

# 휴리스틱 보정에 의한 절삭조건의 최적화

박병태\* · 박면웅\*

## Optimization of Cutting Conditions Using Heuristic Modification

Byoung-Tae Park · Myon-Woong Park

### (요 약)

일반적으로 공정설계자는 실제 절삭을 위하여 각 공정의 표준 절삭조건에 대하여 적절한 보정을 수행한다. 이러한 보정과정에서 사용되는 지식은 경험에 바탕을 둔 것이므로 이의 시스템화는 경험 지향적인 방법론(Experience-Oriented Method)을 요구한다. 본 논문에서는 밀링 공정을 대상으로, 검색된 표준 절삭조건에 대하여 최적의 절삭조건을 결정하기 위한 방법과 제안된 방법에 의해 개발된 시스템을 소개한다.

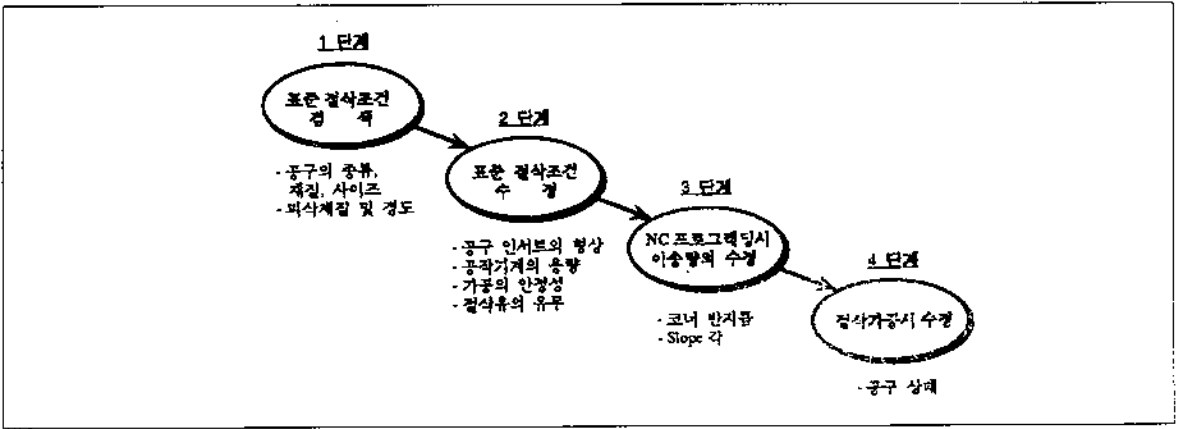
주요어 : 공정계획(Process Planning), 작업설계(Operation Planning),  
표준 절삭조건(Reference Cutting Condition), 신경회로망(Neural Network)

## 1. 서론

직적 공정계획 시스템의 목표는 가공 준비 노하우의 소프트웨어화를 통한 효율 증대 및 그에 따른 생산성 향상에 있다. 첨단 생산시스템에서는 모든 생산정보의 생성과 변환이 자동적으로 이루어지게 함으로써, 엔지니어나 작업자의 경험편차 없이 최적의 결과를 얻도록 한다. 여기서 설계정보의 가공정보화를 공정계획 시스템에서 수행하게 된다. 일반적으로 공정계획은 공정의 종류와 순서를 결정하는 공정설계 기능과 개별 공정에서 필요한 파라미터 - 사용할 공구 및 홀더, 절삭 깊이 및 폭, 이송속도 및 절삭속도 - 를 결정하는 작업설계 기능으로 구분될 수 있다. 절삭가공 대상은 형상에 따라 회전형 가공물(Rotational Part)과 각주형 가공물(Prismatic Part)로 대별되는데[1][2], 전자는 선반에서, 후자는 밀링, 드릴링, 보링 머신 혹은

