

심층 신경회로망을 이용한 엔드밀 가공의 절삭 조건 개선

이신영^{a*}Improvement of Cutting Conditions in End-milling Using
Deep-layered Neural NetworksSin-Young Lee^{a*}^a Dept. of Mechanical Engineering, Kunsan National University, 558, Daehak-ro, Gunsan, Jeonbuk-do, 54150, Korea

ARTICLE INFO

Article history:

Received	26	April	2017
Revised	27	June	2017
Accepted	9	August	2017

Keywords:

End-milling
Deep-layered neural network
Number of neurons
Average cutting forces
Force simulation
Cutting conditions

ABSTRACT

Selection of optimal cutting conditions is important for improving productivity and implementing efficient process control in metal machining. In this study, improvement of cutting conditions in machining using end-mills is studied by using deep-layered neural networks, which comprise an input layer, output layer, and two hidden layers. System networks are designed with inputs as cutting conditions, and they output the cutting force. A pseudo-inverse network is designed that has the adjustable cutting condition as output and cutting force and other cutting conditions as input. The combination of the system network and pseudo-inverse network enables selection or improvement of cutting conditions that results in the expected cutting force.

1. 서론

절삭가공에서 적절한 절삭조건을 선정하는 것은 공정설계 또는 생산성 향상에 있어서 기본적인 요구사항 중의 하나이다^[1]. 절삭조건이 부적절한 경우 절삭성능이 저하되든지 또는 과도한 절삭력을 발생하게 하고 절삭력이 크면 진동이나 공구 손상 등의 부작용이 발생하게 된다. 절삭가공 중 엔드밀을 이용한 가공은 공작기계가 개발되어 사용된 이래 각종 기계 부품의 가공에 널리 사용되고 있다. 엔드밀 가공 시 여러 가지의 절삭조건들이 절삭력에 영향을 미치며, 이를 예측하기 위하여 많은 모델들이 개발되었다^[2]. Smith 등은 일정한 절삭강성을 도입하여 절삭실험에서 얻어진 평균 절삭력으로부터 비절삭력계수를 얻고, 비절삭력계수로부터 절삭력을

구하는 방법을 제시하였다^[3]. 밀링가공 시의 절삭저항은 공구 제원 및 회전속도, 반경방향 및 축방향 절삭 깊이, 이송률, 반경방향 및 접선방향 비절삭력계수 등이 주어지면 절삭저항을 구할 수 있다^[4]. 그렇지만 비절삭력계수 산출에 1차적으로 요구되는 평균절삭력을 정확하게 구하는 것은 잘 알려지지 않고 있다. 본 논문에서는 심층 신경회로망에 의하여 엔드밀 가공의 절삭력을 시뮬레이션하고, 희망하는 절삭력과 비교하여 새로운 또는 적절한 절삭조건을 제안하며, 수정된 절삭조건에 따른 절삭력을 제시함으로써 절삭 성능 개선에 도움이 되고자 하였다.

초기의 신경회로망은 입력층과 출력층만을 갖거나 소수의 뉴런을 갖는 한 개의 은닉층을 갖는 것이 주로 사용되었는데 점차 은닉층의 수 및 뉴런의 수를 증가시켜 신경회로망의 성능을 향상시키고

* Corresponding author. Tel.: +82-63-469-4716

Fax: +82-63-469-7433

E-mail address: sinylee@kunsan.ac.kr (Sin-Young Lee).

있다⁵⁾. 본 논문에서는 두 개의 은닉층을 갖고 각 은닉층은 다수의 뉴런으로 구성되는 심층 신경회로망을 이용하여 절삭조건에 따른 절삭력을 시뮬레이션 하고자 하였다¹¹⁾. 뉴런의 수 및 은닉층의 수에 따른 학습을 수행하고 학습하지 않은 데이터에 적용하여 오차의 크기를 비교하였다. 이 회로망을 시스템 네트워크라 하고, 절삭력으로부터 절삭조건을 찾는 회로망을 역역 네트워크라 한다. 절삭조건과 희망하는 절삭력을 입력하면 시스템 네트워크에서 절삭력을 시뮬레이션하고, 역역 네트워크에서 수정된 절삭 조건을 제시하며, 이 수정된 절삭 조건에 따른 절삭력을 시스템 네트워크에 의하여 구하도록 하였다.

