

이 논문은 1995년도 학술진흥재단의 공모과제 연구비에 의하여 연구되었으며, 이에 감사드립니다.

적응모델링과 유전알고리즘을 이용한 절삭공정의 최적화(II) - 절삭실험 -

고 태 조*, 김 희 슬*, 안 병 욱**,

Optimization of Machining Process Using an Adaptive Modeling and Genetic Algorithms(II) - Cutting Experiment -

Tae Jo Ko*, Hee Sool Kim*, Byung Wook An**

ABSTRACT

In this study, we put our object to carry out adaptive modeling of cutting process in turning system, and to find out the optimal cutting conditions to maximize material removal rate under some constraints. We used a back-propagation neural network to model the cutting process adaptively and a genetic algorithm to find out optimal cutting conditions. The experimental results show that a back-propagation neural network could model the cutting process efficiently, and optimized cutting conditions for maximizing the material removal rate were obtained through the adaptive process model and genetic algorithms. Therefore, the proposed approach can be applied to the real machining system.

Key Words: Material removal rate(소재 절삭률), Adaptive modeling(적응모델링), Optimal cutting conditions(최적절삭조건), Back-propagation neural network(오차역전파 신경회로망), Genetic algorithms(유전이론)

1. 서 론

현재의 CNC화된 기계가공시스템에서는 절삭속도, 이송속도 그리고 절삭깊이 등과 같은 절삭조건은 On-line으로 제어되는 장치를 갖지 않고 Off-line으로 프로그래머의 경험이나 절삭가공의 데이터 핸드북을 통하여 결정되어진다. 이러한 절삭조건은 절삭률 즉 생산성의 측면에

서 최적의 값이 될 수가 없는데, 이는 프로그래머가 공구의 마모나 표면거칠기 또는 공작기계의 부하 등을 고려하여 소극적으로 NC프로그램을 짜기 때문이다.

상기와 같은 문제점을 해결하기 위한 한가지의 방법은 절삭가공의 센서신호에 기초하여 절삭조건을 최적인 방향으로 조절할 수 있는 최적제어시스템을 구성하는 것이다. 현재까지 생산성의 대표적 지수인 절삭률을 최대화시키려

* 영남대학교 기계공학부, 정회원

** 영남대학교 대학원 기계공학과

는 적응제어⁽¹⁾의 연구결과는 많지만 현장에서 실제로 사용이 되어지지 못하고 있는데, 그 이유는 우리가 목적함수인 성능지수를 잘 정의하였다 하더라도 절삭과정을 나타내는 수학적 공정모델이 최적화 알고리즘에서 반드시 필요하다는 점이다. 둘째로는 비록 다변수에 대하여 잘 작동하는 수학적 도구인 모델링 기법이 있더라도 다양한 절삭환경에 대하여 절삭모델을 만들기 위해서는 Off-line 상태에서 수없이 많은 절삭데이터를 실험을 통하여 얻어야 한다는 점이다. 셋째로는 Kapoor⁽²⁾ 등이 제시한 절삭력 예측모델 등은 공구의 마모나 기타 환경의 변화를 수용하지 못하는 시불변(Time invariant) 모델이라는 점이다. 넷째로는 비록 상기와 같은 문제점을 해결한 모델이 있더라도 통상 사용하는 고전적인 수학적 최적화 방법은 전역 최적값(Global optimum)을 얻지 못하고 초기값 근처에서 최적값을 찾기 때문에 지역 최적값(Local optimum)을 제공한다는 것이다⁽³⁾. 절삭과정은 많은 변수들에 의해 지배받는 매우 복잡하고 비선형적인 현상을 내포하고 있기 때문에 필연적으로 절삭과정의 최적화는 지역 최적값이 될 가능성이 있고, 따라서 우리가 찾는 절삭조건으로는 최적의 생산, 즉 공작기계가 낼 수 있는 최대한의 능력 내에서 절삭률을 올려 생산성을 극대화시킬 수가 없다⁽³⁻⁶⁾.

따라서 본 연구에서는 절삭공정을 적응적으로 모델링할 수 있는 오차역전파 신경회로망⁽⁴⁾⁽¹¹⁾과 모델링된 절삭공정을 이용하여 전역 최적화시키는 도구로서 유전 알고리즘⁽⁷⁻⁹⁾을 사용하여 절삭공정을 최적화시키는 실험적 연구를 행하였다.

먼저 임의의 절삭조건을 CNC선반에 입력한 후, 선반에 설치된 공구동력계, 전류계, 가속도계를 통하여 공구에 걸리는 주절삭력, 주축모터의 전류값 그리고 공구홀더의 진동을 각각 측정하였다. 그리고 한벌의 입력 절삭조건과 측정값들을 이용하여 오차역전파 신경회로망을 적응적으로 학습시켰다. 이때 신경망은 학습이 이루어지지 않은 초기단계이기 때문에 신경회로망의 출력값과 측정값사이에는 큰 오차가 있고, 따라서 이들 값은 신경망에 의하여 학습이 이루어진다.

