

유전알고리듬을 이용한 선삭공정의 적응최적화 (Adaptive Optimization of Turning Operation Using a GAs)

김 도 균*, 고 태 조**, 김 회 술**

* : 영남대 대학원

** : 영남대 기계공학과

1. 서론

최근의 절삭가공 생산시스템은 무인자동화, 고속화, 정밀화로 대별되면서 생산성을 극대화시킬려는 방향으로 연구가 진행되고 있다. 종래의 CNC화된 기계가공시스템에서는 절삭속도, 이송속도 그리고 절삭깊이 등과 같은 절삭 조건은 On-line으로 조절되는 장치를 갖지 않고 Off-line으로 프로그래머의 경험이나 절삭가공의 데이터 핸드북을 통하여 결정되어진다. 이러한 절삭조건은 절삭률 즉 생산성의 측면에서 최적의 값이 될 수가 없다. 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. 이런 능력을 갖춘 시스템을 적응제어 (Adaptive Control) 시스템이라고 부르고 있다[1]. 이는 구속조건의 적응제어 (ACC)와 최적화를 위한 적응제어 (ACO)로 대별되고 있으며, 가공의 생산성 향상을 도모하기 위해서는 통상 후자의 방법을 이용하여 어느 범위 (입력과 출력에 대한 구속조건) 이내에서 절삭률 (Material Removal Rate) 을 최대화시키거나 가공비를 최소화시키는 방향으로 연구가 진행되고 있다.

비록 현재까지 절삭률을 최대화시키려는 적응제어의 연구 (ACO) 결과는 많이 발표되고는 있지만 대부분 현장에서 실제로 사용이 되어지지 못하고 있다. 그 이유는 비록 우리가 목적함수인 성능지수를 잘 정의하였다 하더라도 절삭과정을 나타내는 수학적 공정모델이 최적화 알고리듬에서 반드시 필요하다는 점이다. 둘째로는 비록 다변수에 대하여 잘 작동하는 수학적 도구인 모델링 기법이 있더라도 상기와 같은 절삭환경에 대하여 절삭모델을 만들기 위해서는 Off-line상태에서 수없이 많은 절삭데이터를 실험을 통하여 얻어야 한다는 점이다.셋째로는 기존의

절삭력 예측모델들은 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 전체적으로 최적의 값 (Global optimum)을 구하지 못하고 초기값 근처에서 최적 값을 찾기 때문에 국부적인 최적값 (Local optimum)을 제공한다는 것이다.

이러한 문제 때문에 현재 개발되어지고 있는 대부분의 적응제어시스템은 실용화가 되지못하고 있는 실정이어서 효율적인 적응제어시스템의 개발은 필수적이다[2][3].

따라서 본 연구에서는 무인자동화 가공시스템에서 생산성을 최대화하기 위하여 사용하는 ACO 시스템에서 발생하는 상기의 문제를 해결하여 실용화할 수 있는 가공 최적화 시스템을 개발함을 연구의 목적으로 하고 있다.

2. 절삭공정의 적응 모델링

본 연구는 절삭가공공정을 적용 적으로 모델링하기 위한 부분과 모델링된 공정을 적용적으로 최적화하기 위한 최적화 부분으로 구성이 되어 있다. 절삭공정을 적용적으로 모델링하기 위해서는 오차역전파 다층구조 신경회로망 (Multilayer neural network)이 사용되며, 최적화를 위해서는 유전알고리듬 (Genetic algorithms)이 사용된다. 전체적으로 그 구조를 살펴보면 Fig 1과 같이 구성되어 있다.

먼저 공작기계의 입력조건으로 들어가는 u_k 는 CAD/CAM 소프트웨어에서 NC 코드를 생성시킬 때 최초에 들어간 입력데이터로서 절삭속도, 이송속도 그리고 절삭깊이이다. 이 값은 공작기계 및 신경회로망에 입력데이터로 들어가게 된다. 이때 신경회로망은 절삭공정을 학습하지 않은 초기상태이다. 센서로써 받는 절삭신호는 절삭시 발생하는 절삭력 (이송분력), 공작기계의 주축모터에 걸리는 전류, Tool holder에서 측정하는 공작기계의 진동 등이다. 이 값은 공작기계 및 절삭과정으로부터 직접 관측되어지