머시닝 센터에서 가공된다. 선삭공정들은 기본적으로 한가지 메커니즘(Mechanism)으로 표현될 수 있고, 이 차원 절삭으로 단순화할 수 있어 회전형 가공물의 공정 및 작업설계를 위한 비교적 실용적인 시스템이 발표되어 왔다. 그러나 밀링 공정은 메커니즘을 대표할 수식이 아직 부재하고 공정과 공구의 종류가 다양하여 해석적인 알고리즘에 의한 시스템을 개발하는데 어려움이 있다. 밀링류 절삭조건을 해석적인 방법으로 산출하는 것은 현재로서는 무의미하므로 현재까지 작업설계 시스템에서는 가공 데이터 핸드북(Machining Data Handbook)등에서 제공하는 절삭조건을 이용하여 표준 절삭조건 데이터베이스를 구축한 후 공정, 재질 등에 따라 검색하게 되어 있다. 검색된 표준치가 실제 현장에서 사용되기 위해서는 공정설계자에 의해 검색시 고려되지 않은 파라미터를 이용하여 보정되어야 한다. <그림 1>은 절삭조건산정의 4 단계와 각

\* 한국과학기술연구원 기전연구부



〈그림 1〉 절삭조건 산정의 단계 및 파라미터

단계에서 고려되어야 할 파라미터를 보여주고 있는데, 개발된 최적 절삭조건 결정 시스템은 이 중 상위 2단계를 구현한 것이다. 본 논문에서는 공정설계자가 표준치를 보정하는 과정을 모델링하기 위한 방법론과 이 방법론에 의해 개발된 시스템을 소개하고, 각주형 형상 부품의 작업설계를 사례연구로 수행하였다.

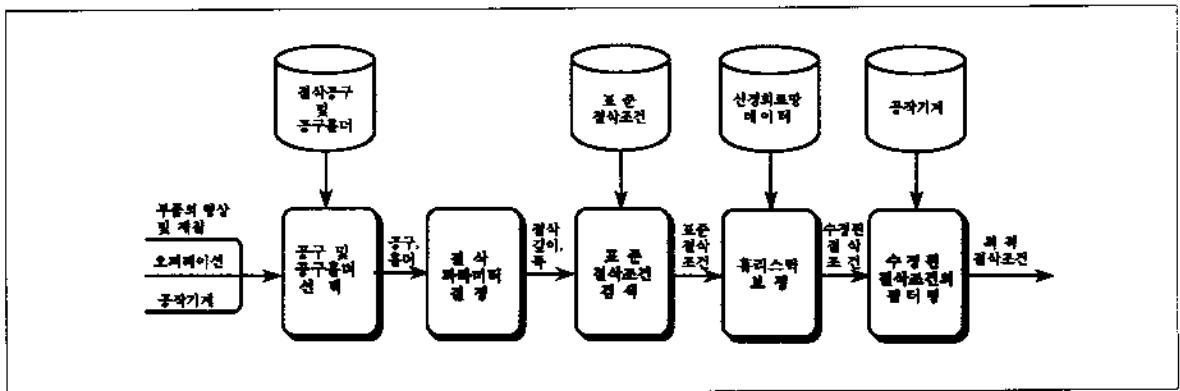
## 2. 절삭조건의 수정

공정 정보, 형상정보가 입력되면 공구와 홀더의 상세 선택을 하고, 경제적으로 고품질 표면을 얻을 수 있는 절삭깊이, 절삭폭, 표준 및 최적 절삭조건을 결정하게 된다. 〈그림 2〉는 보정기능을 포함한 전체 작

업설계 시스템의 정보 흐름을 보여 준다. 본 연구에서 개발된 최적 절삭조건 결정 시스템은 검색된 표준 절삭조건으로부터 최적의 절삭조건을 결정하기 위하여 2단계를 거친다. 1단계는 표준 절삭조건의 결정시 고려되지 않은 요소들 - 인서트의 형상, 공구의 길이, 피삭재의 표면상태 등 - 의 영향을 반영하기 위해 신경회로망을 이용하는 휴리스틱 보정 과정이고, 2단계는 수정된 절삭조건이, 사용할 장비의 용량을 만족하는지 체크하기 위한 필터링 과정이다.

