

< 論 文 >

면삭 밀링공정에서의 절삭조건의 적응 최적화

고태조* · 조동우**

(1994년 6월 21일 접수)

Adaptive Cutting Parameter Optimization Applied to Face Milling Operations

Tae-Jo Ko and Dong-Woo Cho

Key Words : Intelligent Machine Tools(지능 공작기계), Adaptive Optimization(적응 최적화), Neural Network(신경회로망), Cutting Force(절삭력), Surface Roughness(표면거칠기), Cutting Power(절삭동력), Material Removal Rate(절삭률)

Abstract

In intelligent machine tools, a computer based control system, which can adapt the machining parameters in an optimal fashion based on sensor measurements of the machining process, should be incorporated. In this paper, the technology for adaptively optimizing the cutting conditions to maximize the material removal rate in face milling operations is proposed using the exterior penalty function method combined with multilayered neural networks. Two neural networks are introduced ; one for estimating tool wear length, the other for mapping input and output relations from experimental data. Then, the optimization of cutting conditions is adaptively implemented using tool wear information and predicted process output. The results are demonstrated with respect to each level of machining such as rough, fine and finish cutting.

1. 서 론

종래의 컴퓨터화된 수치가공(CNC) 시스템에서는 절삭속도, 절삭깊이, 이송속도와 같은 절삭조건은 온라인 상태로 조절됨이 없이 프로그래머의 경험에 의해 결정되어 졌다. 이러한 절삭조건은 생산성(production rate) 또는 절삭률(Material removal rate)의 측면에서 최적이라고 볼 수가 없다. 이를 해결하기 위한 한가지 방법은 센서의 정보를 이용하여 절삭조건을 최적화시키는 것이며, 주로 적응 제어(adaptive control) 기법에 의해 이루어지는데 이는 ACO(adaptive control with optimization) 및 ACC(adaptive control with constraints)로 나누어

진다.⁽¹⁾

ACO 시스템에 대해서는 많은 연구가 진행되었으나,^(2~8,14) 실제 사용되어지는 것은 거의 없다. 이는 정확한 절삭과정의 수학적 모델이 존재한다는 가정으로부터 출발하기 때문이다. 또한 비록 Kapoor 등⁽⁹⁾에 의해 제시된 절삭과정 모델이 절삭력을 예측하는데 유용하더라도 이는 공구의 마모진행과 같은 절삭과정의 변화를 고려하지 못하고 있다. 즉 새로운 절삭환경에 대해 절삭조건을 적응적으로 제어해야만 시스템의 능력을 최대화시킬 수 있다. 이러한 관점에서 절삭과정의 모델은 절삭환경의 변화를 수용할 수 있어야 하며 따라서 공구마모의 평가와 같은 센서의 정보는 절삭과정의 효율적인 최적화를 위해서 필수불가결하다.

본 연구에서는 신경회로망과 구속조건(constraint) 하에서의 최적화기법인 exterior penalty function

*정회원, 영남대학교 기계공학과

**정회원, 포항공과대학교 기계공학과

법을 이용하여 면삭 밀링공정에서 절삭조건을 적응 최적화기법을 제안한다. 최적화의 목표는 가공정밀도, 공구의 파단 그리고 기계의 용량을 고려했을 때 표면거칠기, 절삭력 그리고 절삭동력이라는 구속조건하에서 절삭률을 최대화시키는 것이다. 상기의 구속조건은 절삭조건과 공구마모에 따라서 변하기 때문에 입력(절삭조건)과 출력(절삭력, 표면거칠기, 절삭동력) 사이의 상관관계는 적응적이기 위해서 공구마모의 영향을 포함시켜야 한다.

Fig. 1과 같이 2개의 신경회로망이 도입되는데 하나는 공구마모길이를 평가하기 위한 것이고 다른 하나는 실험 데이터로부터 입력과 출력사이의 관계를 매핑하기 위한 것이다.

전자는 이송절삭력의 AR 모델계수를 신경회로망의 입력으로 사용하여 공구마모길이를 평가하게 되며, 후자는 입력되는 절삭조건과 전자에서 평가된 공구마모의 길이를 이용하여 절삭력, 표면거칠기 그리고 절삭동력을 예측하기 위한 것이다. 즉 이 신경회로망은 공구마모길이의 변화를 포함하는 유한개의 입출력 데이터를 학습시킴에 의해 일반화된 관계를 맺게 하는 것이다. 그리고 미리 결정된 구속조건 하에서 Exterior penalty function 과

Steepest descent법을 이용하여 성능지수를 최소화함에 의해 절삭조건을 적응적으로 최적화시킨다. 절삭과정 최적화는 황삭(rough cutting), 정삭(fine cutting) 그리고 최종공정(finish cutting)에 대해서 그 성능이 비교된다.

