

## 신경회로망에 의한 분사가공공정의 표면거칠기 및 재료제거량 예측에 관한연구

### A Study on the prediction of Surface Roughness and Material Removal in Powder Blasting using Neural Network

김권흡\*, 유우식\*\*, 박동삼\*\*\*

\* 인천대학교 대학원 산업공학과(jinquanqia@hanmail.net)  
 \*\* 인천대학교 산업공학과 (wsyoo@incheon.ac.kr)  
 \*\*\* 인천대학교 기계공학과(dspark@incheon.ac.kr)

#### Abstract

The old technique of sandblasting which has been used for paint or scale removing, deburring and glass decorating has recently been developed into a powder blasting technique for brittle materials, capable of producing micro structures larger than 100 $\mu$ m. In this paper, The surface characteristics of powder blasted glass surface were tested under different blasting parameter. Finally, we proposed a predictive model for powder blasting process using a neural network. A detailed analysis of the simulation results has been carried out and compared with experimental results.

#### 1. 서론

파우더 블라스팅(powder blasting)은 고압의 공기 에 의하여 가속된 100 $\mu$ m 이하의 미세 분사재를 노즐로부터 고속으로 분사하여 분사재의 충격력에 의하여 재료를 가공하는 기계적 에칭 가공법으로 미세가공(micromachining)의 한기법으로 최근 그 용도가 크게 증가하고 있다.

특히, 최근 평판디스플레이의 급격한 발전에 따라 수십 혹은 수백 마이크로미터 단위의 구조물 성형을 위한 고정밀도의 기계적 에칭기법이 연구되고 있는데 파우더 블라스팅 기법이 아주 효율적 방법으로 인식되기 시작하여 연구 또한 활발히 진행되고 있다(1-5).

최근에 수학적으로 모델링하기 어려운 분야에 신경회로망을 이용하여 접근하는 연구가 많이 진행되어지고 있다. Jain, r.k<sup>(7)</sup>은 알루미늄재료의 분사가공에 신경회로망을 이용하였다. 본 연구에서는 파우더 블라스팅을 이용하여 취성재료인 유리의 가공시 가공조건이 표면 거칠기와 재료제거율에 미치는 영향을 규명하고, 역전파 신경회로망을 이용하여 블라스팅 가공공정변수와 표면형상의 상관관계를 조사하고 신경회로망을 이용하여 블라스팅 가공의 표면특성을 예측하고 실험 데이터와의 비교를 통하여 그 유효성을 평가함으로써 최적의 블라스팅 가

공 파라메타를 선정하는 데 기여하고자 한다.

#### 2. 파우더 블라스팅의 가공기구

파우더 블라스팅의 가공기구는 기본적으로 Marshall<sup>(1)</sup> 이 제안한 압입이론(indentation theory)을 이용하여, 파우더 블라스팅 시 고체 미립자에 의한 공작물에의 충격과 경도시험시의 압입사이의 유사성에 기초한 해석모델을 제시하였다. 비교적 최근에 제안된 Slikkeryeer<sup>(2)</sup> 의 모델에 의하면, Fig. 1과 같이 날카로운 인덴터 팁의 압입 시 팁 아래 부분에서 압축응력에 의하여 소성변형영역이 형성되는데 하중이 증가할수록 소성영역도 증가하여 결국에는 표면과 수직인 방향으로의 반경/중앙 크랙과 수평방향으로의 측면 크랙이 형성된다. 측면 크랙은 표면의 제거에 직접적인 역할을 하지만 반경/중앙

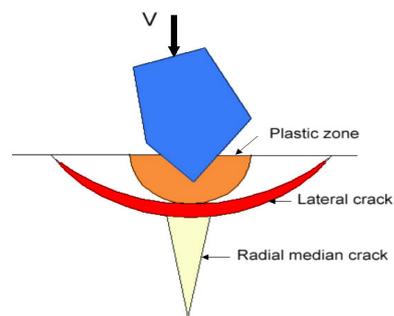


Fig. 1 micro cracks in indentation process

크랙은 결함발생과 연관성을 갖는 것으로 가공깊이가 깊어질 경우 가공을 촉진하는 역할도 한다.

