

# 실험계획법과 뉴럴 네트워크를 이용한 밀링 버 형상 예측

이성환<sup>+</sup>, 김설빔<sup>\*</sup>, 조용원<sup>\*</sup>  
(논문접수일 2006. 1. 5, 심사완료일 2006. 3. 9)

## Prediction of Burr Types using the Taguchi Method and an Artificial Neural Network

Seoung Hwan Lee<sup>+</sup>, Seol Bim Kim<sup>\*</sup>, Yong Won Cho<sup>\*</sup>

### Abstract

Burrs formed during face milling operations can be very difficult to characterize since there exist several parameters which have complex combined effects that affect the cutting process. Many researchers have attempted to predict burr characteristics including burr size and shape, using various experimental parameters such as cutting speed, feed rate, in-plane exit angle, and number of inserts. However, the results of these studies tend to be limited to a specific process parameter range and to certain materials. In this paper, the Taguchi method, a systematic optimization method for design and analysis of experiments, is introduced to acquire optimum cutting conditions for burr minimization. In addition, an in process monitoring scheme using an artificial neural network is presented for the prediction of burr types.

**Key Words** : Taguchi method(다구찌 방법), Neural network(신경망), Milling(밀링), Burr(버), Non-dimensionalization(무차원화)

## 1. 서론

버(burr)는 절삭가공 시 가공면의 끝부분에서 공구의 모서리 부 이탈 시 피삭재의 절삭저항에 기인한 밀림 현상과 이에 따른 소성변형으로 인하여 모서리에 발생하는 물체의 원치 않는 돌출부분을 말한다. 버는 부품의 정밀도와 품질의 악화, 조립 시 공차 문제 야기, 생산 라인의 자동화 어려움

에 따른 생산성 저하 등 오늘날 점점 무인화, 자동화 방향으로 발전해 가는 절삭공정에 있어서 큰 걸림돌이 되고 있다. Gillespie<sup>(1)</sup>는 정밀 부품의 가공에 있어서 deburring 공정이 전체 부품 단가의 약 30%까지 차지한다고 지적 하였다. 이처럼 디버링 공정에 낭비되는 비용과 시간을 줄이기 위해서는 버를 최소화 할 수 있는 가공 조건을 찾는 것이 필요하다. 지금까지의 연구 사례를 보면, 버의 생성과 관련된 내용은

<sup>+</sup> 한양대학교 기계공학과 (sunglee@hanyang.ac.kr)  
주소: 426-791 경기도 안산시 상록구 사1동 1271  
<sup>\*</sup> 한양대학교 대학원 메카트로닉스시스템공학과

Gillepie(1976), Ko(1991), Chern(1993), Olvera(1996)<sup>(2-5)</sup> 등에 의해 주로 실험적으로 이루어 졌으며 밀링 공정에서 버의 발생에 영향을 주는 인자인 이송율(feed rate), 주축의 회전 속도(spindle speed), 절삭 깊이(depth of cut), 가공면 끝부분과 절삭 날의 진행방향이 이루는 각 IXA(in-plane exit angle)등의 가공 파라미터를 중심으로 연구가 진행되었다. 이중 Chern<sup>(4)</sup>은 버의 종류를 형태에 따라 curl-type burr, wave type burr, knife-type burr, secondary burr의 4가지로 분류하였으며, Kishimoto(1981)<sup>(6)</sup> 등은 버를 primary burr와 secondary burr로 구분하였다. Chern의 분류에서 위의 4가지 중 secondary burr를 제외한 나머지 유형은 Kishimoto가 분류한 primary burr에 속한다. 그러나 이러한 대부분의 연구가 버의 생성과 그에 관련된 파라미터와의 개략적 연관성을 밝히는데 국한되었고, 가공 모니터링 및 제어에 연관되는 연구는 미미하였다. 선행 연구인 실험 계획법에 의한 최적 가공 조건 도출만으로는 가공 조건 변화에 따른 적용이 어려우므로 인공지능신경망(ANN)의 도입이 필요하게 되었다. 따라서 본 논문에서는 다구찌방법을 통해 산출된 가공 파라미터로 인공지능신경망을 실행하였으며, 입력값에 따른 결과값을 서로 비교해 봄으로써 입력값 선정의 중요성을 확인함과 동시에 효과적으로 밀링내 버 발생을 예측하는 시스템 구성을 위한 연구를 수행하였다.

