

신경회로망을 이용한 엔드밀 가공의 비절삭력계수 모델링

이 신 영* · 이 장 무**
(1998년 8월 22일 접수)

Specific Cutting Force Coefficients Modeling of End Milling by Using Neural Network

Sin-Young Lee and Jang Moo Lee

Key Words: Specific Cutting Force Coefficients(비절삭력계수), End Milling(엔드밀링), Cutting Dynamics(절삭동역학), Chip Load(칩부하), Neural Network(신경회로망), Cutting Experiments(절삭실험).

Abstract

In a high precision vertical machining center, the estimation of cutting forces is important for many reasons such as prediction of chatter vibration, surface roughness and so on, and cutting forces are difficult to predict because they are very complex and time variant. In order to predict the cutting forces of end-milling process for various cutting conditions, a mathematical model is important and this model is based on chip load, cutting geometry, and the relationship between cutting forces and chip loads. Specific cutting force coefficients of the model have been obtained as interpolation function types by averaging forces of cutting tests. In this paper, the coefficients are obtained by neural network and the results of the conventional method and those of the proposed method are compared. The results show that the neural network method gives more correct values than the function type and that in learning stage as the omitted numbers of experimental data increases the average errors increase.

1. 서론

밀링가공 공정에 있어서 이송량 혹은 절삭깊이는 바람직하지 않은 진동인 채터(chatter) 또는 과도한 절삭력으로 인한 변형으로 인하여 종종 제한을 받게 된다.⁽¹⁾

고정밀 머시닝센터에 있어서 회전부의 불평형 질량이나 절삭력의 변동에 의하여 채터진동이 쉽게 발생된다. 머시닝센터의 채터 특성을 해석하기 위해서는, 기계 구조의 동적 특성과 절삭동역

학을 인지하는 것이 필요하다.⁽²⁾ 구조동특성에 대하여 많은 연구가 진행되어 왔으며 절삭동역학에 있어서 다양한 절삭조건에 대한 밀링 공정의 절삭력을 예측하기 위하여 많은 방법들이 연구되어 왔다. 나선 엔드밀에 의한 가공에 대하여 일정한 원주절삭저항과 절삭력비 상수가 사용되었고,⁽³⁾ Altintas 등⁽⁴⁾과 Minis 등⁽⁵⁾은 직선 엔드밀 가공에 있어서 일정한 비절삭압력과 절삭력비를 제시하였다. Targ⁽⁶⁾은 증분식 접선력에 대한 비절삭압력과 접선방향 힘에 대한 반경방향 힘의 비율을 회전당 평균 칩 두께의 지수함수로써 표현하였고, 김국원 등⁽⁷⁾은 유한요소 해석을 통하여 금속절삭을 해석하려고 하였다. Smith 등⁽⁸⁾은 일정한 절삭강성을 도입하였고 반경방향 힘을 접선방향 힘에 비례한다고 고려하였다. Kline 등에 의하여 칩 부하와 절삭 기하학 및 절삭력과 칩 부하 사이의 관계에 기초를 둔 수학적 모델이 주어졌

* 회원, 군산대학교 기계공학부

** 회원, 서울대학교 공과대학

다.⁽⁹⁾ 이 모델의 비절삭상수는 절삭실험에서 얻어진 평균절삭력으로부터 얻어진다.

본 논문에서는, 머시닝센터에서 엔드밀 가공 중의 절삭력을 예측하기 위하여 밀링가공 중의 절삭력에 대한 수학적 모델을 제시하였으며, 이 모델은 칩 부하와 절삭 기하학 및 절삭력과 칩 부하 사이의 관계에 기초를 두고 있다. 이 모델을 가지고 엔드밀 가공의 절삭력을 예측하기 위하여 수직머시닝센터에서 다양한 절삭조건에 대하여 절삭실험을 수행하였다. 이 모델의 비절삭력계수는 절삭실험에서 얻어진 평균 절삭력으로부터 신경회로망⁽¹⁰⁻¹⁴⁾을 이용하여 얻어진다. 주어진 절삭조건하에서의 절삭력을 예측하는 프로그램을 개발하였고, 여러 가지 절삭조건에 대하여 절삭력을 계산하였으며 실험결과와 비교하였다.

