

고속가공에서 2중 신경망을 이용한 표면거칠기 예측과 가공DB 구축 효율화 방안

원종률*, 남성호+, 유송민++, 이석우+, 최헌중+

Prediction of Surface Roughness using double ANN and the Efficient Machining Database Building Scheme in High Speed Machining

Jong-Youl Won*, Sung-Ho Nam+, Song-Min Yoo++, Seok-Woo Lee+, Hon-Zong Choi+

Abstract

In this paper, a double artificial neural network (ANN) approach and the efficient machining database building scheme are presented for the prediction of surface roughness in high-speed machining. In this approach, 4 machining parameters are used for the prediction of cutting force components, and the combinations of 4 parameters and the predicted cutting force components are finally used for the prediction of surface roughness. The experimental results comparing the these results with the predicted values using simple 4 input nodes have been also investigated to verify the effectiveness of the proposed approach.

Key Words : Artificial neural network (신경망), High Speed Machining (고속가공), Machining Condition (가공조건), Surface Roughness (표면거칠기)

1. 서론

고속가공(HSM; High-Speed Machining)은 높은 소재제거율과 가공 후 무연마나 고품위 가공을 이용하여 고품위, 고정도의 가공물을 생성하여 공정을 축소시키며, 공구교환 시간 및 가공시간을 단축시켜 생산성을 향상시킬 수 있다. 절삭가공의 특성은 공작기계의 특성, 공구 및 가공조건뿐만 아니라 제품 형상 등의 다양한 요인에 의해 결정되어진다. 고속가공의 가공조건 선정은 매우 복잡하고 해석적인 모델에 의해 쉽게 예측될 수 없기 때문에 핸드북이나 숙련된 운영자의 경험과 직관에 의지하는 것이 일반적이다.^[1]

공구와 가공물간의 기하학적인 간섭과 칩형성 과정 등의 절삭 메카니즘 분석에 의해 절삭력 모델을 세우고 표면 거칠기와 공구마모 특성 등을 예측하고자 하는 연구들이 수행되어 왔으나, 수만 rpm의 주축회전과 정삭조건하에서의 절삭 메카니즘은 정확히 밝혀지지 못하고 있다.^[2]

이러한 문제점에 대한 대안으로써 불분명한 개념을 수학적으로 계산하는 퍼지 이론이나 학습과정을 거쳐 임의의 값을 계산하는 신경망, 의사결정 모듈을 포함한 전문가 시스템(expert system)의 개념들을 생산시스템과 접목시키고자 하는 연구들이 수행되었다.^{[3][4][5][6]} 이러한 일련의 과정은 기존의 생산영역에서 얻은 데이터를 바탕으로 새

* 발표자, 한국생산기술연구원 나노가공팀 (wjr@kitech.re.kr)
주소: 406-130 인천시 연수구 동춘동 994-32 송도TP단지내
+ 한국생산기술연구원 나노가공팀
++ 경희대학교 기계공학과

로운 생산영역에 적용하여 미지의 값을 추론해 내는 방식으로, 직접 경험하지 못한 생산조건에서 최적의 생산조건을 선정하는데 그 목적이 있다.

그러나, 이러한 절삭조건 선정 방법론들은 지식영역의 한계와 넓은 변수를 포함하는 데이터가 필요하다는 점과 결과에 대한 이유의 해석이 난해하고, 효율적이고 체계적으로 가공데이터를 DB화하고 이를 활용하여 가공특성을 예측하는 접근방법이 미흡하다는 측면에서도 앞으로의 연구가 더 진행되어야 한다.

본 연구에서는 절삭시 복합적인 가공특성을 내포하고 있는 요인이 최종 가공특성에 미치는 영향을 분석·활용하기 위하여 절삭력 데이터를 표면거칠기 예측에 활용할 수 있는 2중 신경망 예측방법을 제시하였다. 또한, 신뢰성 있는 예측을 위한 학습데이터를 최소한의 가공조건 조합하에서 확보하기 위하여 실험계획법을 적용함으로써 실제 가공시스템에 적용될 수 있는 효율적인 방안임을 기술한다.

