min, a feed rate of 0.1 mm/rev, and a depth of cut of 1.0 mm. The developed DNN model demonstrated high prediction performance with a coefficient of determination (R^2) of 0.984 and a root mean square error (RMSE) of 0.145. The proposed prediction model is expected to be effectively utilized for quality control and optimal cutting condition selection in interrupted turning processes.

Key Words : SCM440, Interrupted Turning, Deep Learning-based Prediction Model, Data-driven Prediction

* † 객재섭(<https://orcid.org/0000-0003-2456-2000>) : 교수, 국립부경대학교 기계공학과
E-mail : jskwak5@pknu.ac.kr, Tel : 051-629-6139
* 이진영(<https://orcid.org/0009-0001-5716-3084>) : 대학원생, 국립부경대학교 기계공학과
* 이정희(<https://orcid.org/0000-0001-8771-1996>) : 연구원, 국립부경대학교 기계공학과

* † Jae-Seob Kwak(<https://orcid.org/0000-0003-2456-2000>) : Professor, Mechanical Engineering, Pukyong National University.
E-mail : jskwak5@pknu.ac.kr, Tel : 051-629-6139
* Jin-Young Lee(<https://orcid.org/0009-0001-5716-3084>) : Graduate student, Mechanical Engineering, Pukyong National University.
* Jung-Hee Lee(<https://orcid.org/0000-0001-8771-1996>) : Mechanical Engineering, Pukyong National University.

1. 서 론

선삭 가공은 다양한 기계 부품 제조에 널리 사용되는 대표적인 금속 절삭 공정으로, 높은 정밀도와 생산성을 확보하기 위해 공정 제어의 중요성이 지속적으로 강조되고 있다.¹⁾ 특히 최근 산업계에서는 crankshaft나 camshaft와 같이 비대칭 형상이나 비원형 단면을 가진 복잡 형상 부품의 수요가 증가하고 있으며, 이러한 부품을 가공하기 위해서는 기존 연속선삭과는 차별화된 가공 전략이 요구된다. 이와 같은 비정형 형상의 선삭 가공에서는 회전 중 공구와 공작물의 접촉이 주기적으로 단절되는 단속선삭 조건이 필연적으로 수반된다. 단속선삭은 비연속적인 절삭 구간의 반복으로 인해 공정 거동이 복잡해지며, 연속선삭과는 다른 절삭 메커니즘을 형성한다.²⁾

단속선삭에서는 공구가 특정 구간에서만 절삭을 수행하기 때문에 절삭 부하가 급격하게 변동하며, 이로 인한 반복적인 충격 하중과 진동이 발생된다. 이러한 특성은 비대칭·비원형 형상 공작물에서 더욱 두드러지게 나타나며, 비연속적인 절삭 환경은 열적 거동의 균일성을 저해하고, 칩 형성 양상과 공구 마모에 복합적인 영향을 미쳐 표면 품질을 저하시키는 주요 요인으로 작용한다. 따라서 절삭조건이 주기적으로 변화하는 단속선삭 가공에서는 절삭 속도, 이송 속도, 절삭 깊이와 같은 공정변수가 표면 특성에 미치는 영향을 면밀히 분석하는 것이 매우 중요하다. 특히 단속선삭에서는 각 공정변수의 변화만으로도 절삭력, 진동, 열적 거동이 크게 달라지기 때문에, 이들의 조합에 따른 변화를 체계적으로 이해하는 것이 가공 안정성과 표면 품질 확보의 핵심 요소로 작용한다.^{3,4)}

최근 제조 공정의 복잡도가 증가됨에 따라 산업계 전반에서는 인공지능(Artificial Intelligence, AI)을 활용한 품질 예측 및 공정 최적화 연구가 활발히 이루어지고 있다. 인공지능망, 적응형 신경 퍼지 추론 시스템, 의사결정나무 기반 알고리즘 등 다양한 AI 모델들이 적용되고 있으며, 기존의 경험적 모델이 설명하기 어려운 비선형적 문

제를 효과적으로 예측할 수 있음이 입증되고 있다.⁵⁾ 이러한 데이터 기반 예측 기법은 공정 변동성이 크게 나타나는 단속선삭 환경에서 공정변수와 품질 특성 간의 복잡한 비선형 관계를 효과적으로 모델링할 수 있는 유용한 접근 방식이다.^{6,7)}