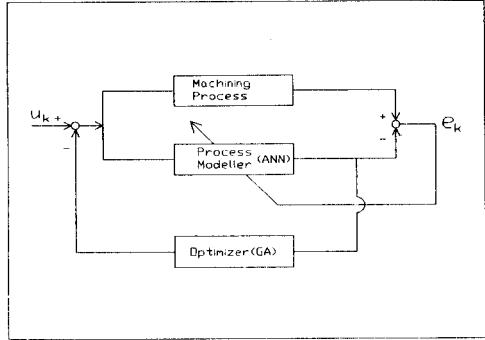


Fig.1 The adaptive optimization of cutting operation

는 량이고, 또한 신경회로망에 의해서도 예측되어진다. 그러나 신경회로망의 출력값은 신경망이 절삭과정을 초기상태에서는 학습하지 않은 상태이기 때문에 많은 오차(절삭공정의 센서신호와 신경망 출력값의 차이)를 발생시키게 되며, 이 오차 e_k 는 신경망을 학습하기 위한 값으로 사용된다[4].

본 연구에서 사용되어지는 신경회로망은 이미 잘 알려진 입력층, 출력층, 은닉층으로 구성되어지는 Rumelhart가 제안한 다층 신경회로망을 이용하였다.

3. 유전이론(GAs)에 의한 최적화

학습과 동시에 신경망의 출력값은 절삭공정을 최적화하는데 사용되는데, 여기에 사용하는 최적화 도구는 유전알고리듬이다. 최근 생물의 진화원리(선택도태, 교배, 돌연변이)로부터 착상을 얻은 일종의 학습알고리듬으로서, 유전학의 개념을 근거로 한 최적화 방법의 하나인 유전 알고리듬이 공학의 여러 분야에 적용되어지고 있다[6][7]. 유전 알고리듬(Genetic algorithms : GAs)은 1975년 미시간대학의 Holland와 그의 학생들에 의해 수행된 세포자동화(cellular automata)의 연구로부터 기원된다[5]. 그들 연구의 초점은 1) 자연계의 적응과정을 설명하고, 2) 자연계의 메커니즘을 인위적 시스템인 소프트웨어로 설계하는 것이었다. 그 이후 유전 알고리듬은 꾸준히 발전하여 현재는 공장의 스케줄링, 신경회로망의 학습, 화상특징추출, 화상인식 및 각종 최적화의 문제 등에 적용되고 있다.

유전 알고리듬은 모사추론과정이라기 보다는 자연의 선택도태 메커니즘을 모델화한 탐색알고리듬이다. 즉 자연계에서는 우수한 형질을 가진 개체가 환경에 잘 적응하여 큰 생존확률을 가진다. 또한 우수한 형질을 가진 두 개체

가 교배를 통하여 더욱 우수한 자손을 생성하며, 돌연변이에 의해 생긴 우수한 형질이 자손에게 유전됨으로써 진화가 진행된다. 유전 알고리듬은 이와 같은 자연계의 법칙에 착상하여 재생, 교배, 돌연변이 등의 인위적인 조작을 통하여 목적함수의 최적해를 찾아내는 모의진화형의 탐색알고리듬이다.

단순한 유전 알고리듬은 재생, 교배 그리고 돌연변이의 세 조작자로서 구성된다. 재생과정은 목적함수의 값(적용도 값)에 비례하여 각 개체가 복제되어지는 과정이며, 이는 Darwin의 적자생존에 근거를 둔 자연선택의 인공적 모델이다. 재생과정을 거치고 난 후 랜덤하게 선택된 개체끼리 교배의 과정을 거친다. 교배의 과정에서는 이진비트로 표현된 개체의 스트링중 랜덤하게 선택된 교배점(crossover point)을 중심으로 두 개체끼리 유전자의 교환을 시도한다. 재생과 교배과정은 랜덤 수의 창성, 개체복사 그리고 스트링의 부분적 교환 등으로 이루어진 단순과정이다. 이 과정을 통하여 좋은 성능의 개체는 더 좋은 성능을 위해 탐색과정에서 계속하여 시험되고 교환을 거듭하게 된다. 돌연변이는 이러한 과정에서 회복할 수 없는 손실, 즉 초기집단이 가지고 있는 형질만 가지고 해를 찾으려고 하는 성질, 을 방지한다. 돌연변이는 적응과정의 2차적 조작자로서 아주 작은 확률을 가지고 스트링의 한 비트의 값을 바꿈에 의해 개체집단의 다양성을 증가시킨다. 이러한 과정을 거치면서 개체군은 한 세대를 마감하게 되고, 다음 세대를 맞이하게 된다.