그 다음 모델링된 절삭공정에 대하여 유전알고리즘을 이용하여 전역 최적절삭조건을 구하게 되는데, 이때 잘 학습되어지지 않은 신경망의 출력값을 이용하여 최적값을 구하였기 때문에 이 값은 최적값이 될 수가 없다. 따라서 이 값이 원래의 입력값과 합쳐져서 또 다른 입력값을 만들어내는 사이에 입력과 출력의 전 영역을 신경망은 반

복적으로 학습을 하게 되고, 학습이 완벽하게 이루어질 시점에 정확한 최적의 절삭조건도 구하여지는 구조로 되어 있다.

상기와 같은 최적화 제어구조를 갖는 시스템을 구축하여 이송속도를 제어하는 Feedrate override기능과 주축 회전수를 제어하는 Spindle override기능을 이용하여 On-line상태로 작동하는 절삭실험을 수행하였다. 실험결과 본 연구는 비록 초기에 임의의 절삭조건을 주더라도 주어진 구속조건을 위반하지 않으면서 최대의 절삭률을 줄 수 있는 절삭조건을 잘 찾아내어 On-line으로 제어할 수가 있었다. 또한 공구의 마모와 같이 점진적으로 변하는 절삭환경도 신경회로망이 적응적으로 모델링을 하고 있기 때문에 그때의 환경하에서 최적의 절삭조건을 잘 찾아서 제어할 수 있었다. 따라서 본 시스템은 임의의 공작기계에 장착되어 실용화할 수 있는 가능성을 제시하고 있다.

2. 절삭공정의 적응모델링

본 연구에서 사용된 최적화 시스템은 절삭가공공정을 적응적으로 모델링하기 위한 부분과 모델링된 공정을 최적화하기 위한 최적화 부분으로 구성이 되어 있다. 즉 Fig. 1과 같이 절삭공정을 적응적으로 모델링하기 위해서는 오차역전파 다층구조 신경회로망(Multilayered neural network)이 사용되며, 최적화를 위해서는 유전 알고리즘(Genetic algorithms)이 사용된다.

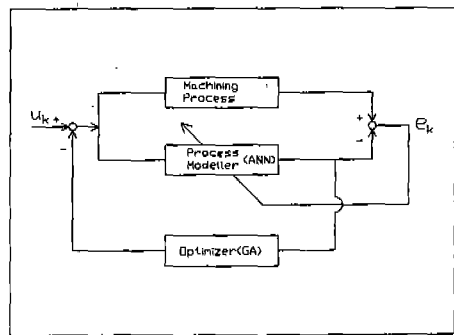


Fig. 1 Schematic diagram for cutting parameter optimization.

절삭공정을 적응적으로 모델링하는 과정은 먼저 CAD/CAM 소프트웨어에서 NC 코드를 생성시킬 때 임의로 입력된 입력데이터로서 절삭속도, 이송속도 그리고 절삭깊이의 값인 u_k 를 공작기계 및 신경회로망에 각각 입

력시킨다. 이때 신경회로망은 절삭공정을 학습하지 않은 초기상태이기 때문에 임의의 절삭조건인 입력값에 대하여 출력값은 정확하지 못하다. 한편 또 하나의 입력조건은 CNC선반에 주어져서 절삭력과 주축모터의 전류값 그리고 동작기계의 진동값을 출력하게 된다. 이 경우 절삭공정에서 나오는 출력값과 신경회로망에서 예측된 값사이에는 초기오차가 많이 발생하고 이 오차값은 신경회로망을 학습하기 위해 이용된다.

한편 학습이 적절하게 이루어지지 않은 이 신경회로망 모델을 이용하여 유전알고리즘을 통하여 최적화를 시키게 되면 그때의 최적값은 정확한 값이 될 수 없으며, 이 값은 다시 입력 u_k 에 더하여져서 또 다른 값을 입력절삭조건으로 취하게 된다. 이 값은 다시 신경망과 동작기계에 입력으로 들어가서 학습이 이루어지고, 이들 출력값에서 오차가 일정범위 이내에 들어올 때까지 수회 반복하게 됨에 따라서 절삭공정은 적응적으로 학습이 이루어져서 모델링이 완성되게 된다. 본 연구에서 사용되어진 신경회로망은 이미 잘 알려진 입력층, 출력층, 은닉층으로 구성된 Rumelhart가 제안한 다층 신경회로망을 이용하였다⁽⁴⁾⁽¹¹⁾.

3. 절삭공정의 최적화

유전자 알고리즘을 이용한 절삭공정의 최적화에서 최적화 시키려는 변수는 이송속도와 절삭속도이고, 최대화시킬 성능지수는 절삭량으로서 선삭에서는 식(1)과 같이 3개의 변수의 곱으로 나타낼 수 있다.