이와 같은 연구 동향에도 불구하고, 특정 비정형 형상 공작물의 단속선삭 특성을 고려하여 공정변수와 표면거칠기 간의 관계를 정량적으로 평가하고, 고정밀 예측 모델을 구축한 연구는 여전히 부족한 실정이다. 이에 따라 본 연구에서는 심층신경망(Deep Neural Network, DNN)을 활용하여 TQM(Three Quarter Moon) 형상 공작물의 표면거칠기 예측모델을 개발하고자 한다. TQM 형상은 crankshaft의 웹(web) 단면을 단순화한 것으로, 원형 단면의 약 3/4에 해당하는 볼록한 달(gibbous) 형상을 가지며, 회전 중 공구와 공작물의 접촉이 주기적으로 단절되는 단속선삭 특성을 재현하기에 적합하다. 이를 바탕으로 절삭 속도, 이송 속도, 절삭 깊이가 표면거칠기에 미치는 영향을 다구찌 실험계획법을 통해 분석하고, 해당 데이터를 기반으로 DNN 예측모델을 구축하였다. 제안된 접근법은 형상 기인 단속 절삭 특성을 반영한 데이터 기반 예측모델을 제시함으로써, 향후 비정형 공작물의 선삭 가공 조건 최적화 및 품질 안정성 향상에 기여할 것으로 기대된다.

2. DNN 기반 예측모델

DNN은 Fig. 1과 같이 입력층과 출력층 사이에 다수의 은닉층을 포함하는 다층 구조의 인공지능망으로, 비선형성이 강한 공정 데이터의 예측 및 패턴 분석에 널리 활용되고 있다. 신경망의 각 l 번째 층은 이전 층의 출력 $a^{(l-1)}$ 을 가중치 $W^{(l)}$ 와 편향 $b^{(l)}$ 으로 선형 결합한 후, 활성화 함수 $f(\cdot)$ 를 통해 비선형 변환을 수행하는 구조를 갖는다. 이러한 계산이 여러 층에 걸쳐 반복됨으로써, 단층신경망에 비해 복잡한 데이터 구조를 보다 정교하게 표현할 수 있다. 이러한 심층신경망의 기본 연산은 식 (1)과 같이 이루어진다.




Fig. 1 Schematic architecture of DNN

$$z^{(l)} = W^{(l)}a^{(l-1)} + b^{(l)} \quad (1)$$

여기서, $W^{(l)}$ 과 $b^{(l)}$ 는 각각 l 번째 층의 가중치와 편향을 의미하며, $a^{(l-1)}$ 은 이전 층의 출력을 나타낸다.

여기에 활성화 함수 $f(\cdot)$ 를 적용하면 l 번째 층의 출력 $a^{(l)}$ 은 식 (2)와 같이 계산된다.

$$a^{(l)} = f(z^{(l)}) \quad (2)$$

본 연구에서는 식 (3)과 같이 연산 효율이 높고 기울기 소실 문제를 완화할 수 있는 ReLU 함수를 적용하였다.

$$f(x) = \max(0, x) \quad (3)$$

학습 과정에서 신경망은 예측값과 실제값의 차이를 최소화하는 방향으로 가중치를 갱신하게 된다. 이를 위해 본 연구에서는 손실함수로 평균 제곱 오차(Mean Squared Error, MSE)를 사용하며, 이는 식 (4)와 같이 표현된다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

여기서, n 은 데이터 샘플 수, y_i 는 i 번째 데이터의 실측값, $\hat{y}_i$ 는 i 번째 데이터의 예측값을 의미한다. 이러한 최적화 과정은 모든 층에 대해 반복 수행되며, 모델이 데이터의 비선형 패턴을 점차

학습하도록 한다.

따라서 본 연구에서는 형상 특성으로 인해 절삭 조건이 주기적으로 변하는 SCM440 단속선삭 공정에서 공정변수가 표면거칠기에 미치는 영향을 체계적으로 분석하고, 이를 기반으로 표면거칠기를 예측할 수 있는 심층신경망 기반 예측모델을 구축하고자 한다. 특히 TQM 형상 공작물과 같이 비정형 형상을 갖는 단속선삭 가공에서는 공정변수와 표면거칠기 간의 관계가 절삭 구간에 따라 달라질 수 있으므로, 이를 단순한 선형 모델로 일반화하는 데에는 한계가 있다. 이에 본 연구에서는 비선형 회귀 문제에 적합한 DNN 구조를 활용하여, 다양한 가공 조건에서도 안정적인 예측 성능을 확보하고자 하였다.