유전 알고리듬의 흐름구성은 Fig 2과 같다.

Fig. 2의 과정을 상세히 기술해 보면,

1. 이진수로 구성되는 유전형으로 개체를 나타내기 위하여 개체의 특성을 표현하는 이진 코드의 길이와 초기개체수를 결정한다.
2. 개체의 특성을 표현하는 이진코드를 랜덤하게 구성하여 초기집단을 형성한다.
3. 각 개체의 이진코드를 개체의 특성으로 변환하고 목적함수를 통하여 적용도를 평가한다.
4. 재생과정에서 확률적으로 적용도가 높은 개체는 더 많이 복제시킨다.
5. 교배과정에서는 교배확률에 해당하는 수만큼의 교배쌍을 선택하여 유전에서의 염색체의 교배과정과 유사하게 이진코드의 일부를 잘라 교배시킨다.
6. 돌연변이 확률에 따라 이진코드를 구성하는 이진비트를 반전시킴으로써 유전에서의 돌연변이와 유사한 조작을 한다.

```

t ← 0
generate initial population G(0);
evaluate G(0);
repeat
    t ← t+1
    generate G(t) using G(t-1);
    evaluate G(t);
until solution is found.

```

Fig 2. Genetic Algorithm(GA)

- 위의 과정을 정해진 세대수만큼, 또는 수렴 기준을 만족할 때까지 반복한다.

유전 알고리듬은 복잡한 해의 공간에 대해서 이론적 및 경험적으로 견인한 탐색을 할 수 있으며, 또한 함수의 연속성, 미분가능성, Unimodality등의 문제에 제약이 없는 것이 특징이다. 즉 유전 알고리듬은 다음의 4가지 측면에서 종래의 최적화알고리듬과 다른 특성을 지닌다.

- 유전 알고리듬은 결정론적인 규칙이 아닌 확률적인 추이규칙을 사용한다.
- 유전 알고리듬은 각 파라미터를 별개로 취급하지 않고 개체의 특성에 해당하는 파라미터집합을 하나로 묶어 취급한다.
- 유전 알고리듬은 단일해를 사용하여 해공간을 탐색하지 않고, 해집단을 사용하여 해공간을 탐색한다.
- 유전 알고리듬은 도함수 또는 다른 보조적인 정보가 필요하지 않고 목적함수로부터 산출되는 적응도만을 이용한다.

4. 절삭실험.

4.1 실험 장치

최적화 절삭 실험을 수행하기 위하여, 본 실험에서 사용한 실험 장치는 Fig.3과 같다. 본 실험에서 사용된 공작 기계는 소형CNC선반이고, 절삭시 발생하는 절삭력을 측정하기 위해 공구동력계를 Gang type 테이블 위에 특별히 제작된 치구를 이용하여 고정하였다. 공구동력계는 3축(주분력, 배분력, 이송분력)과 모멘트를 측정할 수 있으나, 실제 절삭시 가장 영향이 큰 주 절삭력만을 측정하였다.

그리고 절삭시 공구 Holder에서 일어나는 진동을 측정하기 위해 Piezo Film을 공구 Holder 아래쪽에 부착하였다. 또한 주축 모터에 걸리는 부하인 전류신호를 측정하기 위해 Hall Type 전류센서를 이용하여 Motor에 인가되

어지는 전류를 측정한다. 그러나 Spindle drive unit에는 Spindle motor에 걸리는 전류값의 변화를 나타내기 위하여 Load meter를 부착할 수 있도록 신호를 인가시키고 있는데, 이 신호는 Spindle drive unit가 제어를 하기 위하여 내장된 전류계로부터 측정되어진 신호로서 3상 임에도 불구하고 합성된 신호를 제공하고 있음으로 실제 적용을 매우 쉽게 하여주고 있다.

이런 아날로그 신호들을 디지털 신호로 컴퓨터가 받아들일 수 있게하기위해 A/D Converter를 사용하였고, 받아들여진 신호를 연산 처리하고 난 후 공작기계를 제어하기 위한 신호를 주기 위해서 I/O Card를 제작하였다.