2. 밀링가공의 절삭동역학

절삭력 예측의 기본 요소는 Fig. 1에 표시한 바와 같이 공구에 작용하는 칩 부하(chip load)이다. 칩 두께에 대하여 제안된 많은 식 중에서 가장 기본적인 것은 식 (1)이다.

$$t_c = f \sin \beta \quad (1)$$

여기에서 t_c 는 순간적인 칩두께, f 는 날당 이송이고 β 는 절삭 중 공구날의 각 위치(angular position)를 나타낸다. 임의의 순간에 대한 엔드밀 칩 부하의 총합은 공구의 축을 따라서 분할된 얇은 원판 형상의 각각의 칩 부하를 합한 것이다. 절삭력은 칩부하에 비례하는 접선절삭력과 접선절삭력에 비례하는 반경방향 절삭력으로 구성된다.

$$\Delta F_{\tan} = K_{T_0} D_z t_c \quad (2)$$

$$\Delta F_{rad} = K_R \Delta F_{\tan} \quad (3)$$

여기에서 ΔF_{\tan} 는 해당하는 날에 대한 접선 방향 힘, ΔF_{rad} 는 날에 대한 반경방향 힘, D_z 는 축방향으로 절단된 미소원판의 폭, t_c 는 식 (1)의 칩두께, K_{T_0} 와 K_R 는 실험에서 구해지는 상수들이다.

비절삭력(specific cutting force) K_{T_0} 는 칩두께에 따라서 변화하지만 비선형 정도가 약하므로 개략적으로 다음과 같이 사용할 수 있다.




Fig. 1 Concept of end-milling.

$$\begin{aligned} \Delta F_{\tan} &= [Ct_c^{-0.3}]D_z t_c \\ &= CD_z (f \sin \beta)^{0.7} \approx K_T D_z f \sin \beta \quad (4) \end{aligned}$$

식 (4)의 비절삭력계수 K_T 는 이송, 반경방향 절삭깊이, 축방향 절삭깊이 등의 각종 절삭조건에 따라 변한다. 반지름이 Rad , 엔드밀의 날수가 N_f 이고 나선각이 α_{hx} 인 공구에 의한 하향 절삭의 경우에 대하여 적용하면

$$\begin{aligned} \beta(i, k, t) &= -\theta(t) + \frac{2\pi}{N_f}(k-1) \\ &\quad + (i - \frac{1}{2})D_z \cdot \frac{\tan \alpha_{hx}}{Rad} \quad (5) \end{aligned}$$

여기에서 i 는 축방향 미소원판의 번호, t 는 경과시간, k 는 날의 번호이다. 이 $\beta(i, k, t)$ 값 중에서 절삭범위 안에 해당하는 경우만이 절삭력에 기여하게 된다. 접선방향과 반경방향은 전체 좌표계 X, Y 로 분해될 수 있고, 그 합이 절삭력이 된다.

$$\begin{aligned} F_x(t) &= \sum_{i=1}^{N_s} \sum_{k=1}^{N_f} \{ -\Delta F_{rad}(i, k, t) \sin \beta(i, k, t) \\ &\quad + \Delta F_{\tan}(i, k, t) \cos \beta(i, k, t) \} \quad (6a) \end{aligned}$$

$$\begin{aligned} F_y(t) &= \sum_{i=1}^{N_s} \sum_{k=1}^{N_f} \{ \Delta F_{rad}(i, k, t) \cos \beta(i, k, t) \\ &\quad + \Delta F_{\tan}(i, k, t) \sin \beta(i, k, t) \} \quad (6b) \end{aligned}$$

식 (3), (4)를 식 (6)에 대입하면

$$F_x(t) = K_T D_2 f \sum_{i=1}^{N_x} \sum_{k=1}^{N_t} \{-K_R \sin^2 \beta(i, k, t) + \sin \beta(i, k, t) \cos \beta(i, k, t)\} \quad (7a)$$

$$F_y(t) = K_T D_2 f \sum_{i=1}^{N_x} \sum_{k=1}^{N_t} \{K_R \sin \beta(i, k, t) \cdot \cos \beta(i, k, t) + \sin^2 \beta(i, k, t)\} \quad (7b)$$

따라서 절삭력은 비절삭력계수 K_R , K_T 의 함수가 되며 비절삭력계수를 구하면 임의의 시에서의 절삭력을 해석할 수 있게 된다.