2. 신경회로망 및 학습

여러 가지 형태의 신경회로망 중 본 논문에서는 오차를 거슬러 전파하는 방법에 의하여 학습이 이루어지는 퍼셉트론 구조의 신경회로망을 사용한다^{6,9)}. 여기에서의 기본 소자는 여러 개의 입력과 하나의 출력을 갖는 뉴런이다^{6,7)}. 몇 개의 뉴런들이 한 층을 이루고 몇 개의 층이 전체 신경회로망을 구성한다. 제 n 층 i 번째 뉴런의 내부 상태 U_i^n 는 앞 층의 출력 O_j^{n-1} , 결합계수 $W_{j,i}^{n-1,n}$ 및 역치 θ_i^n 에 의하여 식 (1)과 같이 주어지고, k 는 $n-1$ 층 뉴런의 수를 나타낸다. 출력 O_i^n 은 내부 상태와 출력함수에 의하여 식 (2)와 같이 주어진다¹¹⁾.

$$U_i^n = \sum_{j=1}^k W_{j,i}^{n-1,n} O_j^{n-1} + \theta_i^n \quad (1)$$

$$O_i^n = f(U_i^n) \quad (2)$$

식 (2)의 출력함수로는 시그모이드 함수를 이용하였다.

최종 층의 출력에 대응하도록 주어진 신호를 교사신호 T_i 라고 한다. 신경회로망의 평가함수로 사용하는 것은 최종 층에서의 출력과 교사신호 차의 제곱 합이고, 다음과 같이 표기한다.

$$J = \frac{1}{2} \sum_{i=1}^m (T_i - O_i^N)^2 \quad (3)$$

여기서 m 은 최종층(N 층) 뉴런의 수를 나타낸다.

평가함수의 편미분으로부터 최종 층(N 층)과 직전 층($N-1$ 층) 사이의 결합계수 및 역치의 수정을 다음과 같은 방법으로 구할 수 있다¹¹⁾.

$$\frac{\partial J}{\partial W_{j,i}^{N-1,N}} = -(T_i - O_i^N) f'(U_i^N) O_j^{N-1} \quad (4)$$

$$\frac{\partial J}{\partial \theta_i^N} = -(T_i - O_i^N) f'(U_i^N) \quad (5)$$

수식을 간단히 표현하기 위하여 식 (4)와 (5)에 공통으로 등장하는 항인 $-(T_i - O_i^N) f'(U_i^N)$ 을 오차신호 δ_i^N 이라고 하면 결합계수의 수정량은 식 (6)과 같고,

$$\Delta W_{j,i}^{N-1,N} = -\epsilon_1 \delta_i^N O_j^{N-1} \quad (6)$$

역치의 수정량은 다음과 같다.

$$\Delta \theta_i^N = -\epsilon_2 \delta_i^N \quad (7)$$

식 (6)과 (7)에서 ϵ_1 과 ϵ_2 는 각각 결합계수와 역치의 학습계수이다. 같은 방법으로 $N-1$ 층과 $N-2$ 층 사이의 결합계수와 역치의 수정량을 구할 수 있으며 출력 함수의 기울기 관련 값 역시 같은 방법으로 수정량을 구할 수 있다. 또한 극소치에 떨어질 가능성이 있는 결점을 피하기 위하여 전회의 수정량을 고려하는 제1차 모멘트 및 전전회의 수정량을 고려하는 제2차 모멘트를 사용하는 자기회귀형 오차역전파법¹⁰⁾을 사용하였다.

3. 절삭 실험 데이터

본 연구에서는 머시닝센터에서 2날 엔드밀을 사용하여 수행한 절삭실험¹¹⁾의 결과를 사용하였다. 절삭시편의 재질은 SM45C이었고, 시편의 절삭부 폭은 45 mm이었으며, 절삭에 사용한 엔드밀 지름은 16 mm와 20 mm이었다. 절삭력의 측정에 사용한 공구동력계는 Kistler 9257B, 전하증폭기는 Kistler 5019A이었다. 폭 45 mm에 걸쳐서 절삭을 진행하고, 평균절삭력을 구하였다. 본 연구에서는 이송방향으로 측정되는 절삭력 성분과 이송방향에 직교하는 방향의 절삭력 성분의 합력을 절삭력으로 표시하였고, 전체 실험 데이터의 수는 74개 이었으며 각 실험 데이터에서 얻은 절삭력의 예는 Table 1과 같다.

4. 시스템 네트워크

입력층은 주축 회전속도, 공구반지름, 반경방향 절삭깊이, 축방향 절삭깊이, 날당 이송속도의 5가지로 하고, 출력층은 절삭합력의 1 가지로 하는 시스템 네트워크를 구성하였으며, 프로그램은 C언어를 사용하여 코딩하였다. 은닉층은 2개로 구성하고, 제1 은닉층의 뉴런 수와 제2 은닉층의 뉴런 수를 변경하면서 학습을 수행하였