### 2.1 표준 절삭조건의 검색

표준 절삭조건을 검색하기 위하여 가공 데이터 행



〈그림 2〉 작업설계 시스템의 정보 흐름

드북[3]과 공구 메이커의 공구 카탈로그에서 제공하는 공구, 공구 홀더, 표준 절삭조건 데이터 그리고 현장에서 사용하고 있는 절삭조건 데이터를 이용하여 5개의 절삭가공 데이터베이스 - 공구, 피삭재, 공구 홀더, 장비 및 표준 절삭조건 데이터베이스 - 를 ORACLE RDBMS를 이용하여 구축하였다. 형상정보, 공정정보, 장비, 피삭재가 입력되면 최적 절삭조건 결정 시스템은 공구, 공구 홀더를 사용자와 반 대화형으로 결정하고 절삭량을 계산한 후 구축된 데이터베이스로부터 표준 절삭조건을 검색한다.

## 2.2 휴리스틱 보정을 위한 신경회로망 모델

본 연구에서는 병렬적인 정보 처리 능력으로 동시에 여러 요소들간의 비선형적인 관계를 적절히 표현할 수 있는 신경회로망 기법[4]을 이용하여 표준 절삭조건 결정시 고려되지 않은 요소들의 영향을 반영하였다. 휴리스틱 보정 과정은 네개의 모듈과 신경회로망 데이터베이스를 포함한다. <그림 3>은 이 과

모들의 입력 형태로 바꾼다.

### (2) 신경회로망 재현 모듈

신경회로망 데이터베이스에 저장되어 있는 신경회로망의 사이즈, 계수 및 가중치를 읽어 신경회로망 모델을 구성한 후 변환된 형상 및 공구정보를 입력받아 이송량의 수정율을 출력한다

### (3) 후처리 모듈

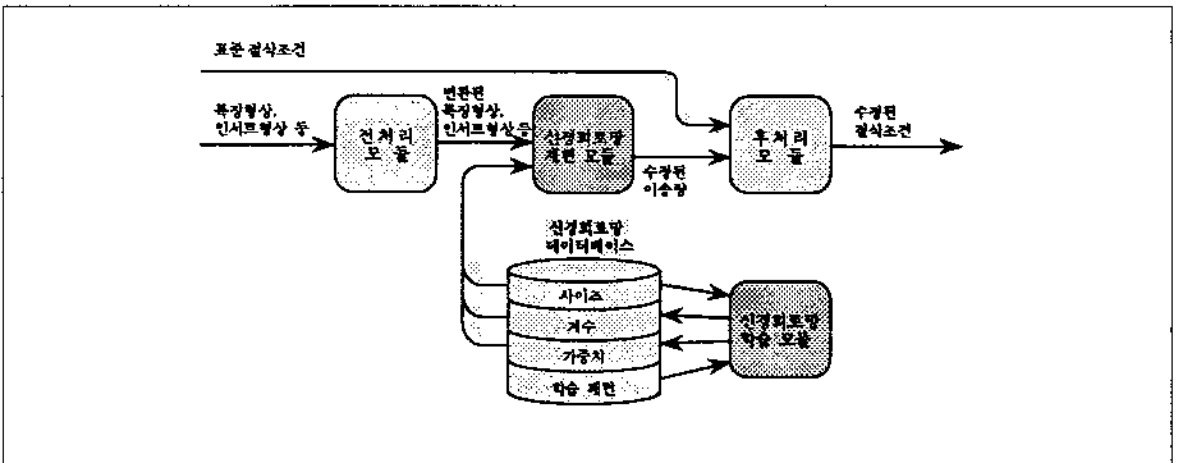
표준 절삭조건을 결정된 수정율을 이용하여 수정한다.

### (4) 신경회로망 학습 모듈

신경회로망 데이터베이스로부터 먼저 신경회로망의 사이즈를 읽어 신경회로망 모델을 구성한 후 다시 학습패턴을 읽어 신경회로망 모델을 학습시킨다. 학습결과는 신경회로망 데이터베이스에 저장한다.

### (5) 신경회로망 데이터베이스

신경회로망 모델의 학습이나 재현시 사용되는 데이터를 저장한다. 저장되는 데이터의 종류는 신경회로망의 사이즈, 계수, 가중치 및 학습패턴이다.