3. 비절삭력계수의 결정

3.1 최소자승법에 의한 비절삭력계수

특정한 절삭조건(주어진 공구에 대한 반경방향 및 축방향 절삭깊이, 이송)에 대하여 평균절삭력을 구하면, 평균절삭력은 K_R , K_T 의 함수이므로 1회의 실험에서 1쌍의 K_R , K_T 를 구할 수 있다. 이송과 반경방향 절삭깊이, 축방향 절삭깊이를 각각 변화시켜 가면서 K_T 와 K_R 을 구하면 최소자승법(least square method)에 의하여, 이송, 반경방향 절삭깊이 및 축방향 절삭깊이의 보간함수 형태로 K_T 와 K_R 을 표현할 수 있다.

$$K_T = a_0 + a_1 RD + a_2 AD + a_3 f + a_4 RD \cdot AD + a_5 f \cdot RD + a_6 f \cdot AD + a_7 RD^2 + a_8 AD^2 + a_9 f^2 \quad (8a)$$

$$K_R = b_0 + b_1 RD + b_2 AD + b_3 f + b_4 RD \cdot AD + b_5 f \cdot RD + b_6 f \cdot AD + b_7 RD^2 + b_8 AD^2 + b_9 f^2 \quad (8b)$$

위 방법을 Least square method A라 표시하고, 이 방법에 의한 모델링의 표현정도를 개선하기 위하여 절삭실험에서의 변수인 공구 직경과 절삭속도를 추가하여 최소자승법으로 비절삭력계수를 구하는 방법을 Least square method B라고 표시하여 프로그래밍 하였다.

3.2 신경회로망을 이용한 비절삭력계수

주어진 절삭조건에서 변수가 되는 것은 공구지름, 반경방향 및 축방향 절삭깊이, 이송, 절삭속

도 등과 같이 다양하다. 따라서 식 (8)의 최소자승법으로 비절삭력계수 K_R , K_T 를 이송, 반경방향 절삭깊이 및 축방향 절삭깊이의 함수 형태로 표현하는 것이 많이 사용되기는 하지만, 공구 직경 및 절삭속도 등의 여러 변수를 변경하는 경우 식 (8)과 같이 세 가지의 인자만을 사용하는 것은 절삭력의 계산결과에 오차가 있게 된다. 그러므로 본 연구에서는 공구직경과 절삭속도를 입력변수에 추가하는 최소자승법에 의한 모델링을 제시하는 한편, 주어진 절삭조건에서 구해진 여러 쌍의 비절삭력계수로부터 신경회로망을 이용하여 비절삭력계수를 계산하는 방법을 구현하고자 하였다. 신경회로망의 입력변수는 공구지름, 반경방향 절삭깊이, 축방향 절삭깊이, 이송, 및 절삭속도로 하고, 신경회로망의 출력변수는 반경방향 및 접선방향 비절삭력계수로 하였다.

3.3 신경회로망 이론

신경회로망의 기본 구조는 다입력 1출력의 뉴론이라고 부르는 단위소자로 구성된다.⁽¹⁰⁻¹³⁾ 각 뉴론의 내부상태 U_i^n 와 출력 O_i^n 은 결합계수 $W_{j,i}^{n-1,n}$ 와 역치 θ_i^n 를 사용하여 표현된다.

$$U_i^n = \sum_{j=1}^k W_{j,i}^{n-1,n} O_j^{n-1} + \theta_i^n \quad (9)$$

$$O_i^n = f(U_i^n) \quad (10)$$

본 논문에서는 출력함수 $f(x)$ 로서 변형된 시그모이드(sigmoid)함수를 사용하였다.

$$f(x) = \frac{2}{1 + \exp(-x/a)} - 1 \quad (11)$$

여기에서 a 는 함수의 기울기를 나타내는 상수이다. 또한 신경회로망은 뉴론모델을 Fig. 2에 표시한 바와 같은 계층형 네트워크로 사용한다. 가중치와 역치의 학습에는 오차역전파법을 사용하였다.⁽¹⁰⁾ Fig. 2에 표시한 N 층 신경회로망을 고려하면, 제 N 층 i 번째 뉴론의 내부상태 및 출력은 다음 식과 같다.

$$U_i^N = \sum_{j=1}^k W_{j,i}^{N-1,N} O_j^{N-1} + \theta_i^N \quad (12)$$

$$O_i^N = f(U_i^N) \quad (13)$$




Fig. 2 N layer neural network.