본 연구에서는 절삭깊이는 고정하게 되는데, 그 이유는 CNC작업기계에 제어값을 입력할 때 외부단자인 Feed rate 및 Spindle override기능을 이용하도록 시스템을 구현하고 있기 때문이다. 또 다른 한편으로는 절삭깊이의 제어는 황삭가공에서는 정삭가공을 위한 전가공에 문제가 있고, 정삭가공에서는 그 자체에 문제가 있기 때문에 본 연구에서는 고려의 대상에서 제외하였다.

$$H = f \cdot d \cdot v \quad (1)$$

여기서 f 는 이송속도, d 는 절삭깊이 그리고 v 는 절삭속도이다. 식 (1)에서 단순하게 절삭량만을 최대로 하려면 3개의 변수 값의 최대값만을 취하면 된다. 그러나 원하는 제품의 품질을 얻기 위해서는 절삭공정에 여러 가지의 구속조건을 갖게 된다. 즉, 식(1)은 본 실험에서는 다음과 같은 구속조건을 갖고 있다.

출력구속조건 :

$$F_c < F_{cmax}, I_s < I_{smax}, A_s < A_{smax} \quad (2)$$

입력구속조건 :

$$f_1 < f < f_2, s_1 < s < s_2 \quad (3)$$

여기서 F_{cmax} , I_{smax} , A_{smax} 는 각각 절삭력, 전류값 및 가속도 신호의 최대 제한값을 나타내고, f_1 , f_2 , s_1 , s_2 는 각각 이송속도 및 절삭속도의 하한 및 상한값을 나타낸다.

이러한 구속조건을 만족하기 위해서 Penalty 기법을 이용하여 구속 문제를 식 (4)와 같이 무구속 문제로 변환하여 문제를 풀 수 있다⁽¹⁰⁾.

$$\begin{aligned} H &= f \cdot d \cdot v \\ &- R_1 (< f_1 - f >^2 + < s_1 - s >^2 \\ &+ < f - f_2 >^2 + < s - s_2 >^2) \\ &- R_2 (< F_c - F_{max} >^2 + < I_s - I >^2 \\ &+ < A_s - A >^2) \end{aligned} \quad (4)$$


여기서 $\langle \cdot \rangle$ 는 $g \geq 0$ 때 $\langle g \rangle = g$, $g < 0$ 때 0을 나타낸다. 또한 R값들은 구속조건들을 만족하지 못하였을 경우 부과되는 벌칙값의 상대적인 양을 결정짓는 계수이다. 즉 구속조건을 만족하지 못하였을 경우 일정한 벌칙값을 적용도에서 감소시킴으로서 전체적인 적용도를 낮추는 역할을 한다. 위 식 (4)의 첫 번째 항은 기본적인 목적함수이고, 두번째항은 절삭조건에 대한 구속조건으로서 이송속도, 주축회전수에 대한 하한과 상한에 대한 조건이다. 그리고 세번째 항은 절삭력, 전류값, 진동에 대한 상한값에 대한 구속조건에 해당한다. 식 (4)의 성능지수를 사용하여 유전 알고리즘으로 최적의 절삭조건을 구하게 된다.

4. 실험방법

4.1 실험장치의 구성

최적화 절삭실험을 수행하기 위하여 본 실험에 사용한 동작기계는 Fig. 2와 같이 소형CNC선반(대구중공업 DC-2)이고, 각종의 공정결과를 측정하기 위해서 공구동력계, Hall type 전류계 그리고 가속도계를 사용하였다.

먼저 절삭시 발생하는 절삭력을 측정하기 위해 공구동력계를 Gang type 테이블 위에 특별히 제작된 치구를



1. Workpiece
2. Tool Dynamometer
3. Piezo Film Sensor Attached
Below Tool Holder
4. Dynamometer Holder

Fig. 2 Sensors assembled in the tool table.

이용하여 고정하였다. 본 연구에서 사용한 공구동력계(KISTLER 9272)는 3축방향의 절삭력(주분력, 배분력, 이송분력)과 모멘트를 동시에 측정할 수 있으나, 실제 절삭시 가장 영향이 큰 주절삭력만 측정하였다.

그리고 공구홀더에서 일어나는 진동을 측정하기 위해 Piezo Film을 공구홀더의 아래쪽에 부착하였다. 진동을 측정하기 위하여 Piezo Film을 사용한 이유는 본 시스템을 상용화시킬 때 저가적으로 시스템을 구현하기 위함이다. 본 연구에서 사용된 Piezo Film은 감도 10 mV/g의 Pennwalt사제를 사용하였다.

한편 주축모터인 AC모터에 걸리는 부하인 전류신호를 측정하기 위해 Hall Type 전류센서를 이용하여 모터에 걸리는 전류값을 측정할 수 있으나 이 신호는 3상 신호이기 때문에 합성을 할 필요가 있다. 그러나 FANUC사제 AC Spindle drive unit(A06B-6060-H003#H503)에서 주축모터에 걸리는 전류값의 변화를 표시하기 위하여 Load meter를 부착할 수 있도록 합성된 신호를 제공하고 있는데, 본 연구에서는 이 단자를 이용하여 전류값을 측정하였다.