3. 단속선삭 가공 실험 및 분석

3.1 TQM 형상 공작물의 단속선삭 특성

단속선삭은 공구와 공작물이 지속적으로 접촉하는 연속선삭과 달리, 공작물의 형상 특성에 의해 공구와 공작물이 절삭과 비절삭을 주기적으로 반복하는 가공 방식이다. 특히 TQM 형상과 같은 비정형 공작물의 선삭가공에서는 회전 중 공구가 특정 구간에서만 절삭을 수행하게 되므로, 절삭력이 순간적으로 변화하는 특성이 나타난다. 이러한 특성으로 인해 절삭력 변동과 이에 따른 충격 및 진동이 발생할 수 있으며, 이는 표면거칠기와 공




Fig. 2 Schematic illustration of interrupted turning process

구 마모에 영향을 미친다. Fig. 2는 본 연구에서 수행한 TQM 형상 공작물의 단속선삭 가공 개념을 도식화한 그림으로 비정형 형상으로 인해 절삭 영역이 일정 주기마다 단절되는 가공 특성을 나타낸다. 이와 같은 형상에 따른 단속선삭 특성은 절삭력과 진동의 변동성을 증가시키며, 공정 안정성과 가공 품질 확보를 저해하는 주요 요인으로 작용한다.

3.2 공정변수 설정 및 실험 설계

3.2.1 시편 및 공구 선정

본 연구에서는 크롬과 몰리브덴을 주요 합금원소로 포함한 SCM440 강을 사용하였다. 이 소재는 열처리 후에도 높은 강도와 내마모성을 유지하여 기계구조용 부품, 특히 축이나 기어 등 고강도 부품의 제작에 폭넓게 활용된다. 본 연구의 목적이 비정형 형상 공작물의 단속선삭 특성을 분석하는데 있음을 고려하여, 단속선삭 가공 시 비원형·비대칭 형상의 절삭 특성을 모사하기 위해 내연기관 부품 중 대표적인 crankshaft 형상을 TQM 형상으로 단순화하여 시편을 설계하였다. 시편의 세부 형상과 치수는 Fig. 3과 같다.

단속선삭 가공 실험은 CNC선반(Hi-Tech 200A, Hwacheon)을 사용하여 수행하였다. TQM 형상 시편은 회전 중 절삭하중의 변동이 크게 발생할 수 있으므로, 공작물의 고정 상태의 안정성이 매우 중요하다. 회전 운동 중 불균형 및 진동의 발생을 최소화하기 위하여 공작물을 척에 장착할 때 주축 스피들의 동심도 및 평행도를 정밀하게 조정하고자 런아웃 오차를 0.02 mm 이내로 유지하며 고정하였다. 본 연구에서는 Taegutec사의 공구홀

더(SVJBR 2525 M16)와 초경인서트 팁(VBMT 160404 FG CT3000)을 사용하여 가공을 수행하였다. 또한 모든 실험은 습식 조건에서 진행되었으며, 절삭유(Tectyl cool 240, Korea Houghton)는 5% 농도로 희석하여 사용하였다.

3.2.2 공정변수 및 수준 설정

단속선삭 가공에서 공정변수의 적절한 선정은 표면 품질을 결정하는 핵심 요소로 작용한다. 특히 형상 특성으로 인해 절삭조건이 주기적으로 변화하는 단속선삭 가공에서는 공정변수 변화에 따른 표면거칠기 거동을 체계적으로 분석하는 것이 중요하다. 따라서 본 연구에서는 선삭가공 시 표면거칠기에 가장 큰 영향을 미치는 대표적인 공정변수로 절삭 속도, 이송 속도, 절삭 깊이를 주요 인자로 선정하였다.