Table 1 Samples of average cutting forces

Spindle RPM	Tool radius (mm)	Radial depth (mm)	Axial depth (mm)	Feed rate (mm/tooth)	Force (N)
600	8	2	20	7.083e-2	504.1
600	8	4	20	7.083e-2	890.2
600	8	8	20	7.083e-2	1562.
900	8	2	20	4.722e-2	415.5
900	8	4	20	4.722e-2	692.8
900	8	6	20	4.722e-2	990.8
900	8	2	20	6.667e-2	416.2
900	8	6	20	6.667e-2	1002.
900	8	8	12	4.722e-2	782.5
600	8	4	12.	0.100	707.3
600	8	8	12.	0.100	1352.
480	10	2	12.	6.979e-2	263.0
480	10	4	12.	6.979e-2	668.0
480	10	8	12.	8.854e-2	1711.
480	10	8	20.	6.979e-2	1850.
480	10	4	20.	8.854e-2	1415.
600	8	6	20.	7.083e-2	1212.
600	10	2	12.	5.583e-2	303.4

으며, 학습하지 않은 데이터에 대한 오차의 RMS (Root Mean Square) 값을 구하였다. 입력층, 두 개의 은닉층 및 출력층으로 이루어진 4층 시스템 네트워크의 제1 은닉층 뉴런 수(NH)와 제2 은닉층 뉴런 수(NJ)가 30개로 주어진 경우 학습하지 않은 데이터에 대한 오차는 Table 2와 같다. 결합계수 $W_{j,i}^{n-1,n}$ 의 학습계수는 0.2, 역치 θ_i^n 의 학습계수는 0.12, 시그모이드 함수 기울기의 학습계수는 0.12, 전회의 수정량을 고려하는 제1차 모멘트는 0.6, 전전회의 수정량을 고려하는 제2차 모멘트는 0.2로 설정하였다. 학습하지 않은 데이터의 수는 8개와 12개의 2 가지 경우에 대하여 비교하였고, 각각의 신경회로망의 학습 시 초기 데이터는 난수 생성에 의하여 출발하므로 각기 다른 결합계수를 가지며 따라서 오차도 제각기 다르게 되었다. 전체 데이터의 수는 74개이고, 미학습 데이터를 제외한 나머지 데이터를 학습에 이용하였다.

Table 3은 NH×NJ가 35×35인 경우, Table 4는 NH×NJ가 40×40인 경우, Table 5는 NH×NJ가 45×45인 경우, Table 6은 NH×NJ가 50×50인 경우의 미학습 데이터에 따른 RMS 오차를 나타낸다. 기존의 연구^[11]와 비교하면 충분한 수의 은닉층 소자 및 가중치를 포함하는 신경회로망을 구성한 경우이며 전통적 방법^[7]의 최소 신경회로망 은닉층 소자 수 = (입력층 소자 수) + (출력층 소자 수) = 5+1 = 6개에 비하여 매우 큰 경우로써, 전체적으로 볼 때 오차가 양호하다고 판단되었다. 물론 NH×NJ가 40×40인 심층 신경회로망의 경우 구해야 할 결합계수는 1,840개인 반면 은

Table 2 Simulation error of forces (NH=30, NJ=30)

Case	No. of untaught data	RMS error (%) in Forces
A	8	3.91
B	8	3.94
C	8	4.13
D	8	4.98
E	8	5.72
F	12	6.01
G	12	5.73
H	12	4.69
I	12	7.66
J	12	4.17
Total average		5.08

Table 3 Simulation error of forces (NH=35, NJ=35)

Case	No. of untaught data	RMS error (%) in Forces
A	8	3.34
B	8	5.20
C	8	6.93
D	8	3.36
E	8	3.74
F	12	6.47
G	12	5.73
H	12	4.69
I	12	7.66
J	12	4.17
Total average		5.34

Table 4 Simulation error of forces (NH=40, NJ=40)

Case	No. of untaught data	RMS error (%) in Forces
A	8	6.08
B	8	3.78
C	8	4.85
D	8	3.62
E	8	6.43
F	12	6.42
G	12	6.19
H	12	5.85
I	12	5.72
J	12	7.80
Total average		5.68

닉층의 수가 6개인 신경회로망의 경우 구해야 하는 결합계수의 수는 36개에 불과하여 계산 양의 차이는 크다.