## 2. 다구찌 방법

다구찌방법을 이용한 최적화에서 파라미터 설계의 목적은 원하는 특성치의 값과 원하는 이론적인 목표값과의 실제적인 차이를 최소화하기 위한 최적의 값을 찾는 것으로 정의할 수 있다. 특히, 파라미터 설계시 손실함수와 S/N 비를 사용하여 도출된 최적의 파라미터는 외부의 환경변화나 다른 잡음 요인에 매우 둔감한 특성을 가지므로 다구찌방법에 있어 파라미터 설계는 최적화의 성공 여부를 결정짓는 관건이라 할 수 있다<sup>(7,8)</sup>.

### 2.1 S/N 비

S/N 비(signal to noise ratio)는 특성치의 기능을 판단하기 위하여 통계적으로 계산된 수치로서 S/N 비의 값이 크면 클수록 그에 해당하는 특성치는 목표치에 근접하는 특성을 나타내게 되며, 각각의 인자가 잡음에 대하여 강건하다는 것을 의미한다. S/N 비는 목적함수, 즉 특성치에 의해 그 정의가 달라지게 되는데 특성치는 망목(The nominal the better), 망소(The lower the better), 망대(The higher the better) 특성

의 3가지로 분류된다. 본 연구는 버의 최소화에 대한 연구이므로 망소 특성을 적용하였으며, 이 경우 S/N비는

$$S/N = -10 \log \left[ \frac{1}{n} \sum_{i=1}^n y_i^2 \right] \quad (1)$$

이다. 식에서  $n$ 은 실험횟수를 나타내고  $y_i$ 는  $i$ 번째 실험값을 나타낸다.

### 2.2 분산분석(ANOVA)

분산분석(Analysis of Variance : ANOVA)은 어떤 파라미터가 특성치에 크게 영향을 미치는가를 알기 위한 방법으로, 다구찌방법의 파라미터 설계에 보완하여 각각의 파라미터의 유의성을 파악하는데 매우 유용하다. 우선, 편차의 제곱의 총합  $S_T$ 는 다음과 같이 표시된다.

$$S_T = \sum_{j=1}^n (n_j - n_m)^2 \quad (2)$$

여기서  $j$ 는 직교배열표의 실험번호,  $n$ 은 전체실험횟수,  $n_j$ 는  $j$  번째 S/N 비,  $n_m$ 는 평균 S/N 비를 나타낸다.  $S_T$ 는 각 파라미터 편차의 제곱합 성분과 에러에 의한 제곱합( $S_e$ ) 성분으로 나눌 수 있는데,  $S_T$ 에 대한 각 파라미터 제곱합 성분의 백분율( $\rho$ )로 해당 파라미터의 이산 기여도를 표시한다. 또한 각 파라미터의 평균 제곱합과 오차제곱합의 비인  $F$ 값을 계산하여 각 파라미터의 오차에 비한 중요도를 수치로 표시할 수 있다.

## 3. 실험장치 및 방법

### 3.1 실험 재료 및 측정 방법

본 논문에서는 버 연구에 주로 이용되는 가공성이 우수한 Al6061 과 난삭재로서 열전도도가 매우 낮은 SUS304 를 재료로 선택하였으며 기계적 성질은 Table 1에 제시되었다. 시편은 25(w) × 25(h) × 50(l)mm 크기의 직육면체이며 측정 기구는 분해능이 0.005mm인 공구현미경을 사용하였다.

Table 1 Mechanical properties of Al6061 and SUS304

Material	Al6061	SUS304
Tensile strength(Mpa)	310	580
Yield stress(Mpa)	275	265
Fracture strain	0.50	0.55

측정 방식은 정상상태 가공시 의 버를 고려하기 위하여 시편 의 임의의 여러 포인트를 측정하여 평균을 내어 얻어 낸 수 치이다. 실험장치는 최대 주축 회전수가 1000rpm인 수직형 머신센터(AJV-18)을 이용하였다. Cutter의 지름은 100 mm 이며, 인서트는 SPCN 계열을 사용하였다.