소재의 제거 즉 가공과 관련되는 측면 크랙의 길이  $l_c$  와 깊이  $l_d$  는 다음과 같이 유도된다.

$$l_c \propto \frac{E^{3/8} H^{1/8} \Delta V^{5/12}}{K_c^{1/2}} \quad (1)$$

$$d_c \propto \left(\frac{E}{H}\right)^{1/2} \Delta V^{1/3} \quad (2)$$

- 단, E: 소재의 탄성계수
- H: 경도
- $K_c$ : 소재의 파괴인성(fracture toughness)
- $\Delta V$ : 모재 변형량(Indented volume)

입자의 충돌 동안 모든 운동에너지가 소성변형으로 흡수된다고 가정할 수 있는데 이는 아주 높은 하중상태 아래서는 탄성변형이나 크랙 생성에 소요되는 에너지는 소성변형에 필요한 에너지에 비하여 5% 이하로 아주 작기 때문이다. 경도 H가 압입 깊이 전 구간을 통하여 일정하다고 가정하고 충돌에 따른 운동에너지를 소성변형에 필요한 에너지와 같다고 두면 다음 식을 얻을 수 있다

$$\frac{1}{2}mv^2 = \int_0^{\delta} p(\delta')d\delta' = H\Delta V \quad (3)$$

위식에서 m는 분사재 질량, v 는분사재 입자의 속도,  $\square\square$  는 분사재 압입 깊이를 나타낸다.

한편, 미립분사재의 단위 무게당 제거되는 소재 무게의 비로서 정의되는 가공율(erosion rate) $\square\square_R$  는 각각의 분사재 입자가 측면크랙의 깊이  $d_c$ 와 측면크랙 자체의 표면적에 비례하여 소재의 각 입자들을 제거한다고 가정할 때 식(1)과 식(2),(3)을 이용하여 다음과 같이 구할 수 있다.

$$V_R \propto \pi d_c^2 \propto \frac{\rho_i E^{5/4}}{H^{17/12} K_c} \rho_p^{1/6} r_p^{1/2} v_p^{7/3} \quad (4)$$

- 단.  $\rho_i$ : 소재의 비질량(specific mass)
- $\rho_p$ : 분사재 입자의 비질량(specific mass)
- $r_p$ : 분사재 입자의 평균직경
- $v_p$ : 분사재 입자의 속도

식 (4)로부터 가공율은 두 개의 파라미터 군으로 구성된다는 것을 알 수 있는데 앞부분은 가공하고자 하는 소재에, 뒷부분은 가공공정 변수들에 영향을 받는 요소가 된다. 또한 일정한 분사재에서 분사속도와 분사압력, 분사량이 재료 제거량에 영향을 미치는 것을 알 수 있다.

### 3. 실험조건 및 장치

본 실험에서 사용된 장치는 일본 신토(Sinto)에서 제작된 Micro Blaster(MB-1)이며 일반적인 샌드 블라스터와는 달리 정량공급 장치가 장착되어 일정량의 분사재를 공급하면서 정밀 미세가공이 가능한 장치이다. Fig. 2에는 이 장비를 이용한 파우더 블라스팅의 기본 가공원리를 나타내었다.

실험시편은 일반적인 슬라이드 글래스로 Menzel 사 제품이며 규격은 ISO Norm 8037/1에 근거하여 제작된 시편을 사용하였으며 시편크기는 26mm×76mm×1.0mm이다. Fig. 3은 실험에 사용된

Microblaster 장비사진을 나타낸다.

실험에서 사용된 미립분사재는 알루미늄의 일종인 WA#600으로 입자의 평균크기는 26~31 $\square\square$  m이다.

실험에서 분사재의 분사압력을 각각 0.1MPa, 0.25MPa, 0.4MPa, 분당 분사량을 60g, 100g, 노즐이송속도를 50mm/sec, 100mm/sec 및 150mm/sec로 변화시키면서 유리표면을 분사가공 하였다. Table 1에서 시편의 가공조건을 나타낸다. 각 조건에서 형성된 표면을 미세형상측정기(Veeco NT1000)와 공구현미경(KT100 High Scope)을 이용하여 표면형상을 관찰하고, 분사가공 전후의 시편에 대하여 0.01mg 정밀천칭을 이용하여 무게를 측정하였다. 각 조건에서 7장식 가공하여 평균치를 산출하였다.