단속선삭 가공은 연속선삭보다 진동과 충격의 영향이 크게 작용하므로 절삭 속도는 60, 100, 140 m/min으로 설정하였다. 이 범위에서는 저속 영역에서의 절삭 안정성을 평가함과 동시에, 고속 영역에서의 표면품질 변화를 동시에 관찰하기 위한 목적을 가진다. 선삭가공 시 공구의 이송량이 증가하면 절삭 흔적이 뚜렷해져 표면거칠기가 악화되는 경향을 보인다. 이에 따라 생산성과 표면 품질의 균형을 고려하여 0.1, 0.2, 0.3 mm/rev의 세 수준으로 설정하였다. 절삭 깊이는 지나치게 낮을 경우, 구성인선의 잔류로 인해 표면 품질이 저하될 수 있으며, 반대로 깊이가 과도하면 공구 마모 및 진동이 증가하여 파손 위험이 증가한다. 이러한 점을 고려하여 절삭 깊이는 0.2, 0.6, 1.0 mm의 세 수준으로 구분하였다. 이 세 가지 변수는 절삭력, 칩 형성 거동, 공구 마모, 가공 온도 등에 직접적인 영향을 미치며, 각 변수의 변화에 따라 표면거칠기와 가공 안정성의 상관성이 달라진다. 공정변수의 수준은 산업 현장에서 사용되는 실제 절삭조건과 공구 제조사의 권장 사양을 종합적으로 고려하여 설정하였으며, 설정된 공정변수 및 수준은 Table 1에 제시하였다. 확보된 표면거칠기 데이터는 공정변수 분석과 DNN 기반 예측모델 구축에 활용되었다.




Fig. 3 Schematic drawing of workpiece

Table 1 Process parameters and conditions

Process parameter	Value	Unit
Cutting speed, A	60, 100, 140	m/min
Feed rate, B	0.1, 0.2, 0.3	mm/rev
Depth of cut, C	0.2, 0.6, 1.0	mm

3.2.3 실험 설계 및 표면거칠기 측정 방법

본 연구에서는 공정변수의 수준 변화가 표면거칠기에 미치는 영향을 평가하기 위하여 실험의 횟수를 최소화하면서 공정변수의 영향을 효과적으로 분석할 수 있는 다구짜 $L_9(3^3)$ 직교배열표를 적용하였다.⁸⁾ 이에 따라 9가지 조건에 대해 각 조건별로 3회 반복하여 총 27회 실험을 수행하였다.

가공 후 표면거칠기는 접촉식 표면거칠기 측정기(SJ-310, Mitutoyo)를 사용하여 평가하였으며, 대표값으로 산술 표면거칠기 R_a 를 사용하였다. Cut-off 길이와 sampling 길이는 각각 0.8 mm와 4.0 mm로 설정하였다. 가공 중 발생하는 기계적 진동은 측정값에 영향을 미칠 수 있으므로, 이를 고려하여 측정 신뢰성을 확보하고자 하였다. 따라서 Fig. 4와 같이 가공 방향에 수직인 y방향으로 5개 지점을 선정하여 표면거칠기를 측정하였다. 측정값 중 최댓값과 최솟값을 제외하고, 나머지 3개의 값을 산술평균하여 최종 R_a 값으로 사용하였다.




Fig. 4 Measurement method of surface roughness

3.3 실험 결과 및 분석

비정형 형상 SCM440 강의 단속선삭 가공에서 공정 조건에 따른 표면 품질 개선 정도를 정량적으로 비교 및 평가하기 위하여 식 (5)와 같이 표면거칠기 계수 SR 를 활용하였다.

$$SR = \frac{R_{a,i} - R_{a,f}}{R_{a,i}} \quad (5)$$

여기서 $R_{a,i}$ 과 $R_{a,f}$ 는 각각 단속선삭 공정 전과 후의 표면거칠기 값을 의미한다.

본 연구에서는 조건 간 비교의 일관성을 확보하기 위해 모든 시험편의 초기 표면거칠기를 4.49 μm 로 동일하게 설정하였다.

SR 은 표면 품질의 개선 정도를 수치화한 지표로서, 값이 클수록 표면거칠기 향상 정도가 크다는 것을 의미한다. 이러한 정의를 통해 초기 표면상태의 영향을 배제하고, 공정 조건에 따른 상대적인 표면 품질 개선 효과를 평가할 수 있다. 본 연구에서는 이 계수를 기반으로 식 (6)에 나타낸 바와 같이 망대특성의 S/N 비를 적용하여 실험 결과를 분석하였다.

$$S/N \text{ ratio} = -10 \log \left[\frac{1}{n} \sum_{i=1}^n \frac{1}{SR_i^2} \right] \quad (6)$$

여기서, n 은 각 공정 조건별 실험의 반복 횟수를 의미한다.

