

신경망 및 입력인자 민감도 분석을 이용한 연삭디스크의 가공조건 예측에 관한 연구

이동규*, 유송민+, 이위로**, 신관수***

The study on the disk grinding using neural network and input sensitivity analysis

Dong Gyu Lee *, Song Min Yoo+, Wi Ro Lee** and Kwan Soo Sin***

Abstract

When most manufacturing company produce grinding product, operators decide grinding condition by experience and subjective judgment. The study on grinding manufacture have been developed to get the grinding condition with the same result when non-experienced or experienced worker work. The objective of this study is to develop the grinding condition and predict the result of grinding by neural network. Several discussions were made in following areas as; getting MRR with image processing, the architecture optimization of neural network with experiment design, analysis of the input neurons using sensitivity approach. The results showed that the developed approach was the best method in predicting grinding condition with respect to surface finish quality.

Key Words : Disk grinding(디스크 연삭), Grinding condition(연삭조건), Input sensitivity analysis(민감도분석), Neural network(신경망)

1. 서론

현재 디버링과 그라인딩 작업과 같은 연삭작업은 거의 수작업에 의존하고 있는 실정이다. 하지만 생산시스템의 효율성과 생산성 향상을 위하여 연삭공정의 자동화에 관한 연구가 시급한 상황이다. 숙련공이 연삭작업을 할 경우 시각 및 청각 등의 감각적인 센서와 경험과 같은 정성적인 데이터를 가지고 연삭조건을 선정하게 된다. 가령 절삭칩의 색을 보고 적절한 색이 될 때까지 절삭속도를 증가시키거나 기계의 상태를 보며 가공조건을 조정하는 것이 하나의 예이다. 보다 정량적인 접근을 위해 제공되어지는 핸드

북이나 전문가 시스템(Expert System)은 다양한 자료를 바탕으로 적절한 조건을 제시하게 되지만 수집된 데이터에는 많은 법칙들을 포함하고 세부적인 내용은 알기가 힘들며, 각 시스템에 따라서는 부적합 경우가 많다. 소극적인 연삭조건은 생산성을 저하시키는 반면 과도한 연삭조건은 제품의 정밀성과 공구의 수명을 저하시키게 된다. 연삭가공에 대한 연구는 일반적으로 숙련자에 의존하던 작업을 컴퓨터의 발전과 더불어 자료화하여 비숙련자가 작업을 진행시켜도 동일한 결과를 얻고자 하는 취지에서 진행되어 왔다.⁽¹⁾ 일반적으로 연삭가공이 공작물의 최종 가공작업으로 가공면의 정밀도를 향상시키는 목적으로

* 발표자, 경희대학교 기계공학과 대학원 (mecha76@empal.com)
주소: 139-743 경기도 수원시 기흥읍 서천1리 경희대학교 기계공학과 정밀공학연구소
+ 경희대학교 기계산업시스템공학부
++ 산업자원부 기술표준원
+++ 시립인천 전문대학

사용되는 것에 반하여 유연성 디스크를 이용한 연삭가공작업은 선박 및 자동차산업 분야에서 활발히 사용되는 가공작업으로 용접잔류물의 제거 또는 가공 후에 남은 가공잔류물(burr)의 제거용 및 대형의 공작물 가공용으로 사용되어 왔다. 이러한 연삭공정을 감시하고 이상상태를 진단하기 위해서는 연삭공정에 영향을 미치는 조건간의 상호관계에 대한 이해가 필요하다. 알맞은 작업조건을 선정하기 위한 연구는 주로 압전소자에 의한 절삭저항의 변화를 이용하거나 열기전력과 접촉 전기저항을 이용하는 방법 음압의 주파수를 분석하는 방법 등이 수행되었다.⁽⁵⁾

이러한 조건을 찾아내기 위해서 다양한 연구를 수행하고 있지만 각 조건간의 상호관계와 연삭가공의 불규칙성에 의하여 이론적인 접근이 힘든 실정이다.

본 연구에서는 복잡한 이론과 많은 양의 데이터가 없어도 단순한 학습법에 의해 경험을 축적할 수 있고, 입력자료에 의해 생긴 잡음, 변형, 파손 등에 강한 장점을 지닌 신경망을 통해 연삭결과를 예측하고 실험계획법을 통해 신경망 구조를 최적화하고 측정센서의 수를 최소화하여 최적의 예측을 수행할 수 있는 민감도 분석을 하고자 한다.