2. 신경회로망을 이용한 최적화

본 절에서는 다층 신경회로망을 이용한 성능지수의 최소화방법을 논의하고자 한다. 신경회로망으로의 입력은 절삭속도, 절삭깊이, 이송속도 그리고 평가된 공구마모길이이다. 그리고 신경망은 절삭력, 절삭동력 그리고 표면거칠기를 예측하게 된다. 이러한 예측은 신경망에 학습된 입력과 출력사이의 일반화 매핑정보에 의해서 이루어진다. 출력값은 공구파단이나 가공정도를 고려하여 상한값을 갖고, 입력값은 장비의 용량(예를 들어 최대 이송속도는 이송모터의 용량에 의해 제한받는다.)에 의해 제한값을 갖게 된다.

p 개의 입력노드, q 개의 출력노드 그리고 n 개의 숨은 층을 갖는 다층 신경회로망을 고려한다. 여기서 z_i : i 번째 입력노드의 입력값, y_i : i 번째 출력노드의 예측값, 그리고 m 개의 출력노드에 대해 d_i 는 출력노드의 목표값, 그리고 나머지 $q-m$ 개의 노드에 대해 d_i 는 출력노드에 대한 최대 허용값이라고 하자. 최소화되어야 할 성능지수는

$$H = \lambda_1 F + \lambda_2 G \tag{1}$$

여기서, λ_1 과 λ_2 는 F 와 G 의 상대적인 중요성을 나타내는 상수이다. F 는 신경망의 출력층에서의 출력값의 오차로서 등가구속조건(equality constraint)을 위반함에 의해 발생하는 값이며 다음과 같이 정의가능하다.

$$F = \frac{1}{2} \sum_{i=1}^m (d_i - y_i)^2 \tag{2}$$

G 는 성능지수로서 본 연구에서는 절삭량을 최대화시키기 위한 값으로

$$G = - \prod_i z_i \tag{3}$$

와 같이 정의가능하다. 여기서 음의 부호는 성능지수를 최소화하기 위해서 도입된다. 따라서 최적화는 다음의 부등가구속조건(inequality constraint)을 가질때 H 를 최소화하는 입력값 z_i 를 찾는 것이다.

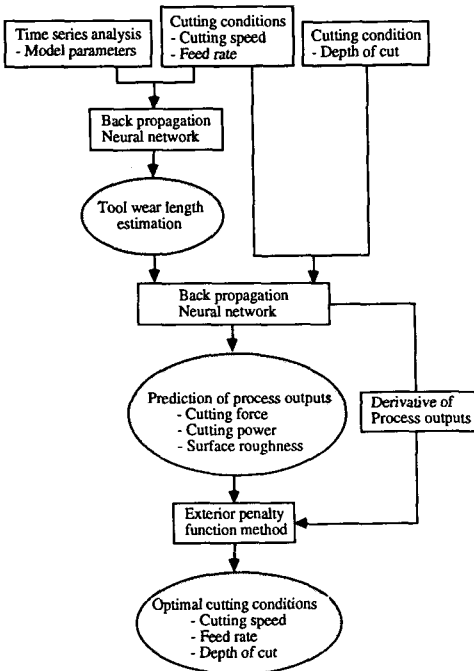


Fig. 1 Structure for adaptive optimization of machining process

$$\text{입력구속 } z_{\min i} \leq z_i \leq z_{\max i}, i=1, p \quad (4)$$

$$\text{출력구속 } v_i = (d_i - y_i) \geq 0, i=(m+1), q \quad (5)$$

여기서, $z_{\min i}$ 와 $z_{\max i}$ 는 각각 입력 z_i 에 대한 허용 최소 및 최대값이다.

상기와 같은 구속 최적화문제는 무구속 최적화문제로 전환함에 의해 풀 수 있다. 즉, 성능지수를 최소화하는 신경망의 입력값은 무구속문제로 전환함에 의해 해결가능하다. 이러한 전환은 Exterior penalty function법으로 해결되며,^(5-6,10) 최적화는 Steepest descent법으로 수행한다. 최적화를 위해서는 $\partial F/\partial z_i$ 및 $\partial v_i/\partial z_i$ 가 필요하며 이는 오차역전과 알고리즘을 이용하여 구할 수가 있다.⁽⁷⁾ 즉, 신경망의 학습 후 입력에 대한 출력의 예측과 편미분을 얻을 수가 있으며 이로써 정확한 수학적 모델이 없이도 학습된 신경망을 이용하여 최적화를 수행할 수가 있다.