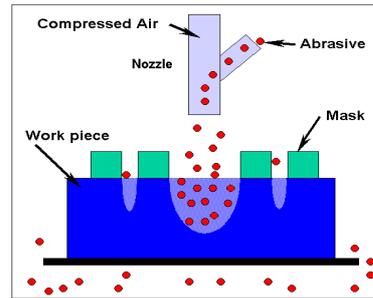


Fig. 2 Basic principle of powder blasting



Fig. 3 Photograph of Micro-Blaster

Table 1 Blasting parameter for sample

Abrasive	WA#600
Amount of abrasive (Q)	60, 100 g/min
Blasting Pressure (p)	0.1 Mpa, 0.25 Mpa, 0.4 Mpa
Nozzle X Speed (f)	50,100,150 mm/s
Nozzle Y Speed	100 mm/s
Nozzle Pitch	5 mm/s
Angle of impact	90°
Distance of Nozzle	100mm
Nozzle diameter	8mm
Number of pass	3

### 4. 역전파 신경회로망 모델

역전파 알고리즘의 기본은 그래디언트 알고리즘을 사용하는 일반화된 델타 법칙이다. 역전파 알고리즘은 오차신호가 시스템을 거쳐 신경망의 가중치 값을 update 한다. Fig. 4는 3개의 층(입력층, 은닉층, 출력층)으로 구성된 역전파(Back-propagation)신경회로망을 나타낸다. 입력층의 입력은 분사량, 분사압력, 분사속도로 하고 출력은 소재의 재료 제거량과 표면거칠기다. 그림에서 w와 b는 각각 각층의 가중치와 바이어스 가중치를 나타낸다.

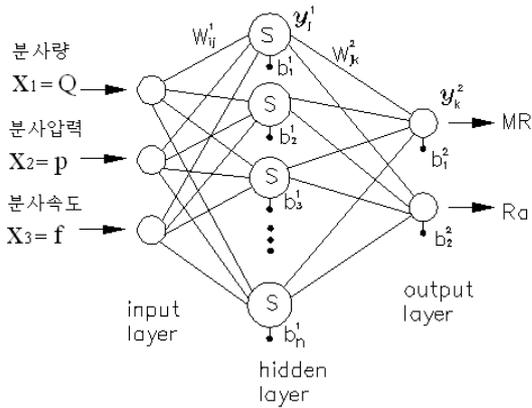


Fig. 4 Neural networks used in training and predicting surface roughness and material removal

본 연구에서는 은닉층의 출력과 출력층은 모두 시그모이드 전달함수를 사용하였다. 이때 은닉층의 출력은 아래와 같다.

$$y_j^1 = f(s_j) = \frac{1}{1 + e^{-s_j}} \quad (5)$$

여기서 은닉층의 노드의 합은 아래와 같다.

$$s_j = \sum_{i=1}^3 w_{ij} X_i + b_j^1 \quad (6)$$

출력층의 출력은

$$y_k^2 = \frac{1}{1 + e^{-s_k}} \quad (7)$$

$$s_k = \sum_{j=1}^n w_{jk} y_j^1 + b_k^2 \quad (8)$$

따라서 신경망으로부터 출력된 값  $y_k$ 는 원하는 값  $yd_k$ 과 비교되어 오차를 만든다. 최소화할 목적함수는 모든 에러의 합으로 다음과 같다.

$$\epsilon = \frac{1}{2} \sum_k e_k^2 = \frac{1}{2} \sum_k [yd_k - y_k]^2 \quad (9)$$

은닉층의 전달함수를 시그모이드 함수를 사용시 입력층과 은닉층의 가중치 변화율은 델타법칙에 의해 아래와 같이 표현한다.

$$\Delta w_{ij} = \eta f'(s_j) x_i \sum_{k=1}^n e_k f'(s_k) w_{jk} \quad (10)$$

위식에서  $\eta$ 는 학습속도를 향상시키기 위한 학습률을 나타낸다. 최종 출력값과 목표값의 오차를 식(9)에 따라 계산하고 식(10)은 가중치를 보정하는 식으로 학습 시 이루어진다.

### 5. 실험결과 및 분석

Fig.5는 실험조건중의 하나인 분사압력을 0.4MPa, 분사량을 100g/mim, 분사속도를 50mm/sec로 하였을 때 시편의 표면 거칠기를 나타낸다. 본 연구에서 신경망의 입력으로 3개의 공정변수들로부터 정확한 표면 거칠기와 재료 제거량을 예측하도록 학습시킨다. 예측 값이 실제 측정값과 차이가 있으면