<그림 3> 휴리스틱 보정 과정


정의 정보 흐름을 보여준다. 각 모듈에 대하여 살펴보면 다음과 같다.

### (1) 전처리 모듈

입력된 형상 및 공구정보를 신경회로망 재현(Recall)

### 2.2.1 신경회로망의 구조 및 학습 알고리즘

<그림 4>는 표준 절삭조건의 휴리스틱 보정을 위해 제안된 4개의 층(Layer)을 가지고 있는 신경회로망 모델의 구조이다. 이 모델은 15개의 뉴런(Neuron)을 가지고 있는 입력층과 각각 15개의 뉴런을 가지고 있는



〈그림 4〉 신경회로망 모델의 구조

2개의 은닉층(Hidden Layer) 및 한 개의 뉴런을 가지고 있는 출력층(Output Layer)으로 구성된다. 이는 각각 1, 2, 3개의 은닉층과 5, 10, 15개의 뉴런에 대하여 테스트 한 결과 시간대 학습정도가 가장 우수한 구조였다. 그리고 이 모델의 학습을 위하여 문제의 성격 - 입력 파라미터에 따른 이송량의 수정을 결정 - 에 적합한 지도학습(Supervised Learning) 알고리즘인 역전파 학습 알고리즘(Back-Propagation Learning Algorithm)[4]이 사용되었다.

### 2.2.2 학습데이터의 수집

신경회로망의 학습을 위하여 ASME, SME등에서 제공하는 데이터[5-7]를 이용하였고 이 데이터는 현장 전문가와의 인터뷰를 통하여 검증 및 보완되었다. 수집한 데이터는 표 및 그래프 형태로써 공구 종류 및 재질, 피삭재질을 기준으로 공구 수명, 피삭재의 표면상태, 인서트 형상, 절삭유 등에 따라 이송량의 수정

율을 표현한 것이다.

### 2.2.3 입력 파라미터의 분류

신경회로망의 입력 파라미터는 7개의 고려사항 - 불완전 칩발생 가능성, 공구 길이, 공구 수명, 절삭깊이, 인서트 형상, 피삭재의 표면상태 및 절삭유의 종류 - 에 대하여 총 15개로 결정하였다. 15개의 파라미터에 대하여 파라미터별 클래스를 구성하고 학습 및 재현시 신경회로망 입력 파라미터의 값으로서 클래스 번호를 입력한다. 클래스 번호의 입력 이유는 첫째, 이송량의 수정에 같은 영향을 주는 파라미터를 하나의 값으로 표현하여 학습데이터의 양을 줄이기 위한 것이고, 둘째는 문자를 값으로 가지는 경우 이를 대신하기 위한 것이다. <표 1>은 15개의 입력파라미터 분류내용의 일부를 보여준다. 여기서 기준 공구와 기준 절삭깊이는 표준 절삭조건 결정시 기준이 된 공구 및 절삭깊이를 나타낸다.