2. 실험장치 및 방법

연삭조건에 영향을 미치는 요인은 매우 다양하지만 본 연구에서는 신경망을 학습시키기 위한 연삭조건을 크게 두 가지로 구분하였다. 연삭조건을 예측하기 위한 기본적인 연삭조건(Primary grinding condition)은 디스크의 입도, 스피indel 회전수이며, 부차적인 연삭조건(Secondary grinding condition)은 절삭깊이, 연삭시편의 종류, 테이블 이송속도, 디스크 각도이다. 각 조건에 따라 적절한 요인과 수준수를 선정하였으며, 신뢰성 있는 데이터를 확보하기 위하여 3회 반복실험을 하였다.

2.1 실험장치




Fig 1 Diagram of experiment equipment

유연성 연삭디스크의 학습을 위해 입력신호로 각 연삭조건에 따른 공구동력계, 가속도센서, 화성처리 신호를 얻기 위해 Fig 1과 같이 실험장치를 구성하였다. 공구동력계는 Kistler 社의 Type 5017A를 사용하여 연삭시 발생하는 주분력, 이송분력, 배분력을 측정하였다. 가속도 센서는 PCB 社의 Model 356B07인 주파수 범위가 5kHz이고 50G까지 측정 가능한 센서를 사용하여 연삭시 발생하는 진동을 측정하였다. 또한 삼성 社의 Model BW-360ED인 36만 화소 1/2" 흑백 CCD 카메라를 사용하여 연삭전·후의 시편영상을 획득하였다. 연삭신호의 Sampling time은 약 3msec이고, Sampling Duration은 15sec이다. 실험조건은 Table 1과 같다.

Table 1 Processing condition for grinding

Feed speed	310mm/min			
Dept of grinding	4mm			
workpiece	SC410	Yield Strength	Tensile Strength	C (%)
		205 (MPa)	410 (MPa)	
size of workpiece (mm)	48(width)×48(height)×4.5(thickness)			
Grinding angle of disk	20°			
Disk grain size	#36, #60, #80			
Spindle speed(rpm)	940, 1465, 2300			

2.2 신호처리

연삭가공시 가공단계는 초기, 중기, 말기의 3단계로 구분이 된다. 각 단계는 다음과 같다.

1) 초기단계 (Entrance stage)

디스크가 작업시작 후부터 공작물과 접촉을 시작하여 디스크의 끝부분이 완전히 접촉되기까지의 시점이다.

2) 중기단계 (Between edge stage)

디스크의 끝부분이 완전히 공작물에 접촉되어 공정이 진행되며 이후 디스크가 공작물을 벗어나기 시작하는 구간까지로 이 단계에서는 디스크의 변형상태가 일정하게 유지되는 정상상태가 되는 시점이다.

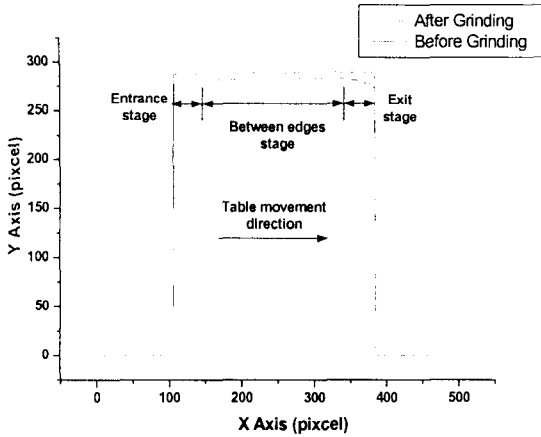


Fig 2 Real cutting depth with Image processing

3) 말기단계 (Exit stage)

디스크가 벗어나기 시작하는 중기단계 이후부터 작업종료까지의 시점이다. 이 시점에서 변형되었던 디스크가 원래의 상태로 돌아오게 되는데 동일하중 하에서 접촉면적이 줄어들기 때문에 과절삭이 일어나는 구간이다. (Fig 2 참조)

초기와 말기 단계는 디스크와 연삭시편과의 기하학적 접촉면적의 변화에 의하여 신호가 안정적이지 못하므로 신호가 안정적으로 되는 중기단계의 신호를 학습신호로 선택하였다. 신경망의 학습을 위해 각 연삭조건에 따른 신호(공구동력계, 가속도센서, 화상처리)를 분석하기 위하여 각 신호를 20구간으로 분배하여 학습패턴을 만들었다. 각 신호들은 발생된 에너지 값을 비교하기 위해 식1과 같이 RMS(Root mean Square)을 사용하여 정량화하였다.

$$RMS = \left(\frac{1}{\Delta T} \int_0^{\Delta T} v^2(t) dt \right)^{\frac{1}{2}} \quad (1)$$

단, ΔT 는 시간간격, $v(t)$ 는 신호함수이다.

