

AL6061-T4의 측면 엔드밀 가공에서 표면거칠기 예측을 위한 인공신경망 적용에 관한 연구

천세호*,#

*계명문화대학교 기계과

A Study on the Application of ANN for Surface Roughness Prediction in Side Milling AL6061-T4 by Endmill

Se-Ho Chun*,#

*Department of Mechanical Engineering, Keimyung College University

(Received 02 March 2021; received in revised form 18 March 2021; accepted 29 March 2021)

ABSTRACT

We applied an artificial neural network (ANN) and evaluated surface roughness prediction in lateral milling using an endmill. The selected workpiece was AL6061-T4 to obtain data of surface roughness measurement based on the spindle speed, feed, and depth of cut. The Bayesian optimization algorithm was applied to the number of nodes and the learning rate of each hidden layer to optimize the neural network. Experimental results show that the neural network applied to optimize using the Expected Improvement(EI) algorithm showed the best performance. Additionally, the predicted values do not exactly match during the neural network evaluation; however, the predicted tendency does march. Moreover, it is found that the neural network can be used to predict the surface roughness in the milling of aluminum alloy.

Key Words : ANN(인공신경망), Surface Roughness(표면거칠기), Bayesian Optimization(베이지안 최적화)

1. 서 론

절삭가공에서 최적 가공조건을 선정하기 위해서는 일반적으로 공작물, 공작기계 그리고 절삭공구 등에 관한 숙련된 작업자의 경험과 지식이 필요하다. 이는 아직 가공 품질과 절삭변수와의 명확한 수학적 모형이 도출되지 않아 최적 가공조건을 이

론적으로 판단하기는 어렵기 때문이다^[1,2].

가공 품질을 판단하는 여러 기준 중에서 표면거칠기(surface roughness)는 부품 간의 조립성, 수명, 성능 등에 영향을 미치는 주요 지표이다. 표면거칠기는 절삭조건뿐만 아니라 공구의 형상, 공작기계의 강성, 절삭유의 사용 여부 등에 따라서 민감하게 변화하기 때문에 최적 가공조건을 도출하는데 고려해야 할 변수가 많다^[2]. 이에 양호한 표면품위를 획득하기 위해서는 이들 입력변수에 따른 정밀한 표면거칠기 예측 모델 구축이 필수적이다.

Corresponding Author : chunsh@kmcu.ac.kr

Tel: +82-53-589-7621, Fax: +82-53-589-7372

표면거칠기 예측 모델을 도출하기 위해 다양한 방법이 시도되었으며 회귀분석^[3,4], 실험계획법^[5,6], 그리고 인공신경망^[1,2,7,8]에 의한 연구가 대표적이다. 인공신경망(artificial neural network, ANN)은 최근 하드웨어의 발달과 더불어 데이터를 처리하는 다양한 알고리즘의 개발로 인해 여러 학분 분야에서 적용이 이루어지고 있다. 특히 표면거칠기 부분에 있어서 인공신경망을 활용한 우수한 예측 성능 결과가 보고되고 있다^[1,2,7,8].

한편 공작물의 종류에 따라 가공조건에 따른 표면거칠기 변화 경향이 달라질 수 있다. 최근 산업 현장에서는 기계 부품의 경량화를 위해 알루미늄 합금의 적용이 증대되고 있다. 알루미늄 합금은 절삭가공 시 강(steel) 또는 주철(cast iron)에 비해 민감한 열변형과 빈번한 구성인선(built-up edge)의 영향을 받아 품질관리가 어려워 난삭재로 분류되고 있다. 이러한 난삭재의 경우 여러 가지 요인들이 반응 결과에 영향을 미치기 때문에 수학적인 표면거칠기 예측 모델 구축이 어려울 것으로 예상된다.