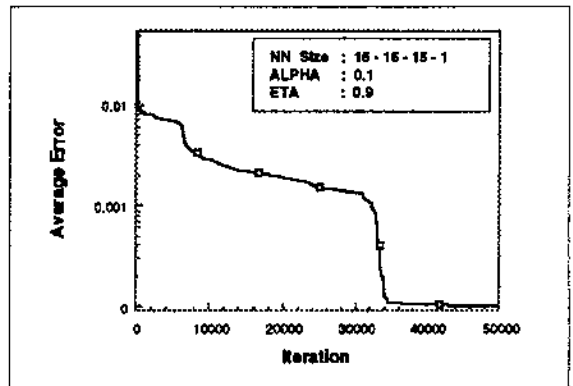
〈표 1〉 입력파라미터 분류 내용의 일부

Class No.	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Input Parameters														
Tool Type	Drill	Tap	End mill	Face mill	Bore	X	X	X	X	X	X	X	X	X
:	:	:	:	:	:	:	:	:	:	:	:	:	:	:
Tool Material	Hss	Carbide	X	X	X	X	X	X	X	X	X	X	X	X
R <sub>TL</sub>	0.7	0.8	0.9	1	1.5	2	3	4	5	6	7	8	9	10
Raw Material	Carbon Steels	Alloy Steels	Cast Irons	Aluminum Alloys	Coppers	X	X	X	X	X	X	X	X	X
R <sub>DC</sub>	0.7	0.8	0.9	1	1.5	2	3	4	5	6	7	8	9	10
R <sub>NR</sub>	0.7	0.8	0.9	1	1.5	2	3	4	5	6	7	8	9	10
R <sub>LA</sub>	0.7	0.8	0.9	1	1.5	2	3	4	5	6	7	8	9	10
Surface Condition Of Raw Material	Surface With Scale Of Heat Treatment	Shot Blasted Cast	Cast Without Shot Blasting	X	X	X	X	X	X	X	X	X	X	X
:	:	:	:	:	:	:	:	:	:	:	:	:	:	:

주 :  $R_{TL} = \frac{\text{선택한 공구의 수명}}{\text{기준 공구의 수명}}$       $R_{NR} = \frac{\text{선택한 공구의 인선반경} + 0.8}{\text{기준 공구의 인선반경} + 0.8}$   
 $R_{DC} = \frac{\text{선택한 절삭깊이}}{\text{기준 절삭깊이}}$       $R_{LA} = \frac{\text{선택한 공구의 리이드각} + 15}{\text{기준 공구의 리이드각} + 15}$

2.2.4 신경회로망의 학습

신경회로망의 구조를 결정하기 위해 먼저 은닉층의 갯수 및 각 은닉층의 노드 갯수 등을 변화시키는 동시에 학습을  $\eta$ 와 가중치  $\alpha$ 의 값을 조절해 가면서 신경회로망의 에러 수렴정도를 판단하였다. 여기서  $\eta$ 와  $\alpha$ 는 0과 1사이의 상수이다. 신경회로망의 학습은 인터그래프 W/S(InterPro Series 2700)에서 280 분 동안 수행되었다. 〈그림 5〉는 124개 학습패턴에 대한 신경회로망의 학습과정을 보여주고 있다. X축은 학습 반복횟수를, Y축은 각 학습 단계에서 학습패턴의 평균 에러를 나타낸다.  $\eta$ 는 0.9,  $\alpha$ 는 0.1, 학습 반복횟수가 50000번일 때 평균 에러는 0.000099였다. 〈표 2〉는 신경회로망의 학습 조건 및 결과를 보여준다.



〈그림 5〉 신경회로망의 학습과정

〈표 2〉 신경회로망의 학습 조건 및 결과

NN Coefficients & Learning Parameters		Values
NN Model		Multi-Layered Feed Forward Network
Learning Algorithm		Back-Propagation Learning Algorithm
Number Of Nodes Of Each Layer	Input	15
	Hidden	15
	Output	1
Number Of Hidden Later		2
Number Of Learning Patterns		124
Learning Rate, $\eta$		0.9
Momentum Term, $\alpha$		0.1
Error Bound		0.000099
Number Of Iteration		50,000
Time Spent For NN Training		280

송량을 수정한다.

2.4 수정된 절삭조건외의 필터링

수정된 절삭조건이 장비의 용량을 만족하는지 판정하여 부적절하면 공정별로 단순화된 수식을 이용하여 필터링 한다. 예로써 면삭가공(Face Milling)에서, 결정된 절삭조건이 장비의 최대 절삭동력을 만족하는지 검사하기 위한 수식은 다음과 같다.

$$N_r = \frac{1000 \cdot \text{Speed}}{\pi \cdot D}$$

$$P_{kw} = \frac{K_s \cdot \text{Depth—Cut} \cdot \text{Width—Cut} \cdot \text{Feed} \cdot Z_n \cdot N_r}{612000 \cdot \eta}$$

$$F_{kw} = \frac{612000 \cdot \eta \cdot P_{nominal}}{K_s \cdot \text{Depth—Cut} \cdot \text{Width—Cut} \cdot Z_n \cdot N_r}$$

If  $P_{kw} > P_{nominal}$

Then

$$\text{Feed} = \text{Feed} - \frac{\text{Feed} - F_{kw}}{2} \text{ And}$$

$$\text{Speed} = \text{Speed} \cdot \frac{F_{kw}}{\text{Feed}}$$

- 여기서  $N_r$  : 계산된 스피들 회전수(rpm)
- $K_s$  : 비절삭저항값(kg/mm<sup>2</sup>)
- $\eta$  : 기계 효율(0.7 - 0.8)
- $P_{nominal}$  : 장비의 허용 절삭력(Kw)
- $Z_n$  : 공구의 날수(teeth/rev.)

