

실험계획법 및 신경망을 이용한 코팅공구의 성능예측에 관한 연구

최광진 · 백재용 · 백영남

(경희대학교 기계·산업시스템공학부)

Prediction on the Efficiency of Coated Tool Using Experimental Design and Neural Network

Choi, Gwang Jin · Baek, Jae Yong · Paik, Young Nam

(KyungHee University of Mechanical and Industrial System Engineering)

ABSTRACT

In this study, the prediction on the quality of tools after coating process has been investigated. Under different coating conditions, cutting resistances have been obtained and analyzed with a tool dynamometer to provide optimized coating conditions.

The optimized coating condition has been computed with the most effective factors found by S/N ratio of Taguchi method.

To evaluate the influence of the factors on cutting efficiency through the minimum of number of experiment times, the way of neural network design using Taguchi method has been employed.

Keywords : Cutting Resistance(절삭저항),
Tool Dynamometer(공구동력계),
Neural Network(신경망),
Taguchi Method(다구찌법)

1. 서 론

생산기술이 발달함에 따라 기계 가공품에 대한 고정밀도가 요구되고 있는 요즈음, 정밀 제품의 품질 보증 및 생산성 향상을 위한 감시에 있어서 공구마멸에 의해 일어나는 절삭효율 및 공

구성능의 변화에 대한 평가는 일반적이다. 공구가 마멸하게 되면 절삭력이 증가하고 마멸이 어느 한계치를 넘으면 가공 정밀도 등의 절삭효율이 급격히 감소하게 되므로, 공구를 적기에 교체하는 것은 공작물의 불량률을 줄일 뿐 아니라, 생산성을 높여주고 경제적 손실을 줄일 수 있는 방법 중의 하나이다.¹⁾⁽²⁾⁽³⁾⁽⁴⁾.

이와 더불어 1980년대 후반부터 국내에서 소재 개발과 더불어 소재의 단점을 저렴한 가격에 보완 할 수 있는 각종 프로세싱들이 개발이 되었는데, 그 중에 하나로서 이온 플레이팅이 많은 연구자들에 의해 개발이 되었다. 이러한 내마모성의 향상을 위해 코팅 공구에 대한 의존도가 상당히 높게되어, 공구수명 또한 박막의 특성에 따라 많이 좌우되게 된다.

본 연구에서는 공구의 손상 및 효율향상을 위해 코팅 공구생산을 위한 인자들의 상호관계를 규명하고자 한다. 이온 플레이팅법으로 코팅된 앤드밀을 사용하여 코팅공정 조건별 절삭저항의 변화를 공구동력계를 이용하여 측정하고, 가공공정이 진행되는 과정에서 공구마멸에 의해 일어나는 절삭저항 변화추이를 분산분석 및 신경망 학습법을 이용하여 절삭효율 및 공구성능변화를 예측하여 이온플레이팅법에 의한 여러 조건별 코팅 공정에서 코팅공구의 절삭성능에 가장 큰 영향을 미치는 인자를 검출하고 코팅공구의 특성을 최대한 이용할 수 있는 최적조건들을 산출하였다.

2. 이론적 배경

2.1 실험계획법

실험계획법이란 주어진 실험에 대한 실험방법을 의미하는 것으로, 어떠한 통계적 방법으로 데이터를 분석하면 최소의 실험회수에서 최대의 정보를 얻을 수 있는가를 계획하는 것이라고 정의할 수 있다. 실험계획법에서 많이 이용되는 데이터의 분석방법으로는 분산분석, 상관분석, 회귀분석 등이 있으나 본연구에서는 분산분석을 사용하였다.

분산분석은 실험계획법에서 가장 많이 이용되는 분석방법으로, 실험에서 얻은 특성치의 산포를 제곱합으로 나타내고 이 제곱합을 실험과 관련된 요인별의 제곱합으로 분해하여 오차에 비해 특히 큰 영향을 주는 요인이 무엇인가를 찾아내는 분석방법이다, 각 요인의 제곱합을 그 요인의 자유도로 나누면 그 요인의 제곱평균이 되며 오차분산에 비하여 얼마나 큰가를 검토하게 된다. 따라서 분산분석이란 특성치의 산포를 요인별로 분해하여 어느 요인이 큰 산포를 나타내고 있는가를 규명하는 방법이라 할 수 있다⁵⁾.