이에 본 연구에서는 기계 부품 소재로 활용되는 AL6061-T4의 밀링가공 표면거칠기 예측을 위해 인공신경망을 적용하고자 하였다. 이를 위해 엔드밀을 이용하여 측면 밀링가공 데이터를 확보한 후 인공신경망을 구성하였다. 특히 인공신경망의 성능을 좌우하는 초매개변수(hyper-parameter)를 최적화하기 위해 베이지안 최적화(bayesian optimization)^[9]를 적용하고 그 성능을 평가하였다.

2. 절삭가공 데이터

인공신경망의 훈련을 위해 각기 다른 조건에서 90개의 데이터를 확보하였다. 이 중 70개는 신경망의 훈련(train)으로 사용되고 나머지 20개는 학습 상태를 검증(validation)하기 위한 용도로 활용하였다. 실험에 사용된 공구는 코팅되지 않은 직경 12mm 초경 엔드밀(AES3120 UF10, TaeguTec)이며 날 길이는 30mm, 칩 배출과 생산성을 고려하여 3날을 선정하였다. 입력변수는 Fig. 1에서와같이 주축 회전수(rpm), 이송($mm/teeth$), 그리고 축 방향 절입깊이(axial depth, mm)를 선정하였고 반경 방향 절입깊이(radial depth)는 일정(2mm)하게 유지하였다.

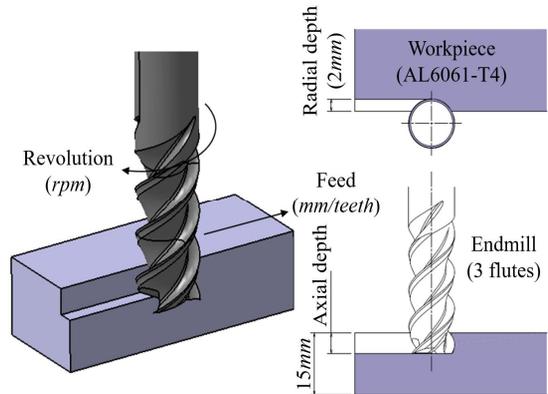


Fig. 1 Schematic diagram of experimental set-up

Table 1 Cutting conditions for experiment

Factors	min.	max.
Spindle speed(rpm)	800	8,000
Feed($mm/teeth$)	0.02	0.40
Axial depth(mm)	0.3	4.0

Table 2 Conditions for measurement

Filter	Gauss
Curvature	R
Cut-off(λ_c , mm)	0.8
Number of sampling length	5
Measure speed(mm/s)	0.5
Measurement parameter(μm)	Ra

예비실험을 통해 가공 가능한 영역을 탐색하였고 데이터 수집을 위한 각 변수에 따른 절삭조건 범위를 Table 1에 나타내었다. 그리고 선정된 범위 내에서 표본편향(sample bias)을 최소화하기 위해 임의추출(random sampling) 방식으로 90개의 데이터를 수집하였다. 그리고 알루미늄 합금의 경우 구성인선이 가공에 많은 영향을 미치므로 이를 최소화하기 위해 절삭유를 사용한 습식가공으로 진행하였다.

각 조건별 절삭이 완료된 공작물의 측면을 세척하였으며 절입깊이 방향으로 측침식 표면조도측정

기(Surfscast SJ-310, Mitutoyo Corp.)를 활용하여 거칠기 값을 측정하였다. 측정 방법은 중심선 평균 거칠기 (arithmetical average roughness, Ra)값을 채택하였고 측정조건은 Table 2와 같다.

3. 인공신경망 적용

3.1 신경망 구성

Table 3에서는 실험데이터를 바탕으로 표면거칠기 예측을 위한 인공신경망 구성에 대해 나타내었다. 일반적으로 신경망은 입력층(input layer), 은닉층(hidden layer), 그리고 출력층(output layer)으로 설계된다. 입력층에는 주축 회전수, 이송, 그리고 절입깊이가 변수로 입력되고 출력층에는 표면거칠기 예측값이 출력되도록 하였다. 표면거칠기 예측에 관련된 최근 연구^{1,7,8)}에서 2개의 은닉층으로 높은 예측 정밀도를 확보하였으며, 실시간 학습이 아닌 데이터에 대해서는 2개의 은닉층이 단층 은닉층 구조보다 성능이 높다고 하였다⁷⁾. 이에 기존 연구를 바탕으로 2층 구조를 적용하고자 하였다.