2.5 결정된 절삭조건외의 평가

일반적으로 신경회로망 모델의 성능은 대부분 학습 데이터에 의해 결정된다[4]. 그러므로 휴리스틱 보정 결과의 최대 기대치는 124개의 학습데이터에 의존한다고 볼 수 있다. 본 연구에서 사용한 학습데이터는 현장 전문가에 의한 사전 검증 및 보완 과정을 거쳤고, 〈그림 5〉에서 보는 바와 같이, 학습데이터에서의 기대치(Desired Output)와 신경회로망 출력값과의 평균 에러가 0.000099였으므로 휴리스틱 보정 결과의 유

2.3 검색된 표준 절삭조건외의 휴리스틱 보정 과정


학습된 신경회로망을 이용하여 검색된 표준 절삭조건을 보정하는 과정은 다음과 같다.

- (1) 특징형상, 인서트 형상 및 피삭재의 표면상태 등의 정보가 입력되면 시스템은 먼저 신경회로망 데이터베이스로부터 신경회로망 정보 - 사이즈, 계수, 가중치 - 를 입력하여 신경회로망을 구성한 후 각 입력 데이터에 해당 클래스 번호를 부여한다.
- (2) 만약 입력 데이터가 실수(Real Number)이면서 파라미터의 클래스 분류 내용과 일치하지 않는다면, 가까운 좌우 값에 해당하는 2개의 클래스 번호를 보간(Interpolation)한 후 신경회로망의 입력 값으로 사용한다.
- (3) 결정된 입력 파라미터의 클래스 번호를 이용하여 신경회로망을 전파시켜 이송량의 수정율을 구한다.
- (4) 결정된 이송량의 수정율을 이용하여 입력된 이

효성을 확인할 수 있었다.

### 3. 사례연구

본 최적 절삭조건 결정 시스템은 인터그래프 W/S 상에서 데이터베이스 관리를 위하여 ORACLE RDBMS, CAD 시스템으로 I/MDS, GUI를 위한 툴인 I/FORMS, 그리고 프로그래밍을 위하여 PPL, C 언어를 이용하여 구현되었다. <그림 6>은 예제로 선택한



