

## 신경망과 실험계획법을 이용한 절삭력 예측

이영문(경북대 기계공학부), 최봉환\*, 송태성, 김선일, 이동식(경북대 대학원 기계공학과)

### Prediction of Cutting Force using Neural Network and Design of Experiments

Y. M. Lee(Mech. Eng. Dept., KNU), B. H. Choi\*, T. S. Song, S. I. Kim, D. S. Lee(Graduate School, KNU)

#### ABSTRACT

The purpose of this paper is to reduce the number of cutting tests and to predict the main cutting force and the specific cutting energy. By using the SOFM neural network, the most suitable cutting test conditions has been found. As a result, the number of cutting tests has been reduced to one-third. And by using MLP neural network and regression analysis, the main cutting force and specific cutting energy has been predicted. Predicted values of main cutting force and specific cutting energy are well coincide with the measured ones.

Key Words : Main cutting force(주분력), Self Organizing Feature Map(SOFM, 자기조직화 형상지도), Regression analysis(회귀분석), Multi-Layer Perceptron(MLP, 다층퍼셉트론), Specific cutting energy(비절삭에너지)

#### 1. 서론

절삭과정은 그 본질에 있어 칩 생성과정이며, 대부분의 금속절삭시 칩 생성은 전단역이라 불리우는 극히 한정된 영역에서 매우 좁은 간격을 두고 잇달아 일어나는 집중된 전단소성변형에 의해 이루어지고 생성된 칩은 공기경사면과 심한 마찰을 일으키면서 외부로 배출된다. 따라서 절삭성 평가에 있어 가장 기초적인 문제는 전단소성변형거동과 칩-공구경사면의 마찰거동에 미치는 절삭조건, 피삭재와 공구의 재질 및 형상 등 절삭입력조건의 영향을 밝히는 것이다.<sup>(1-2)</sup> 절삭성 평가를 위하여 가장 일반적으로 채택되는 파라미터는 비절삭에너지(specific cutting energy)이다. 피삭재의 비절삭에너지를 구하기 위해서는 절삭실험을 통하여 주분력(main cutting force)을 측정해야 된다. 대부분의 연구에서는 절삭실험시 여러 가지 절삭입력조건 중 한번에 한 조건만을 변화시켜 실험함으로써 많은 실험량이 요구된다.

이러한 문제점을 해결하기 위해서 본 논문에서는 SOFM(Self Organizing Feature Map)신경망을 이용하여 여러가지의 절삭실험조건중 일부분의 실험조건만을 찾아내어 실험횟수를 줄이는 방법을 제시하였다. 또한 실험횟수의 감소가 타당한지를 검토하기 위해

서 SOFM신경망을 이용하여 찾아낸 조건만으로 절삭실험을 행하여 얻어진 주분력을 MLP(Multi-Layer Perceptron)신경망과 실험계획법(design of experiments) 중에서 회귀분석(regression analysis)을 이용하여 다른 절삭조건에서의 주분력을 예측하고, 예측된 주분력과 실험을 통해 구한 주분력과 비교하였다.

#### 2. 기초이론

##### 2.1 SOFM(Self Organizing Feature Map)

SOFM신경망은 자기조직화 형상지도 신경망으로서 Kohonen에 의해서 개발되어 코호넨 네트워크라고도 한다.<sup>(3)</sup>

SOFM신경망은 BP(backpropagation)신경망과는 달리 Fig. 1에서 보는 바와 같이 두 개의 층으로 이루어져 있다. 첫 번째 층은 입력층(input layer)이고 두 번째 층은 경쟁층(competitive layer)인데 2차원 격자(grid)로 되어 있다. SOFM신경망의 학습 철학은 '승자 독점(winner take all)'이다. 승자만이 출력을 낼 수 있으며, 승자와 그의 이웃들만이 그들의 연결강도를 조정할 수 있다. 식(1)은 승자뉴런과 그 이웃한 뉴런들의 연결강도(weight)를 재조정하는 식이다.




Fig. 1 SOFM model Fig. 2 Architecture of the MLP with two hidden layer

$$w_{i,j}(n+1) = w_{i,j}(n) + \alpha Z_k(x - w_{i,j}) \quad (1)$$

여기서  $w$ 는 연결강도(weight),  $\alpha$ 는 학습률,  $Z$ 는 Mexican-hat function이다.