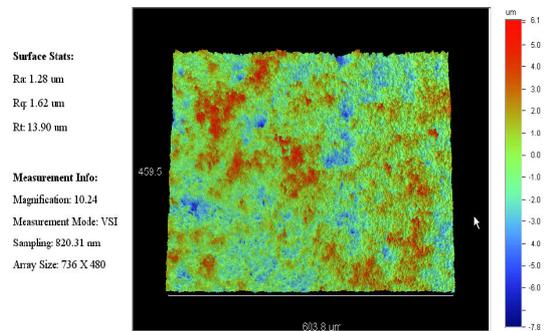


Fig. 5 Three dimensional display of machined surface

학습법칙에 의해 신경회로망 내부의 매개변수들을 조절하여 오차가 줄어들도록 반복 학습을 하며 반복 학습 횟수가 주어진 횟수에 도달할 때까지 반복되게 하며 이러한 조절과정이 끝나면 신경회로망을 최적의 입출력 관계를 잘 표현 할 수 있는 가중치를 얻게된다. 새로운 입력값이 주어지면 내부에서 형성된 입출력관계에 적합한 출력값을 계산하여 출력한다. 시그모이드 함수는 0, 1에 접근하면 곡선이 비교적 평활하여지고 변화속도가 느려지므로 신경회로망의 학습시간을 단축시키기 위하여 입출력데이터를 0.1와 0.9사이의 값으로 변환하는 Generalization 과정을 수행하였다.

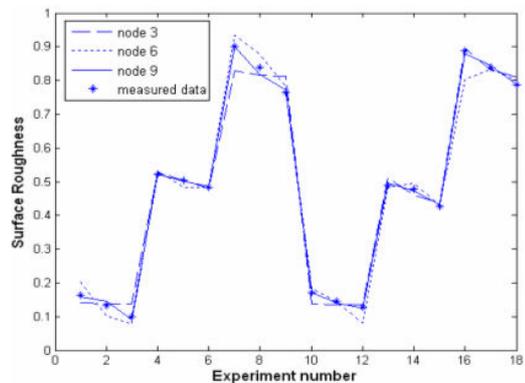


Fig. 6 surface roughness measured and predicted with different node

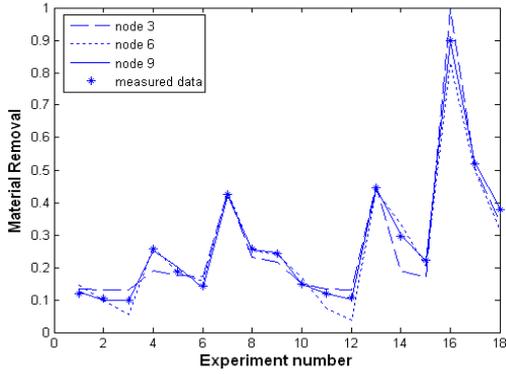


Fig. 7 material removal measured and predicted with different node

신경회로망에서 가장 민감한 변수는 학습률이다. 학습률이 너무 크면 불안정해지고 너무 작으면 수렴하지 않는 경우가 있다. 일반적으로 0에서 1사이의 값으로 취한다. 학습률을 1보다 큰 값을 설정할 경우에는 너무 많이 보상되어 나쁜 영향을 미치게 된다.

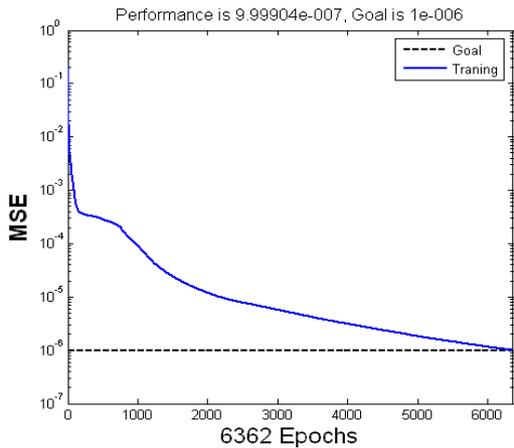


Fig. 8 Variation of MSE with number of iterations

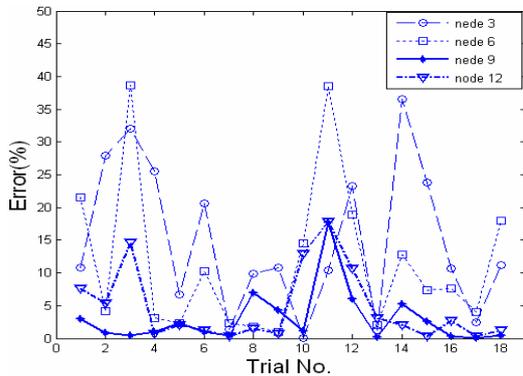


Fig. 9 Variation of absolute error with different number of node on material removal