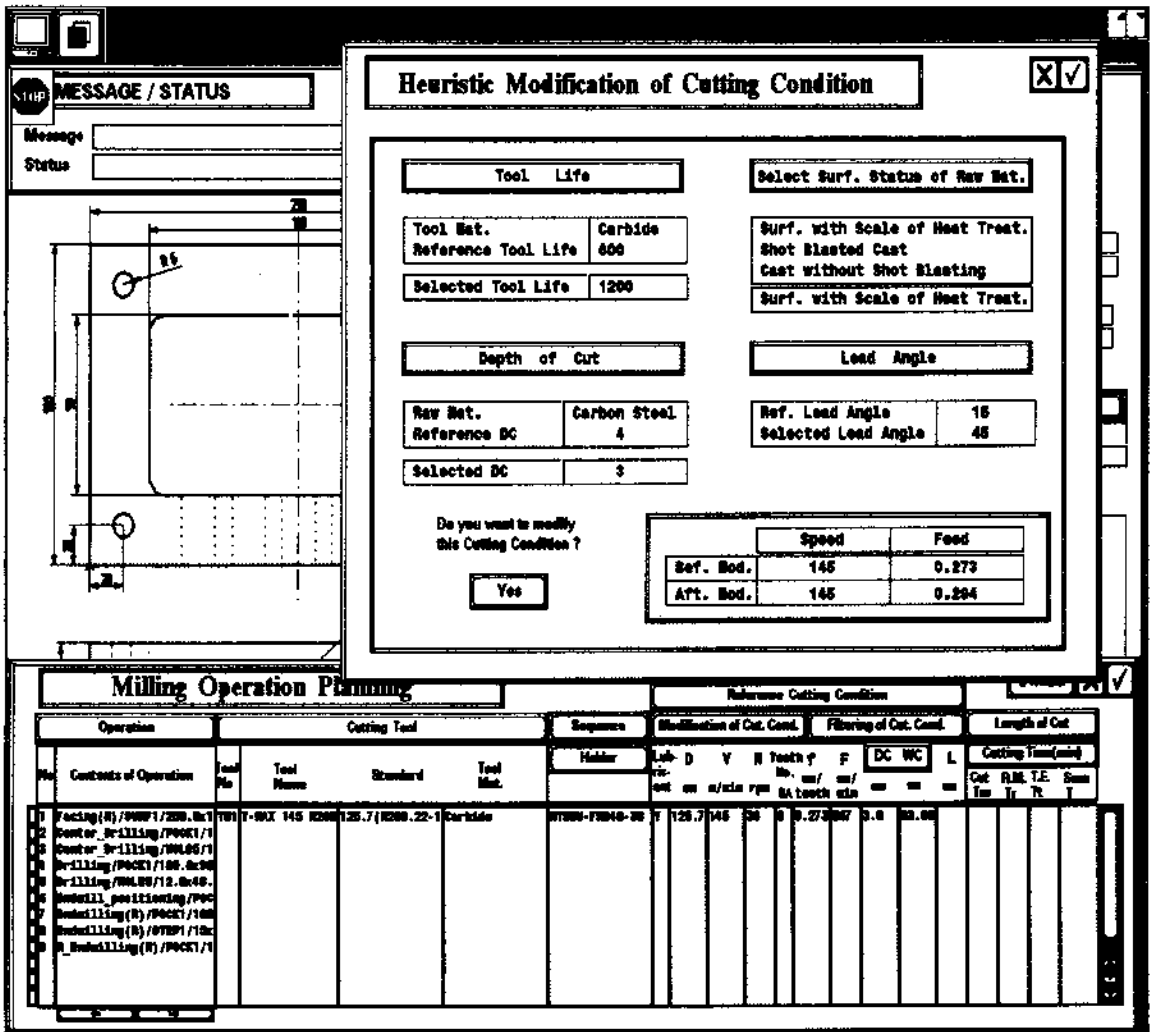
<그림 6> 예제 도면

부품 도면을 보여준다. 피삭재질은 열처리 스케일 (Scale)이 붙은 면을 가지고 있는 탄소강이고, 사용할 공작기계는 머시닝센터 TMV-2로 하였다. 도면에는 Pocket, Step, Surface, Hole 특징형상이 존재한다. 이 중 Surface 특징형상에 대한 'Facing(R)/SURF1/250X160X3' 오퍼레이션에 대하여, SANDVIK사의 공구규격이 '125 (R260.22-125-15)'이고 인서트 및 재질이 'SEMNI2 04 AZ/SMA', 공구경이 125, 날수가 8, 리이드각이 45°인 면삭공구 T-MAX 145를 선택하고 절삭깊이 및 폭을 각각 3.0, 83.3으로 했을 때 표준 절삭조건으로 절삭 속도, 145, 이송량, 0.2가 검색되었다. 가공방법이 면

삭가공인 경우, 불완전 칩발생 가능성 등은 반영할 필요가 없으므로 공구수명, 절삭깊이, 리이드각, 피삭재의 표면상태에 대하여 신경회로망에 의한 보정을 수행한다. 즉, 공구수명과 관련된 입력 파라미터인 공구 재질과  $R_{TL}$ 의 값이 각각 'Carbide', 2이므로 <표 1>에 의해 각각 2와 6의 클래스 번호를 부여한다. 이러한 방법으로 타 파라미터의 값을 결정된 후 신경회로망을 전파(Propagation)시켜 결정된 이송량의 수정율은 1.09이다. <표 3>은 이러한 휴리스틱 보정 과정에서, 이송량의 수정율이 결정되는 과정 및 결과를 보여준다. <표 3>의 결과를 이용하여 절삭속도 및 이송량은 원래의 145, 0.2에서 145, 0.218로 수정된다. <그림 7>은 수정된 결과를 보여준다. 마지막으로 수정된 절삭 조건은 장비의 최대 절삭력, 스펀들 진동가능성, 최대 스펀들 속도, 가공 안정성을 만족하므로 수정되지 않았다.