최종항 N 층에서의 오차제곱을 평가함수 J 라고 하고 다음과 같이 정한다.

$$J = \sum_{i=1}^m (T_i - O_i^N)^2 / 2 \quad (14)$$

여기에서 T_i 는 교사신호라고 부르는 것으로 입력신호에 대한 理想出力值이다. 최급강하법에 의하면 일반적으로 제 n , $n-1$ 층간에 있어서 결합계수 및 역치의 수정은 다음 식과 같다.

$$\begin{aligned} W_{j,i}^{n-1,n}(t+1) &= W_{j,i}^{n-1,n}(t) + \Delta W_{j,i}^{n-1,n} \\ \theta_i^n(t+1) &= \theta_i^n(t) + \Delta \theta_i^n \end{aligned} \quad (15)$$

여기에서,

$$\begin{aligned} \Delta W_{j,i}^{n-1,n} &= -\varepsilon \frac{\partial J}{\partial W_{j,i}^{n-1,n}} \\ \Delta \theta_i^n &= -\varepsilon \frac{\partial J}{\partial \theta_i^n} \end{aligned} \quad (16)$$

ε 은 양의 상수이다. 여기에서 최종 출력층인 제 N 층에서의 오차신호로써

$$\delta_i^N = \frac{\partial J}{\partial U_i^N} = -(T_i - O_i^N) f'(U_i^N) \quad (17)$$

라고 놓으면, N , $N-1$ 층 사이의 결합계수와 역치의 각각의 수정량은 다음 식과 같이 표현된다.

$$\begin{aligned} \Delta W_{j,i}^{N-1,N} &= -\varepsilon \delta_i^N O_j^{N-1}, \\ \Delta \theta_i^N &= -\varepsilon \delta_i^N \end{aligned} \quad (18)$$

제 $N-1$, $N-2$ 층간에서 결합계수와 역치의 평가함수 J 의 gradient는 다음과 같다.

$$\frac{\partial J}{\partial W_{s,j}^{N-2,N-1}} = \left(\sum_{i=1}^m \delta_i^N W_{j,i}^{N-1,N} \right) f'(U_j^{N-1}) O_s^{N-2} \quad (19)$$

$$\frac{\partial J}{\partial \theta_j^{N-1}} = \left(\sum_{i=1}^m \delta_i^N W_{j,i}^{N-1,N} \right) f'(U_j^{N-1}) \quad (20)$$

이와 같은 방법을 이용하여 제 $N-1$, $N-2$ 층 사이의 결합계수 및 역치의 각각의 수정량을 구할 수 있다. 학습의 수렴을 빨리 하기 위하여 결합계수와 역치의 수정법으로써 식 (21), (22)와 같은 관성항을 고려한 모멘트(moment)법 등이 제안되어 있다.

$$\Delta W_{j,i}^{n-1,n}(t) = -\varepsilon \delta_i^n O_j^{n-1} + \alpha \Delta W_{j,i}^{n-1,n}(t-1) \quad (21)$$

$$\Delta \theta_i^n(t) = -\varepsilon \delta_i^n + \alpha \Delta \theta_i^n(t-1) \quad (22)$$

여기에서 t 는 수정의 횟수를 나타낸다.

오차역전파법에서 최대의 결점은 극소치에 떨어질 가능성이 높은 점이다. 이 결점을 피하기 위하여 본 논문에서는 다음과 같은 변화를 주어 제의 특성을 인식하는데 사용하였다. 그 첫째는 식 (23), (24)와 같이 전전회의 수정량을 고려하는 假想임피던스법⁽¹⁴⁾을 사용하였고, 둘째는 시그모이드 함수의 기울기도 학습변수에 포함시켜 오차역전파법에 의하여 기울기를 결정하는 방법을 사용하였다.

$$\begin{aligned} \Delta W_{j,i}^{n-1,n}(t) &= -\varepsilon \delta_i^n O_j^{n-1} + \alpha_1 \Delta W_{j,i}^{n-1,n}(t-1) \\ &\quad + \alpha_2 \Delta W_{j,i}^{n-1,n}(t-2) \end{aligned} \quad (23)$$

$$\begin{aligned} \Delta \theta_i^n(t) &= -\varepsilon \delta_i^n + \alpha_1 \Delta \theta_i^n(t-1) \\ &\quad + \alpha_2 \Delta \theta_i^n(t-2) \end{aligned} \quad (24)$$

4. 절삭실험 및 비절삭력계수의 결정

4.1 절삭실험

머시닝센터에서 다양한 조건하에 절삭실험에 의하여 비절삭력계수를 실험적으로 결정하고, 최소자승법에 의하여 개발된 프로그램으로부터 식 (8)의 상수들을 구하였다. 본 논문에 사용된 머시닝센터는 통일산업의 TNV-40이고 절삭력 측정을 위하여 공구동력계(Kistler 9257B)를 사용하였다. 실험에서의 절삭조건은 Table 1과 같고, 엔드밀 직경이 16mm인 경우의 평균절삭력의 예는 Table