### 3.2 가공 변수 설정과 직교 배열표 선정

다구찌방법의 파라미터 설계 과정에서 직교배열표 선정 시 필요한 가공 파라미터를 선정하고, 그 파라미터의 수준을 적절하게 정하기 위한 예비절차로서 예비실험을 실시하였다. 여기서 파라미터는 가장 보편적이면서도 중요하게 고려 되는 IXA, 절삭깊이, 피드레이트, 절삭속도로 정하였고, 수

준은 가공영역을 벗어나지 않고 기술적으로 의미를 가지는 범위를 선정하였다. Table 2는 예비 실험에 사용된 가공 범위와 기준 가공 조건을 나타내고 있다. Table 2의 조건대로 각각 4개의 파라미터를 하나씩 교체 변경시키면서 예비 실험을 실시한 결과 Fig. 2, Fig. 3, Fig. 4, Fig. 5와 같다.

Table 2 Cutting conditions of preparatory experiment

Parameters	Range	Standard machining condition
In-plane exit Angle(°)	30 ~ 150	90
Depth of cut(mm)	0.5 ~ 3.5	2
Feed rate(mm/tooth)	0.05 ~ 0.25	0.15

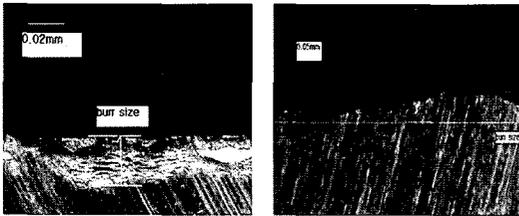


Fig. 1 (a)Al6061 실험결과 (b)SUS304 실험결과

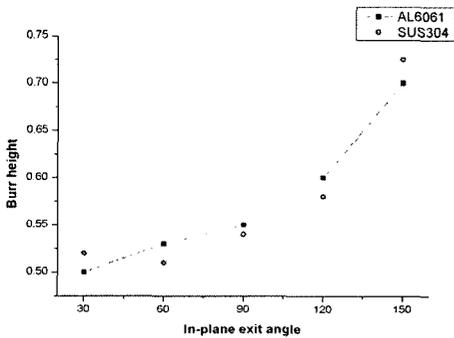


Fig. 2 In-plane exit angle vs burr height

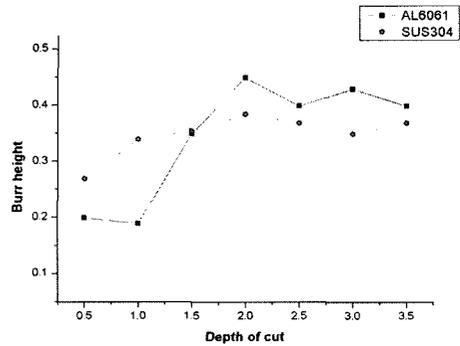


Fig. 3 Depth of cut vs burr height

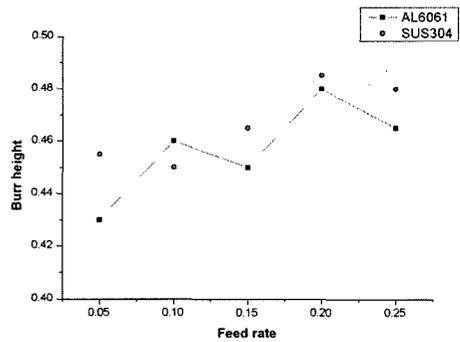


Fig. 4 Feed rate vs burr height

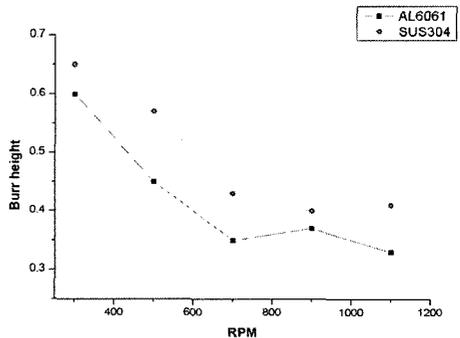


Fig. 5 Cutting speed vs burr height

**Table 3 Parameters and their levels**

Symbol	Level			
	1	2	3	4
A : In-plane eXit Angle(°)	30	70	110	150
B : Depth of cut(mm)	0.5	1.0	1.5	2.0
C : Feed rate(mm/tooth)	0.05	0.1	0.15	0.2
D : Spindle speed(rpm)	300	500	700	900

**Table 4 Orthogonal array(L<sub>16</sub>(4<sup>4</sup>))**

No.	Factor			
	A	B	C	D
1	1	1	1	1
2	1	2	2	2
3	1	3	3	3
4	1	4	4	4
5	2	1	2	3
6	2	2	1	4
7	2	3	4	1
8	2	4	3	2
9	3	1	3	4
10	3	2	4	3
11	3	3	1	2
12	3	4	2	1
13	4	1	4	2
14	4	2	3	1
15	4	3	2	4
16	4	4	1	3

위 예비실험의 결과를 통해, 버 생성에 영향을 주는 4개의 인자와 4개의 수준을 Table 3과 같이 선정하였다. 실험조건은 4수준 4인자이므로 직교 배열표 가운데 L<sub>16</sub>(4<sup>4</sup>)를 선택하였다. Table 4는 Al6061과 SUS304에 적용될 직교 배열표로써 특정한 파라미터에 치중되지 않고, 직교 배열된 16회의 실험횟수를 나타낸다. 각각의 실험결과에 대한 신뢰성을 위해서 3회의 반복 실험을 수행하였다.