## 2.2 MLP(Multi-Layer Perceptron)

MLP는 입력층(input layer)과 출력층(output layer) 사이에 하나 이상의 중간층이 존재하는 신경망이다. 이 때 입력층과 출력층 사이의 중간층을 은닉층(hidden layer)이라 부른다. 입력층과 출력층은 입력 유닛과 출력 유닛을 가지고 있는데, 이들은 각각 입력값과 출력값을 나타낸다. MLP의 학습 알고리즘의 기본원리는 흔히 오류 역전파(error backpropagation) 알고리즘을 이용하는데, 입력층의 각 유닛에 입력신호를 주면, 이 신호는 은닉층의 각 뉴런으로 전달되고, 이 신호는 다시 출력 뉴런으로 전달되어 출력층에서 신호를 출력하게 된다. 이 출력값과 목표값(target)을 비교하여 차이(error)를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다.<sup>(4)</sup> Fig. 2는 본 연구에서 사용한 은닉층이 두개인 MLP신경망의 구조를 나타낸 것이다. 여기서  $x$ 는 입력값,  $y$ 는 출력값,  $w$ 는 연결강도,  $i$ 는 입력층,  $k$ 와  $j$ 는 은닉층,  $l$ 는 출력층이다.  $h$ 는 시그모이드함수로서 식(2), (3)과 같고, 출력값  $y$ 는 식(4)로 표시할 수 있다

$$h_k^{(1)} = f\left(\sum_i w_{ki}x_i\right) \quad (2) \quad h_j^{(2)} = f\left(\sum_k w_{jk}h_k^{(1)}\right) \quad (3)$$

$$y_l = f\left(\sum_j w_{lj}h_j^{(2)}\right) \quad (4)$$

## 2.3 회귀분석(Regression analysis)

회귀분석이란 변수들간의 관련성을 규명하기 위하여 어떤 수학적 모형을 가정하고, 이 모형을 측정된 변수들의 데이터로부터 추정하는 통계적 분석방법이다. 본 연구에서는 종속변수의 변화를 설명하는 독립변수가 두 개 이상인 경우의 회귀모형인 다중회귀모형(multiple regression model)을 사용하였다.<sup>(5)</sup>

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad (5)$$

$$\beta_0, \beta_1, \beta_2, \dots, \beta_k : \text{회귀계수}$$

독립변수가  $X_1, X_2, \dots, X_k$ 로  $k$ 개이고 종속변수가  $Y$ 인 경우 다중회귀모형은 식(5)와 같다.

다중회귀모형 식(5)를 통해 독립변수  $X$ 와 종속변수  $Y$ 사이의 선형관계를 파악하고자 할 때 다중회귀분석 과정에서 제일 중요한 것은 회귀계수를 추정하는 것이다. 최소자승법(least square method)은 실제 관측된 종속변수  $Y$ 와 추정된 종속변수  $\bar{Y}$ 사이의 차이의 제곱합 즉 오차의 제곱합(sum of squares)인  $\sum(Y - \bar{Y})^2$ 을 최소화 하는 회귀계수  $\beta$ 를 추정하는 방법이다. 최소자승법에 의해 추정된 회귀계수  $\beta$ 에 대한 추정값을  $b$ 라 하면 추정된 다중회귀모형은 식(6)과 같다.

$$\bar{Y} = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_k X_k \quad (6)$$

다중회귀분석의 경우 통계 소프트웨어의 도움없이 데이터를 처리하는 것에는 한계가 있으므로 본 연구에서는 통계 프로그램인 SAS(statistical analysis system)를 이용하여 회귀식을 구하였다. SAS프로그램에서 회귀식을 구하는 방법으로 변수증감법(stepwise)을 이용하였다. 변수증감법은 매 단계에서 변수가 추가된 후 이미 있던 변수가 제거될 수 있는지를 고려하는 방식이다.

Table 1 Cutting test conditions

Cutting speed	80, 140, 200 m/min
Depth of cut (DOC)	0.8, 1.6, 2.4 mm
Feed rate	0.098, 0.296, 0.493 mm/rev

cutting speed(v)	depth of cut(d)	feed(f)	cutting area(fxd)
80	0.8	0.098	0.0784
80	0.8	0.296	0.2368
80	0.8	0.493	0.3944
80	1.6	0.098	0.1568
80	1.6	0.296	0.4736
80	1.6	0.493	0.7888
80	2.4	0.098	0.2352
80	2.4	0.296	0.7104
80	2.4	0.493	1.1832
140	0.8	0.098	0.0784
140	0.8	0.296	0.2368
140	0.8	0.493	0.3944
140	1.6	0.098	0.1568
140	1.6	0.296	0.4736
140	1.6	0.493	0.7888
140	2.4	0.098	0.2352
140	2.4	0.296	0.7104
140	2.4	0.493	1.1832
200	0.8	0.098	0.0784
200	0.8	0.296	0.2368
200	0.8	0.493	0.3944
200	1.6	0.098	0.1568
200	1.6	0.296	0.4736
200	1.6	0.493	0.7888
200	2.4	0.098	0.2352
200	2.4	0.296	0.7104
200	2.4	0.493	1.1832

## 3. 절삭실험

### 3.1 절삭실험조건

절삭실험조건은 Table 1에서 보는 것처럼 총 27회의 절삭실험조건을 설정하였다.