3. 신경회로망의 구성

3.1 절삭실험

최적화 수행에 있어서 첫번째 일은 절삭실험으로부터 입력과 출력사이의 데이터를 얻는 것이다. 절삭실험은 Fig. 2와 같이 컴퓨터로 제어가능하도록 변경시킨 니이형 수직밀링머신에서 행해졌다.

실험에 사용된 밀링커터는 6개의 등간격으로 배치한 초경인서트(p20)를 사용했으며, 폭 60 mm, 길이 70 mm의 탄소강(SM45C)으로 된 사각형 소재

가 사용되었고 절삭조건은 다음과 같다.

절삭속도(rpm): 350, 650, 1100

이송속도(mm/min): 30, 60, 90


절삭깊이(mm): 0.5, 0.8, 1.0

신경회로망을 학습시키기 위해 공구마모진행의 상태에 따라 상기의 절삭속도의 조합을 이용하여 총 120개의 절삭데이터를 얻었다. 또한 신경망의 성능을 시험하기 위해서 동일한 절삭조건하에서 새로이 30개의 절삭데이터를 별도로 준비했다. 절삭력의 이송분력을 측정하기 위해서 공구동력계(KISTLER Type 9257A)를 사용했으며 그 위에 절삭소재를 부착시켰다.

실험에서 구한 공구의 마모진행에 따른 절삭력과 표면거칠기의 변화를 Fig. 3과 Fig. 4에 각각 나타냈다.


절삭력은 이송속도와 절삭깊이의 증가 그리고 공구의 마모진행에 따라서 증가하는 양상을 나타낸다. 그러나 표면거칠기는 Fig. 4(b)와 같이 통상적인 절삭속도에서는 공구의 마모진행과 더불어 표면거칠기가 나빠지나, Fig. 4(a)와 같이 저속의 절삭속도에서는 공구의 마모와 더불어서 버니싱이 발생하여 상대적으로 표면거칠기가 좋아 보이지만 피삭재의 가공면에는 상당한 가공경화가 발생하였다.

이 결과로부터 알 수 있듯이 절삭력과 표면거칠기는 절삭조건 뿐만 아니고 공구의 마모에 의해 많은 영향을 받고, 그 결과 절삭량은 공구의 마모 정도에 의해 영향을 받게 된다. 그러므로 정확한 절




- | | | |
|--------------------|--------------------|-------------------|
| ① Data recorder | ⑤ Computer | ⑨ Cutter |
| ② Filter | ⑥ Servo drive unit | ⑩ Milling machine |
| ③ Oscilloscope | ⑦ Sero motor | ⑪ Accelerometer |
| ④ Charge amplifier | ⑧ Tool dynamometer | |


Fig. 2 Photograph of experimental setup



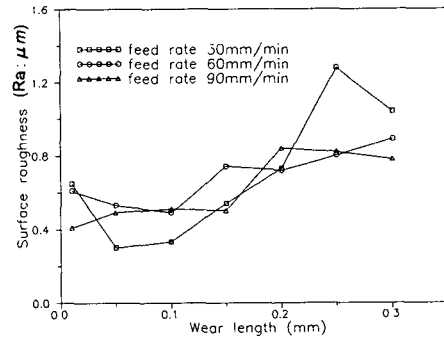
(a) Cutting speed : 350 rpm, Depth of cut : 0.5 mm



(a) Cutting speed : 350 rpm, Depth of cut : 0.5 mm



(b) Cutting speed : 650 rpm, Feed rate : 30 mm/min



(b) Cutting speed : 1100 rpm, Depth of cut : 0.5 mm

Fig. 3 Cutting force variations with respect to the progress of tool wear

Fig. 4 Surface roughness variations with respect to the progress of tool wear




Fig. 5 Variation of power spectral density of feed directional cutting force with respect to the progress of tool wear (cutting speed : 650 rpm, Feed rate : 60 mm/min, depth of cut : 0.5 mm)




Fig. 6 Model parameters under the different tool states (cutting speed : 650 rpm, feed rate : 60 mm/min, depth of cut : 0.5 mm)

삭력이나 표면거칠기의 예측은 Fig. 1과 같이 공구 마모길이의 평가를 필요로 한다. 최적화를 위해서는 두개의 신경회로망이 사용되는데 하나는 공구마

모의 길이를 평가하기 위한 것이고, 다른 하나는 평가된 공구마모길이의 절삭조건을 이용하여 절삭력, 표면거칠기 그리고 절삭동력을 예측하기 위한

것이다.