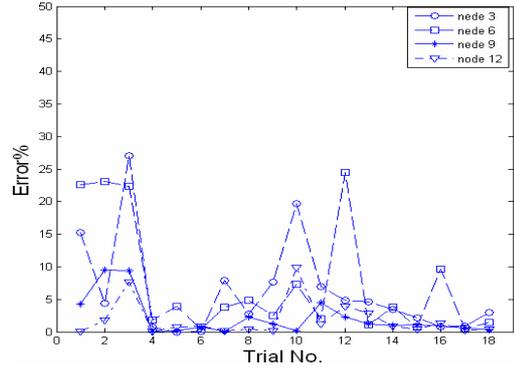


Fig. 10 Variation of absolute error with different number of node on surface roughness

역전과 알고리즘에서 최적의 학습률을 설정하는 방법이 없다. 학습률은 convergence 속도와 에러의 크기와 관련되어 있으므로 trial error 를 반복하여 정할 수밖에 없다. 또한 은닉층의 최적의 노드수를 설정하는 방법도 없다. 간단한 시스템은 계산양을 줄이기 위해 은닉층의 수를 줄이도록 하지만 비선형성이 강한 경우 은닉층의 수는 늘어나야 한다. 하지만 최적의 수를 알 수 있는 방법이 없다. 일반적으로 대부분 경험에 의하여 설정하거나 혹은 실험을 통해 설정한다. 일반적으로 노드수가 많으면 학습시간이 너무 길며 노드수가 너무 적으면 오차가 발생할 수 있다. 또한 노드수가 많아서 좋은 것은 아니다. 노드수를 설정할 때 아래와 같은 경험식을 참조 할 수 있다.

$$n = \sqrt{n_i + n_o} + a \tag{11}$$

위식에서

- $n$  : 은닉층의 노드 수
- $n_i$  : 입력층의 노드 수
- $n_o$  : 출력 수
- $a$  : 1~10사이의 상수이다.

본 연구에서는 학습률을 0.05로 하고 은닉층의 노드수를 3, 6, 9로 하여 신경회로망 예측기를 이용하여 예측하였다. fig. 6는 여러 가지 노드에서 시편에 대한 표면 거칠기 예측결과와 측정결과를 나타낸다. fig. 7은 재료 제거량에 대한 예측결과와 측정치와 상당히 근접하게 나타낸다.

실험에서 목표치를  $1e^{-6}$ 로 설정하고 epoch수를 6500으로 하였다. 이때 epoch로 학습하는 방법은 모든 패턴을 입력한 뒤에 가중치의 변화율을 합해서 한번 update하고 또 모든 패턴에 대해 update하는 과정을 반복한다. 학습과정에서 현재 오차가 설정한 목표치 보다 작거나 반복회수를 넘으면 그만 멈춘다. 아니면 반복적인 학습을 계속 진행한다.

fig. 8에서 노드수가 9일 때 신경망 예측기를 이용하여 반복 학습을 하는 과정을 나타낸다. 학습에서 반복학습을 통하여 epoch가 6362에서 목표치에 도달하여 학습이 종료되었다. 최종오차는  $9.9990e^{-7}$

Table 2 Comparison of predicted data error for different node number

MR				Ra			
node =3	node =6	node =9	node =12	node =3	node =6	node =9	node =12
10.77	21.49	2.96	7.61	15.24	22.65	4.31	0.06
27.87	4.15	0.88	5.33	4.42	23.08	9.56	1.77
32.00	38.60	0.40	14.70	27.00	22.40	9.40	7.70
25.53	3.15	1.03	0.72	0.81	1.83	0.01	0.01
6.66	2.36	2.36	2.05	0.00	3.88	0.14	0.76
20.61	10.33	1.02	1.22	0.03	0.42	0.80	0.86
1.36	2.27	0.52	0.39	7.87	3.76	0.06	0.12
9.86	1.73	6.90	1.46	2.71	4.89	2.30	0.37
10.80	1.02	4.36	0.71	7.69	2.54	1.28	0.23
0.10	14.47	1.19	12.99	19.67	7.34	0.15	9.84
10.44	38.51	17.67	17.82	6.94	2.08	4.47	1.28
23.34	18.88	6.07	10.70	4.81	24.49	2.27	3.90
1.31	2.12	0.24	3.08	4.61	1.07	1.20	2.89
36.52	12.77	5.30	2.09	3.50	3.80	0.96	0.84
23.84	7.36	2.60	0.29	2.15	0.75	1.07	0.39
10.69	7.57	0.39	2.72	0.77	9.58	0.92	1.38
2.39	4.04	0.03	0.28	0.88	0.57	0.67	0.31
11.24	17.98	0.46	1.31	3.02	1.47	0.24	0.39
AVG. 14.74	AVG. 11.60	AVG. 3.02	AVG. 4.748	AVG. 6.78	AVG. 7.59	AVG. 2.21	AVG. 1.84

에 도달하였다.