Table 5 Simulation error of forces (NH=45, NJ=45)

Case	No. of untaught data	RMS error (%) in Forces
A	8	3.50
B	8	6.19
C	8	5.22
D	8	5.26
E	8	3.95
F	12	5.16
G	12	8.29
H	12	7.50
I	12	6.40
J	12	7.52
Total average		5.90

Table 6 Simulation error of forces (NH=50, NJ=50)

Case	No. of untaught data	RMS error (%) in Forces
A	8	4.21
B	8	3.82
C	8	4.60
D	8	4.31
E	8	4.36
F	12	6.00
G	12	4.94
H	12	8.93
I	12	7.46
J	12	4.61
Total average		5.33

Fig. 1은 학습데이터의 수가 66개이고 미학습 데이터의 수가 8개인 경우에 은닉층 뉴런의 수에 따른 RMS 오차를 나타낸다. 가로축은 제1 은닉층과 제2 은닉층 뉴런의 수를 나타내고, 세로축은 RMS 오차(%)를 나타낸다. Table 2~6에 제시된 바와 같이 각각의 학습 결과에서 오차가 산포되어 있음을 볼 수 있고, 전체적으로 5% 내외의 오차를 나타내었으며 NH×NJ가 50×50인 경우가 가장 작은 오차를 나타내었다. Fig. 2는 미학습 데이터의 수가 12개인 경우에 은닉층 뉴런의 수에 따른 RMS 오차를 나타낸다. Fig. 1과 같은 모양으로 각각의 학습 결과에서 오차가 산포되어 있음을 볼 수 있고, 전체적으로 6% 내외의 오차를 나타내었으며 NH×NJ가 30×30인 경우가 가장 작은 오차를 나타내었다. Fig. 1 및 Fig. 2로부터 오차가 6% 내외로 종전의 경우^[11]에 비하여 작은 것을 볼 수 있다. 또한 기존의 수학적 모델에서는 접선방향 및 반경방향 비절삭력계수를 정의하여 절삭력을 유도하고, 이들 비절삭력계수는 절삭조건의 2차 조합으로 표현한 다음 최소자승법에 의하여 이송, 반

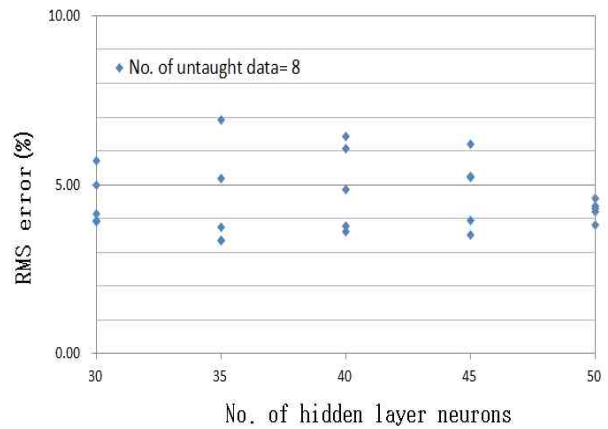


Fig. 1 RMS error of system networks (No. of untaught data=8)

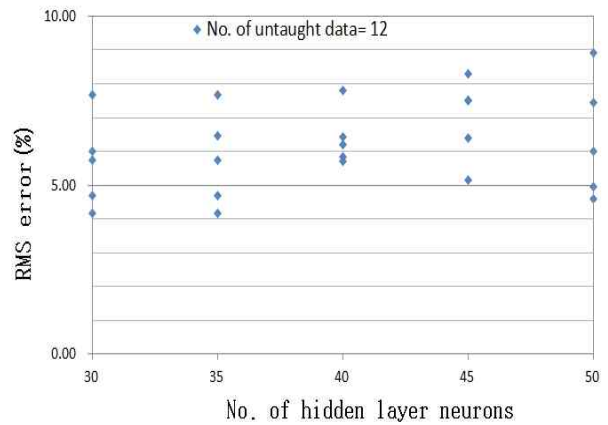


Fig. 2 RMS error of system networks (No. of untaught data=12)

경방향 절삭깊이 및 축방향 절삭깊이의 2차 함수 형태로 구해졌다^[2]. 그 결과를 보면 절삭실험의 결과와 최소자승법에 의하여 구해진 비절삭력계수에 의한 계산결과에 상당한 오차가 있음을 알 수 있다. 본 논문에 사용된 방법의 경우에는 신경회로망의 특성상 비선형 모델링이 가능함으로 인하여 충분히 많은 은닉층 및 뉴런을 사용하여 학습을 수행하고 그 결과를 비교하면 절삭실험의 결과와 시뮬레이션한 결과 사이에 상대적으로 작은 오차가 발생하는 것을 확인할 수 있었다.

5. 의역 네트워크

여러 가지의 절삭조건이 절삭력에 영향을 미치므로 희망하는 절삭력으로부터 적당한 절삭조건을 일시에 찾기는 간단하지 않다. 본 연구에서는 변경가능 또는 조정 가능한 절삭조건을 출력층으로 하고 나머지 절삭조건 및 절삭력을 입력층 소자로 하는 의역 (pseudo-inverse) 네트워크를 구상하였다. 즉, Table 1에 주어진 절삭 실험 결과를 데이터로 하여, 입력층은 주축 회전속도, 공구반

지름, 절삭력, 축방향 절삭깊이, 날당 이송속도의 5가지로 하고, 출력층은 반경방향 절삭깊이의 1 가지로 하는 의역 네트워크를 구성하였다.