3.2 공구마모 평가기

절삭력의 이송분력의 DC성분과 주축의 흔들림

성분을 제거하기 위해서 20 Hz의 컷오프 주파수를 갖는 high-pass 필터를 거친 신호는 low-pass 필터를 거치게 된다. Low-pass 필터의 컷오프 주파수는 공구통과 주파수의 3번째 조화주파수까지만 포

Table 1 Learning data set for training the neural network

Input nodes	Output nodes	Learning conditions	
AR model parameters	Tool wear length	Input node number	10
Cutting conditions		Output node number	1
		Number of sample pattern	120
		Learning rate η	0.2
		Momentum rate β	0.2
		Shape factor θ_0	1.0
		Error bound	0.001

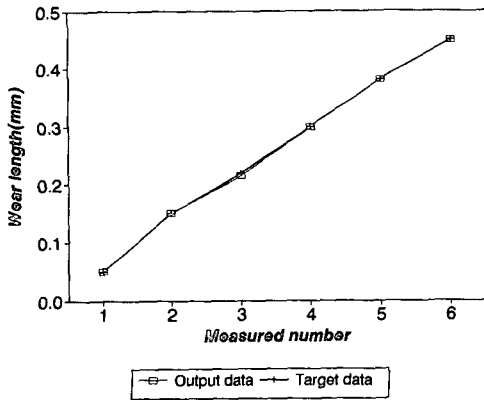


Fig. 7 Output node values with respect to training data sets (cutting speed : 350 rpm, feed rate : 30 mm/min, depth of cut : 0.5 mm)

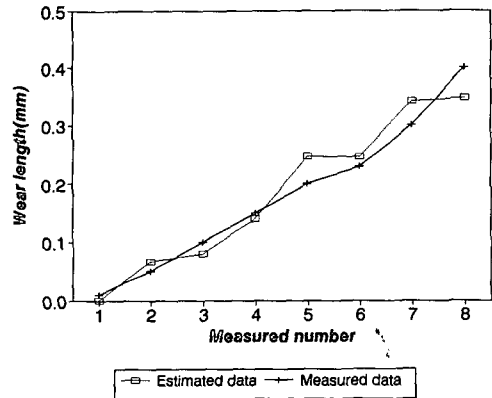


Fig. 8 Results of tool wear length estimation with respect to test data sets (cutting speed : 650 rpm, feed rate : 60 mm/min, depth of cut : 0.5 mm)

Table 2 Learning data set for training the neural network

Input nodes	Output nodes	Learning conditions	
Tool wear length	Cutting force	Input node number	4
Cutting conditions	Cutting power	Output node number	3
	Surface roughness	Number of sample pattern	120
		Learning rate η	0.6
		Momentum rate β	0.6
		Shape factor θ_0	1.0
		Error bound	0.001

함하도록 주축의 회전수에 동기하여 조절된다.⁽¹¹⁾

이 신호를 사용하여 시계열 AR 모델링을 하는데,⁽¹²⁾ 사용된 모델의 차수는 잔류오차와 모델링 속도를 고려하여 8로 했다.⁽¹⁵⁾ Fitting 알고리즘은 RLS(recursive least square)로 적응적으로 데이터를 모델링하게 된다.

모델의 계수가 수렴된 후 공구의 마모진행에 따른 AR 모델계수로부터 구한 이송분력의 파워스펙트럼의 변화가 Fig. 5이다.⁽¹⁵⁾

공구마모의 진행에 따른 파워스펙트럼의 변화는 현저하며, 이는 AR 모델계수로부터 구해진 것이므로 이들 계수를 공구마모의 특징으로 사용할 수가 있음을 알 수 있다. 공구의 마모에 따른 AR 모델계수의 변화를 보기위해 $[\phi_1, \phi_2, \dots, \phi_8]$ 의 값을 Fig. 6에 나타냈다. 그림에서 볼 수 있듯이 공구의 마모에 따른 모델계수의 변화는 뚜렷하며 특히 ϕ_1 과 ϕ_4 의 변화가 현저함을 알 수 있다.

다음은 이들 모델계수를 특징(feature)로 하여 다층 신경망에 적용시킨다.⁽¹³⁾ 신경망의 입력으로는 이송분력의 AR 모델값들과 절삭속도와 이송속도를 포함해서 총 10개의 특징이 사용된다. 한편 신경망의 출력값은 공구의 마모길이를 평가하기 위해서 하나의 노드를 사용하며, 공구마모의 길이를 정규화한 0과 1사이의 아날로그값이 되도록 한다. 신경망의 구조의 선정은 공구마모 평가의 성능을 좌우하는 중요한 것으로 본 연구에서는 학습의 능력을 고려하여 10-10-5-1(입력노드의 수 10, 첫번째 숨은 층의 노드의 수 10, 두번째 숨은 층의 노드의 수 5, 출력노드의 수 1)로 하였다. Table 1의 학습조건을 이용하여 신경망을 학습시킨 후 학습시 사용했던 데이터를 다시 신경망에 제시했을 때 평가된 공구마모의 길이와 학습패턴사이의 비교가 Fig. 7이다.