### 4. 실험결과

#### 4.1 실험 결과와 S/N ratio 분석

버는 type1과 type2의 두 가지로 분류하였으며, type1은 상

**Table 5 Experiment results for Al6061 & SUS304**

No.	Al6061			SUS304		
	Burr type	Burr height	S/N ratio	Burr type	Burr height	S/N ratio
1	Type 1	0.13	17.72	Type 1	0.42	7.53
2	Type 1	0.06	24.43	Type 2	0.60	4.43
3	Type 1	0.12	18.41	Type 1	0.15	16.47
4	Type 1	0.15	16.47	Type 2	0.93	0.63
5	Type 1	0.21	13.55	Type 1	0.10	20.00
6	Type 1	0.08	21.93	Type 2	1.12	-0.98
7	Type 2	0.65	3.74	Type 2	0.76	2.38
8	Type 1	0.43	7.33	Type 1	0.34	9.37
9	Type 2	0.60	4.43	Type 2	1.05	-0.42
10	Type 1	0.17	15.39	Type 2	0.85	1.41
11	Type 1	0.51	5.84	Type 2	0.54	5.35
12	Type 2	0.72	2.85	Type 1	0.20	13.97
13	Type 2	0.55	5.19	Type 2	1.30	-2.27
14	Type 2	1.04	-0.34	Type 1	0.48	6.37
15	Type 2	0.90	0.91	Type 2	0.69	3.22
16	Type 2	0.80	1.93	Type 1	0.50	6.02

**Table 6 Average S/N ratio for each level(Al6061)**

Parameter Level	A	B	C	D
1	<b>19.26</b>	10.23	<b>11.86</b>	5.99
2	11.64	<b>15.36</b>	10.44	10.70
3	7.13	7.23	7.46	<b>12.33</b>
4	1.93	7.15	10.20	10.94

**Table 7 Average S/N ratio for each level(SUS304)**

Parameter Level	A	B	C	D
1	7.27	6.21	4.48	7.57
2	<b>7.69</b>	2.81	<b>10.41</b>	4.22
3	5.08	6.86	7.95	<b>10.98</b>
4	3.33	<b>7.50</b>	0.54	0.61

대적으로 버의 치수가 작은 Secondary 버와 Edge-breakout 이 발생하는 경우를 말한다. type 2는 Curl-type 버, Wave-type 버, Knife 버가 발생하는 경우이다. 실험 결과 Al6061

보다 SUS304의 버높이가 대체로 더 컸으며, 본 연구에서 Al6061에서는 type1이, SUS304에서는 type2의 버가 더 많이 발생하였다. 버 발생 사진을 Fig. 1에 첨부하였다.