2와 같으며, 엔드밀 직경이 20mm인 경우의 예는 Table 3과 같이 구해졌다. 최소자승법에 의한 비절삭력계수의 계수들은 Table 4와 같이 구해졌고, 이 계수들을 사용하여 구한 비절삭력계수와 절삭 실험에서 구한 비절삭력계수들을 비교하면 Table 5와 같다. Table 6에는 절삭실험에 의해서 얻어진

Table 1 Cutting conditions for tests.

Diameters of cutter(mm)	16, 20
Radial depth of cut (mm)	2, 4, 6, 8, 10
Axial depth of cut (mm)	12, 20
Feedrate (mm/min)	67, 85, 120
Spindle speed (R. P. M.)	480, 600, 900

Table 2 Samples of average cutting forces for each cutting test(tool diameter 16mm).

No	Radial depth (mm)	Axial depth (mm)	RPM	Feed (mm/min)	Fx (N)	Fy (N)
1	2	20	600	85	294.2	409.4
2	4	20	600	85	457.5	763.7
4	8	20	600	85	343.8	1523.
11	4	20	600	120	576.9	1035.
12	6	20	600	120	577.2	1584.
17	8	20	900	120	254.1	1369.
25	6	12	900	85	141.7	557.9
26	8	12	900	85	102.1	578.2
37	10	12	900	120	-254.4	1154.

Table 3 Samples of average cutting forces for each cutting test (tool diameter 20 mm).

No	Radial depth (mm)	Axial depth (mm)	RPM	Feed (mm/min)	Fx (N)	Fy (N)
38	2	12	480	67	171.6	199.3
39	4	12	480	67	389.8	542.5
41	8	12	480	67	190.3	1091.
48	4	12	480	85	447.6	778.4
49	6	12	480	85	480.5	1221.
56	2	20	480	67	393.8	293.3
62	6	20	600	67	435.7	1328.
63	8	20	600	67	353.4	1841.
74	10	20	600	85	231.0	3888.

Table 4 Coefficients of specific cutting forces in least square method A.

a_i	-0.831E10, -0.161E12, 0.810E12, 0.205E15, -0.450E12, 0.137E16, -0.121E16, 0.619E13, -0.207E14, -0.135E19
b_i	-0.443, 72.7, 46.98, 8590., -2987., -0.804E05, -0.153E06, -907., -577., -0.394E08

Table 5 Comparisons of specific cutting forces

Sample No	$K_T (\times 10^{10})$		K_R	
	Experiment	Calculated	Experiment	Calculated
1	0.4047	0.5324	0.5076	0.4589
2	0.3833	0.5211	0.3593	0.4566
11	0.3572	0.4110	0.3949	0.4387
12	0.3464	0.4194	0.3847	0.4245
25	0.3991	0.4139	0.5054	0.4536
26	0.3231	0.4067	0.4136	0.5064
37	0.3274	0.4945	0.7493	0.5563
38	0.4529	0.5233	0.4630	0.3782
39	0.6056	0.5011	0.3512	0.4230
48	0.6156	0.4681	0.4695	0.4284
49	0.6080	0.4624	0.4701	0.4654
62	0.5984	0.4957	0.5429	0.4574
63	0.6119	0.5018	0.5411	0.4600
74	0.8107	0.5529	0.5562	0.4468

Table 6 Comparisons of cutting forces

Sample No	Fx (N)		Fy (N)	
	Experiment	Calculated	Experiment	Calculated
1	294.2	400.3	409.4	513.1
2	457.5	551.7	763.7	1124.
11	576.9	628.6	1035.	1234.
12	577.2	641.8	1584.	1968.
25	141.7	167.7	557.9	560.4
26	102.1	75.0	578.2	761.8
37	-254.4	-133.2	1154.	1629.
38	171.6	208.0	199.3	209.0
39	389.8	301.1	542.5	479.5
48	447.6	354.9	778.4	571.0
49	480.5	368.4	1221.	925.5
62	435.7	420.6	1328.	1037.
63	353.4	374.7	1841.	1440.
74	231.0	371.6	3888.	2515.

평균절삭력과 Table 4의 계수들에 의하여 구해진 평균절삭력을 비교하였다.