2.2 신경망과 다구찌 방법

제품 및 공정의 설치단계에서 실험의 측정데이터, 즉 특성치(Characteristic)가 수반하는 오차는 참 값으로부터의 차우침과 데이터의 편차로 나누어지는데, 편차로 인한 오차는 그 수정이 매우 어렵다⁶⁾. 따라서 특성치의 편차가 심한 제품은 품질이 낮다고 말할 수 있으며, 이 편차의 정도를 나타내는 지표로서 다구찌는 S/N 비(Signal to Noise Ratio)라는 개념을 도입하여 생산공정에 적용하였다⁷⁾⁸⁾. 본 연구에서 고려한 망소특성식은 아래의 식과 같다.

$$S/N_{LB}(n) = -10 \log \left(\frac{1}{r} \sum_{i=0}^r y_i^2 \right)$$

여기서, r 은 동일설계변수조합에서 잡음인자를 고려한 실험 횟수이며, n 은 설계변수조합으로 수행한 실험 횟수를 나타낸다. y 는 설계특성치를, 그리고 첨자 i 는 동일설계변수조합에서 잡음인자를 고려한 실험 번호를 나타낸다.

직교배열표에 따라 설계된 설계변수조합으로

부터 최적의 변수조합을 구하기 위하여 다구찌 방법으로 변환된 S/N 비를 신경망 학습의 목적값(Target Value)으로 사용하였다. 신경망은 비선형 문제, 형상분류, 제어 등의 분야뿐만 아니라 함수근사까지 그 응용범위가 상당히 넓다. 본 연구에서는 감독학습의 역전파 학습알고리즘을 이용하여 목적값과 학습으로 계산된 실제 출력값과의 차를 줄여 나갔다.

신경망의 능력을 최대한 살리기 위해서는 신경망 학습데이터의 선정에 주의를 기울여야 한다. 학습데이터에 따라 그 결과의 정확도가 달라질 수 있으며, 정확한 해석을 위해서는 많은 학습데이터를 필요로 하기 때문이다. 실험계획법만으로 공정 설계를 수행할 때에도, 변수 수준간의 폭이 좁아야 하며 전문가적 지식이 요구된다는 제약이 따른다. 이러한 실험계획법과 신경망이 가지는 단점을 보완하고 장점만을 살려 보다 신속히 최적의 설계변수조합을 얻기 위하여 실험계획법에서 사용된 직교배열표를 신경망의 학습데이터로 사용할 수 있도록 하였다. 이렇게 함으로써, 시뮬레이션 횟수를 줄이는 동시에 많은 학습효과를 얻을 수 있고, 전문가적 지식이 없어도 설계변수 수준을 잡는데 큰 어려움이 없다. 그리고 특별한 데이터 해석이 없어도 최적의 변수조합을 선정할 수 있으므로 설계변수의 다수준 영역에서 특성치에 미치는 영향을 파악하는 효과를 얻을 수 있다⁹⁾¹⁰⁾. 본 연구에서 학습에 사용된 신경망 프로그램은 입력층, 은닉층과 출력층을 포함한 $3 \times 8 \times 8 \times 1$ 형태의 4층구조로 수행하였고, 각 공정에 따라 은닉층의 뉴런 수 변경이 용이하도록 하였으며, 허용오차 범위는 10^{-4} 으로 하였다.

3. 실험장치 및 실험방법

3.1 이온플레이팅 장치 및 방법

CD(Hollow Cathode Discharge) Gun을 이용한 Ti 증발방식을 채택한 Ion-Plating 장비를 이용하였다. 이 장치는 내부직경이 800mm, 높이 600mm인 원통형으로 주변에 3개의 시창구를 각기 다른 높이에 설치하여 내부의 관찰을 용이하게 하였다.

개 하였다. 내부에는 코팅물을 예열하기 위한 가열(Heating) 장치와 시창구가 코팅되는 현상을 막기 위한 셔터 등을 보강하였고, 실험조건을 여러 가지로 변화할 수 있도록 하기위해 가스 공급 조절장치와 온도조절, 전압, 전류를 임의대로 조절 할 수 있는 장치를 설치하였다(Fig. 1 참조). 또한 안정된 Bias 전압을 공급하기 위해 스위칭 전원 공급장치(Switching Power Supply)를 사용하였다. 실험에 사용한 코팅 대상물로는 두날 엔드밀을 사용하였으며 엔드밀의 소재는 SKD-56으로 성분은 Table. 1과 같은 고속도 공구강이다.