Table 5는 각 재료별 버 유형, 버 높이, S/N 비를 보여주고 있다. 파라미터 설계절차에 따라 Table 6과 Table 7에 나타난 것처럼, 계산된 S/N 비를 수준별로 평균을 구하여 정리하였다. Table 6, Table 7의 S/N 비 자료를 이용해서 분산분석을 실시한 결과는 Table 8, Table 9에 정리하였다.

여기서 주목할 만한 부분은 Al6061(Table 8)의 경우, IXA의 p(%)값이 약 66%정도로서 아주 큰 기여도(p)를 보이고 있으며, 다른 파라미터의 경우는 그다지 커다란 영향을 미치지 않는다는 것을 알 수 있다. 또, SUS304(Table 9)의 경우에는 피드레이트와 절삭속도가 각각 35.97%, 38.59%의 기여도를 보임으로써 두 파라미터의 변화에 따라서 버의 크기는 매우 민감하게 변할 수 있음을 알 수 있다. 이런 사실은 재료의 열전도율과 점성이 버의 크기에도 큰 영향을 미친다는 사실을 말해준다.

난삭재인 SUS304의 경우, 열전도율이 낮기 때문에 가공시 열이 잘 발산되지 못하여 점성이 더욱 커지면서 버가 생기는 끝단에서 굽힘에 의한 버가 매우 커진다는 것을 예상할

수 있다.

본 연구에서는 계산된 S/N 비를 수준별로 평균을 구하여 각 파라미터별로 가장 큰 값을 선택함으로써 최적의 가공조건을 선정하였고, 그 결과는 Table 10과 같다.

### 4.2 인공지능 신경망 및 무차원화

다양한 입력조건들의 변화를 실시간으로 버 예측에 반영하기 위해 인공지능 신경망을 채택하였고 Al6061에 대한 인공지능 신경망을 구성하였다. 먼저 각 가공인자별 수준값은 인공지능 신경망의 입력값으로 사용할 때, 보다 우수한 결과값을 얻기 위하여 이 값들의 무차원화를 시도하였다. 각 인자에 대하여 가장 작은 버 높이를 갖는 수준을 0, 가장 큰 버 높이를 갖는 수준을 1로 선정하고, 각 인자의 수준값을 0에서 1사이의 값으로 무차원화 시켰다. 또한, 분산분석을 통해 나온 검정통계량 중 특성치에 가장 큰 영향을 주는 인자를 기준으로 하여 각 인자들의 가중치를 결정하였다<sup>9)</sup>.

본 논문에서는 인공지능신경망의 입력값으로 절삭조건을 사용하는 다음의 세 가지 경우를 선택하여 그 결과를 서로 비교해보았다. 먼저 무차원화 시키지 않은 파라미터로 인공지능신경망을 실행시킨 경우와 두번째는 경향성 무차원화 시킨 파라미터로 인공지능신경망을 실행시킨 경우, 세번째는 사실적 무차원화 시킨 파라미터로 인공지능신경망을 실행시킨 경우이다.

편의상, 한 쪽 방향으로 버 높이가 계속 커지거나 작아진다고 가정하는 무차원화를 경향성 무차원화(tendencious dimensionless)라 하고, 실험 결과에 입각한 무차원화를 사실적 무차원화(real dimensionless)라고 했다.