4.2 신경회로망을 이용한 비절삭계수 계산

Table 4와 같이 최소자승법을 이용한 전통적인 방법의 경우 Table 5와 Table 6에 나타낸 바와 같이 오차가 비교적 커서, 본 연구에서는 공구직경과 절삭속도를 추가하는 방법에 의한 비절삭력계수를 구현하는 방법을 사용하였고 또한 신경회로망을 이용한 절삭계수 계산방법을 제안한다. 신경회로망에 의한 학습에 있어서 3층으로 이루어진 회로망을 사용하였고 입력층 변수는 공구지름, 반경방향 절삭깊이, 축방향 절삭깊이, 이송량, 절삭속도의 5종으로 하였으며 출력층 변수는 비절삭력계수 K_R 과 K_T 로 하였다. 각 층간의 결합계수 초기치는 임의의 난수를 발생시켜 설정하고, 은닉층(제2층)의 뉴런 수를 변화시켜 가며 학습하였다. 은닉층이 25, 30인 경우의 학습오차변화는 각각 Fig. 3 및 4의 가는 곡선 한 개와 같고, Fig. 3과 4에서 굵은 선은 그 평균을 나타낸다.

Fig. 5는 은닉층의 뉴런 수가 변화됨에 따른 학습결과 오차의 평균치 변화를 나타낸다. Fig. 3, Fig. 4 및 Fig. 5에서 교사신호의 수는 74쌍이었다. Table 7에는 은닉층의 뉴런 수를 30으로 하고 학습한 결과를 이용하여 비절삭력계수 및 평균절삭력을 계산한 것을 나타낸다. 이 경우는 오차를 비교하는 Table 8의 NH30, case 7에 해당하는 것이고, 실험에 의한 비절삭력계수와 절삭력은 Table 5와 6에 제시되어 있다. Table 4의 결과(LMS A로 표시) 및 최소자승법에 공구직경과 절삭속도를 추가한 결과(LMS B), 은닉층 뉴런의 수




Fig. 3 Error trends when No. of neurons in hidden layer(NH) is 25.




Fig. 4 Error trends when No. of neurons in hidden layer(NH) is 30.




Fig. 5 Error trends with various No. of neurons in hidden layer.

Table 7 Calculation results using neural network

Sample No	Specific cutting coeff.		Cutting forces (N)	
	$K_T \times 10^{10}$	K_R	Fx	Fy
1	0.4044	0.5076	294.0	409.2
2	0.3836	0.3593	457.9	764.4
11	0.3582	0.3948	578.6	1038.
12	0.3450	0.3847	574.9	1578.
25	0.3981	0.5054	141.3	556.4
26	0.3239	0.4138	102.2	579.8
37	0.3276	0.7494	-254.5	1154.
38	0.4527	0.4628	171.6	199.2
39	0.6059	0.3513	390.0	542.8
48	0.6159	0.4694	447.8	778.7
49	0.6072	0.4700	480.0	1219.
62	0.6003	0.5430	437.0	1332.
63	0.6104	0.5411	352.6	1836.
74	0.8088	0.5564	229.9	3879.

를 30과 35개로 하였을 때, 평균절삭력을 계산한 경우의 오차의 평균은 Table 8과 같다. Table 8은 전체 실험에 대한 데이터를 신경회로망의 학습에 이용한 경우의 결과이다. 여기에서 신경회로망의 경우는 각기 독립적으로 학습시킨 15 개의 신경회로망에 대한 결과들과 그것들의 평균을 나타낸다. 학습하지 않은 경우에 대한 예측정도를 확인하기 위하여 전체 실험 중 임의의 실험을 제외시켜 학습을 수행한 후 전체 실험에 대한 오차의 평균을 계산한 결과는 Table 9 및 Table 10과 같다.

Table 9는 임의의 6 개의 실험을 학습에서 제

외시킨 경우이고, Table 10은 임의의 10 개의 실험을 학습에서 제외시켜 64 쌍의 실험을 학습에 이용한 경우를 나타낸다. Table 8, 9 및 10을 종합하여 그 평균들만을 도시하면 Fig. 6과 같다.

Fig. 6을 보면 전통적으로 반경방향 절삭깊이, 축방향 절삭깊이 및 이송을 입력변수로 하여 최소자승법에 의하여 비절삭계수를 단순함수 형태로 구한 경우보다 공구직경 및 절삭속도를 추가한 경우가 오차가 적으며, 이 두 가지 경우보다 신경회로망을 이용하여 비절삭계수를 구하는 경우가 오차가 적음을 알 수 있다. 또한 F_y 의 경우가 F_x 의 경우보다 오차가 적은데 이것으로부터

Table 8 Averages of errors by LMS and neural networks.