은닉층은 2개로 구성하고, 제1 은닉층의 뉴런 수와 제2 은닉층의 뉴런 수를 변경하면서 학습을 수행하였으며, 학습하지 않은 데이터에 대한 오차의 RMS 값을 구하였다. 입력층, 두 개의 은닉층 및 출력층으로 이루어진 4층 의역시스템 네트워크의 제1 은닉층 뉴런 수(NH)와 제2 은닉층 뉴런 수(NJ)가 각각 30개로 주어진 경우 학습하지 않은 데이터에 대한 RMS (root mean square) 오차는 Table 7과 같다. 학습하지 않은 데이터의 수는 8개(학습에 사용한 데이터의 수는 66개)와 12개(학습에 사용한 데이터의 수는 62개)의 2 가지 경우에 대하여 비교하였다. Table 8은 4층 의역시스템 네트워크의 제1 은닉층 뉴런 수(NH)와 제2 은닉층 뉴런 수(NJ) NH×NJ가 35×35인 경우, Table 9는 NH×NJ가 40×40인 경우,

Table 7 Simulation error of forces (NH=30, NJ=30)

Case	No. of untaught data	RMS error (%) in Forces
A	8	7.36
B	8	0.54
C	8	0.07
D	8	1.49
E	8	2.10
F	12	0.07
G	12	0.48
H	12	1.74
I	12	1.16
J	12	1.44
Total average		1.65

Table 8 Simulation error of forces (NH=35, NJ=35)

Case	No. of untaught data	RMS error (%) in Forces
A	8	3.27
B	8	1.52
C	8	1.33
D	8	4.32
E	8	1.14
F	12	1.05
G	12	1.52
H	12	0.72
I	12	0.25
J	12	1.20
Total average		1.63

Table 10은 NH×NJ가 45×45인 경우, Table 11은 NH×NJ가 50×50인 경우의 미학습 데이터에 따른 RMS 오차를 나타낸다. 충분한 수의 은닉층 소자 및 가중치를 포함하는 신경회로망을 구성한 경우이며 전통적 방법^[7]의 최소 신경회로망 은닉층 소자 수 = (입력층 소자 수) + (출력층 소자 수) = 5+1 = 6 개에 비하여 매우 큰 경우로써, 전체적으로 볼 때 오차가 양호하다고 판단되었다.

Fig. 3은 미학습 데이터의 수가 8개인 경우에 은닉층 뉴런의 수에 따른 의역 네트워크의 RMS 오차를 나타낸다. 가로축은 제1 은닉층과 제2 은닉층 뉴런의 수를 나타내고, 세로축은 RMS 오차(%)를 나타낸다. Table 7~11에 제시된 바와 같이 각각의 학습 결과에서 오차가 산포되어 있음을 볼 수 있고, 전체적으로 3% 내외의 오차를 나타내었으며 NH×NJ가 45×45인 경우가 가장 작은 오차를 나타내었다.

Fig. 4는 미학습 데이터의 수가 12개인 경우에 은닉층 뉴런의

Table 9 Simulation error of forces (NH=40, NJ=40)

Case	No. of untaught data	RMS error (%) in Forces
A	8	3.05
B	8	0.47
C	8	0.93
D	8	0.33
E	8	2.57
F	12	0.24
G	12	0.15
H	12	2.50
I	12	0.18
J	12	0.66
Total average		1.11

Table 10 Simulation error of forces (NH=45, NJ=45)

Case	No. of untaught data	RMS error (%) in Forces
A	8	0.95
B	8	2.14
C	8	1.38
D	8	0.64
E	8	0.63
F	12	1.79
G	12	0.43
H	12	0.20
I	12	2.04
J	12	0.72
Total average		1.09

Table 11 Simulation error of forces (NH=50, NJ=50)

Case	No. of untaught data	RMS error (%) in Forces
A	8	3.55
B	8	1.35
C	8	0.99
D	8	2.61
E	8	1.27
F	12	3.28
G	12	0.65
H	12	2.47
I	12	0.98
J	12	3.00
Total average		2.02

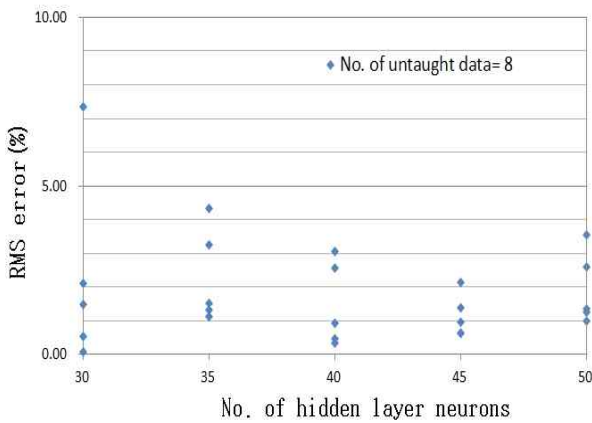


Fig. 3 RMS error of pseudo-inverse networks (No. of untaught data=8)