Table 11은 두 재료의 파라미터를 경향성 무차원화 시킨 것이고, Table 13은 사실적 무차원화 시킨 것이다. 뉴럴 네트워크는 출력층의 오차신호를 이용하여 은닉층과 출력층간의 연결강도를 변경하고, 출력층의 오차 신호를 은닉층에 역전파하여 입력층과 은닉층과의 연결강도를 변경하는 학습방

Table 8 ANOVA of Al6061

Symbol	D.O.F	Sum of square	Mean square	F	p(%)
A	3	647.63	215.88	21.24	65.54
B	3	178.14	59.38	5.84	18.03
C	3	40.59	13.53	1.33	4.11
D	3	91.35	30.45	3.00	9.24
Error	3	30.49	10.16		3.09
Total	15	988.18			100.00

Table 9 ANOVA of SUS304

Symbol	D.O.F	Sum of square	Mean square	F	p(%)
A	3	49.32	16.44	0.90	8.02
B	3	52.45	17.48	0.96	8.53
C	3	221.23	73.74	4.05	35.97
D	3	237.38	79.13	4.34	38.59
Error	3	54.68	18.23		8.89
Total	15	615.06			100.00

Table 10 최적의 가공 조건

Optimal parameters		
Parameter/ material	Al6061	SUS304
In-plane exit angle(°)	30	70
Depth of cut(mm)	1.0	2.0
Feed rate(mm/tooth)	0.05	0.1
Spindle speed(rpm)	700	700

법인 BP(back propagation) 알고리즘을 사용하였다.

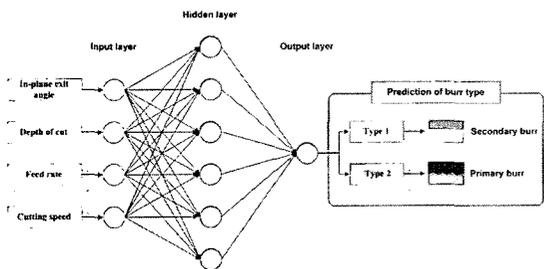
input node는 4개, hidden layer는 1층, hidden node는 6개, output node는 1개로 하며 input node의 각 변수들은

**Table 11 경향성 무차원화와 가중치(AI6061)**

		1	2	3	4	5	6	7
A	Range	30	50	70	90	110	130	150
	Dimensionless	0	0.17	0.33	0.5	0.66	0.83	1
	Weight factor	0	0.17	0.33	0.5	0.66	0.83	1
B	Range	0.5	0.75	1.0	1.25	1.5	1.75	2
	Dimensionless	0	0.17	0.33	0.5	0.66	0.83	1
	Weight factor	0	0.05	0.09	0.14	0.18	0.23	0.28
C	Range	0.05	0.075	0.1	0.125	0.15	0.175	0.2
	Dimensionless	0	0.17	0.33	0.5	0.66	0.83	1
	Weight factor	0	0.01	0.02	0.03	0.04	0.05	0.06
D	Range	300	400	500	600	700	800	900
	Dimensionless	1	0.83	0.66	0.5	0.33	0.17	0
	Weight factor	0.14	0.11	0.09	0.07	0.04	0.02	0

**Table 12 사실적 무차원화와 가중치(AI6061)**

		1	2	3	4	5	6	7
A	Range	30	50	70	90	110	130	150
	Dimensionless	0	0.17	0.33	0.5	0.66	0.83	1
	Weight factor	0	0.17	0.33	0.5	0.66	0.83	1
B	Range	0.5	0.75	1.0	1.25	1.5	1.75	2
	Dimensionless	0	0.17	0.33	0.5	0.66	0.83	1
	Weight factor	0.09	0.05	0	0.14	0.18	0.23	0.28
C	Range	0.05	0.075	0.1	0.125	0.15	0.175	0.2
	Dimensionless	0	0.17	0.33	0.83	1	0.5	0.66
	Weight factor	0	0.01	0.02	0.05	0.06	0.03	0.04
D	Range	300	400	500	600	700	800	900
	Dimensionless	1	0.83	0.66	0.5	0	0.17	0.33
	Weight factor	0.14	0.11	0.09	0.07	0	0.02	0.04



**Fig. 6 Architecture of Neural Network**

IXA, 절삭 깊이, 피드레이트, 절삭속도 4가지이다. 1개의 output node를 사용해서 버 형태를 분류하였다. 결과 데이터 값이 0인 경우는 type 1(secondary burr)에 해당하며, 데이터 값이 1인 경우는 type 2(curl-type burr, wave-type burr, knife-type burr)에 해당한다. 학습으로부터 얻은 노드 간의 연결강도를 바탕으로 신경망을 구성하였다. 입력값은 실험에서 얻은 데이터 중에서 연결강도를 구하는데 사용한 데이터를 제외한 나머지 데이터를 사용하였다. Table 14, Table 16, Table 18의 결과값을 비교하기 쉽도록 Fig. 7에 도시하였다.