Table 2는 각 조건에서 측정된 표면거칠기 값과 SR 값, S/N 비를 나타낸 것이다. 분석 결과, SCM440 단속선삭 가공에서 가장 우수한 표면 품질은 절삭 속도 140 m/min, 이송 속도 0.1 mm/rev, 절삭 깊이 1.0 mm의 7번 실험 조건($A_3B_1C_3$)으로 확인되었다. 해당 조건에서의 평균 표면거칠기 값은 0.99 μm 로 나타났으며, 이는 초기 표면거칠기 대비 약 78%의 표면 정도 향상 효과를 나타낸다. 반면, 절삭 속도 60 m/min, 이송 속도 0.3 mm/rev, 절삭 깊이 1.0 mm인 3번 실험 조건에서는 표면거칠기 값이 5.32 μm 로 측정되어, 상대적으로 표면 정도가 가장 악화된 조건으로 나타났다.

Table 2 Experimental conditions and results

Exp. No.	Level combination	$R_{a,i}$ (μm)	Avg. $R_{a,f}$ (μm)	SR	S/N ratio
1	A ₁ B ₁ C ₁	4.49	1.04	0.77	-2.29
2	A ₁ B ₂ C ₂		3.39	0.24	-12.22
3	A ₁ B ₃ C ₃		5.32	-0.18	-14.66
4	A ₂ B ₁ C ₂		1.29	0.71	-2.94
5	A ₂ B ₂ C ₃		1.84	0.59	-4.58
6	A ₂ B ₃ C ₁		3.81	0.15	-16.40
7	A ₃ B ₁ C ₃		0.99	0.78	-2.16
8	A ₃ B ₂ C ₁		2.06	0.54	-5.33
9	A ₃ B ₃ C ₂		3.62	0.19	-14.26

S/N 비 분석 결과, 이송 속도가 0.3 mm/rev인 3, 6, 9번 조건에서 가장 낮은 값을 보여, 이송 속도가 표면거칠기에 가장 지배적인 영향을 미치는 인자임을 확인하였다. 이송 속도가 증가할수록 바이트의 이송 흔적이 공작물 표면에 더욱 뚜렷하게 남아 R_a 값이 상승하는 경향을 보였다. 또한 S/N 비의 변화 폭이 가장 크게 나타난 요인 역시 이송 속도로, 표면 품질 변화에 대한 민감도가 가장 높은 인자로 확인되었다. 이에 비해 절삭 속도와 절삭 깊이는 상대적으로 S/N 비의 변화가 작아, 표면거칠기에 미치는 영향이 제한적인 것으로 나타났다.

각 인자별 S/N 비가 최대가 되는 수준을 조합하여 최적 공정조건을 도출한 결과, SCM440 비정형 단속선삭에서 표면 품질을 최적으로 확보할 수 있는 조건은 절삭 속도 140 m/min, 이송 속도 0.1 mm/rev, 절삭 깊이 1.0 mm인 A₃B₁C₃로 나타났다. 이 조건은 표면거칠기 개선과 절삭 공정의 안정성을 동시에 만족시키는 단속선삭 가공 조건으로 판단된다.

4. 예측모델 개발 및 성능평가

본 연구에서는 $L_9(3^3)$ 다구치 직교배열표에 따라 수행된 총 27개의 실험에서 각 조건 별 5회

Table 3 Specifications of the DNN model

Parameter		Condition
Number of input		3 (A, B, C)
Target		R_a
Hidden layers	Layer	2
	Node	9, 3
Data split	Train : Test	9 : 1
Optimizer		Adam
Learning rate		0.01
Activation function		ReLU
Weight initialization		He normal initialization
Number of epochs		50 per attempt

반복 측정으로 확보한 135개의 표면거칠기 데이터를 활용하여 DNN 기반 예측모델을 구축하였다. 입력 변수는 절삭 속도, 이송 속도, 절삭 깊이의 3개로 구성되어 있으며, 입력 변수 수와 데이터 구조를 고려할 때 135개의 데이터는 모델 학습에 활용 가능한 규모로 판단된다. 또한 본 데이터 셋은 다구치 실험계획법에 따라 체계적으로 확보되었으며, 입력 변수의 수가 제한된 소규모 데이터셋에서도 DNN 모델의 높은 예측 성능을 달성할 수 있음이 선행연구에서 보고된 바 있다.^{9,10)} 확보된 전체 데이터는 모델의 일반화 성능을 확보하기 위해 학습용과 시험용 데이터로 9:1의 비율로 분할하였다.