이 결과로부터 신경망은 입력과 출력의 관계를 잘 매핑하고 있음을 알 수가 있다. 또한 학습시 사용하지 아니했던 검사용 데이터를 이용하여 신경망의 성능을 평가한 것이 Fig. 8이며, 이 결과에서 알 수 있듯이 신경회로망을 이용하여 공구의 마모 길이를 평가하는 것이 가능함을 알 수 있다.

3.3 절삭과정 예측기

두번째의 신경망은 Fig. 1에서 볼 수 있듯이 전 절에서 평가된 공구마모길이를 포함해서 절삭조건을 이용하여 절삭력, 표면거칠기 그리고 절삭동력

을 예측하는 것이다. 즉 이 신경망은 공구마모의 진행정도에 따른 유한개의 입력과 출력데이터를 이용하여 이들 사이의 관계를 일반화 매핑하는 것이


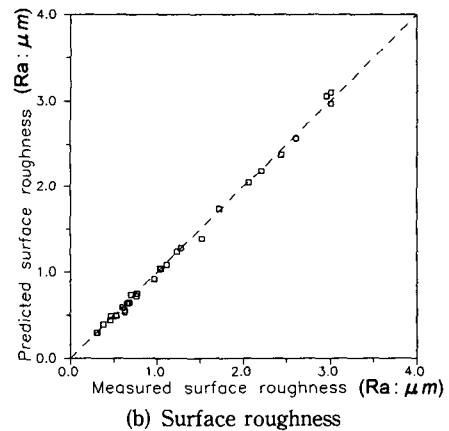
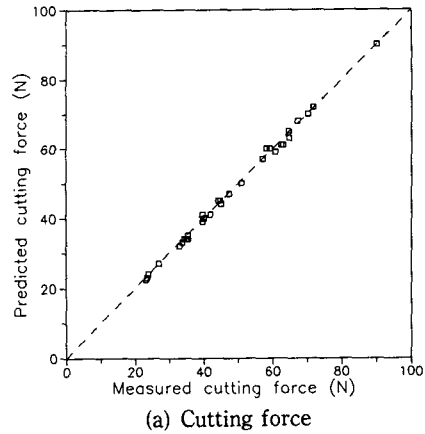


Fig. 9 Performance of the network

다. 입력과 출력변수를 고려하여 신경망의 입력과 출력노드의 수는 각각 4와 3으로 하였다. 신경망의 구조는 4-16-8-3(입력노드의 수 4, 첫번째 숨은 층의 노드의 수 16, 두번째 숨은 층의 노드의 수 8, 출력노드의 수 3)이며 Table 2의 학습조건으로 학습시켰다. 학습후 미리 준비된 검사데이터를 이용하여 신경망의 성능을 평가한 것이 Fig. 9인데 이는 예측된 출력신호와 센서신호의 비교값이다. Fig. 9(c)에서의 약간의 변동을 제외하고는 신경망의 예측성능은 만족할 만하다.

다음 이 학습된 신경망은 최적의 절삭조건을 찾는 데 이용이 되며 이때 최적화를 위해서는 입력조건에 대한 출력값의 예측과 각 입력조건에 대한 출력의 편미분을 필요로 하게 된다.

4. 절삭과정 최적화

최소화되어야 할 성능지수는 절삭량(밀링공정에서는 이송속도 f , 절삭깊이 d , 절삭폭 w 의 곱이다.)의 음의 값이며 이는

$$H = -fdw \quad (6)$$

로 나타나며 부등가속조건을 갖게 되는데 이는 식(1)에서 $\lambda_1=0$, $\lambda_2=1$ 인 경우이다. 즉, 식(6)은 등호 구속조건이 없이 출력값이 부등가속조건인 상한값에 의해서 구속됨을 나타낸다. 따라서 목적함수는 Exterior penalty function법을 이용하면 다음과 같이 무구속함수로 전환된다.

$$H = -fdw + R_1(\langle f_1 - f \rangle^2 + \langle d_1 - d \rangle^2 + \langle v_1 - v \rangle^2 + \langle f - f_2 \rangle^2 + \langle d - d_2 \rangle^2 + \langle v - v_2 \rangle^2) + R_2(\langle F_c - F_{cmax} \rangle^2 + \langle R_a - R_{amax} \rangle^2 + \langle P - P_{max} \rangle^2) \quad (7)$$

여기서, R_1 과 R_2 는 규정된 사양이나 절삭과정의 제한을 지키지 못할 때 부과되는 벌칙값의 상대적인 양을 결정짓는 계수이다. 상기 식에서 오른 쪽 첫번째 항은 절삭량을 최대화하기 위한 기본적인 목적함수이고 나머지 두 항은 다음과 같은 가중함수이다.