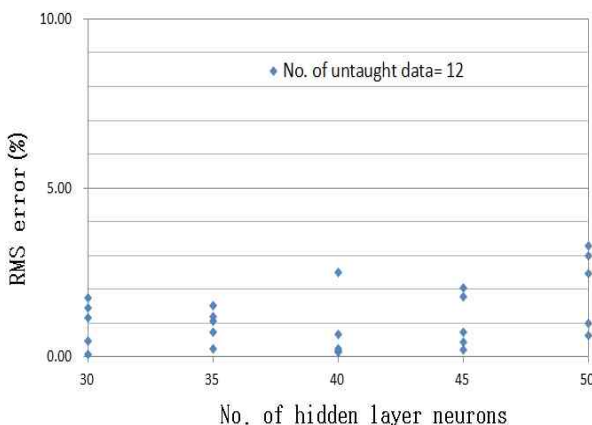


Fig. 4 RMS error of pseudo-inverse networks (No. of untaught data=12)

수에 따른 의역 네트워크의 RMS 오차를 나타낸다. 가로축은 제1 은닉층과 제2 은닉층 뉴런의 수를 나타내고, 세로축은 RMS 오차

(%)를 나타낸다. Fig. 3과 같이 각각의 학습 결과에서 오차가 산포되어 있음을 볼 수 있고, 전체적으로 2% 내외의 오차를 나타내었으며 NH×NJ가 40×40인 경우가 가장 작은 오차를 나타내었다.

6. 절삭조건 개선

통합 네트워크인 절삭조건 개선 프로그램에서는 1차로 선정된 절삭조건과 희망하는 절삭력을 입력으로 한다. 시스템 네트워크로부터 주어진 절삭조건에 따른 절삭력을 예측하고, 또한 의역 네트워크로부터 희망하는 절삭력에 따른 절삭조건을 추출한다. 이 추출된 절삭조건을 시스템 네트워크에 입력하면 조정된 절삭력이 구해지는 방식으로 프로그램을 C언어를 사용하여 작성하였다. 이 프로그램에서는 시스템 네트워크에서 학습한 가중치 및 역치, 시그모이드 함수의 기울기 등이 저장된 파일명을 입력하고, 다음에 의역 네트워크에서 학습한 가중치 및 역치, 시그모이드 함수의 기울기 등이 저장된 파일명을 입력한다. 그 다음 1차 선정된 절삭조건과 희망하는 절삭력을 입력하면 조정된 절삭조건 및 조정된 절삭력을 구하도록 하였다.

조정된 절삭력이 희망하는 절삭력과 1.0% 이상 차이가 나는 경우에는 보간법에 의하여 절삭조건을 재조정하고 재조정된 절삭조건을 시스템 네트워크에 입력하여 재조정된 절삭력을 구하였다.

절삭력 조정 프로그램의 출력 사례는 Fig. 5와 같다. Fig. 5에서 절삭실험 결과로부터 도출한 시스템 네트워크의 결합계수, 역치 및 시그모이드 함수 기울기 등의 데이터는 NH×NJ가 50×50인 경우에 대하여 학습을 진행한 ‘B50y.wgt’로부터 입력하였다. 의역 네트워크의 결합계수, 역치 및 시그모이드 함수 기울기 등의 데이터는 NH×NJ가 45×45인 경우에 대하여 학습을 진행한 ‘R111.wgt’로부터 입력하였다.

8개의 사례를 나타내고 있으며 첫째의 문제는 주축회전속도 600 rpm, 공구 반지름 8 mm, 반경방향 절삭깊이 2 mm, 축방향 절삭깊이 20 mm, 날당 이송 0.070833 mm/tooth의 절삭조건에서 기대하는 절삭력이 690 N인 경우이다.

주어진 절삭조건에서 절삭력은 503 N으로 예측되었으며 희망하는 절삭력을 얻기 위해서는 반경방향 절삭깊이를 2.86 mm로 조정하는 것이 산출되었고, 조정된 절삭조건에서의 절삭력은 693 N으로 모사되었다.