### 3.2 SOFM를 이용한 절삭실험조건

절삭실험에 앞서 본 연구에서는 총 27회의 절삭실험조건중 일부분의 절삭실험조건만을 찾아내기 위하여 SOFM신경망을 이용하였다. Fig. 3(a)는 SOFM

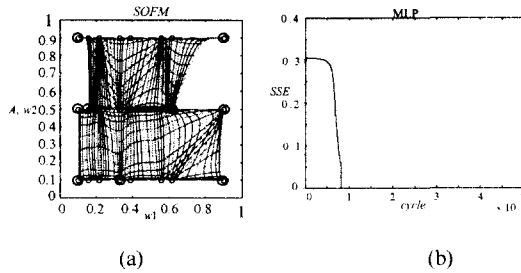


Fig. 3 Self organization of two dimensional and selection of cutting test conditions(a) and Graph of SSE(sum of square of error)(b)

신경망에서 입력패턴이 2차원인 지도가 자기조직화한 것을 나타낸 것이다.

절삭단면적 A는  $f \times d$ 로 정의할 수 있으며 절삭단면적이 커질수록 주분력은 증가하게 된다. 따라서 SOFM신경망에서 절삭조건  $f, d, V$ 를 2차원 입력값으로 절삭단면적( $f \times d$ ) A와 속도  $V$ 를 사용하였다.

Table 2 Selected cutting test conditions using SOFM

cutting speed(v)	depth of cut(DOC)	feed(f)
80	0.8	0.098
80	0.8	0.493
80	2.4	0.493
140	0.8	0.098
140	1.6	0.098
140	1.6	0.493
140	2.4	0.493
200	0.8	0.098
200	2.4	0.493

Fig. 3(a)에서 27개의 입력패턴 중 map상의 변곡점과, 입력패턴과 map이 서로 겹쳐지는 꼭지점, 그리고 map상의 weight가 임의의 입력패턴쪽으로 간격이 좁아지거나 혹은 치우치는 점들을 찾은 결과, 9개의 절삭실험조건을 찾았으며 Table 2에 나타내었다.

#### 4. 실험결과 및 고찰

##### 4.1 실험결과

SOFM을 이용하여 선택된 절삭조건 9개만을 실험을 하여 주분력  $F_y$ 를 구하여 Table 3에 나타내었다.

Table 3 Results of cutting test

cutting speed(v)	depth of cut(DOC)	feed(f)	$F_y$
80	0.8	0.098	238.72
80	0.8	0.493	850.02
80	2.4	0.493	2503.49
140	0.8	0.098	236.10
140	1.6	0.098	458.48
140	1.6	0.493	1517.54
140	2.4	0.493	2429.81
200	0.8	0.098	233.71
200	2.4	0.493	2267.29

##### 4.2 절삭력 예측 및 비교

Table 3에 나타난 결과를 MLP와 실험계획법의 회귀분석을 이용하여 실험을 하지 않은 절삭조건에 대하여 절삭력을 예측하고, 또 실제값과 비교하였다.

Fig. 3(b)는 MLP를 이용하였을 때 출력값과 목표값(target)을 비교하여 차이(error)가 0으로 수렴할 때

를 나타낸 것이다.


Table 4 Analysis of variance

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	7674727	3837363	3818.37	< .0001
Error	6	6363.13916	1060.52323		
Total	8	7681090			


Table 5 Regression coefficient and F-test of variable

Variable	Parameter Estimate	F Value	Pr > F
Intercept	142.23	88.79	0.0003
feed* $d$	2106.52	2482.65	< .0001
feed* $v$	3.84	31.2	< .0014


Table 4는 회귀모형식의 적합성 유무를 F검증을 통해 분산분석을 한 것이다. 유의수준을 5%로 했을 경우 귀무가설  $H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$ 을 기각하게 된다. 즉 모형으로서의 적합성을 인정하는 결론을 얻을 수 있다.