그리고 공구동력계나 Piezo Film신호를 증폭하기 위하여 Charge Amplifier가 사용되었고, Hall Type 전류센서에 전원을 공급하기 위한 Power Supplier, 신호를 감시하기 위하여 오실로스코프, 제어를 하기 위하여 마이크로컴퓨터(486Dx266)등이 사용되었다

본 실험에 사용된 피삭 재료로는 SM45C 탄소강으로 Ø40×105mm의 단봉이다. 사용된 공구는 초경 인서트이다.

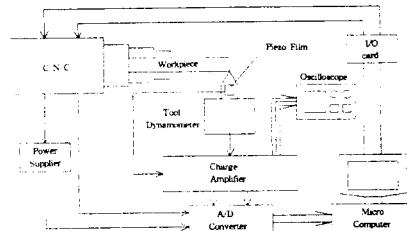


Fig.3 Schematic diagram for experimental set up

4.2 실험방법

본 실험은 절삭시 발생하는 절삭력, 진동, 모터에 걸리는 부하 등을 주어진 센서로부터 받아들여 컴퓨터로 데이터를 처리하여 신경망을 학습시키고, 이 결과를 이용하여 최적화 알고리듬인 Genetic Algorithm을 통과 시킨 후 다시 CNC로 신호를 보내어 제어를 하도록 한다.

센서로부터 얻어진 신호들을 A/D Converter를 이용하여 2kHz로 샘플링 하여 900개의 데이터를 세개의 채널로 받아들이고, 이 데이터를 RMS(Root Mean Square)값으로 평균하여 신경회로망을 학습하는데 이용한다. 여기서 각 RMS값은 하나의 센서 신호로부터 300개의 데이터를 평균한 값을 이용하였다. 이 신경회로망의 정보를 이용하여

유전자 알고리듬을 수행시키게 되고 최적값을 계산하게 된다.

이렇게 얻어진 최적값을 공작기계로 제어하기 위해 본 실험에서는 CNC공작기계의 Override기능을 이용한다. CNC공작기계의 Override기능은 현재 주어진 값(feed, spindle)으로부터 얼마간의 값을 증가시키거나 감소시켜 주는데 Feedrate Override와 Spindle Override가 있다.

Feedrate override는 4개의 각각의 단자에 24Volt의 신호를 주거나 아니면 주지 않음으로써 16분류로 분주를 하게 된다. 즉 0%부터 150%까지의 신호를 줄 수 있다.

한편, Spindle Override는 Feedrate Override와 같은 방법으로 분주를 하게 되는데 단자가 3개밖에 없으므로 8분류, 즉 50%에서 120%까지 분주할 수 있다.

실제 본 실험에서 사용된 CNC 공작기계에는 Spindle Override기능은 없지만, 이런 역할을 할 수 있게 Decoder를 제작하여 특별히 부착하였다.

우선 CNC 공작기계에 있는 Feedrate override 단자에 들어가는 신호들을 일부에서 차단하고 각단자에 들어가는 24Volt 신호를 모두 컴퓨터에서 제어되도록 구성하였다. Feedrate override나 Spindle override에 대한 전기 회로도는 부록 B와 같다. 이런 방법으로 인해 컴퓨터에서 계산된 제한값이 CNC 공작기계로 전달되어 CNC 공작기계를 제어하도록 하였다.

5. 적응 최적화의 실험결과.

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 100N으로하고 진동에 의한 가속도의 제한값은 2.5g(m/s^2)로한다. 그리고 모터에 걸리는 전류의 제한값은 15A로 두었다.

또, 이송속도와 절삭속도의 범위로는 0mm/rev에서 0.75mm/rev 과 500rpm에서 1200rpm으로 주었다. 이 범위 내에서 최적 절삭조건을 찾도록 하였다.

실험은 두 가지 경우로 나누어 해 보았는데, 먼저 절삭깊이를 다르게 하여 각 절삭깊이를 절삭하였을 때 최적의 조건으로 절삭을 하는지를 알아보았다. 그리고 두 번째로 공구가 마모되었을 때 절삭조건이 어떻게 변하는지를 알

아보기 위해 공구 인서트를 임의로 마모를 시켜서 절삭조건의 변화를 알아보았다.