(1) 이송속도 f , 절삭깊이 d , 절삭폭 w 에 부과된 다음과 같은 하한과 상한의 값을 위반할 때 부과되는 벌칙값

$$f_1 < f < f_2, d_1 < d < d_2, v_1 < v < v_2$$

(2) 절삭력 F_{cmax} , 표면거칠기 R_{amax} , 절삭동력

P_{max} 의 상한값을 벗어날 때의 벌칙값

식(7)의 최소화는 Steepest descent법을 이용하여 풀 수가 있다.

5. 적용예제

다음은 황삭(rough cutting), 정삭(fine cutting) 그리고 최종공정(finish cutting)에 대한 최적화의 과정을 나타낸다. 본 연구에서 사용되어진 밀링머신은 다음과 같은 입력 제한조건을 갖고 있다.

$$\begin{aligned} 30 \text{ mm/min} &\leq \text{feed rate} \leq 100 \text{ mm/min} \\ 0.3 \text{ mm} &\leq \text{depth of cut} \leq 1.0 \text{ mm} \\ 350 \text{ rpm} &\leq \text{spindle speed} \leq 1100 \text{ rpm} \end{aligned}$$

먼저 공구마모의 정보는 임의의 값으로 하고, 실제 공구마모길이의 평가와 최적화의 수행은 뒤에서 취급한다. 기계의 주축은 벨트에 의한 구동이기 때문에 350, 650, 1100 rpm으로 고정되어 있다.

5.1 황삭

이 경우 절삭력과 절삭동력은 기계의 채터진동, 공구의 파단 또는 기계의 용량을 고려하여 어떤 범위 이내의 값이 되어야 한다. 따라서 출력값은 다음의 구속조건을 갖는 것으로 한다.

$$\begin{aligned} \text{Cutting force } F_{max} &= 80 \text{ N} \\ \text{Cutting power } P_{max} &= 0.3 \text{ kW} \end{aligned}$$

이러한 조건하에서 Table 3과 같이 각각의 공구마모길이에 대해 최적 절삭조건이 구해졌다.

이 표에 의하면 공구의 마모진행에 따라서 절삭량이 감소하는 것을 볼 수 있는데 이는 출력값에 대한 구속조건을 만족하기 위해서 이송속도 뿐만 아니라 절삭깊이가 변하기 때문이다. 각각의 다른 절삭환경 하에서 최대절삭량이 구해졌으며 특히 절삭깊이의 심한 변화는 절삭력이 이 값을 조절함에 의해 쉽게 제어가능함을 의미한다.

5.2 정삭

정삭의 경우는 황삭의 경우에 대해 표면거칠기를 추가해야 한다. 따라서 출력조건을 다음과 같이 변경한다.

$$\begin{aligned} \text{Cutting force } F_{max} &= 50 \text{ N} \\ \text{Cutting power } P_{max} &= 0.3 \text{ kW} \\ \text{Surface roughness } R_{amax} &= 1.5 \text{ } \mu\text{m} \end{aligned}$$

Table 3 Network prediction of optimal inputs in case 1

Tool wear length mm	Optimal input values			MRR mm ³ /min	Predicted sensor output	
	Cutting velocity m/min(rpm)	Feed rate mm/min	Depth of cut mm		Force N	Power kW
0.01	87.9(350)	100	1.0	6000	77	0.22
0.05	87.9(350)	100	0.84	5040	66	0.18
0.1	87.9(350)	100	0.70	4200	67	0.19
0.15	87.9(350)	100	0.68	4080	78	0.22
0.2	163.3(650)	99	0.66	3920	55	0.3
0.25	163.3(650)	90	0.61	3294	57	0.3
0.3	163.3(650)	90	0.54	2916	63	0.3

Table 4 Network prediction of optimal inputs in case 2

Tool wear length mm	Optimal input values				MRR mm ³ / min	Predicted sensor output		
	Cutting velocity m/min(rpm)	Feed rate mm/min	Depth of cut mm	Force N		Surface roughness Ra : μ m	Power kW	
0.01	163.3(650)	95	0.82	4674	57	0.7	0.30	
0.05	163.3(650)	100	0.77	4620	54	1.32	0.30	
0.1	163.3(650)	100	0.7	4200	45	1.47	0.27	
0.15	163.3(650)	100	0.68	4080	47	1.29	0.28	
0.2	163.3(650)	99	0.66	3920	55	0.54	0.30	
0.25	163.3(650)	90	0.61	3294	57	0.31	0.30	
0.3	163.3(650)	90	0.54	2916	63	0.56	0.30	