Fig. 9, 10는 신경회로망 예측기를 이용하여 예측한 데이터와 실제 측정된 데이터를 퍼센트 오차로 계산한 오차를 도시적으로 나타낸다. Table 2 에서는 예측한 데이터와 실제 측정된 데이터와의 오차를 나타내었다. 예측오차는 아래와 같은 수식으로 계산하였다.

$$e = \frac{\text{predicted} - \text{measured}}{\text{measured}} \times 100\% \quad (12)$$

위의 테이블로부터 예측한 평균오차는 표면 거칠기의 경우 노드 수 9에서 2.21%이고, 노드 수 12에서는 1.84%로 거의 비슷한 오차를 나타낸다. 재료 제거량의 경우 노드 수 9에서 3.02%이고 노드 수 12에서는 4.75%로 조금 높은 오차로 나타났다. 또한 노드 수 12에서는 오차가 10%이상인 수가 각각 14.7%, 12.99%, 17.82%, 10.70% 이고, 노드수가 9인 경우에는 17.67% 하나만 나타났다.

결론적으로 노드수가 9일 때 전체적으로 더 정확한 결과를 나타낸다. 본 연구에서는 신경회로망 예측기 입력층, 은닉층, 출력층을 3□□ 9□□ 2로 하여 실험분석에 의해 생성한 예측모델과 비교를 하였다. 분사가공에서 재료제거량 MR 과 표면조도 Ra 예측모델은 아래와 같이 표현 될 수 있다<sup>(6)</sup>.

$$MR = CQ^{a1} P^{a2} f^{a3} \quad (13)$$

$$Ra = SQ^{b1} P^{b2} f^{b3} \quad (14)$$

단, C, S, a1, a2, a3, b1, b2, b3는 회귀분석 모델에 의한 상수이고 Q, P, f 는 분사량, 분사압력, 분사 속도를 나타낸다.

본 실험에서 사용한 유리시편의 분사가공 시 표면 거칠기와 재료제거량은 아래와 같이 나타낸다<sup>(11)</sup>.

$$MR = 0.1227 Q^{1.221} P^{1.802} f^{-0.8687} \quad (15)$$

$$Ra = 2.175 Q^{0.0258} P^{0.436} f^{-0.064} \quad (16)$$

Fig. 11와 Fig. 12은 분사량 60g/min 일 때 분사압

력이 시편의 표면거칠기와 재료제거량에 미치는 영향을 도시적으로 나타낸 것이다. 그림에서 심볼(symbol)로 표시한 것은 실제 측정된 데이터이고,

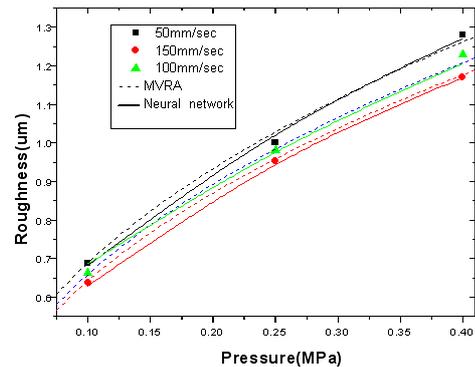


Fig. 11 Effect of pressure on surface roughness (mass flow rate : 60g/min)

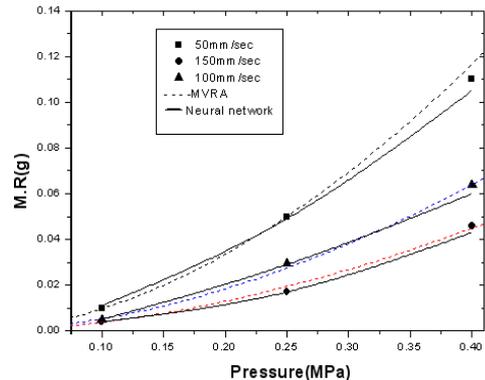


Fig. 12 Effect of pressure on material removal (mass flow rate : 60g/min)