3.2 절삭력 측정장치 및 방법

코팅된 엔드밀을 이용하여 피 절삭물을 가공하고 가공시에 생기는 절삭력을 측정하여 절삭력 증가율을 측정하였다. 절삭력을 측정하기 위하여 사용된 장치는 Fig. 2에 나타낸 화천 기공의 Silius-2 머시닝 센터를 사용하였고, 공구동력계는 Fig. 3에 나타낸 Kistler사의 9257B 공구동력계를 사용하였다. 또한 5019A130 전류 증폭기 등을 사용하여 절삭시에 발생되는 절삭력을 측정하였다. 절삭 실험을 위한 절삭 조건은 공구 회전속도 1500rpm에서 절삭깊이 12mm에, 이송속도는 0.027mm/rev, 절삭폭은 0.5mm로 하였다.

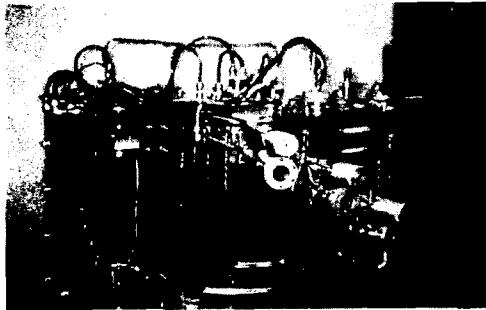


Fig. 1 Coating Chamber

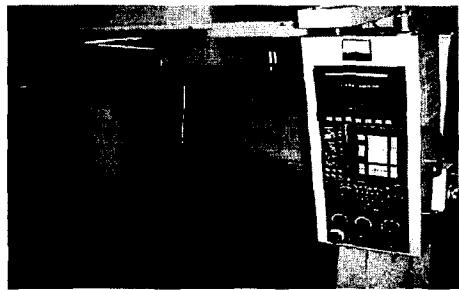


Fig. 2 CNC Machining Center

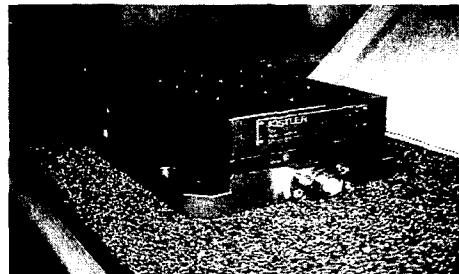


Fig. 3 Dynamo-Meter (5,000N)

4. 실험결과 및 고찰

4.1 절삭저항 실험평가

본 연구에서는 Table. 2에서 나타내는 바와 같이 Ar가스 주입량, N₂가스 주입량, 온도, 바이어스 전압 그리고 Gun전류의 5 가지의 변수가 Table. 2와 같이 각각 3 수준의 값을 가지므로 모든 경우, 총 243번(3×3×3×3×3)의 실험을 수행하여야 하지만 직교배열표를 이용하여 코팅 조건을 27가지로 줄였으며, 실험결과의 검증을 위해 각 조건별로 3번의 실험을 하였다. Fig. 4에는 코팅된 엔드밀의 절삭저항 추세선이다.

Table. 1 Component of SKD-56

component	C	Si	Mn	P	S	Cr	Mo	W	V	Co
content (%)	0.85 ~0.95	less than 0.4	less than 0.4	less than 0.030	less than 0.030	3.80 ~4.50	4.60 ~5.30	5.70 ~6.70	1.70 ~2.20	7.00 ~8.00

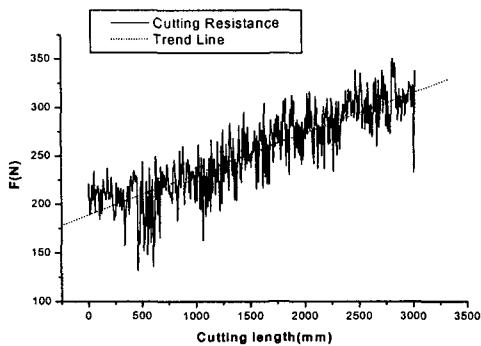


Fig. 4 Gradient of Cutting Force

각 코팅조건별 절삭저항 추세선에서 엔드밀의 성능을 단적으로 나타내는 표현으로 평균절삭저항 증가율 즉, 절삭저항기울기로 표현하였다. 신경망을 학습시키기 위해 S/N비를 산출하여 목적패턴으로 활용하였다. Fig. 5에서는 특성치의 각 인자의 수준별 절삭저항 기울기 값을 평균치와 가장 큰 오차 값으로 도시한 것이다.