그 결과, 사실적 무차원화 시킨 파라미터로 인공지능신경망을 실행시킨 결과값이 실험결과에 가장 가까웠고, 그 다음은 경향성 무차원화 시킨 파라미터, 마지막으로 무차원화 시

**Table 13 비무차원화 학습 데이터(AI6061)**

Input parameters				Desired output
In-plane exit angle (°)	Depth of cut (mm)	Feed rate (mm/tooth)	Spindle speed (rpm)	Burr type (type1=0 type2=1)
30	0.5	0.15	300	0
30	1.0	0.1	500	0
70	0.5	0.1	700	0
70	1.0	0.05	900	0
110	0.5	0.15	900	1
110	1.0	0.2	700	0
150	0.5	0.2	500	1
150	1.0	0.15	300	1

**Table 14 비무차원화의 NN(Neural Network) 결과값 (AI6061)**

Input parameters				Output	Real type
In-plane exit angle (°)	Depth of cut (mm)	Feed rate (mm/tooth)	Spindle speed (rpm)	Burr type (type1=0 type2=1)	
30	1.5	0.15	700	0.0183	0
30	2.0	0.2	900	0.0178	0
70	1.5	0.2	300	0.6562	1
70	2.0	0.15	500	0.1366	0
110	1.5	0.05	500	0.2521	0
110	2.0	0.1	300	0.8991	1
150	1.5	0.1	900	0.9467	1
150	2.0	0.05	700	0.8872	1

Table 15 경향성 무차원화의 학습 데이터(AI6061)

Input parameters				Desired output
In-plane exit angle (°)	Depth of cut (mm)	Feed rate (mm/tooth)	Spindle speed (rpm)	Burr type (type1=0 type2=1)
0	0	0	0.14	0
0	0.09	0.02	0.09	0
0.33	0	0.02	0.04	0
0.33	0.09	0	0	0
0.66	0	0.04	0	1
0.66	0.09	0.06	0.04	0
1	0	0.06	0.09	1
1	0.09	0.04	0.14	1

Table 16 경향성 무차원화의 NN 결과값(AI6061)

Input parameters				Output	Real type
In-plane exit angle (°)	Depth of cut (mm)	Feed rate (mm/tooth)	Spindle speed (rpm)	Burr type (type1=0 type2=1)	
0	0.18	0.04	0.04	0.0002	0
0	0.28	0.06	0	0.0001	0
0.33	0.18	0.06	0.14	0.7656	1
0.33	0.28	0.04	0.09	0.1038	0
0.66	0.18	0	0.09	0.1081	0
0.66	0.28	0.02	0.14	0.9083	1
1	0.18	0.02	0	0.9984	1
1	0.28	0	0.04	0.9685	1

Table 17 사실적 무차원화의 학습 데이터(AI6061)

Input parameters				Desired output
In-plane exit angle (°)	Depth of cut (mm)	Feed rate (mm/tooth)	Spindle speed (rpm)	Burr type (type1=0 type2=1)
0	0.09	0	0.14	0
0	0	0.02	0.09	0
0.33	0.09	0.02	0	0
0.33	0	0	0.04	0
0.66	0.09	0.06	0.04	1
0.66	0	0.04	0	0
1	0.09	0.04	0.09	1
1	0	0.06	0.14	1

Table 18 사실적 무차원화의 NN 결과값(AI6061)