5.1 절삭깊이의 변화에 따른 적용 최적화

절삭깊이를 0.3mm로 하였을 때, Fig.4는 주어진 절삭조건 범위 안에서 구속 조건을 위배하지 않는 한도 내에서의 최대절삭량을 보여주고 있다. Fig 5는 이송속도의 변화를, 그리고 Fig.6은 절삭속도의 변화이다. 이들 그림에서 볼 수 있듯이 절삭깊이를 0.3mm로 하였을 때에는 이송속도와 절삭속도는 처음 몇 차례 최적값을 찾다가 빠르게 최적 절삭조건으로 수렴함을 볼 수 있다. 이때 최적값을 찾는 과정은 신경회로망의 학습과 동시에 진행이 되며, 이때의 신경망의 학습은 빨리 학습하여 학습이 잘되어진다. 여기서 최적 절삭조건으로 찾은 이송속도 0.75mm/ rev과 절삭속도 1200rpm은 주어진 절삭조건 범위의 최대값으로서, 절삭깊이가 0.3mm일 때에는 최대 절삭조건으로 절삭을 하여도 구속조건(Constraints)을 넘지 않는 결과가 나왔다.

이때 절삭깊이를 0.3mm에서 0.6mm로 변경을 해 보았다. 여기서 절삭깊이가 0.3mm일 때의 뉴럴 네트워크의 학습과 유전 알고리듬의 정보들을 바로 적용을 시켜서 절삭깊이가 변하였을 때 잘 적용이 되어 최적조건을 찾아가는지를 살펴보았다.

Fig.8와 Fig.9는 이송속도와 절삭속도의 변화를 보여주는데, 초기의 약 35세대(Generation)동안은 절삭깊이가 0.3mm일 때의 학습된 뉴럴 네트워크를 다시 절삭깊이 0.6mm에 적합하도록 재 학습을 하면서 최적조건들을 찾아가는 과정을 보여준다. 따라서 이 경우 초기에는 공정을 다시 학습하기 위하여 이송속도와 절삭속도가 Fig.8와 Fig.9처럼 변동하고 있음을 알 수 있다. 그리고 35세대(Generation)이후는 신경회로망도 학습이 어느 정도 수행되어서 최적값을 찾았음을 보여준다. 절삭깊이 0.3mm일 때와 비교해 보면 절삭속도는 변함없이 1200rpm인데 반해 이송속도는 0.055mm/rev으로 감소되었음을 보여준다. 결과적으로 Fig.7와 같이 유전 알고리듬에서 목적함수의 최대값과 평균값 절삭깊이 0.3mm일 때보다 다소 적음을 볼 수 있다. 이 결과에서 알 수 있듯이 초기에 절삭깊이가 급변함에 의하여 절삭과정에는 많은 오차가 발생하고 따라서 오차역전파 알고리듬에 의해서 원하는 목표값을 학습하여야 한다. 이러한 과정이 수회 지나고 나면 학습은 완료되고, GA가 찾는 값이 전역 최적해가 된다.