신경망에 입력되는 데이터는 비선형 함수의 일종인 활성화 함수(activation function)를 경유하여 다음 층으로 이동한다. 활성화 함수는 최근 성능이 입증된 Rectified Linear Unit(ReLU)^[10] 함수를 적용하였다. 그리고 각 가중치 매개변수에 대한 초기값 설정 방법은 ReLU 함수에 특화된 He initialization^[11] 알고리즘을 적용하였다. 신경망 학습에서 오버피팅(overfitting) 및 국소 최적값(local optimum value)을 찾는 오류를 최소화하기 위해 각 신경망 층에서 활성화 함수 출력값이 고르게 분포시켜야 한다는 기존 연구^[12] 결과에 따라 각 층에서의 입력 데이터와 출력 데이터는 정규화(normalization) 처리를 하였다.

Table 3 Design of ANN layers

Layers	Input	ReLU	→	Batch Normalization
		He initialization		
	Hidden (2 layers)	ReLU	→	Batch Normalization
		He initialization		
	Output	Linear	→	Prediction
		He initialization		

3.2 신경망 학습

데이터가 신경망을 통과한 후 검증 데이터와 비교하여 오차를 계산한 후 보상되는 과정을 거쳐야 한다. 그리고 오차를 반영하여 각 신경망의 가중치와 같은 매개변수(parameter)를 갱신해야 하는데 손실함수(loss function)에 의한 평가가 이루어진다. 본 신경망에서는 평균제곱오차(Mean Squared Error, MSE)를 손실함수로 적용하였다. 식(1)과 같이 신경망에서 출력된 데이터(t_i)는 손실함수(f_{MSE})를 통해 검증 데이터(k_i)와 손실함수로 평가되고 신경망의 매개변수를 갱신할 수 있도록 구성하였다.

$$f_{MSE} = \frac{1}{n} \sum_{i=1}^n (t_i - k_i)^2 \quad (1)$$

손실함수를 최소화할 수 있는 매개변수로 갱신이 가중치 조정 주기(epoch)마다 지속해서 이루어져야 하며 이를 통해 신경망이 최적화된다. 이때 적절한 매개변수를 찾는 방법이 필요하며 최근 연구에서 Adam^[13] 알고리즘이 다양한 상황에서 적절하다고 제시하였다. 이에 Adam을 통해 주기마다 가중치 갱신이 이루어지도록 하였다.

3.3 초매개변수 최적화

신경망 학습 과정에서 가중치 갱신의 경우 데이터에 의해 결정되지만, 은닉층의 개수, 각 은닉층의 노드 수, 학습률 등은 신경망 설계자가 직접 설정하는 변수이다. 특히 이러한 변수들을 일반적으로 초매개변수라고 하며 인공신경망의 성능에 많은 영향을 미친다. 최적화하기 위한 목적함수가 수학적으로 도출되지 않은 미지의 함수이기 때문에 이를 최적화하는 방법으로 Manual search와 Grid search 방법이 있으나 고려해야 할 변수에 따라 탐색 시간이 많아진다. 이를 개선하기 위해 확률적 무작위 추출을 적용한 Random search 방법의 경우 최적값 탐색 시간을 줄일 수 있으나 이전 탐색값에 대한 정보를 반영하지 않기 때문에 비효율적이다. 이에 이전 탐색값의 정보를 반영하면서 확률적 추정이 가능한 베이저안 최적화(bayesian optimization)^[9] 알고리즘이 제시되었다.