Table 3 Comparison of predicted data and experimented

Measured		Predicted(MRVA)				Predicted(neural network)			
MR	Ra	MR	Ra	error(MR)%	error(Ra)%	MR	Ra	error(MR)%	error(Ra)%
0.0100	0.6890	0.0096	0.6896	4.04	0.09	0.0111	0.6826	10.51	0.93
0.0050	0.6630	0.0053	0.6597	5.10	0.50	0.0053	0.6726	5.37	1.45
0.0040	0.6370	0.0037	0.6428	7.63	0.91	0.0041	0.6296	2.95	1.17
0.0500	0.9760	0.0500	1.0283	0.04	5.35	0.0492	0.9707	1.55	0.54
0.0300	0.9610	0.0274	0.9836	8.69	2.36	0.0287	0.9554	4.36	0.58
0.0167	0.9440	0.0193	0.9584	15.57	1.53	0.0171	0.9423	2.59	0.18
0.1000	1.2800	0.1090	1.2621	9.00	1.40	0.0993	1.2704	0.66	0.75
0.0500	1.2300	0.0540	1.2074	8.00	1.84	0.0552	1.2055	10.42	1.99
0.0460	1.1700	0.0449	1.1764	2.33	0.55	0.0429	1.1694	6.78	0.05
0.0180	0.6950	0.0179	0.6988	0.53	0.54	0.0175	0.6939	2.88	0.16
0.0100	0.6740	0.0098	0.6684	1.95	0.83	0.0110	0.6683	10.00	0.85
0.0060	0.6600	0.0065	0.6513	8.33	1.32	0.0055	0.6573	8.33	0.40
0.1060	0.9500	0.0933	1.0419	11.95	9.67	0.1057	0.9498	0.30	0.02
0.0620	0.9400	0.0580	0.9967	6.45	6.03	0.0574	0.9317	7.48	0.89
0.0400	0.9000	0.0359	0.9712	10.15	7.91	0.0417	0.8995	4.25	0.05
0.2400	1.2700	0.2177	1.2789	9.29	0.70	0.2390	1.2537	0.43	1.28
0.1280	1.2300	0.1192	1.2234	6.86	0.54	0.1280	1.2252	0.04	0.39
0.0860	1.1900	0.0838	1.1920	2.53	0.17	0.0865	1.1799	0.59	0.85
				AVG.6.58	AVG.2.35			AVG.4.42	AVG.0.7

접선은 실험계획법인 MRVA(Multivariable regression analysis)모델에 의해 생성한 예측모델을 이용한 예측결과를 나타내고, 실선은 신경회로망 예측기를 이용하여 예측한 결과를 나타내고 있다. 그림에서 표면거칠기와 재료 제거량은 분사압력이 증가함에 따라 증가하고 분사속도가 증가하며 줄어드는 양상을 보인다. 표면거칠기의 경우 주로 분사압력에 큰 영향을 미치고 분사속도에 의한 영향은 다소 미미한 양상을 보인다. 따라서 Table 3에서는 실험계획법에 의한 예측모델을 이용하여 예측한 데이터와 신경회로망 예측기를 이용하여 예측한 데이터와 실제 측정된 데이터를 식(9)에 의해 산출한 예측오차를 나타낸다. 실험계획법에 의한 예측오차가 재료 제거량의 경우 최소오차가 0.04% 이고 최대 15.57%까지 나타나고 전체오차의 평균값은 6.58%이다. 표면거칠기의 경우 최소0.09%, 최대 9.67%이고 평균값은 2.35%로 나타난다. 신경회로망 예측기로 예측한 경우 재료제거량은 최소0.04%이고 최대 10.51% 이고 평균값은 4.42%로 나타난다. 표면거칠기의 경우 최소오차는 0.02% 이고 최대오차는 1.99% 이고 평균 오차는 0.77%로 나타난다. 전체적으로 본 연구에서 개발한 신경회로망 예측기가 실험계획법에 의한 예측모델에 비해 어느 정도 더 정확한 예측결과를 나타낸다. 또한 표면조도에 대한 예측결과가 재료제거율에 비해 더 정밀한 예측결과를 얻었다.

6. 결론

신경회로망을 이용하여 파우더 블라스팅의 공정 변수(분사량, 분사압력, 분사속도)를 이용하여 재료 제거량과 가공표면 거칠기를 측정하여 블라스팅 공정변수가 재료제거량과 가공표면 거칠기에 미치는 영향을 실험적으로 규명하고 신경회로망의 일종인 역전파 신경회로망을 이용하여 재료 제거량과 가공 표면 거칠기를 예측하고 실험계획법에 의해 생성한 예측모델과 비교를 하였다.