2. 절삭력 활용을 위한 2중신경망 예측 방법

고속가공을 포함한 절삭가공에 있어서는 표면거칠기는 공구와 가공물 간의 기하학적인 간섭과 절삭시 공구 런아웃, 열발생, 기계특성, 공구 휨 등의 복합적인 절삭 메커니즘에 의해 결정된다. 절삭력 모델은 이러한 복합적인 영향을 분석하기 위한 중요한 척도가 되며, 이 절삭력 데이터를 표면거칠기 예측에 활용함으로써 예측의 정확도를 크게 향상시킬 수 있다.

Fig. 1은 미지의 가공인자 조합에 대한 표면거칠기 예측에 절삭력 데이터 활용하기 위하여 설계된 2중 신경망의 구조를 도식적으로 나타낸 그림이다. 본 연구에서의 신경망

구조는 주어진 가공인자 조합에 대하여 절삭력을 예측하기 위한 신명망 예측 단계와 가공인자와 예측된 절삭력을 통하여 최종적으로 표면거칠기 R_a 를 예측하기 위한 신명망 예측 단계의 2중 구조로 되어 있다.

한편, 본 연구에서는 이러한 신경망을 이용한 표면거칠기 예측에 있어서 신뢰도 있는 학습 데이터 확보에 필요한 실험 조합을 제한하기 위하여 가공인자의 조합을 실험계획법의 직교배열표에 의하여 랜덤하게 선정하였다.

3. 실험결과 및 분석

3.1 실험장치 및 방법

본 논문에서 사용된 고속가공기는 독일의 Roeders GmbH사의 RP-800으로 42,000rpm의 최대 주축회전속도, 60,000mm/min의 최대 급승이송속도 사양을 가진 3축 밀링가공기이다. 공구는 Jibro-Tool사의 $\phi 4$, 2날 볼 엔드밀 JH-110을 사용하였고 시편은 금형산업에서 가장 많이 사용되는 재질 중의 하나인 비 열처리된 SKD-61을 사용하였다. 가공조건은 Table 1과 같이 주축회전속도(spindle speed), 이송속도(feedrate), Z축 절입깊이(depth of cut), X-Y축 절입깊이(X-Y pitch)를 가공인자로 선정하였으며 각각의 인자를 4수준계 직교배열표를 이용하여 조합한 후 실험순서를 랜덤하게 선정하였다. 조건에 따른 가공특성 파악을 위하여 Fig. 2와 보는 바와 같이 구역별로 상이한 조건을 부가하여 직선 평면가공을 수행하였다.

각 가공조건에 따른 절삭력은 Kistler 9256A 공구동력계를 사용하였으며, 신경망 학습 데이터로 사용되는 각 축 절삭력 성분은 일정한 측정시간 동안의 RMS값이 사용된다.

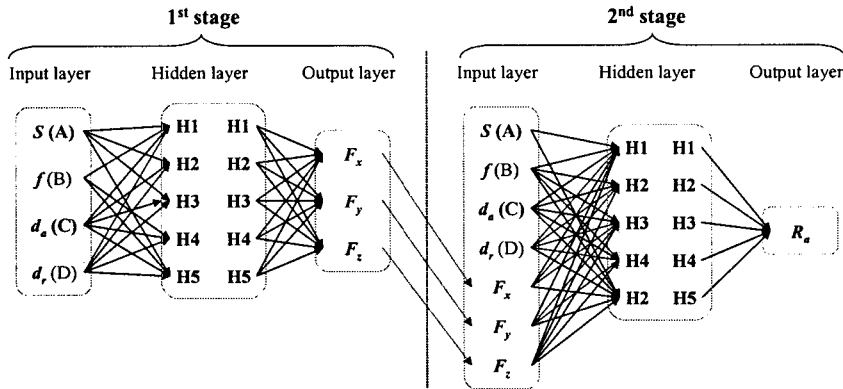


Fig. 1 Diagram of double ANN architecture




Fig. 2 The photograph of an test specimen

Table 1 Factors and levels for design of experiments

Sign	Factor	Level			
		0	1	2	3
A	Spindle speed [rpm]	20,000	30,000	35,000	40,000
B	Feedrate [mm/min]	2,000	3,000	4,000	5,000
C	Depth of cut [mm]	0.05	0.1	0.3	0.5
D	X-Y pitch [mm]	0.05	0.1	0.15	0.2