Method	NH	C a s e	Errors (%) in average F _y	Errors (%) in average F _x		
LMS A	-	-	33.1	31.3		
LMS B	-	-	15.6	26.8		
Neural Network	30	1	0.05	0.06		
		2	0.03	0.04		
		3	0.06	0.07		
		4	0.03	0.05		
		5	0.02	0.03		
		6	0.31	0.33		
		7	0.14	0.14		
		8	0.08	0.09		
		9	0.14	0.18		
		∴	∴	∴		
		14	0.03	0.05		
		15	0.09	0.13		
		Avg	0.15	0.19		
		Neural Network	35	1	0.02	0.03
				2	0.04	0.05
3	0.12			0.12		
4	0.18			0.03		
5	0.32			0.36		
6	0.15			0.19		
7	0.02			0.03		
8	0.08			0.10		
9	0.17			0.23		
∴	∴			∴		
14	0.19			0.20		
15	0.02			0.04		
Avg	0.11			0.13		

Table 9 Averages of errors by LMS and neural networks for 68 set of experiments.

Method	NH	C a s e	Errors (%) in average F _y	Errors (%) in average F _x		
LMS A	-	-	33.7	31.4		
LMS B	-	-	16.3	28.4		
Neural Network	30	1	6.24	3.20		
		2	7.08	23.7		
		3	5.98	14.9		
		4	6.25	19.5		
		5	6.76	21.9		
		6	5.53	3.74		
		7	6.48	16.7		
		8	8.75	5.57		
		9	5.93	6.88		
		∴	∴	∴		
		14	7.72	23.8		
		15	7.06	21.3		
		Avg	6.58	15.5		
		Neural Network	35	1	5.37	5.09
				2	5.57	7.77
3	9.57			13.9		
4	5.15			7.93		
5	6.11			8.25		
6	7.60			25.5		
7	8.64			9.06		
8	6.92			4.17		
9	9.66			9.63		
∴	∴			∴		
14	6.36			9.60		
15	7.41			15.2		
Avg	6.96			11.4		

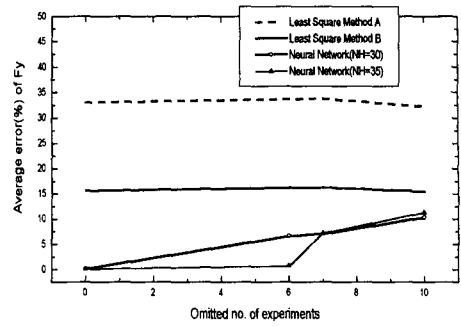
Table 10 Averages of errors by LMS and neural networks for 64 set of experiments.

Method	NH	C a s e	Errors (%) in average Fy	Errors (%) in average Fx		
LMS A	-	-	32.3	30.7		
LMS B	-	-	15.4	27.5		
Neural Network	30	1	9.45	17.1		
		2	7.21	18.9		
		3	13.7	12.8		
		4	14.8	14.1		
		5	9.77	21.6		
		6	6.94	30.9		
		7	4.23	22.7		
		8	11.4	26.1		
		9	9.60	14.9		
		∴	∴	∴		
		14	15.2	14.4		
		15	14.6	15.0		
		Avg	10.3	20.3		
		Neural Network	35	1	5.63	19.5
				2	13.2	20.3
3	14.2			19.3		
4	9.33			16.8		
5	15.8			23.5		
6	7.48			17.3		
7	12.0			11.1		
8	5.35			17.3		
9	5.25			21.5		
∴	∴			∴		
14	13.1			16.4		
15	13.8			14.3		
Avg	11.3			17.9		


터 F_x 의 측정실험에 오차가 많았음을 유추할 수 있다. 또한 Fig. 5에서 예상되었던 바와 같이 중간 은닉층의 뉴런 수가 30인 경우와 35인 경우는 오차에 있어서 큰 차이를 보이지 않는다. 한편, 신경회로망의 학습에 있어서 전체 데이터를 사용하지 않고 일부분의 데이터를 누락시켜서 학습을 하고 그 경우에 얻어진 평균오차를 검토하여 보면, 누락시킨 즉 학습시키지 않은 데이터의 수가 증가할수록 오차의 평균이 증가하여 가는 것을 알 수 있다.