3개의 공정변수를 입력층에 배치하고 2개의 은닉층을 통과한 후 출력층에서 표면거칠기를 예측하도록 모델 구조를 설계하였다. 모델 학습에는 Adam 최적화 기법을 적용하였고, 학습률은 0.01로 설정하였다. 또한 He normal 초기화를 통해 초기 가중치 분포를 안정화하였으며, ReLU 활성화 함수를 적용하여 심층 구조에서의 학습 효율을 확보하였다. 총 50 epochs 동안 학습을 수행하였으며, DNN 모델의 세부 설정은 Table 3에 제시하였다.

모델의 예측정확도는 Fig. 5에 도시한 바와 같이 표면거칠기의 실측값과 DNN 예측값을 비교하여 평가하였다. 대부분의 데이터가 이상선 부근에

밀집하며, 오차의 평균은 $-0.022 \mu\text{m}$, 평균 절대 오차(MAE)는 $0.110 \mu\text{m}$ 로 나타났다. 결정계수(R^2)는 약 0.984로 확인되었고, 평균 제곱근 오차(RMSE)는 0.145로 산출되었다. 예측값이 실측값과 높은 일치도를 나타냈으며, 단속선삭과 같이 절삭조건이 주기적으로 변화하는 가공 환경에서도 안정적인 예측 성능을 확인하였다. 예측모델의 신뢰성을 검증하기 위해 Table 4와 같이 학습에 사용되지 않은 별도의 검증 실험을 추가로 수행하였다. 검증 조건은 다구치 실험에서 설정한 공정변수 수준 범위 내에서 무작위로 선정하였으며, 총 5개의 검증 조건에 대해 실험을 수행하였다. 이를 동일 조건의 반복 측정값이 학습 및 시험 데이터에 혼재되어 발생할 수 있는 누수 가능성을 최소화하였다. 해당 검증 실험을 통해 DNN 모델이 학습 범위 내에서 보간 성능을 갖는지 확인하고, 예측된 표면거칠기와 실제 측정값 간의 일치 정도를 정량적으로 평가하였다. 그 결과, 모든 조건에서 예측값과 실측값 간의 평균 오차율은 2.43%, RMSE는 0.056으로 나타나 실측값과 예측값의 차이가 매우 작은 수준임을 확인하였다. 이를 통해 본 연구에서 구축한 DNN 모델이 공정변수 변화에 따른 표면거칠기를 안정적으로 예측할 수 있음을 검증하였다. 특히 제안된 모델은 공정변수 조합에 따른 표면거칠기 변화를 사전에 예측함으로써, 목표 표면거칠기를 만족하는 절삭 속도, 이

Table 4 Comparison of measured and predicted R_a

Exp. No.	Level			Pred. R_a	Act. R_a
	A	B	C		
1	100	0.1	0.6	1.13	1.15
2	120	0.2	0.5	1.47	1.58
3	60	0.3	0.7	5.15	5.11
4	100	0.25	0.5	2.45	2.46
5	140	0.2	0.3	1.83	1.79

송 속도 및 절삭 깊이 조합을 사전에 탐색하는 데 활용될 수 있으며, 향후 단속선삭 공정의 조건 최적화 및 지능형 공정 제어 시스템 구축을 위한 기초 도구로 활용될 수 있을 것으로 기대된다.