(1) 재료 제거량과 가공 표면 거칠기는 블라스팅 공정변수에 따라 변화함을 알 수 있으며 또한 3개의 가공변수와 재료 제거량과 표면 거칠기의 관계를 신경회로망을 사용함으로써 잘 구현할 수 있다.

(2) 신경회로망의 은닉층은 1개로 하고 노드수를 각각 3, 6, 9, 12로 하여 신경회로망을 수행하였다. 결과적으로 노드수가 9개일 예측치와 측정치 오차가 재료제거량에서 3.02%, 표면조도에서 2.21%로 가장 잘 일치하였다.

(3) 본 연구에서 신경회로망 예측기를 이용하여 예측한 결과와 실험계획법에 의해 생성한 예측모델과 비교하고 실제 측정데이터와 예측오차를 비교하였다. 결과적으로 신경회로망 예측기로 예측한 결과가 실험계획법에 의해 생성한 예측모델에 비해 큰 차이가 없으며 평균 예측오차가 7%이내에 나타났으나 신경회로망을 이용한 예측결과가 다소 정밀한 결과를 나타낸다. 또한 표면조도에 대한 예측결과가 재료 제거량에 비해 상당히 정확한 예측치를 나타낸다.

위의 연구 결과를 통하여 신경회로망을 이용하여 정확한 공정변수에 따른 가공공정의 정확한 결과를 예측할 수 있으며 분사 가공에서 최적의 가공변수 선정이 가능하며 산업현장에서 최적의 품질과 생산 효율을 얻을 수 있는 효과적인 판단 기초로 기대되며 또한 분사가공에서 최적의 가공조건을 선정하기 위한 전문가 시스템을 구축이 가능하다.

따라서 앞으로 신경회로망을 이용한 분사가공조건 선정을 위한 프로그램 개발을 위해 새로운 학습법 개발 및 학습할 데이터의 양과 범위를 늘리고, 이것을 데이터 베이스화 할 경우 본 분사가공 시스템의 신경회로망 예측시스템은 더욱 신뢰성을 높일 수 있을 것으로 사료된다.

## 참고문헌

1. D. B. Marshall, B. R. Lawn, A. G. Evans(1982), "Elastic/Plastic indentation damage in ceramics: the lateral crack system," J. Am. Ceram. Soc. 65, pp. 561-566.
2. P. J. Slikkerveer, P. C. P. Bouten, F. C. M. deHaas(2000), "High quality mechanical etching of brittle materials by powder blasting," Sensors and Actuators 85, pp. 296-303.
3. Henk Wensink, U. W. Berenshot, Henri V. Janseu, Miko C. elwenspoek (2000), "High Resolution Powder Blast Micro machining," Proceedings of the IEEE Micro Electro Mechanical Systems, pp. 769-774.
4. H. J. Lighthart, P. J. Slikkerveer, F. H. In't Verd(1996), "Glass and Glass Machining in Zeus Panels," Philips J. Res., Vol. 50, No. 3/4, pp. 475-499.
5. M. A. Dabnum, M. S. JHashmi (2005), "Surface Roughness Prediction Model by Design of Experiments for Turning Machinable Glass-ceramics," J. Mat. Pro. Tech., 164-165, pp. 1289-1293.
6. V. K. Jain, S. G. Adsul(2000), "Experimental Investigation into Abrasive Flow Machining," Int. J. Machine Tool & Manufacture, Vol. 40, pp. 1003-1021.
7. R. K. Jain, V. K. Jain, P. K. Kalra(1999), "Modelling of Abrasive Flow Machining Process: A Neural Network Approach," Wear, Vol. 231, pp. 242-248.
8. R. K. Jain, V. K. Jain(2000), "Optimum selection of machining conditions in abrasive flow machining using neural network," J. Mat. Processing Technology, Vol. 108, pp. 62-67.
9. 홍정의(2002), "다구찌 방법과 신경회로망을 이용한 사출성형 가공공정의 최적 가공조건 선정에 관한 연구", 산업경영시스템학회지, Vol. 25, No. 2, pp.71-76.
10. 김선진, 성백섭, 조규재, 김하식, 반제삼, (2004). "역전과 신경회로망을 이용한 가공 조건에 따른 STD-11절단면의 신뢰성 평가", 한국공작기계학회논문집, Vol. 13, No.5, pp. 7-15.
11. 김권흡, 박동삼, 유우식, (2006), "파우더 블라스팅에 의한 유리가공시 실험계획법에 의한 재료제거량 및 표면거칠기 예측모델에 관한 연구", 한국공작기계학회논문집, Vol. 15, No.2,