두 번째 문제는 주축회전속도 900 rpm, 공구 반지름 8 mm, 반경방향 절삭깊이 4 mm, 축방향 절삭깊이 20 mm, 날당 이송 0.04722 mm/tooth의 절삭조건에서 기대하는 절삭력이 893 N인 경우이다. 주어진 절삭조건에서 절삭력은 692 N으로 예측되었으며 희망하는 절삭력을 얻기 위해서는 반경방향 절삭깊이를 5.36 mm로 조정하는 것이 산출되었고, 조정된 절삭조건에서의 절삭력

Load-weight file is B50y.wgt
 Load- Pseudo-Inverse_Weight file is R111.wgt
 Test output file is T105.tst
 Total number of optimizing events *ncount* is 8

**** 0 ****
 6.000000e+002 8.000000e+000 2.000000e+000 2.000000e+001
 7.083300e-002

Expected output force is 6.900000e+002
 Simulated output force is 5.032498e+002
 Adjusted Radial Depth of Cut is 2.861688e+000
 Adjusted output force is 6.925041e+002
 Error between Fexp1 and Fexp3 is 3.629128e-001

**** 1 ****
 9.000000e+002 8.000000e+000 4.000000e+000 2.000000e+001
 4.722200e-002

Expected output force is 8.930000e+002
 Simulated output force is 6.924142e+002
 Adjusted Radial Depth of Cut is 5.363289e+000
 Adjusted output force is 8.904001e+002
 Error between Fexp1 and Fexp3 is 2.911417e-001

**** 2 ****
 6.000000e+002 8.000000e+000 4.000000e+000 1.200000e+001
 7.083300e-002

Expected output force is 6.090000e+002
 Simulated output force is 4.384121e+002
 Adjusted Radial Depth of Cut is 4.449386e+000
 Adjusted output force is 6.116449e+002
 Error between Fexp1 and Fexp3 is 4.343034e-001

**** 3 ****
 4.800000e+002 1.000000e+001 4.000000e+000 1.200000e+001
 6.979200e-002

Expected output force is 8.380000e+002
 Simulated output force is 6.677230e+002
 Adjusted Radial Depth of Cut is 5.748302e+000
 Adjusted output force is 8.346808e+002
 Error between Fexp1 and Fexp3 is 3.960801e-001

**** 4 ****
 6.000000e+002 1.000000e+001 8.000000e+000 2.000000e+001
 5.583300e-002

Expected output force is 2.174600e+003
 Simulated output force is 1.874717e+003
 Adjusted Radial Depth of Cut is 9.066180e+000
 Adjusted output force is 2.157201e+003
 Error between Fexp1 and Fexp3 is 8.001007e-001

Fig. 5 Output of the cutting force adjusting program

**** 5 ****
 6.000000e+002 8.000000e+000 8.000000e+000 2.000000e+001
 7.083300e-002

Expected output force is 1.200000e+003
 Simulated output force is 1.562324e+003
 Adjusted Radial Depth of Cut is 5.928516e+000
 Adjusted output force is 1.199377e+003
 Error between Fexp1 and Fexp3 is 5.191211e-002

**** 6 ****
 6.000000e+002 1.000000e+001 8.000000e+000 2.000000e+001
 5.583300e-002

Expected output force is 1.500000e+003
 Simulated output force is 1.874717e+003
 Adjusted Radial Depth of Cut is 6.374558e+000
 Adjusted output force is 1.506179e+003
 Error between Fexp1 and Fexp3 is 4.119342e-001

**** 7 ****
 9.000000e+002 8.000000e+000 1.000000e+001 1.200000e+001
 6.666700e-002

Expected output force is 1.000000e+003
 Simulated output force is 1.181948e+003
 Adjusted Radial Depth of Cut is 7.985979e+000
 Adjusted output force is 1.001194e+003
 Error between Fexp1 and Fexp3 is 1.194009e-001

Fig. 5 Output of the cutting force adjusting program (Continued)

Table 12 Comparison of cutting forces

Case no.	Expected force	Simulated force	Adjusted force
1	690.	503.	693.
2	893.	692.	890.
3	609.	438.	612.
4	838.	668.	835.
5	2175.	1875.	2157.
6	1200.	1562.	1199.
7	1500.	1875.	1506.
8	1000.	1182.	1001.

은 890 N으로 모사되었다. 같은 방법으로 다수의 예제를 해석하였으며 그 결과는 Table 12에 나타난다. Table 12에서 첫 열은 사례 번호를 나타내고, 다음 열들은 기대되는 절삭력, 주어진 절삭조건에 대한 예상 절삭력, 수정된 절삭조건에 대하여 예상되는 절삭력을 나타낸다.