비전시스템을 통하여 획득된 영상의 해상도는 640×480이며, 획득된 영상을 Gray Scale로 변환하고, Laplacian mask를 사용하여 경계선을 검출하였다. 주어진 영상을 적절한 임계값을 적용하고 이진화 하여 Y축을 기준으로 X축 방향의 Pixel위치를 검출하였다. 이와 같은 과정을 통해 연삭전후의 시편의 형상을 비교하여 중기단계(Between edge stage)의 영상을 20구간으로 패턴화 시켰다. 영상처리가 가장 중요한 경계선(윤곽선)은 제품의 위치, 크기 및 무늬와 같은 정보를 가지고 있으며, 빛의 밝기가 불연속적인 곳을

Table 2 Result with difference grinding condition

Index	Grinding force(N)	Acceleration (m/sec ²)			MRR (mm ³ /sec)	specimen condition			
		F _x	F _y	F _z					
#36	940	69	75	119	27	24	33	15.56	normal
	1465	71	76	149	28	26	36	13.70	normal
	2300	76	78	110	26	23	29	23.94	abnormal
#60	940	66	76	89	25	22	31	14.49	normal
	1465	66	77	100	29	29	37	23.76	normal
	2300	69	76	65	24	20	26	30.01	abnormal
#80	940	82	91	205	64	45	63	28.19	normal
	1465	85	95	134	62	36	63	25.24	normal
	2300	86	86	131	43	28	50	47.62	abnormal

나타낸다. 수학적으로 일차미분의 경우 빛의 밝기가 불연속적인 점을 나타내며 이차미분의 경우 방향성을 나타낸다. 이를 수학적으로 표현한 것이 라플라시안 필터이고 식(2)와 같다.

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad (2)$$

라플라시안 필터는 국지적으로 최대인 점만을 윤곽으로 인정하며 연삭속도가 빠르고 다른 연삭자에 비하여 날카로운 윤곽선을 검출하고, 하나의 마스크로 모든 방향의 윤곽선을 검출하기 때문에 경계선 검출을 위한 필터로 많이 활용하고 있다. 이와 같은 과정을 통해 획득된 영상을 분석하여 연삭면적 및 실제 가공된 길이를 분석하였다.

2.3 실험결과

기본 연삭조건인 디스크 입도의 크기와 스펴들 회전수의 변화에 따른 연삭력과 가속도(진동) 재료제거비는 Table2와 같다. 절삭가공에 사용되는 재료제거비(MRR)은 시간에 따른 연삭량으로 식3과 같다.⁽³⁾

$$Q = A \times V_n \quad (3)$$

여기서 A는 접촉면적, V_n 은 법선속도이다. 또한 연삭시 재료제거량은 공구의 동력소비율에 비례⁽³⁾하며 식4와 같다.

$$Q \propto (P - P_f) \quad (4)$$

여기서 P는 시초동력(threshold power)이다. 위의 식을 통하여 재료제거비(MRR)를 구하기 위해서는 연삭모델에 대한 기하학적 해석 및 각 함수의 파라미터(버의 크기, 각속

도 등)을 구하여야 하는 어려움이 있다. 이와 같은 어려움은 화상처리를 이용하여 손쉽게 재료제거비(MRR)를 구할 수 있다. 즉, 화상처리를 통해 연삭전후의 화상을 단순한 사칙연산(빼기연산)을 통해 연삭된 면적을 구하여 계산하면 된다. 화상처리결과 연삭시 연삭깊이는 4mm일때, 각 연삭조건에 따른 가공깊이는 Fig 3과 같다. 실험결과 연삭시 스피인들의 회전수가 낮을 경우 연삭력이 작아 소재의 절삭보다는 디스크 입자의 파괴가 많이 일어났으며, 회전수가 높을 경우 불꽃이 발생하며 절삭력이 많이 걸리고 가공소재의 열변형이 발생하였다. 디스크 입도가 크고 스피인들의 회전수가 빠를수록 절삭량이 많았으나 열변형으로 인한 소재의 열변형부가 증가하였다.