상기의 아날로그 신호들을 디지털 신호로 컴퓨터가 받아들일 수 있게하기 위해 A/D Converter (PCL 812PG)를 사용하였고, 받아들여진 신호를 처리하고 난 후 동작기계를 제어하기 위한 신호를 주기 위해 I/O Card를 특별히 제작하여 Fig. 3처럼 부착하였다.

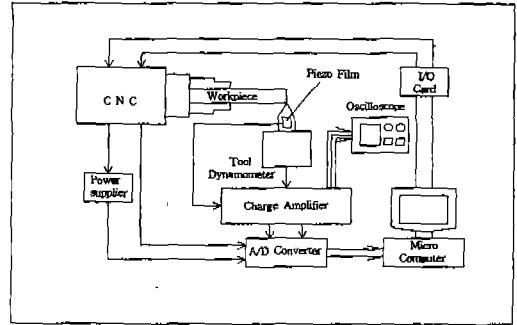


Fig. 3 Schematic diagram for experimental setup.

본 실험에 사용된 피삭재는 SM45C 탄소강($\phi 45 \times 105$ mm)이며, 사용된 공구는 초경인서트(대한중삭 TNMG 160412-B20)이다.

4.2 실험방법

본 실험은 절삭시 발생하는 주절삭력, 공구홀더의 진동, 모터에 걸리는 부하인 전류값을 주어진 센서로부터 받아들여 컴퓨터로 데이터를 처리하여 신경망을 학습시키고, 이 결과를 이용하여 최적화 알고리즘인 Genetic Algorithm을 통과 시킨 후 다시 CNC장치(FANUC 0T)의 Feed rate override와 Spindle override로 신호를 보내어 제어를 하도록 한다.

Fig. 4는 입의의 시편을 0.0, 0.5, 1.0, 1.5 mm의 절삭깊이가 되도록 단을 만들어 절삭하는 동안 A/D Converter로 각종 데이터를 받아 보았는데, Fig. 4(a)와 같이 절삭깊이가 커짐에 따라 점점 절삭력이 증가하고 있음을 알 수 있다. Fig. 4(b)는 또 다른 시편에 대하여 공구동력계와 마찬가지로 단이 지어진 시편을 사용하였을 때의 Piezo Film의 가속도 신호로서 깊이의 변화에 따른 신호의 변화가 잘 나타났다. 한편 Fig. 4(c)는 또 다른 시편을 절삭하는 동안 CNC 동작기계의 Spindle drive unit에서 얻은 전류신호의 변화를 나타낸 것이다.

이상과 같이 절삭과정중에 얻어진 신호들은 A/D Converter를 이용하여 데이터를 받아들이는데 하나의 센서로부터 300개의 데이터를 1000Hz의 샘플링 주파수로 샘플링하여 RMS값으로 평균한 값이 신경회로망을 학습하는데 이용하였다.

이 신경회로망의 정보를 이용하여 유전자 알고리즘을 진행시키게 되고 최적 절삭조건을 계산하게 된다. 이렇게 얻어진 최적값을 동작기계로 제어하기 위해 본 실험에서는 동작기계의 Override기능을 이용한다. 동작기계의




Fig. 4 Sensor signal variations according to the change of depth of cut;
 (a) Cutting force signal, (b) Acceleration signal,
 (c) Current signal.

override기능은 현재 주어진 값으로부터 얼마간의 값을 증가시키거나 감소시켜주는데 이송속도를 제어하는 Feedrate override와 주축속도를 제어하는 Spindle override가 있다. 본 연구에서 제어의 주기는 데이터를 수집하고 평균하며 신경회로망을 학습하고 유전 알고리즘을 계산하는 시간이 포함되어지는데 386DX2 PC 컴퓨터로 약 0.5초의 시간이 소모되었다.

한편 Feedrate override는 4개의 각각의 단자에 24Volt의 신호를 주거나 아니면 주지 않음으로써 16분류로 분주를 하게 된다. 즉 0%로부터 150%까지의 신호를 줄 수 있다. Spindle Override는 Feedrate Override와 같은 방법으로 분주를 하게 되는데 단자가 3개밖에 없으므로 8분류, 즉 50%에서 120%까지를 분주할 수 있다. 실제 본 실험에서 사용된 CNC 공작기계에는 Feedrate override기능만 있고 Spindle override기능은 없는데, 단지 단자는 나와 있으므로 이런 역할을 할 수 있도록 decoder를 제작하여 Spindle override기능을 특별히 부착하였다⁽¹²⁾.

이런 기능이 작동하기 위해서는 우선 CNC 공작기계에 있는 feedrate override 단자에 들어가는 신호들을 모두 차단하고 각단자에 들어가는 24Volt 신호를 모두 컴퓨터에서 제어하도록 구성하였다. 이런 방법으로 컴퓨터에서 계산된 제어값이 CNC 공작기계로 전달되어 CNC 공작기계를 제어하도록 하였다.