<표 3> 이송량 수정율의 결정 과정 및 결과

Factors	Input Parameter	Value Of Input Parameters	Class No.	Modif. Ratio Of Feed
Tool Life	Tool Mat.	Carbide	2	1.09
	$R_{TL}$	2	6	
Depth Of Cut	Raw Mat.	Carbon Steel	1	
	$R_{DC}$	0.75	1,5	
Insert Shape	$R_{LA}$	4	8	
Surface Condition Of Raw Material		Surface With Scale Of Heat Treatment	1	



〈그림 7〉 최종적으로 수정된 절삭조건

4. 결론

각주형 형상의 가공시 실제적인 절삭조건을 결정하기 위하여 공정설계자가 표준 절삭조건에 대해 수행했던 휴리스틱 보정과정을 시스템화하였다. 기존의 알고리즘으로 처리하기 곤란했던 여러 파라미터간의 비선형적인 관계를 신경회로망을 이용하여 적절히 모델링할 수 있었다. 현재 대부분의 공정설계자는 주어진 오퍼레이션에 대한 절삭조건을 결정하기 위하여 여러 참고문헌을 검색하고 이를 수정해야 하므로 개발된

시스템을 이용한다면 표준 절삭조건 검색 및 보정을 용이하게 수행할 수 있다. 또한 절삭조건 데이터베이스는 가공 데이터 핸드북의 데이터뿐만 아니라 실제 현장에서 사용하고 있는 데이터를 이용하여 구축된 것이므로 타 기업에도 쉽게 적용 가능하리라 예상된다. 그러나 공정설계자가, 절삭조건 수정과정에서 이용되는 신경회로망 관련 사항 - 각 모듈의 기능, 학습 데이터의 의미 등 - 을 이해하기에는 어려움이 있으므로 향후, 비전문가도 새로운 학습데이터의 입력 및 신경회로망의 재학습 등이 용이하도록 관리 기능을



추가하는 것이 필요하다. 또한, 보다 현실성 있는 결과를 기대하기 위하여, 다양한 학습데이터의 수집, 활용 및 절삭실험에 의한 검증은 거칠 예정이다.

**【참고문헌】**

[1] T. Matsumura, T. Obikawa, T. Shirakashi, E. Usui, "Autonomous Operation Planning of Machining Processes", Journal of JSPE, 59-10, pp. 94-100, 1993

[2] Zang, H., Anh Alting, L., "Introduction to an Intelligent Process Planning System for Rotational Parts", Advances in Manufacturing System Engineering, ASME, Vol. 31, pp. 15-26, 1988

[3] *Machining Data Handbook*, Machinability Data Center Metcut Research Associates Inc., 1986

[4] Rumelhart, D. E., McClelland, J. L., *Parallel Distributed Processing*, The MIT Press, 1986

[5] Sirotni, J., *Calculation method of machining time*, Kougaku-Sha, Japan., 1984

[6] Shaw, M., *Metal Cutting Principle*, The MIT Press., 1986

[7] 이용성, *기계가공시간계산법*, 한국이공학사, pp. 67-74, 1987



박면웅(朴勉雄)

1987년 University of Manchester Institute of Science & Technology 졸업(박사)  
 1979년 한국과학기술원 졸업(석사)  
 1977년 서울대학교 공과대학 졸업(학사)  
 현재 한국과학기술연구원 책임연구원  
 관심분야: 공정계획, 절삭가공, 공작기계



박병태(朴炳台)

1991년 인하대학교 조선공학과 졸업  
 1993년 인하대학교 대학원 기계공학과 졸업(공학석사)  
 현재 한국과학기술연구원 기전연구부 CAD/CAM팀 연구원  
 관심분야: 공정계획, 작업설계, 인공지능