(a) Cutting speed : 80 m/min



(b) Cutting speed : 140 m/min



(c) Cutting speed : 200 m/min

Fig. 4 Measured and Predicted main cutting force using MLP and Regression model,  $F_y(N)$  vs. feedrate,  $f(mm/rev)$  with cutting speed(m/min) of (a)80 m/min, (b)140 m/min, (c)200 m/min

Table 5는 회귀계수와 회귀식에 사용된 변수들의 F검정을 통해 회귀식에 사용된 변수의 적합성을 나타낸 것이다. Table 5에서 보듯이 stepwise에서 사용된 유의수준 15%로 했을 경우 각 변수들은 회귀모형식에 적합함을 알 수 있다. 식(7)은 SAS프로그램을 이

용하여 회귀식을 구한 것이다.

$$F_y = 142.23 + 2106.52 \times f \times d - 3.84 \times f \times v \quad (7)$$

SOFM의 사용이 적합한지를 알기 위해서 MLP신경망과 회귀식을 이용하여 예측한 주분력과 실제 실험값과 비교하였다. Fig. 4는 실험을 통해 구한 주분력과 MLP, 회귀식을 이용해서 예측한 주분력을 절삭속도 별로 나타낸 것이다. Fig. 4에서 보듯이 실험값은 회귀식으로 예측한 주분력과 아주 잘 일치하고 있다. MLP로 예측한 주분력은 회귀식에 의한 예측값보다 실험값과 다소 큰 차이를 나타내고 있다.

### 4.3 비절삭에너지

절삭가공시 피삭재의 단위 체적당 소요되는 절삭에너지, 즉 비절삭에너지는 식(8)과 같이 나타낼 수 있다.


$$u = \frac{F_y v}{f d v} = \frac{F_y}{f d} \quad (8)$$

여기서  $F_y$ 는 주분력(main cutting force, N),  $V$ 는 절삭속도(cutting speed, m/min),  $f$ 는 이송속도(feed, mm/rev),  $d$ 는 절삭깊이(depth of cut, mm)이다.


식(9)는 식(7)을 식(8)에 대입하여 구한 비절삭에너지에 대한 회귀식이다.

$$u = \frac{142.23 + 2106.52 \times f \times d - 3.84 \times f \times v}{f \times d} \quad (9)$$


Fig. 5는 절삭실험을 통하여 구한 주분력과 MLP와 회귀식을 이용하여서 구한 주분력  $F_y$ 를 식(8)에 대입하여 구한 비절삭에너지(specific cutting energy)를 이송에 따라 나타낸 것이다. Fig. 5에서 보듯이 회귀식과 MLP신경망으로 구한 비절삭에너지는 이송속도가 증가함에 따라 지수함수적으로 감소하는 경향을 나타내고 있다.<sup>16)</sup>



(a) Cutting speed : 80 m/min



(b) Cutting speed : 140 m/min



(c) Cutting speed : 200 m/min

Fig. 5 Predicted specific cutting energy using MLP and Regression model,  $u(N/mm^2)$  vs. feedrate,  $f(mm/rev)$  with cutting speed(m/min) of (a)80 m/min, (b)140 m/min, (c)200 m/min

비절삭에너지는 식(8)을 이용하여 구한 값이므로 회귀식이 MLP신경망보다는 절삭실험값에 잘 일치하고 있음을 알 수 있다.

## 5. 결론

본 논문에서는 절삭실험횟수를 줄이기 위한 방안으로 SOFM신경망을 이용하여 일부분의 절삭실험조건을 찾아내고, SOFM신경망으로 찾아낸 실험조건으로 절삭실험을 행하여 절삭력과 비절삭에너지를 MLP신경망과 회귀분석을 통하여 다른 절삭실험조건에 대한 예측을 하였다.

실험결과, 총 27회의 절삭실험조건중 SOFM신경망으로 9회의 절삭실험조건을 찾아내었고 절삭력과 비절삭에너지를 예측한 결과 MLP신경망과 회귀식은 절삭실험을 통한 실제 절삭력과 비교적 잘 일치하였으며, 회귀식에 의한 경우가 실제값에 더 근접하였다.

## 참고문헌

1. 이영문, 송태성, 박태준, 장운실, "3차원 절삭시 칩-공구 마찰 및 전단특성 해석," 한국정밀공학회지, 제16권, 제12호, pp. 190-196, 1999.
2. Zorev, N. N., "Interrelationship Between Shear Processes Occurring Along Tool Face and on Shear Plane in Metal Cutting," Pro. Inter. Res. Prod. Conf., Carnegie Inst. of Tech., pp. 42-49, 1963.
3. T.Kohonen, "Self-organized formation of topologically feature maps," Biological Cybernetics, Vol. 43, pp. 59-69, 1982.
4. Pineda, F.J., "Generalization of back-propagation to recurrent neural networks," Physical Review Letters, Vol. 59, pp. 2229-2232, 1987.
5. 박성현, "현대실험계획법" 민영사, 1997.
6. W. R. Baker, E. R. Marshall, M. C. Shaw, "The Size Effect in Metal Cutting," TRANS. ASME, Vol. 74, pp. 61~72, 1952.