5. 실험결과 및 고찰

먼저 절삭에 대한 아무 정보도 없는 초기 상태에서 공작물을 일정한 깊이로 절삭하며, 다만 CNC공작기계가 허용하는 절삭력과 모터 전류의 제한값, 그리고 진동의 크기에 대한 제한값들을 부가하기로 한다. 이 제한값(Constraints)들은 기계가 가지고 있는 고유의 한계치이지만 본 실험에서는 그 제한값까지는 실험상의 어려움으로 인해 실험자의 경험으로 어떤 값을 제한치로 주기로 한다. 절삭력에 대한 제한값은 100N으로 하고 진동에 의한 가속도의 제한값은 2.5g로한다. 그리고 모터에 걸리는 전류의 제한값은 15A로 두었다. 또, 이송속도와 절삭속도의 범위로는 각각 0mm/rev에서 0.075mm/rev 과 500rev에서 1200rev으로 주었다. 즉 입력조건이 이 범위 내에서 최적 절삭조건을 찾도록 하였다.

실험은 두 가지 경우로 나누어 수행했는데, 먼저 절삭깊이가 변할 때 최적의 조건으로 절삭을 하는지를 알아보았다. 그리고 두 번째로 공구가 점진적으로 마모되었을 때 절삭조건이 어떻게 변하는지를 알아보기 위해 공구 인서트를 임의로 마모를 시켜서 절삭조건의 변화를 알아보았다.

5.1 절삭깊이의 변화에 따른 절삭조건 변화

Fig. 5는 절삭깊이를 0.3mm로 하였을 때 최적화를 수행하면서 제어가 수행된 결과들이다. 유전알고리즘에서는 초기 개체의 수를 100개, 그리고 교배율을 0.25, 돌

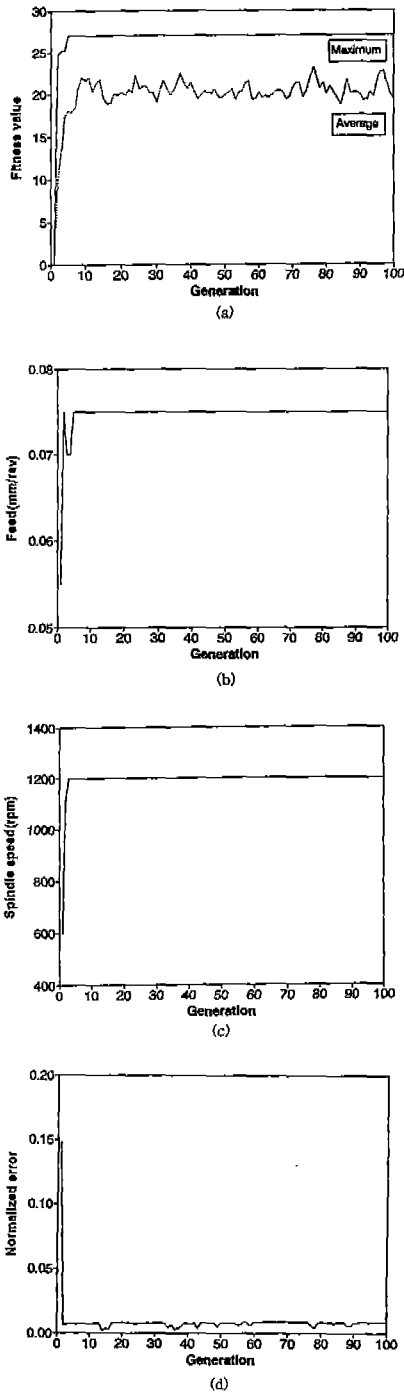


Fig. 5 Results of genetic algorithm according to the evolution: (a) Maximum and average values of evaluated cost, (b) Variation of feed rate, (c) Variation of cutting speed, (d) Learning errors of a neural network.

연변이율을 0.01로 하였다. 먼저 Fig. 5(a)는 유전알고리즘에서 세대가 100세대 진행하는 동안 각 개체중에서 평가함수(적응도)의 최대값과 각 개체의 평균값을 계산한 것이다. 또한 Fig. 5(b)는 절삭조건을 On-line제어하는 동안의 이송속도 변화, 그리고 Fig. 5(c)는 절삭속도의 변화이다. 이들 그림에서 알 수 있듯이 절삭깊이를 0.3 mm로 하였을 때에는 이송속도와 절삭속도는 처음 몇 차례 최적값을 찾다가 빠르게 최적 절삭조건으로 수렴함을 볼 수 있다. 이때 최적값을 찾는 과정은 Fig. 5(d)와 같이 신경회로망의 학습과 동시에 진행이 되며 절삭초기에 빨리 학습하여 학습이 잘 되어진다. 신경회로망은 학습오차 0.01, 학습률 0.5, 모멘텀률 0.5로 하였다. 여기서 최적 절삭조건으로 찾은 이송속도 0.075mm/rev과 절삭속도 1200rev은 주어진 절삭조건 범위의 최대값으로서, 절삭깊이가 0.3mm일 때에는 최대 절삭조건으로 절삭을 하여도 제한조건(Constraints)을 넘지 않는 결과가 나왔다.