Table 4 Cutting conditions for experiment

Factors		min.	max.
No. of nodes	unit 1	5	50
	unit 2	5	50
learning rate		0.001	0.01
No. of iteration		30	

Table 5 Experiment results for acquisition functions

Function	unit 1	unit 2	learning rate	accuracy
EI	12	44	0.001	0.967
UCB	12	29	0.003	0.965
POI	21	26	0.009	0.972

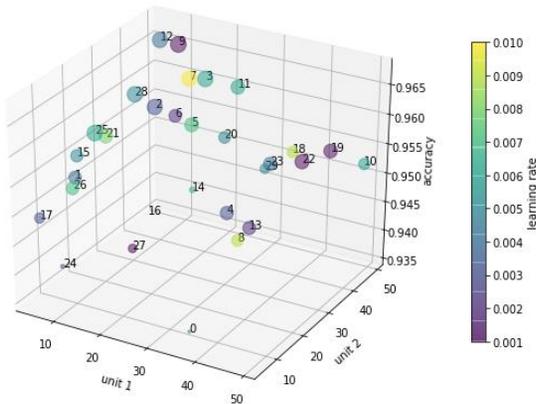


Fig. 2 Results according to the number of iteration

베이지안 최적화는 관측 데이터를 기반으로 미지의 목적함수에 대한 확률적 추정을 하는 Surrogate model과 최적값을 탐색하는 Acquisition function으로 구성된다^[9,14]. 본 연구에서는 각 은닉층의 노드 수와 학습률을 탐색할 대상으로 선정하였으며 탐색 범위는 Table 4와 같다. 효과적인 최적값 탐색을 위해서는 기존 자료를 기반으로 확실성이 높은 다음 최적값을 탐색(exploitation)하는 방법과 불확실성이 높은 미지영역을 탐색(exploration)하는 방법이 적절하게 반영되어야 하며 Expected Improvement(EI), Upper Confidence Bound(UCB), 그리고 Probability of

improvement(POI) 알고리즘이 적용되고 있다^[14]. 이에 Acquisition function에 따른 최적값 탐색 성능평가를 하였으며 그 결과는 Table 5에 나타내었고 검증 데이터와의 평가 시 가장 예측 정밀도가 높은 함수는 Expected Improvement이다. Fig. 2에서는 Expected Improvement 함수를 적용했을 때 갱신회수(no. of iteration)에 따른 최적값 분포 경향을 나타내었다. 여기서 각 데이터 점의 크기는 정밀도에 따라 달리하였으며 점의 크기가 클수록 높은 정밀도를 나타낸다. 그림에서 첫 번째 은닉층의 노드 수는 5에서 25 사이에 집중되고 있으며 두 번째 은닉층의 노드 수는 비교적 30에서 50 사이에 최적값이 분포하는 것으로 보아 첫 번째 층보다 두 번째 층의 노드 수가 많아야 할 것으로 판단된다. 이는 Table 5에서와같이 다른 Acquisition function을 적용했을 때의 결과와도 유사한 경향을 보인다.

3.4 예측성능 평가

은닉층의 노드 수와 학습률에 대한 최적값을 신경망에 적용하여 학습을 진행하였다. 전체 가중치 조정 주기(200 epoch) 내에서 오버피팅은 관찰되지 않았으며 훈련된 신경망과 검증 데이터와의 평가에서 최종 손실값은 0.032이다. 훈련이 완료된 신경망의 예측성능을 평가하기 위해 실험을 추가하여 진행하였고 14개의 데이터를 확보하였다. 추가된 데이터는 신경망 훈련에 사용하였던 절삭조건을 피해 선정하였다. Fig. 4에서는 추가된 테스트 데이터를 이용하여 신경망을 평가한 결과를 나타내었다.