3.2 단계별 신경망 학습 조건

첫번째 단계에서 A, B, C, D의 가공인자 조합에 대하여 절삭력 성분 F_x , F_y , F_z 를 예측하기 위한 최적의 신경망 조건은 Table 2와 같다. 총 48가지 조합의 실험결과에 대하여 임의의 1가지 조합에 대한 측정결과를 테스트 패턴으로 하고, 나머지 47가지 조합에 대한 측정결과를 학습데이터로 사용하여 신경망 예측을 수행하였다.

이러한 방법으로 수행된 신경망 예측의 6 경우에 대한 절삭력 성분의 예측 결과는 Table 3과 같다. 절삭력 성분들은

충분한 정확도 내에서 예측이 가능함을 알 수 있으며, 이후 2단계 신경망의 예측을 위한 테스트 패턴의 인자로 사용될 수 있음을 기대할 수 있다.

Table 2 Optimized learning condition for the 1st stage ANN

Learning algorithm		Back-propagation learning algorithm
Number of learning patterns		47×5
Number of nodes of each layer	Input	4 (A, B, C, D)
	Hidden	5×5
	Output	3 (F_x , F_y , F_z)
Learning rate, α		0.01
Momentum, η		0.9

두번째 단계에서는 가공인자와 절삭력 성분 데이터 - A, B, C, D, F_x , F_y , F_z 를 입력 노드로 하고 표면거칠기 R_a 를 출력 노드로 하여 표면거칠기값 예측이 수행된다. Table 4는 이러한 신경망 학습의 학습 조건을 나타낸 것이다. 첫번째 단계와 유사하게 총 48가지 조합의 실험결과에 대하여 임의의 1가지 조합에 대한 값들을 테스트 패턴으로 하고, 나머지 47가지 조합에 대한 값들을 학습데이터로 사용하였다. 학습시의 절삭력 데이터는 실제 측정값이 사용되며, 예측을 위한 테스트 패턴으로는 첫번째 단계에서 추정된 예측값이 사용된다.

표면거칠기 예측에 절삭력 데이터를 사용하지 않을 경우에는 Fig.3에서 나타내는 바와 같이 절삭력 데이터를 포함하는 예측에 비하여 예측을 오차가 상대적으로 매우 커짐을 알 수 있다. 이는 고속가공의 정삭영역에서 가공특성에 절삭력이 미치는 영향이 매우 큼을 알 수 있는 결과로써 본 연구의 절삭력 데이터를 예측하는데 활용하는 이유가 된다.

Fig.4는 절삭력 데이터를 활용한 2단계 신경망을 이용한 표면거칠기 예측결과를 나타내는 것으로 미지의 가공인자 조합

Table 3 Results of the prediction of cutting force components

No	Cutting force components						Machining condition
	Predicted components [N]			Prediction error rate [%]			
	F_x	F_y	F_z	F_x	F_y	F_z	
1	49.552	36.726	46.513	2.457	4.949	10.776	A2B1C2D1
2	37.502	29.303	38.579	2.893	3.134	2.850	A2B2C0D1
3	45.715	33.454	43.217	14.330	14.299	5.860	A3B1C0D2
4	34.198	20.217	28.892	61.890	38.761	39.499	A0B0C0D0
5	61.236	49.155	65.708	7.453	3.909	0.990	A2B2C1D2
6	56.821	41.652	58.658	11.502	20.221	6.699	A3B2C2D2

A, B, C, D에 대하여 첫번째 단계에서 예측된 절삭력 성분을 이용한 표면거칠기 예측결과와 검증을 위하여 실제 절삭력 데이터를 이용하여 예측된 결과와 비교한 결과이다. 이러한 결과는 본 연구에서 제시된 2중 신경망 예측에 의하여 정교한 표면거칠기 예측이 가능함을 알 수 있다.