4.2 S/N비에 따른 실험조건 인자별 영향 평가

Table. 2의 엔드밀의 코팅조건별로 27가지의 패턴으로 절삭저항을 취득하고 절삭저항기울기를 산출하여 다구찌 실험계획법에 의해 S/N비로 변환하였다. 절삭저항기울기는 특성치가 작으면 작을수록 좋은 경우인 망소특성(Smaller the Better Characteristics)을 적용하여 S/N 값이 클수록 특성치에 좋은 영향을 미치는 조건이며, S/N비가 클수록 절삭저항기울기는 낮은 조건이다. Fig. 6에서는 각각 특성치의 인자수준별 S/N비를 도시한 것이다.

Ar가스 주입량, N₂가스 주입량, 온도, 바이어스 전압 그리고 Gun전류가 미치는 영향을 알아보기 위하여 분산분석(ANOVA: Analysis of Variation) 하여 그 결과를 Table. 3에 나타내었고, Fig. 6에 각 변수의 각 수준별 평균 S/N비를 나타내었다. S/N비가 클수록 절삭저항기울기는 낮아지므로 각 변수의 수준에서 S/N비가 가장 큰 조건은 Ar은 1수준, N₂는 1수준, Temperature는 1수준, Bias V는 2수준, Gun A는 1수준일 경우이다.

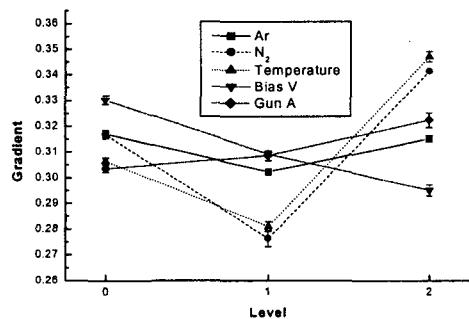


Fig. 5 Gradient Variation of Total Experimental Factor

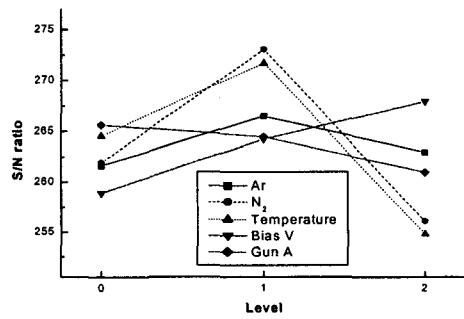


Fig. 6 S/N Ratio of Total Experiment Factor

Table. 2 The Sign Convention of Experiment Value

Levels	Mean Ar gas flow rate (sccm)	Mean N ₂ gas flow rate (sccm)	Mean temperature (°C)	Bias voltage (V)	Gun ampere (A)
0	25	80	450	300	160
1	30	90	500	350	170
2	35	100	550	400	180

Table. 3 ANOVA Table of S/N Ratio

Parameters	Average S/N Value Level			Sum of Square	Number of Freedom	Mean Square	s
	0	1	2				
Ar	261.6237	266.4893	262.9812	4.2027	2	2.1014	1.0780
N ₂	261.9485	273.0473	256.0984	49.4083	2	24.7042	12.6736
Tempera-ture	264.5707	271.7131	254.8104	47.9981	2	23.9990	12.3118
Bias V	258.9242	264.2369	267.9331	13.6720	2	6.8360	3.5069
Gun A	265.6348	264.4718	260.9877	3.8985	2	1.9493	1

Table. 3을 살펴보면 각 실험조건별로 S/N 비의 값을 구하여 각 인자별 수준으로 합계를 구하여 나타내었고 제곱합(Sum of Square)과 자유도(Number of Freedom), 평균제곱(Mean of Square)을 구하고, 제곱합이 가장 작은 Gun전류의 항이 절삭저항기율기에 미치는 영향은 미소하므로 오차항에 풀링(Pooling: 오차로 간주)시켜 변수의 기여도를 계산하여 F-검정을 하여 검정통계량을 표시하였다. 각 인자들의 검정통계량값을 살펴보면 95% 신뢰구간의 유의수준 0.05의 기각치 4.07보다 작은 값인 Ar과 Gun A는 기각되어 절삭저항 기율기에 적은 영향을 미치는 것으로 나타났다. 하지만 Gun A가 절삭저항기율기에 미치는 영향은 미소하나, Fig. 6에서 얻을 수 있는 결과는 값이 커질수록 절삭저항기율기가 낮아짐을 알 수 있었다. 각 인자들의 신뢰구간을 유의하여 수준별로 구하여 정리하여 보면 Table. 4와 같이 얻어진다.