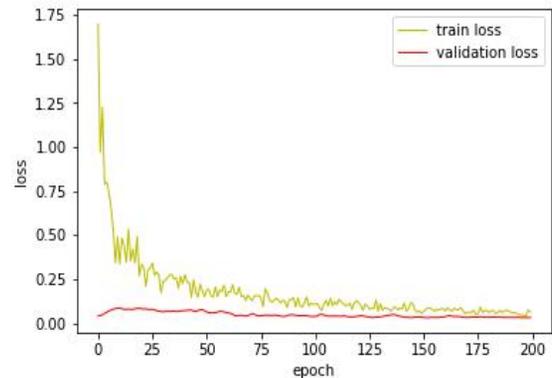
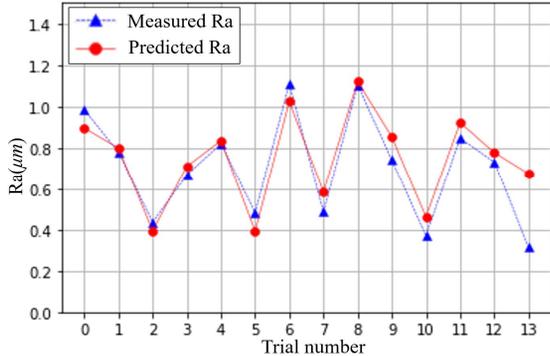
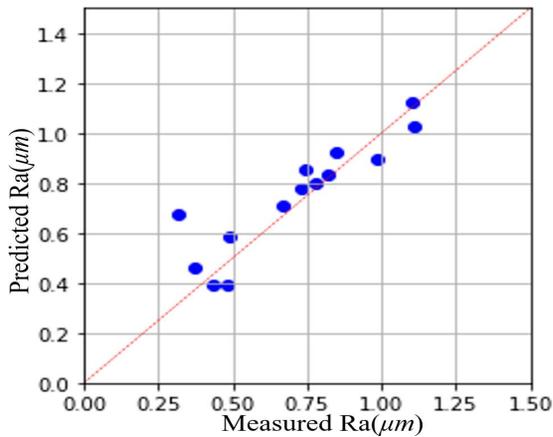


Fig. 3 Loss of optimized ANN

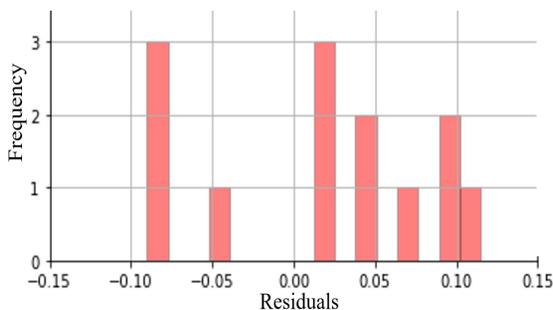
테스트 데이터에 대해 예측 방향성이 대체로 일치하고 있음을 알 수 있고 예측 오차 분포는 13번 데이터를 제외하고 $\pm 0.1 \mu\text{m}$ 이내에 형성되고 있다.



(a) Analysis of curve fitting



(b) Predicted values vs measured values



(c) Histogram of ANN residuals

Fig. 4 Evaluation of ANN with test data set

Table 6 Results of acquisition function test

Function	MSE	MAE	R ²
EI	0.014	0.084	0.778
UCB	0.024	0.139	0.611
POI	0.016	0.092	0.753

한편 훈련에서 사용된 데이터와 평가에서 사용된 데이터는 다르므로 Acquisition function에 따른 최적화 결과를 이용하여 평가하였고 그 결과는 Table 6과 같다. 식(1)의 손실함수에서 사용된 평균제곱오차(MSE), 그리고 평균절대오차(Mean Absolute Error, MAE)와 결정계수(Coefficient of Determination, R²)를 반영하여 평가해본 결과 Expected Improvement에 의한 최적화 모델이 우수하였음을 알 수 있다.