Input parameters				Output	Real type
In-plane exit angle (°)	Depth of cut (mm)	Feed rate (mm/tooth)	Spindle speed (rpm)	Burr type (type1=0 type2=1)	
0	0.18	0.06	0	0.0001	0
0	0.28	0.04	0.04	0.0001	0
0.33	0.18	0.04	0.14	0.8489	1
0.33	0.28	0.06	0.09	0.0272	0
0.66	0.18	0	0.09	0.0833	0
0.66	0.28	0.02	0.14	0.9921	1
1	0.18	0.02	0.04	0.9992	1
1	0.28	0	0	0.9591	1

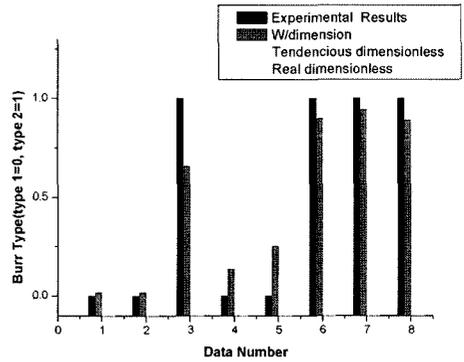


Fig. 7 W/dimension, Tendencious dimensionless, Real dimensionless

키지 않은 파라미터로 인공지능신경망을 실행시킨 결과 값의 순이었다.

### 5. 결론

본 논문에서는 AI6061과 SUS304에 대해 버 높이를 최소화하기 위하여 다구찌방법을 이용한 가공 파라미터의 최적화를 수행하였다. 또한 인공지능신경망의 입력값을 다양화시켜봄으로써 그 결과 값에 대해 비교해 보았다. 그 결론은 다음과 같다.

- (1) 실험결과 AI6061 보다 SUS304의 버 높이가 대체로 더 컸으며, AI6061에서는 type 1이, SUS304에서는

type 2 의 버가 더 많았다.

- (2) 재료에 따라서 버 높이에 중요한 영향을 주는 파라미터가 다르며, 본 논문에서는 Al6061 과 SUS304 에 대해서 파라미터의 최적화를 수행하였다.
- (3) 버 형태를 예측하는데 있어 인공지능신경망의 결과 값은, 무차원화 시키지 않은 절삭조건 보다는 실험적 무차원화 시킨 절삭조건이, 실험적 무차원화 시킨 절삭조건 보다는 사실적 무차원화 시킨 절삭조건을 입력 값으로 이용한 인공지능신경망이 실제 측정에서 얻은 버 형태와 비교해 보았을 때 더 높은 신뢰성을 나타내는 시스템으로 판명되었다.

## 후 기

이 논문은 2004년도 한국학술진흥재단의 지원에 의해 연구되었음 (KRF-2004-041-D00061)

## 참 고 문 헌

- (1) Gillespie, K. L., 1979, "Deburring Precision Miniature Parts," *Precision Engineering*, Vol. 1, No. 4, pp. 189~198.
- (2) Gillespie, K. L. and Blotter, P. T., 1976, "The Formation and Properties of Machining Burr," *ASME J. Engng. for Industry*, Vol. 98, No. 1, pp. 66~74.
- (3) Ko, S. L. and Dornfeld, D. A., 1991, "A Study on Burr Formation Mechanism," *ASME Journal Engineering Materials Technology*, Vol. 113, pp. 75~87.
- (4) Chern, G. L., 1993, *Analysis of Burr Formation and Breakout in Metal Cutting*, PhD thesis, Department of Mechanical Engineering, University of California at Berkeley.
- (5) Olvera, O. and Barrow, G., 1996, "An Experimental Study of Burr Formation in Square Shoulder Face Milling," *Int. J. Mach. Tools Mf.*, 36(9), pp. 1005~1020.
- (6) Kishimoto, W., Miyake, T., Yamamoto, A., Yamanaka, K. and Takano, K., 1981, "Study of Burr Formation in Face Milling," *Bull. Jap. Soc. Prec. Engng*, 15(1), pp. 51~52.
- (7) Park, S., 1998, *Experimental design and applications* (in Korean), Youngji Press, pp. 93~225.
- (8) Lee, S. H. and Lee, S. H., 2001, "Optimization of Experimental Parameters for Burr Minimization," *Journal of the Korean Society of Precision Engineering*, Vol. 18, No. 12, pp. 130~136.