4.3 신경망을 이용한 S/N비의 예측

각각의 코팅조건별 엔드밀의 절삭저항을 이용한 Table. 2의 실험조건 및 직교배열표를 신경망 학습의 입력데이터로 이용하여 미해석 변수조합이 갖는 S/N비를 예측하였다. 직교배열표의 설계된 변수의 조건에 대한 27번의 실험조건을 신경망의 입력층으로 하였고 목적함수로는 변환된 절삭저항기율기값 즉, S/N비를 출력층의 값으로 입력하였다.

Table. 4 Estimation of S/N Ratio
(Significance: 95%)

Paramete-rs	Le vel	Point Estimation of S/N Ratio	Confidence Interval 95%	
			-	+
Ar	0	29.0693	27.0667	31.0719
	1	29.6099	27.6074	31.6125
	2	29.2201	27.2176	31.2227
N ₂	0	29.1054	27.1028	31.1079
	1	30.3386	28.3360	32.3411
	2	28.4554	26.4528	30.4579
Tempera-ture	0	29.3967	27.3942	31.3993
	1	30.1903	28.1878	32.1929
	2	28.3123	26.3097	30.3148
Bias V	0	28.7694	26.7668	30.7719
	1	29.3597	27.3571	31.3622
	2	29.7703	27.7678	31.7729
Gun A	0	29.5150	27.5124	31.5175
	1	29.3858	27.3832	31.3883
	2	28.9986	26.9961	31.0012

사용된 신경망의 구조는 입력층 뉴런은 Ar과 Gun A의 절삭저항기율기 즉, S/N비에 미치는 영향이 미미하다고 판단되어 N₂가스 주입량, 온도, 바이어스 전압의 3개로 하였으며 여기에 설계변수를 할당하였고, 은닉층은 2층 구조로 각각 8, 8개의 뉴런을 가진다. 출력층은 1개의 뉴런에 S/N비를 할당하였다. 학습의 수렴기준은 목적값과 실제 출력값의 차이가 10^{-4} 에 달할 때 까지이며, 그 때까지의 학습반복회수는 50764회이었다.

Table. 4 Sampling Data of Testing Condition

Pattern No.	Mean N ₂ Gas Flow Rate (sccm)		Mean Temperature (°C)		Bias Voltage (V)	
	Experimental Value	Sign Convection	Experimental Value	Sign Convection	Experimental Value	Sign Convection
1	85	0.5	450	0	300	0
2	85	0.5	450	0	350	1
3	85	0.5	450	0	450	2.5
4	90	1	525	1.5	300	0
5	90	1	525	1.5	350	1
6	90	1	525	1.5	450	2.5
7	100	2	550	2	300	0
8	100	2	550	2	350	1
9	100	2	550	2	450	2.5

Table. 5 Verification of Simulation Value

Pattern No.	Point Estimation of S/N Ratio	Confidence Interval 95%		Experiment -al Value
		-	+	
1	29.4064	27.4038	31.4090	29.3962
2	30.0572	28.0546	32.0597	30.3798
3	30.4096	28.4070	32.4121	30.3867
4	29.9624	27.9599	31.9650	29.7312
5	31.2217	29.2192	33.2243	30.8146
6	31.2326	29.2300	33.2351	30.9082
7	27.2110	25.2084	29.2136	27.6270
8	27.5995	25.5969	29.6020	28.0240
9	27.7528	25.7503	29.7554	27.4420

4.4 예측결과의 검증

신경망으로 예측한 미해석 변수조합의 절삭 저항기울기에 대한 검증실험을 위하여 Table. 4의 변수조건으로 코팅된 엔드밀의 공구동력계를 이용한 절삭시험을 수행하였다.

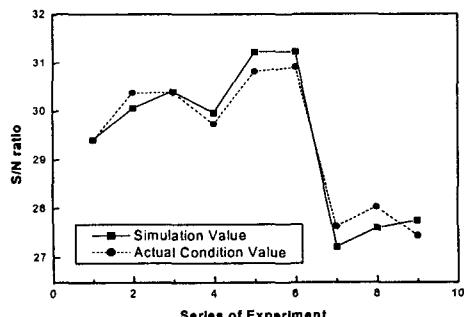


Fig. 7 Comparison Between Neural Network and Experimental Value

Fig. 7에서는 신경망으로 예측된 S/N비와 각각의 조건으로 코팅된 엔드밀의 실험결과를 비교한 것이다.