실제로 측정된 절삭력은 Fig. 6(a)와 같이 절삭력에 대한 제한값인 90N정도로 나타났고, 가속도 신호는 Fig. 6(b)처럼 0.4g를 넘지 않았으며, 전류신호는 Fig. 6(c)에서 보듯이 12A를 넘지 않은 상태에서 안정적인 절삭을 할 수 있었다.

Fig. 7은 절삭깊이가 0.3 mm에서 0.6mm로 변경되었을 때의 최적화 결과들을 나타낸다. 여기서 절삭깊이가 0.3mm일 때의 뉴럴 네트워크의 학습과 유전 알고리즘의 정보들을 바로 적용을 시켜서 절삭깊이가 변하였을 때 잘 적응이 되어 최적조건을 찾아가는지를 살펴보았다. Fig. 7(a)는 각 세대가 진행하면서 나오는 성능지수의 최대값과 평균값의 변화를 나타낸다. 여기서 진동이 많이 발생하는 이유는 학습의 초기에 잘못된 모델을 가지고 최적화를 하였기 때문에 그 때의 값이 구속조건을 위배하기 때문에 나오는 결과이다. 또한 Fig. 7(a)에서 최대 절삭률이 약 19.8로 나타났는데 이는 실제 최대 절삭률은 39.6이나 NC가 인식하고 있는 것은 절삭깊이가 0.3mm이기 때문에 이 값을 기준으로 MRR을 계산하고 있기 때문이다.

Fig. 7(b)와 Fig. 7(c)는 이송속도와 절삭속도의 변화를 보여주는데, 초기의 약 35세대(Generation)동안은 절삭깊이가 0.3 mm일 때의 학습된 뉴럴 네트워크를 다시 절삭깊이 0.6 mm에 적합하도록 재 학습을 하면서 최적조건들을 찾아가는 과정을 보여준다. 따라서 이 경우 초기에는 공정을 다시 학습하기 위하여 이송속도와 절삭속도가 그림처럼 많이 변동하고 있음을 알 수 있다. 그리고




Fig. 6 Results of optimization according to the evolution: (a) Cutting force signal, (b) Acceleration signal, (c) Current signal.

35세대(Generation)이후는 신경회로망도 학습이 어느 정도 수행되어서 Fig. 7(d)처럼 오차가 거의 0에 가깝게 된다. 절삭깊이 0.3 mm일 때와 비교해 보면 절삭속도는 변함없이 1200 rpm인데 반해 이송속도는 0.055 mm/rev으로 감소되었음을 보여준다. 이는 절삭깊이가 증가함으로 인하여 절삭력이 많이 걸리게 되는데 이를 낮추기 위해서는 회전수를 증가하거나 이송속도를 줄여야 한다. 그러나 회전수는 1200 rpm을 상한값으로 주었기 때문에 결국 이송속도를 줄여야하는 결과로서 실제의 경험과 잘 일치하는 결과이다. 물론 여기서도 제한조건들을 모두 만족하였다.

한편 Fig. 8은 절삭조건이 최적화과정에서 계속하여 변

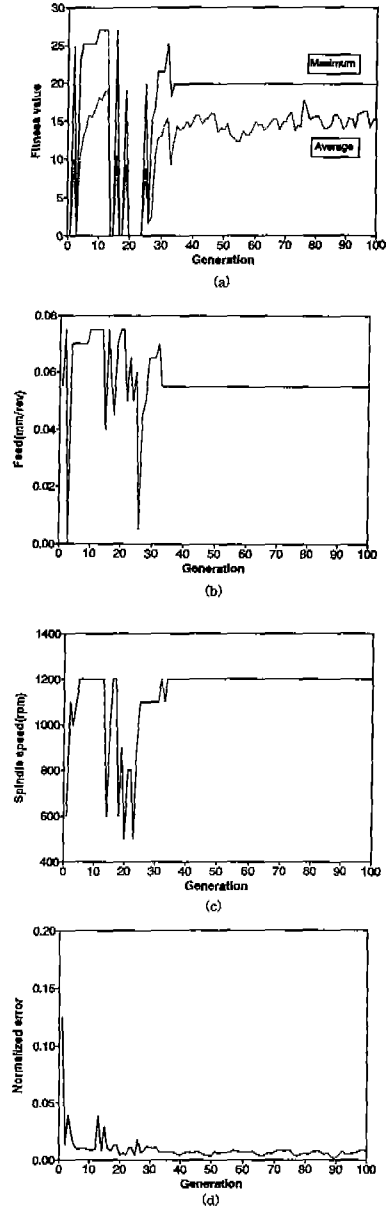


Fig. 7 Results of genetic algorithm according to the evolution: (a) Maximum and average values of evaluated cost, (b) Variation of feed rate, (c) Variation of cutting speed (d) Learning errors of a neural network.