이상에서와 같이 절삭깊이를 변화시켰을 때 최적절삭조건의 변화와 절삭량을 살펴보았는데 절삭깊이의 변화에

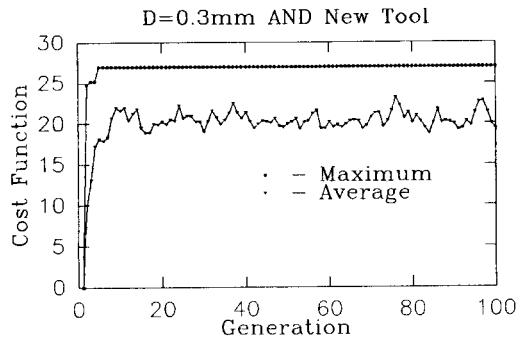


Fig.4 Maximum values and average values of evaluated cost

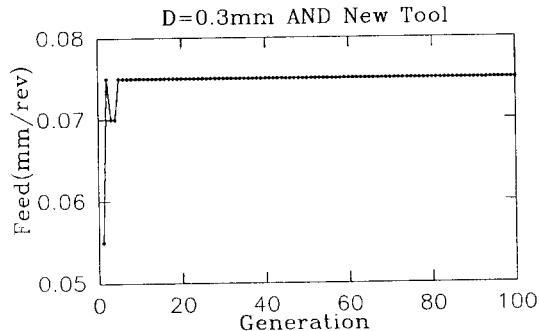


Fig.5 Variation of feedrate

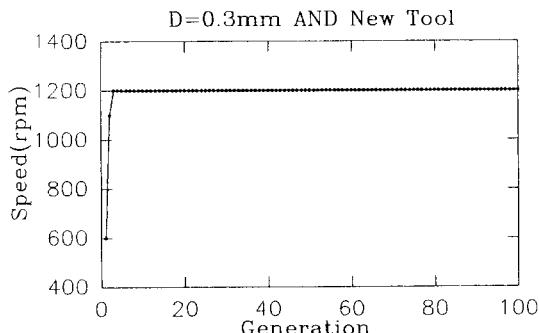


Fig.6 Variation of cutting speed

따라 절삭조건들이 잘 적용하여 제한조건들을 잘 지켜지는 가운데 최적의 절삭조건을 찾아감을 볼 수 있다.

5.2 공구의 마모에 따른 적응 최적화

절삭공정 변화의 대표적인 예인 공구의 마모에 따른 절삭조건들의 변화와 이에 따른 최대절삭량의 변화를 알아보기 위해 새공구(New tool)와 마모된 공구(Worn tool, 0.1mm마모)에 대해 실험을 해 보았다.

절삭깊이는 0.3mm로 고정하고 절삭조건의 변화를 살펴보았다.

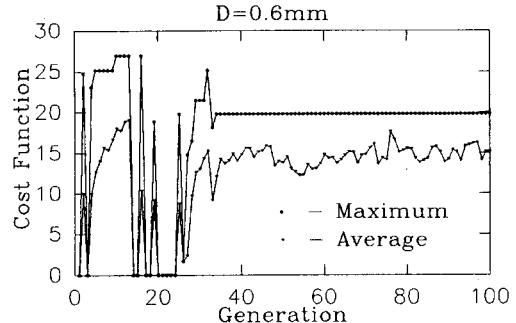


Fig.7 Maximum values and average values of evaluated cost

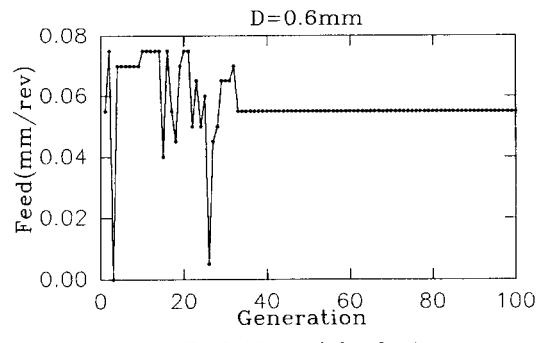


Fig.8 Variation of feedrate

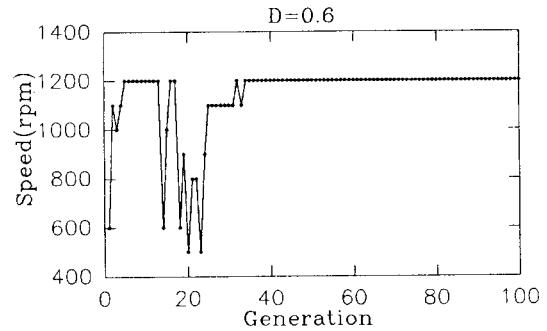


Fig.9 Variation of cutting speed

먼저, 새 공구에 대한 결과들은 절삭깊이의 변화에 따른 절삭조건의 변화에서와 마찬가지로 Fig.4, Fig.5, Fig.6과 같은 결과가 나왔다.