이와 같은 방식으로 주어진 절삭조건에 의하여 예상되는 절삭력을 구하고, 희망하는 절삭력에 의하여 절삭조건을 수정하며, 수정된 절삭조건으로부터 추정되는 절삭력을 확인하는 것이 가능하므로

로 절삭조건을 과소하게 지정하여 절삭성능을 저하하거나, 절삭조건이 과도하여 큰 절삭력을 유발함으로써 절삭 중에 야기되는 진동 또는 정밀도 저하 문제를 해결할 수 있을 것으로 기대된다.

7. 결 론

본 논문에서는 두 개의 은닉층을 갖고 각 은닉층은 다수의 뉴런을 갖는 심층 신경회로망을 이용하여 엔드밀 가공 시의 절삭성능 개선에 기여하고자 하였다.

시스템 네트워크의 입력층은 주축 회전속도, 공구반지름, 반경방향 절삭깊이, 축방향 절삭깊이, 날 당 이송 의 5 소자로 하고, 출력층은 이송방향 절삭력 성분과 이송방향에 수직인 방향의 절삭력 성분의 합력인 1 소자로 설정하였다. 시스템 네트워크의 학습 능력을 검증하기 위하여 학습을 수행하고 학습하지 않은 데이터에 대한 RMS 오차를 계산하였다.

의역 네트워크의 입력층은 주축 회전속도, 공구반지름, 절삭력, 축방향 절삭깊이, 날 당 이송의 5 소자로 하고, 출력층은 반경방향 절삭깊이의 1 소자로 설정하였다. 의역 네트워크의 학습 능력을 검증하기 위하여 학습을 수행하고 학습하지 않은 데이터에 대한 RMS 오차를 계산하였다. 두 가지 네트워크의 결과를 이용하여 시스템 네트워크로부터 주어진 절삭조건에 따른 절삭력을 예측하고, 또한 의역 네트워크로부터 희망하는 절삭력에 따른 절삭조건을 추출한다. 이 추출된 절삭조건을 시스템 네트워크에 입력하면 조정된 절삭력이 구해지며, 조정된 절삭력이 희망하는 절삭력과 차이가 나는 경우에는 보간법에 의하여 절삭조건을 재조정하고 재조정된 절삭조건을 시스템 네트워크에 입력하여 재조정된 절삭력을 구하는 방식으로 프로그램을 작성하였다.

이 프로그램으로 몇 가지 예제를 해석하였으며 이와 같은 방식을 이용하면 절삭조건을 과소하게 지정하여 절삭성능을 저하하거나, 절삭조건이 과도하여 큰 절삭력을 유발함으로써 절삭 중에 야기되는 진동 또는 정밀도 저하 문제를 해결할 수 있을 것으로 기대되며,

따라서 엔드밀 가공 시의 절삭성능 개선에 기여할 수 있을 것으로 판단된다.

References

- [1] Boothroyd, G., 1975, Fundamentals of Metal Machining and Machine Tools, Scripta Book Co., Washington.
- [2] Lee, S. Y., Im, Y. M., 2004, Prediction and Experiments of Cutting Forces in End Milling, J. of the KSMTE, 13:4 9-15.
- [3] Smith, S., Tlustý, J., 1993, Efficient Simulation Programs for Chatter in Milling, Int. J. Mach. Tool Des. Res., 35:7 939-950.
- [4] Kline, W. A., DeVor, R. E., Lindberg, J. R., 1982, The Prediction of Cutting Forces in End Milling with Application to Cornering Cuts, Int. J. Mach. Tool Des. Res., 22:11 7-22.
- [5] An, H. S., 2016, A Study on Split Training and Merging Method for Effective Initialization of Deep Neural Network, Doctorate Thesis, Inha University, Republic of Korea.
- [6] Rumelhart, D. E., Hinton, G. E., Williams, R. J., 1986, Learning Representations by Back Propagation errors, Nature, 323 533-536.
- [7] Shiotsuka, T., Ohta, K., Yoshida, K., Nagamatsu, A., 1993, Identification and Control of Four-Wheel-Steering Car by Neural network, Trans. JSME, C 59 708-713.
- [8] Cha, Y. H., Kim, I. S., Kim, H. S., Lee, Y. S., Kim, D. J., Sung, B. S., Suh, J. Y., 2000, A Study on the Prediction of Welded Residual Stresses using Neural Network, J. of the KSMTE, 9:6 89-95.
- [9] Hong, S. H., Cho, S. S., Joo, W. S., 2001, A Study on Fatigue Damage Model Using Neural Network, J. of the KSMTE, 10:4 14-21.
- [10] Fukuda, T., Kurihara, T., Tokita, M., Mitsuoka, T. 1990, Position and Force Hybrid Control of Robotic Manipulator by Neural Network, Trans. JSME, C 56 1854-1860.
- [11] Lee, S. Y. 2016, Simulating Cutting Forces in Milling Machines Using Multi-layered Neural Networks, J. of the KSMTE, 25:4 271-280.