해가는 동안에 절삭을 한 시편이다. 이 그림의 영역 1과 같이 이송속도가 많이 변하는 곳의 표면조도는 매우 불안정하나, 몇차례의 절삭조건 진동이 있는 후의 영역인 2와 같은 지역에서는 표면 조도가 일정하게 나타남을 볼 수

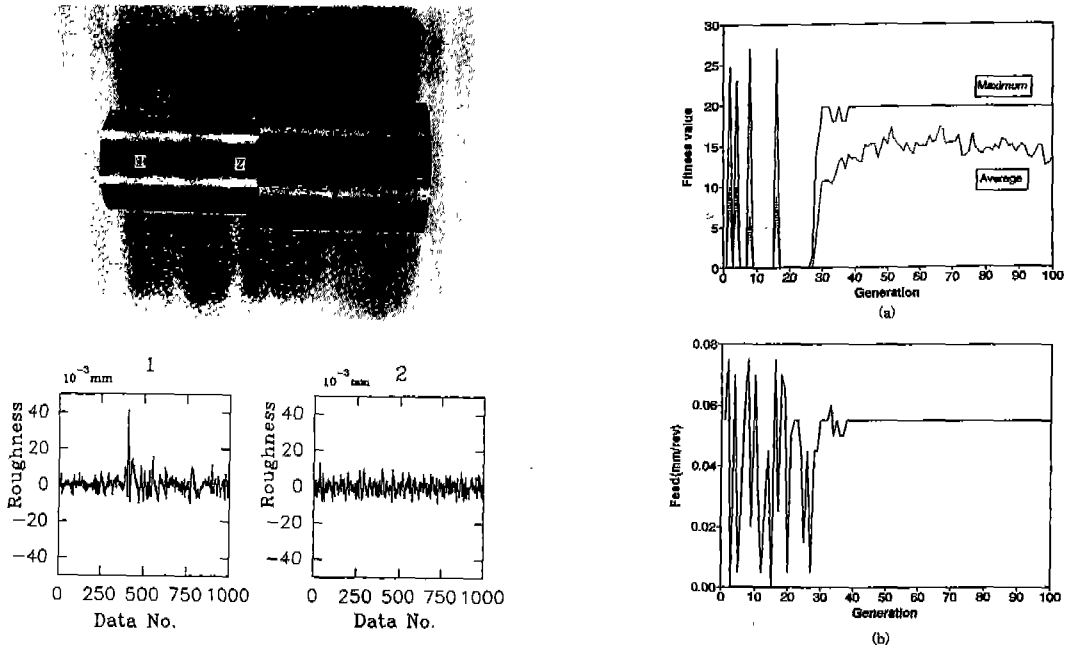


Fig. 8 Photograph and surface roughness of machined workpiece.

있다.

이상에서와 같이 절삭깊이를 변화시켰을 때 최적절삭조건
의 변화와 절삭량, 뉴럴 네트워크의 오차, 제한조건들
의 만족함을 살펴보았는데 절삭깊이의 변화에 따라 절삭
조건들이 잘 적응하여 제한조건들을 잘 지켜지는 가운데
최적의 절삭조건을 찾아감을 볼 수 있다.

5.2 공구의 마모에 따른 절삭조건 변화

절삭공정 변화의 대표적인 예인 공구의 마모에 따른 절삭
조건들의 변화와 이에 따른 최대절삭량의 변화를 알아보기
위해 새 공구(New tool)와 마모된 공구(Worn tool,
0.1mm마모)에 대해서 본 시스템의 적용가능성을 검증하였
다. 비교를 위하여 절삭깊이는 0.3 mm로 고정하고 절삭조
건의 변화를 살펴보았다.

마모된 공구(Worn tool)에 대한 각 결과는 Fig. 9와 같
다. Fig. 9(a)는 마모된 공구를 사용하고 있을 때의 절삭조
건 최적화 과정이다. 즉, 유전 알고리즘의 목적함수의 최대
값과 평균값을 보여주고 있는데, 최적 절삭조건에서의 최대
절삭량은 19.8mm³/min로 구하여진다. 이는 새 공구일 때
보다는 약 7 mm³/min정도 적은 절삭량을 알 수 있다.
Fig. 9(d)에서 보듯이 절삭조건들은 약 30세대가 흐르는
동안, 뉴럴 네트워크를 학습을 하면서 최적절삭조건을 찾으




Fig. 9 Results of optimization according to the evolution: (a) Cutting force signal, (b) Acceleration signal, (c) Current signal, (d) Learning errors of a neural network.




Fig.10 Results of optimization according to the evolution: (a) Cutting force signal, (b) Acceleration signal, (c) Current signal.