마모된 공구(Worn tool)에 대한 결과는 Fig.11과 Fig.12에서 보듯이 절삭조건들은 약 30세대가 흐르는 동안 뉴럴 네트워크를 학습을 하면서 최적절삭조건을 찾으려 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 이를 오차는

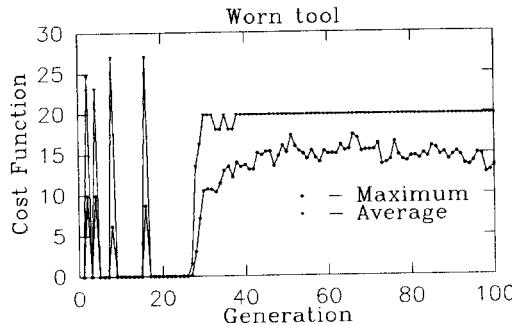


Fig.10 Maximum values and average values of evaluated cost

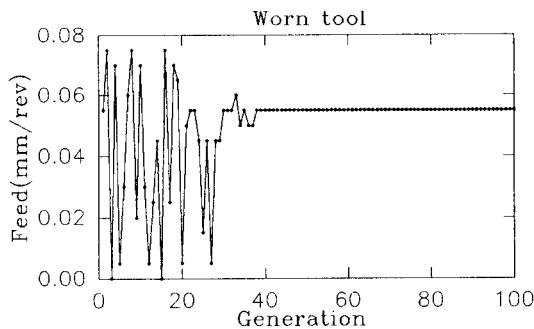


Fig.11 Variation of feedrate

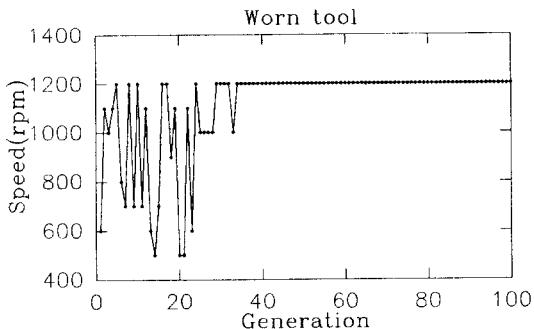


Fig.12 Variation of cutting speed

공정중에 하나씩 하나씩 단계적으로 서서히 학습이 이루어지기 때문에 최적화의 효율은 매우 높을 것이다. 이 속도는 0.055mm/rev, 절삭속도는 1200rpm으로 구해짐을 볼 수 있다. Fig.10는 유전 알고리듬의 목적함수의 최대값과 평균값을 보여주고, 최적 절삭조건에서의 최대절삭량은 19.8mm³/min로 구하여진다. 이는 새 공구일 때보다는 약 7mm³/rev 정도 적은 절삭량임을 알 수 있다. 이상에서 공구의 마모에 대한 최적 절삭조건의 변화에 대해서 살펴보았는데 절삭깊이의 변화에 대한 최적절삭조건의 변화에서와 마찬가지로 제한조건을 만족하면서 최적의 절삭조건으로 잘 찾아감을 볼 수 있다.

6. 결론

신경회로망을 이용하여 절삭공정을 적용적으로 모델링하고, 유전 알고리듬을 이용하여 절삭공정의 최적화를 수행해본 결과 다음과 같은 결론을 얻을 수 있었다.

1. 어떤 절삭조건 환경에서도 적용적으로 모델링 하면서 전역적인 최적값을 찾아감을 볼 수 있었다.
2. 실제로 절삭깊이의 변화에도 본 알고리듬은 적용적으로 모델링 되면서 최적값을 찾아감을 볼 수 있다.
3. 공구의 마모에 대해서도 잘 적용하여 그 조건에 알맞은 최적값을 찾아감을 볼 수 있다.
4. 본 연구에 사용된 구속조건인 모터에 걸리는 전류, 절삭력, 진동신호 외에 표면에 관한 구속조건, 절삭온도에 관한 절삭조건 등을 추가하여 실험한다면 좀 더 정밀한 결과를 얻을 수 있다.

8. 참고 문헌

1. Y. Koren, Computer Control of Manufacturing System, McGraw-Hill Book Company, 1983, pp.249~251.
2. D. Y. Jang, A. Seireg, "Machining Parameter Optimization for Specified Surface Roughness," *ASME J. Engng. Ind.*, Vol.114, 1992, pp. 254~257.
3. 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, 1966, pp. 435~442.
4. Y. H. Pao, Adaptive Pattern Recognition and Neural Networks, Addison-Wesley Publishing Company, Inc., 1989.
5. S. S. Rao, Optimization Theory and Applications, 2nd edition, Wiley Estern Limited, 1984.
6. Z. Michalewicz, Genetic Algorithm + Data Structures = Evolution Programs, Springer-Verlag, 1994.
7. D. E. Goldberg, Genetic Algorithms in Search, Optimization & Machine Learning, Addison Wesley, 1989.