Table 5 Network prediction of optimal inputs in case 3

Tool wear length mm	Optimal input values			MRR mm ³ /min	Predicted sensor output		
	Cutting velocity m/min(rpm)	Feed rate mm/min	Force N		Surface roughness Ra : μ m	Power kW	
0.01	163.3(650)	100	3000	35	0.84	0.17	
0.05	163.3(650)	98	2940	34	1.0	0.19	
0.1	276.5(1100)	63	1890	33	0.53	0.3	
0.15	276.5(1100)	52	1560	34	0.61	0.3	
0.2	163.3(650)	48	1440	43	0.67	0.23	
0.25	163.3(650)	42	1260	46	0.18	0.23	
0.3	163.3(650)	37	1100	49	1.0	0.23	

Table 4는 공구마모길이의 변화에 따른 최적절삭 조건을 나타내는 것으로 공구마모가 작은 부분에서 절삭량이 황삭의 경우보다 작다는 것을 제외하고는 비슷한 경향을 보이고 있다.

5.3 최종가공

최종가공에서는 일반적으로 마지막으로 가공되어야 할 치수를 가공하는 것으로 이는 가공치수에 의해 결정되어지며 이러한 경우를 single pass 절삭이라고 한다. 따라서 이러한 경우는 고정된 절삭깊이 하에서 두개의 변수에 대해 목적함수를 풀어야 한다. 최종적으로 절삭되어야 할 절삭깊이가 0.5 mm라고 가정하고 최종공정임을 고려하여 구속조건을 다음과 같이 설정했다.

- Cutting force $F_{max} = 50$ N
- Cutting power $P_{max} = 0.3$ kW
- Surface roughness $R_{amax} = 1.0$ μ m




Fig. 10 Estimated and measured tool wear length

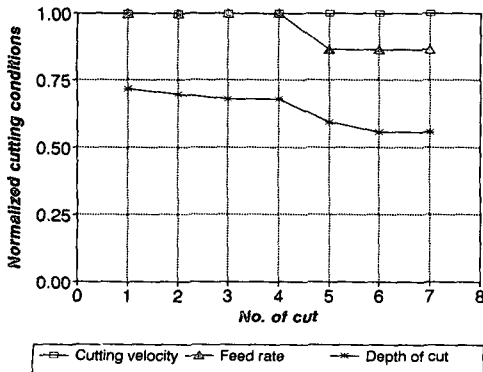




Fig. 11 Variations of normalized cutting conditions according to tool wear length in finish cutting

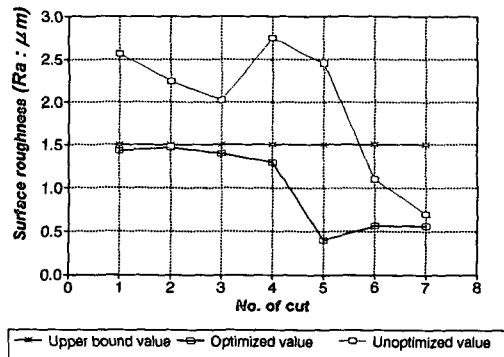
Table 5는 공구마모의 길이변화에 대한 최종공정에서의 최적절삭조건이다. 이 경우 이송속도는 앞의 두 경우에 비해 상당히 작으며, 또한 절삭속도의 변화가 증가하다가 감소하는 변화를 보이고 있다. 이는 앞에서 보았듯이 표면거칠기는 절삭속도에 따라 변동하는 양상을 보였으며 여기서는 목적함수가 표면거칠기에 의해서 구속을 받기 때문으로 해석된다.



(a) Cutting force



(b) Cutting power



(c) Surface roughness

Fig. 12 Prediction of process output values

최종적으로 정삭의 가공조건하에서 실제가공환경에서 적응 최적제어를 수행했다. Fig. 10은 신경회로망으로 예측한 공구마모의 길이의 평가치이며 이를 이용한 적응최적제어의 결과가 Fig. 11이다. 여기서 절삭조건은 감소하는 경향을 보이고 있으며 특히 공구마모의 초기 단계에서는 절삭깊이만의 변경으로 절삭력, 절삭동력, 표면거칠기를 변경시키고 있다. 여기서 절삭깊이만의 변경으로 표면거칠기를 개선할 수 있는 이유는 강성이 매우 높지 못한 기계에서는 기계의 동강성이 피삭재의 가공면 거칠기에 많은 영향을 미치게 되고, 이런 이유에 의해 절삭깊이가 변하면 단속절삭력으로 나타나는 가진력이 변경되기 때문에 표면거칠기가 변화될 수 있다. Fig. 12는 최적화 제어를 할 때 예측된 절삭과정의 결과값이다. 그림에 의하면 공구의 마모가 서서히 진행되면서 절삭력, 표면거칠기, 절삭동력은 만약 제어를 하지 아니하면 상한으로 설정한 값을 넘게됨을 알 수가 있고, 결국 적응 최적화를 이룸에 의해 미리 설정한 상한값 이내에서 제어가 되면서 최대의 절삭량을 얻을 수 있음을 알 수 있다.