려 하고 그 이후로는 학습도 이루어지고 최적절삭조건을 찾아감을 볼 수 있다. 물론 본 실험에서는 미리 인위적으로 마모시킨 공구를 사용하기 때문에 초기에 많은 학습을 필요로 하지만, 공구의 마모는 점진적이기 때문에 이들 오차는 공정중에 하나씩 하나씩 단계적으로 서서히 학습이 이루어지기 때문에 최적화의 효율은 매우 높을 것이다. 이 경우 이송 속도 및 적삭속도는 Fig. 9(b),(c)와 같이 각각 0.055 mm/rev, 1200 rpm으로 구해짐을 볼 수 있다.

상기의 절삭조건에 대해서도 제한 조건들을 모두 만족

하고 있는데 Fig. 10(a)-(c)에서와 같이 절삭력은 약 50 N을 나타내고, 가속도는 0.5g 이하로 그리고 전류는 약 10A 이하에서 유지하고 있었다. 이 값들은 상한 제한값에 비교하면 매우 낮은 값으로서 절삭조건이 최적값과 매우 멀다고 느낄 수 있으나, 절삭과정의 비선형성 때문에 이 조건보다 약간 상회하는 구간에서는 구속조건을 모두 위배하는 결과가 나타나고 있었다.

이상과 같이 절삭깊이의 변화나 공구마모에 대한 최적의 절삭조건에 대하여 살펴 본 결과 본 연구는 절삭 환경의 변화에 대해 매우 적응적이고, 그에 따라 최적절삭조건을 잘 찾아낼 수 있었다.

6. 결론

본 연구에서는 신경망을 이용하여 CNC선반 작업에서 적응모델을 구축하고, 유전 알고리즘을 이용하여 절삭조건을 최적화시켰다. 즉, 적응모델과 유전 알고리즘을 이용한 절삭공정의 최적화(I)에서 제시한 알고리즘을 바탕으로 실제 절삭공정에 적용시켜 검토해 봄으로써 실제 작업현장에서 사용가능한 시스템을 구축하기 위한 연구이다.

이론적인 시뮬레이션 결과와 마찬가지로 실제 절삭공정에 적용시켜본 결과 절삭 환경이 변화함에 따라 적응적으로 모델링 되면서 구속조건들을 위배하지 않는 범위 내에서 최적 절삭조건으로 절삭을 하고 있음을 볼 수 있었다. 실제로 절삭깊이를 변화시켜보고 공구를 임의로 마모시켜 절삭 환경을 변화시켜보았을때 제한한 알고리즘은 절삭환경 변화에 잘 적응하여 그때마다의 최적의 절삭조건으로 절삭을 수행하였다. 이와 같은 결과들로 미루어 볼 때 이 외의 다른 절삭환경의 변화에도 본 알고리즘은 그때의 상황에 잘 적응할 것이고 또 최적의 절삭조건을 찾아 갈 것으로 예측된다. 본 실험에서는 임의적으로 환경을 급변하였지만 실제로 작업중에는 점진적인 환경 변화를 보일 것이고 이 경우 본 알고리즘의 적응력은 시간적으로 좀더 단축시킬 수 있을 것이다. 그리고 본 실험에서는 제한조건들로 주로 절삭력에 관계된 것이지만 나아가 표면에 관한 조건이나 온도에 관한 제한 조건들을 추가로 준다면 좀 더 정밀한 절삭조건을 구할 것이다.

참고 문헌

1. Y. Koren, *Computer Control of Manufacturing*

- System, McGraw-Hill Book Company, pp.249-251, 1983.
2. H: J. Fu, R. E. DeVor, S. G. Kapoor, "A Mechanical Model for the Prediction of the Force System in Face Milling Operations," *ASME J. Engng. Ind.*, Vol. 106, pp.81-88, 1984.
 3. D. Y. Jang, A. Seireg, "Machining Parameter Optimization for Specified Surface Roughness," *ASME J. Engng. Ind.*, Vol. 114, pp. 254-257, 1992.
 4. S. S. Rangwala, D. A. Dornfeld, "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, 1989.
 5. T. Matsumura, T. Obikawa, E. Usui, "Autonomous Turning Operation Planning with Predicting Tool Wear and Surface Roughness," *Transactions of NAMRI/SME*, Vol. 21, pp. 359-366, 1993.
 6. S. M. Wu, D. S. Ermer, "Maximum Profit as the Criterion in the Determination of the Optimum Cutting Conditions," *ASME J. Engng. Ind.*, Vol. 88, pp. 435-442, 1966.
 7. B. P. Buckles, F. E. Petry, *Genetic Algorithms*. IEEE Computer Society Press, 1992.
 8. Z. Michalewicz, *Genetic Algorithms + Data Structures = Evolution Programs*, Springer-Verlag, 1994.
 9. D. E. Goldberg, *Genetic Algorithms in Search, Optimization & Machine Learning*, Addison Wesley, 1989.
 10. S. S. Rao, *Optimization Theory and Applications*, 2nd edition, Wiley Estern Limited, 1984.
 11. Y. H. Pao, *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley Publishing Company, Inc., 1989.
 12. 김도균, "적응모델과 유전 알고리즘을 이용한 절삭공정의 최적화," 영남대 학교 석사학위논문, 1996.