5. 결 론

본 논문에서는, 머시닝센터의 절삭력 해석 및



(a) Average error of y directional forces



(b) Average error of x directional forces

Fig. 6 Average errors with number of omitted experimental data.

예측에 대한 수학적 모델을 제시하였으며, 이 모델은 칩 부하와 절삭 기하학 및 절삭력과 칩 부하 사이의 관계에 기초를 두고 있다. 이 모델을 가지고 엔드밀 공정의 절삭력을 예측하기 위하여 다양한 절삭 조건에 대하여 절삭실험을 수행하였다. 절삭실험에서 얻어진 평균 절삭력으로부터 공구 직경 및 절삭속도를 추가 입력으로 하는 방법을 제시하고, 신경회로망에 의하여 비절삭력계수를 구하는 방법을 제시하였다. 또한 전체 데이터, 임의의 데이터를 제외한 부분 데이터로부터 절삭계수를 구하고 실험치와 비교한 결과를 축방향 및 반경방향 절삭깊이와 이송을 입력으로 하는 일반적으로 사용하는 최소자승법에 의한 방법과 비교하여 볼 때, 본 논문에 의한 방법으로 엔드밀 가공의 절삭력을 보다 정확하게 구할 수

있었다. 또한 학습에 포함되지 않은 데이터의 수가 증가할수록 오차의 양이 증대함을 나타내었다.

참고문헌

- (1) Boothroyd, G., 1981, *Fundamentals of Metal Machining and Machine Tools*, McGraw-Hill International Book Co.
- (2) Sridhar, R., Hohn, R. E. and Long, G. W., 1968, "A General Formulation of the Milling Process Equation," *Trans. ASME, Journal of Engineering for Industry*, Vol. 90, pp. 317 ~ 324.
- (3) Ber, A., Rotberg, J. and Zombach, S., 1988, "A Method for Cutting Force Evaluation of End Mills," *Annals of the CIRP*, Vol. 37/1, pp. 37 ~ 40.
- (4) Altintas, Y. and Ghan, Philip K., 1992, "In-Process Detection and Suppression of Chatter in Milling," *Int. J. Mach. Tool Des. Res.*, Vol. 32, No. 3, pp. 329 ~ 347.
- (5) Minis, I., Yanushevsky, R. and Tembo, A., 1990, "Analysis of Linear and Nonlinear Chatter in Milling," *Annals of the CIRP*, Vol. 39/1, pp. 459 ~ 462.
- (6) Tarng, Y. S., Cheng, C. I. and Kao, J. Y., 1995, "Modeling of Three Dimensional Numerically Controlled End Milling Operations," *Int. J. Mach. Tool Des. Res.*, Vol. 35, No. 7, pp. 939 ~ 950.
- (7) 김국원 · 이우영 · 신호철, 1998, "공구끝단반경이 고려된 2차원 금속절삭에 대한 열-점소성 유한요소해석," *대한기계학회논문집 A권*, 제22권 제1호, pp. 1 ~ 15.
- (8) Smith, S. and Tlusty, J., 1993, "Efficient Simulation Programs for Chatter in Milling," *Annals of the CIRP*, Vol. 42/1, pp. 463 ~ 466.
- (9) Kline, W. A., DeVor, R. E. and Lindberg, J. R., 1982, "The Prediction of Cutting Forces in End Milling with Application to Cornering Cuts," *Int. J. Mach. Tool Des. Res.*, Vol. 22, No. 11, pp. 7 ~ 22.
- (10) Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1986, "Learning Representations by Back-propagating Errors," *Nature*, Vol. 323, pp. 533 ~ 536.
- (11) Chong, K.T. and Parlos, A.G., 1997, "Comparison of Traditional and Neural Network Approaches to Stochastic Nonlinear System Identification," *KSME International Journal*, Vol. 11, No. 3, pp. 267 ~ 278.
- (12) 麻生英樹, 1991, *ニューラルネットワーク情報処理*, 産業圖書, 東京, pp.39 ~ 54.
- (13) 鹽塚稔也, 太田和重, 吉田和夫, 長松昭男, 1993, "ニューラルネットワークによる四輪操舵車の同定と制御", *日本機械學會論文集(C)*, 59卷 559號, pp. 708 ~ 713.
- (14) 淺川和雄, 渡部信雄, 川村 旭, 益岡龍介, 棚橋純一, 山田博, 1990, "階層ニューラルネットワークの機能と學習の高速化", *電學論C(日本)*, 110卷 3號, pp.141 ~ 146.