6. 결 론

구속조건 아래서 절삭량을 최대화 하기위해 적응 최적제어를 수행하는 기법을 제시했다. 구속조건은 가공물의 품위, 공구의 파단, 동작기계의 능력에 따라서 입력과 출력값에 대해 정의를 하였다. 이 방법은 오차역전과 다층 신경회로망과 exterior penalty function법에 의해 이루어졌다. 두개의 신경망이 사용되는데 하나는 공구의 마모길이를 평가하기 위해서, 다른 하나는 절삭실험 데이터로부터 입력과 출력사이의 일반화 매핑을 위한 것이다.

최적화 문제를 풀기 위해서는 입력값에 대해 출력값의 예측과 편미분이 필요하며 이는 후자의 신경망으로 수행되었다. 이 신경망은 절삭조건 뿐만아니고 공구마모와 같은 절삭과정의 변화를 포함하고 있다는 점에서 적응적이다. 따라서 정확한 수학적 모델이 없더라도 여러 구속조건하에서 적응적으로 최적화문제를 풀 수가 있었다. 세 가지 경우의 제한적인 실험절삭과정에서 최적화문제의 결과는 통상의 상식과 일치하는 결과를 추출해 낼 수가 있었으며 향후 지능형 생산시스템에서 효과적인 절삭과정의 제어기법으로 제안할 수가 있다.

후 기

본 연구는 한국과학재단이 지원하는 국제공동연구(뉴로-퍼지 알고리즘을 이용한 가공상태의 모니터링 및 표면거칠기의 제어)로 수행되었으며, 관계자 제위께 감사드립니다.

참고문헌

- (1) Koren, Y., 1983, *Computer Control of Manufacturing Systems*, McGraw-Hill Book Company, pp. 249~251.
- (2) Chang, T. C., Wysk, R. A., Davis, R. P. and Choi, B., 1982, "Milling Parameter Optimization through a Discrete Variable Transformation," *Int. J. Prod. Res.*, Vol. 20, No. 4, pp. 507~516.
- (3) Ermer, D. S., 1971, "Optimization of the Constrained Machining Economics Problem by Geometric Programming," *ASME J. of Engng. Ind.*, Vol. 1, pp. 1067~1072.
- (4) Challa, K. and Berra, P. B., 1976, "Automated Planning and Optimization of Machining Process: A System Approach," *Comput. & Indus. Engng.*, Vol. 1, pp. 35~46.
- (5) Jang, D. Y. and Seireg, A., 1992, "Machining Parameter Optimization for Specified Surface Roughness," *ASME J. of Engng. Ind.*, Vol. 114, pp. 254~257.
- (6) Jang, D. Y., 1990, "Manufacturing System Parameter Optimization for Specified Surface Properties of the Machined Part," University of Florida, Ph. D Thesis.
- (7) Rangwala, S. S. and Dornfeld, D. A., 1989, "Learning and Optimization of Machining Operations Using Computing Abilities of Neural Networks," *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 19, No. 2, pp. 299~314.
- (8) Wu, S. M. and Ermer, D. S., 1966, "Maximum Profit as the Criterion in the Determination of the Optimum Cutting Conditions," *ASME J. of Engng. Ind.*, Vol. 88, pp. 435~442.
- (9) Fu, H. J., DeVor, R. E. and Kapoor, S. G., 1984, "A Mechanistic Model for the Prediction of the

- Force System in Face Milling Operations," *ASME J. of Engng. Ind.*, Vol. 106, pp. 81~88.
- (10) Rao, S. S., 1984, *Optimization Theory and Optimizations*, 2nd Edition, Wiley Estern Limited.
- (11) Ko, T. J. and Cho, D. W., 1994, "Adaptive Modeling of Milling Process and Application of A Neural Network for Tool Wear Monitoring," *Int. J. of Adv. Manuf. Technol.*, to Appear.
- (12) Pandit, S. M. and Wu, S. M., 1983, *Time Series and System Analysis with Applications*, John Wiley & Sons, Inc., pp. 13~45.
- (13) Pao, Y. H., 1989, *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley Publishing Company, Inc.
- (14) 소환철, 김희술, 1993, "정면밀링작업에서의 최적절삭조건 선정," 한국정밀공학회 춘계학술대회논문집, pp. 61~65.
- (15) 고태조, 조동우, 1994, "밀링공정의 적응모델링과 공구마모검출을 위한 신경회로망의 적용," 한국정밀공학회지, 제11권, 제1호, pp. 138~149.