4. 결론

본 연구에서는 엔드밀을 이용한 측면 밀링가공에서 표면거칠기 예측을 위한 인공신경망을 적용하고 평가하였다. 이를 위해 공작물을 AL6061-T4으로 선정하여 주축 회전수, 이송, 그리고 절입깊이 변화에 따른 표면거칠기 측정 데이터를 확보하였다. 각 은닉층의 노드 수와 학습률에 대해 베이지안 최적화 알고리즘을 적용하여 신경망을 최적화하고 성능을 평가하였다. 그 결과 Acquisition function에 Expected Improvement 알고리즘을 이용한 최적화 결과를 적용한 신경망이 가장 우수한 성능을 나타내었다. 그리고 신경망 평가에서 예측값이 정확히 일치하지는 않지만, 대체로 유사한 예측 경향을 보였다. 향후 인공신경망을 활용한 밀링가공의 표면거칠기 예측에 있어서 다양한 종류의 공작물, 공작기계, 공구, 가공조건 등을 적용한 연구가 이루어져야 하며 본 연구의 결과가 후속 연구의 기초 자료로 활용되리라 판단된다.

REFERENCES

1. Won, J. Y., Nam, S. H., Yoo, S. M., Lee, S. W., and Choi, H. Z., "Prediction of Surface

- Roughness using double ANN and the Efficient Machining Database Building Scheme in High Speed Machining,” Proceedings of The Korean Society of Manufacturing Technology Engineers, pp. 411-415, 2004.
2. Won, J. Y., Nam, S. H., Lee, S. W., Choi, H. Z., and Yoo, S. M., “Training Data Selection for Artificial Neural Networks using the Design of Experiments and Prediction of Surface Roughness in High Speed Machining,” Proceedings of the K SMPE Conference, pp. 88-91, 2004.
 3. Lee, S. W., and Lee, D. J., “A Prediction of Surface Roughness on the PCD Tool Turned Al5083 by using Regression Analysis,” Journal of the Korean Society of Manufacturing Process Engineers, Vol. 11, No. 6, pp. 69-74, 2012.
 4. Chun, S. H., “Prediction of Surface Roughness in Hole Machining Using an Endmill,” Journal of the Korean Society of Manufacturing Process Engineers, Vol. 18, No. 10, pp. 42-47, 2019.
 5. Hwang, Y. K., Chung, W. J., and Lee, C. M., “Experimental Study of Cutting Force and Surface Roughness Prediction in MQL Turning of Al6061,” Journal of the Korean Society for Precision Engineering, Vol. 25, No. 6, pp. 159-167, 2008.
 6. Chin, D. H., Kim, J. D., and Yoon, M. C., “Surface roughness model of end-milling surface,” Journal of the Korean Society of Manufacturing Process Engineers, Vol. 12, No. 2, pp. 67-73, 2013.
 7. Lee, J. H., and Lee, E. S., “A Study on the Prediction of Surface Roughness of Ferrule in Centerless Grinding using Artificial Neural Networks,” Proceedings of The Korean Society of Manufacturing Technology Engineers, pp. 505-510, 2006.
 8. Seo, Y. S., Lee, J. H., Lee, S. H., and Kwak, J. S., “Application of Deep Neural Network Model to Predict Surface Roughness,” Proceedings of the KSMPE Conference, p. 106, 2019.
 9. Snoek, J., Larochelle, H., and Adams, R. P., “Practical Bayesian Optimization of Machine Learning Algorithms,” Proceedings of Neural Information and Processing Systems, 2012.
 10. Han, J. S., and Kwak, K. C., “Image Classification Using Convolutional Neural Network and Extreme Learning Machine Classifier Based on ReLU Function,” The Journal of Korean Institute of Information Technology, Vol. 15, No. 2, pp. 15-23, 2017.
 11. He, K., Zhang, X., Ren, S., and Sun, J., “Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification,” 2015 IEEE International Conference on Computer Vision (ICCV), pp. 1026-1034, 2015.
 12. Ioffe, S., and Szegedy, C., “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” International Conference on Machine Learning, pp. 448-456, 2015.
 13. Kingma, D. P., and Ba, J. L., “Adam: A method for stochastic optimization”, International Conference on Learning Representations, 2015.
 14. Li, Y., and Yao, Y., “Bayesian Optimization with Directionally Constrained Search”, arXiv preprint arXiv:1906.09459, 2019.