5. 결론


본 연구에서는 비정형 형상 SCM440의 단속선삭 공정에서 주요 절삭변수들이 표면거칠기에 미치는 영향을 분석하고, 이를 바탕으로 DNN 기반 표면거칠기 예측모델을 개발하였다. 실험 결과, 이송 속도가 표면거칠기에 가장 큰 영향을 미치는 인자로 확인되었으며, S/N 비 분석을 통해 절삭 속도 140 m/min, 이송 속도 0.1 mm/rev, 절삭 깊이가 1.0 mm 조건이 최적임을 확인하였다. 또한 개발된 DNN 모델은 R^2 은 0.984와 RMSE는 0.145를 기록하여 단속선삭과 같이 절삭조건이 큰 가공 환경에서도 높은 예측정확도를 보였다. 이를 통해 DNN 기반 예측모델이 단속선삭 가공의 품질 예측 및 공정 조건 최적화에 효과적으로 활용될 수 있음을 확인하였다.

후 기

이 논문은 국립부경대학교 자율창의학술연구비(2025년)에 의하여 연구되었음.

Author contributions

J. Y. Lee; Conceptualization, Simulation, Investigation,

Fig. 5 Actual vs. predicted R_a in DNN model

Writing-original draft. J. H. Lee; Data analysis, Investigation, Writing-review & editing. J. S. Kwak; Supervision, Writing-review & editing.

References

1. M. Imran, S. Suo, Y. Bai, Y. Wang and R. Naveed, 2024, "Optimising subsurface integrity and surface quality in mild steel turning: A multi-objective approach to tool wear and machining parameters", *Journal of Materials Research and Technology*, 35(20), 3440-3462. (<https://doi.org/10.1016/j.jmrt.2025.01.246>)
2. L. Huang, T. Wei, H. Chen, J. Yuan, Y. Liu, D. Lv, X. Qin, Y. Yang and Z. Zhong, 2025, "Exploring the effects of cutting edge radius on intermittent turning based on experiment and simulation", *Wear*, 580-581, 206235. (<https://doi.org/10.1016/j.wear.2025.206235>)
3. M. I. Bae and Y. S. Rhie, 2014, "Surface Roughness Prediction of Interrupted Cutting in SM45C Using Coated Tool", *Journal of the Korean Society of Manufacturing Process Engineers*, 13(3), 77-82. (<https://doi.org/10.14775/ksmpe.2014.13.3.077>)
4. F. Gong, X. Ni, G. Liu, C. Liu and J. Sun, 2024, "Cutting performance and failure mechanisms of TiB₂-TiC-Al₂O₃ multi-dimensional gradient ceramic tool in intermittent turning of hardened steel", *International Journal of Refractory Metals and Hard Materials*, 118(10), 106438. (<https://doi.org/10.1016/j.ijrmhm.2023.106438>)
5. T. Namboodri and C. Felhő, 2025, "AI for quality optimization in turning: A short review", *MM Science Journal*, 2025(2), 8338-8352. (https://doi.org/10.17973/MMSJ.2025_06_2025033)
6. K. Ullrich, M. von Elling, K. Gutzeit, M. Dix, M. Weigold, J. C. Aurich, R. Wertheim, I. S. Jawahir and H. Ghadbeigi, 2024, "AI-Based Optimisation of Total Machining Performance: A Review", *CIRP Journal of Manufacturing Science and Technology*, 50, 40-54. (<https://doi.org/10.1016/j.cirpj.2024.01.012>)
7. S. Balonji, L. K. Tartibu and I. P. Okokpujie, 2023, "Prediction Analysis of Surface Roughness of Aluminum Al6061 in End Milling CNC Machine Using Soft Computing Techniques", *Applied Sciences*, 13(7), 4147. (<https://doi.org/10.3390/app13074147>)
8. S. H. Im, D. H. Kim, H. J. Kim, K. S. Kim and S. C. Huh, 2021, "A Study on the Wear Characteristics of Al Alloy by Design of Experiments", *Journal of Power System Engineering*, 25(3), 46-55. (<https://doi.org/10.9726/kspse.2021.25.3.046>)
9. T. Palaniappan and P. Subramaniam, 2024, "Investigation in optimization of process parameters in turning of mild steel using response surface methodology and modified deep neural network", *Materials Today: Communications*, 38, 108425. (<https://doi.org/10.1016/j.mtcomm.2024.108425>)
10. J. H. Lee and J. S. Kwak, 2025, "A Study on Optimization of Autoencoder-based Latent Variables for Improving Surface Roughness Prediction", *Journal of Power System Engineering*, 29(1), 23-29. (<https://doi.org/10.9726/kspse.2025.29.1.023>)