Table 4 Optimized learning condition for the 2nd ANN

Learning algorithm		Back-propagation learning algorithm
Number of learning patterns		47×5
Number of nodes of each layer	Input	7 (A, B, C, D, F_x , F_y , F_z)
	Hidden	5×5
	Output	1 (R_a)
Learning rate, α		0.01
Momentum, η		0.9

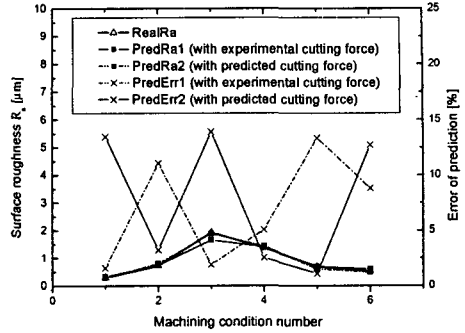


Fig. 4 Prediction results of surface roughness for combinations of machining parameters using double ANN

4. 결론

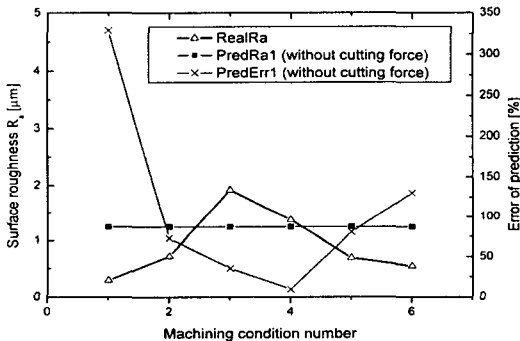
본 연구에서는 가공인자와 절삭력 데이터의 조합을 신경망의 입력 패턴으로 사용하여 2중 신경망에 의한 학습을 통하여 미지의 가공인자에 대한 표면거칠기를 예측하기 위한 절차를 제시하였다. 가공인자 뿐만 아니라 절삭력 데이터 포함할 경우 표면거칠기 예측률이 크게 향상됨을 통하여 고속가공 영역에서 표면거칠기에 미치는 복합된 절삭 메커니즘을 잘 반영함을 알 수 있었다. 또한, 실험계획법을 통하여 한정된 수의 실험데이터만을 신경망 학습에 사용함으로써 충분한 정확도의 예측이 가능하고, 향후 최적조건 선정 프로그램에 효과적으로 적용될 수 있을 것으로 기대된다.

후기


본 연구는 산업자원부 차세대신기술개발사업 “글로벌 정보공유 및 지식기반의 차세대 생산시스템 기술 개발” 과제 의 연구비를 지원받아 수행되었습니다.

참고문헌

- (1) Yang, M.-Y. and Sim, C.-G., “The Prediction of the Cutting Force in Ball-End Milling with a Flexible Cutter”, *International Journal of Machine Tools & Manufacture*, Vol.333, No.2, pp.267-284, 1993
- (2) Paulo Davim, J., Conceicao Antonio, C.A.,



(a) Without cutting force data



(b) With cutting force data

Fig. 3 Prediction of surface roughness for each case with or without cutting force data

- “Optimisation of Cutting Conditions in Machining of Aluminium Matrix Composites Using a Numerical and Experimental Model”, *Journal of Materials Processing Technology*, Vol.112 pp.78-82, 2001
- (3) Adamczyk, Z., Kociol, K., “CAD/CAM Technological Environment Creation as an Interactive Application on the Web”, *Journal of Materials Processing Technology*, Vol. 109 pp. 222-228, 2001
- (4) Wong, S.V., Hamouda, A.M.S., Baradie, El, M.A., “Generalized Fuzzy Model for Metal Cutting Data Selection”, *Journal of Materials Processing Technology*, Vol. 89-90, pp.310-317, 1999
- (5) Benardos, P.G., Vosniakos, G.C. “Prediction of Surface Roughness in CNC Face Milling Using Neural Networks and Taguchi's Design of Experiments”, *Robotics and Computer Integrated Manufacturing*, Vol. 18, pp. 343-354, 2002
- (6) Wong, S.V., Hamouda, A.M.S., “The Development of an Online Knowledge-Based Expert System for Machinability Data Selection”, *Knowledge-Based Systems*, Vol.16, pp.215-229, 2003