Table. 5에서는 신경망의 예측 결과를 실제 실험한 S/N비의 값으로 비교한 내용을 실제 실험값의 95% 신뢰구간을 이용하여 검증하였다. 2~3가지의 실험조건에서 95%의 유의수준에 가깝게 타나났지만 모두 95%의 신뢰구간에 포함되었다.

5. 결론

코팅조건별 엔드밀의 절삭성능평가를 통해 코팅공구의 성능에 영향을 미치는 인자의 검출과 최적조건의 산출에 관한 결론을 요약하면 아래와 같다.

- 1) 코팅된 엔드밀의 절삭성능에 영향을 미치는 각 인자들의 구간 내에서는 N₂가스 유량과 온도가 가장 큰 영향을 미치며 바이어스 전압의 영향도 큰 것으로 나타났다. 그러나 Ar가스 유량과, Gun 전류의 변화량은 절삭성능에 미치는 영향이 작았다.
- 2) 실험계획법에서 사용된 직교배열표를 신경망의 학습데이터로 사용하여 시뮬레이션 횟수를 줄이는 동시에 많은 학습효과를 얻을 수 있었고, 전문가적 지식이 없이도 설계변수 수준을 잡는데 큰 어려움이 없었다.
- 3) 각 코팅 조건 특성치가 미치는 영향은 실험 선택 조건에서 S/N비가 가장 큰 조건을 통해 Ar은 30sccm, N₂는 90sccm, 온도는 500°C, 바이어스 전압은 400V 수준, Gun A는 170A일 경우임을 확인하였다.
- 4) 신경망을 이용하여 미해석 변수조합이 절삭 저항기울기에 미치는 영향을 예측하였고, 실험을 통하여 예측결과의 타당성을 검증하였다. 이를 바탕으로 다구찌 방법을 이용한 신경망의 적용은

효율적인 해석기법임을 알 수 있었다.

- 5) 코팅 조건별 엔드밀의 성능 평가 결과를 예측하기 위한 평균 절삭저항 증가율의 선택은 코팅 조건 변화량에 대한 결과값으로 표현하기에 충분한 타당성을 입증하였다.
- 6) 코팅 공구의 품질을 예측하는 신경망의 구조는 3개의 입력노드 1개의 출력노드 만으로도 충분히 결과를 예측할 수 있다.

6. 참고문헌

1. 윤종학, 김동성: 절삭중 밀링 공구의 磨滅과 音響放出의 관련성에 관한 研究, (1995) pp. 1~3
2. E. K. Asibu Jr. Acoustic Emission Sening of Tool Wear Metal Cutting, General Motors Institute, (1980) pp. 55~59
3. 이병찬: 밀링 加工時 發生하는 工具 磨滅과 AE 信號에 관한 研究, Korea Advanced Institute of Science and Technology, (1987) pp 4-50
4. 方泰圭: AE 信號에 대한 Kurtosis와 Neural Network를 利用한 切削 工具의 異狀 診斷 시스템 開發에 관한 研究, 漢陽大學校 博士學位 論文 (1990) pp. 1-50
5. 박성현: 현대실험계획법, 민영사, (1990) pp. 1~24, 72~91, 323~326, 423~427, 469, 631~646
6. Box G.P., Hunter W.G. And Hunter J.S. : Statistics for Experiments, Wiley, New York, (1978)
7. Ross P.J. : Taguchi Techniques for Quality Engineering, McGraw-Hill, (1988)
8. Montgomery D.C. : Design and Analysis of Experiments, Willy, New York, 2nd edn, (1984)
9. 김동환, 고대철, 김병민, 최재찬: 가공성을 고려한 다단계 금속성형공정의 예비성형체 설계방법: 다구찌방법을 이용한 신경망의 적용, 대한기계학회논문집, A권 제22권 9호, (1998) pp. 161 5~1624
10. Kim. D.H., Ko D.C. and Kim B.M. : Application of Artificial Neural Network and Taguchi Method to Preform Design in Metal Forming Considering Workability, Int. J Machine Tools & Manufacture, Vol. 39, (1999) pp. 771~785