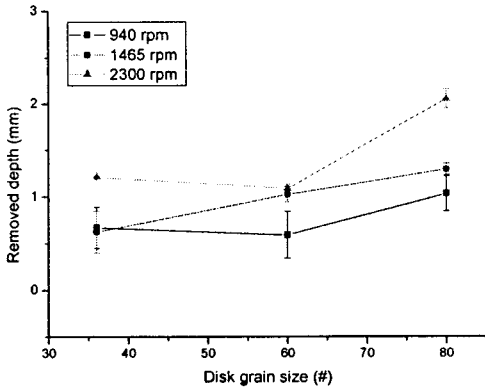


Fig 3 Real removed depth with grinding condition

3. 신경망학습

3.1 신경망 구조

신경망은 인간의 뇌를 구성하고 있는 신경세포들의 상호작용을 모델화한 것으로 학습이론에 따라 많은 모델이 개발되었지만 본 연구에서 사용한 학습알고리즘은 감독학습이론 중 한 종류인 오차역전파법(Backpropagation)이다. 학습은 신경세포의 활성화인 가중치 w_j 값에 따라 결정되며 입력층부터 출력층까지 전파된 값은 입력치에 대한 감독치와 비교하여 그 오차를 줄이도록 각 층 사이의 가중치의 값을 수정을 통해 이루어진다. 가중치를 조절하는 활성화함수는 과포화된 정보를 안정화시키기 위하여 식3과 같이 시그모이드 함수를 사용하였다.

$$f(x) = \frac{2}{1 + \exp(-\sigma x)} - 1 \quad (3)$$

신경망 학습메타는 연삭상태에 영향을 주는 가공조건에 따라 정량화 시킬 수 있는 인자를 입력패턴으로 하였고, 출력패턴은 가공상태를 정상상태와 비정상상태로 구분하여 bipolar(-1~1)값으로 하였다. 입력층(input layer)는 7개의 신경세포로(neuron), 출력층(output layer)는 Fig 5와 같이 열변형이 발생여부를 선정하였으며, 2개의 신경세포로(neuron)으로 하였다.

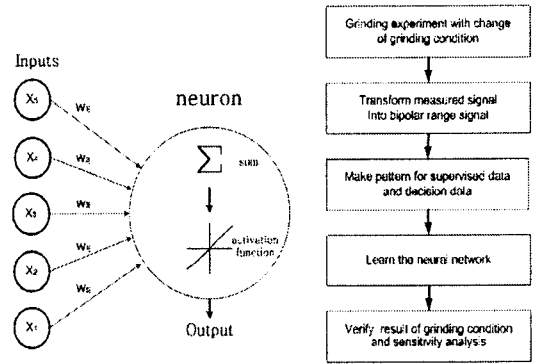


Fig 4 Diagram of artificial neuron and flowchart of experiment process




Fig 5 Surface condition after grinding

3.2 실험계획법을 이용한 신경망 구조 최적화

신경망 학습시 은닉층의 수와 각 은닉층의 노드수, 학습률, 모멘텀, 초기값, 활성화함수의 범위, 입력패턴의 형태(Binary, bipolar)등 많은 변수를 고려하여야 한다. 이러한 모든 조건의 조합을 고려하여 시행착오법으로 신경망을 구성하는 것은 시간적으로 많은 시간이 걸리므로 보다 체계적인 접근을 위하여 3수준계 $[L_3(3^4)]$ 직교배열표를 사용하여 Iteration이 가장 작게 되는 값이 될 때 조건을 신경망 학습 조건으로 선정하였다. 실험조건 및 순서는 Table 3과 같으며 실험은 랜덤화 원리에 의하여 실시하였다. 유의수준 1%

||서 F검정을 한 결과 유의한 주요인은 은닉층의 뉴런수와 학습률이었으며, 모델은 B비가 작아서 오차함에 풀링시켰다. 최적화된 조건은 A3B2이었으며, 이때 모평균의 95% 신뢰구간을 구하면 식5와 같다.

$$\hat{\mu}(A_3B_2) \pm t(\phi, \frac{\alpha}{2}) \sqrt{\frac{V_F}{n_e}} = 422 \pm 44.83 \quad (5)$$

최적화된 구조로 학습한 결과 반복수(number of iteration) = 426으로 신뢰구간을 만족하는 것을 알 수 있다. 또한 은닉층의 수가 많고 학습률이 높을수록 학습패턴과 테스트패턴의 상대오차 줄어들었다. 연구에 사용한 최적화된 신경망 구조는 table 4와 같다.

Table 3 Orthogonal array table with 3 Level [L₉(3⁴)]

Exp.No	Column No.				Data
	A	B	C	e	
1	1	1	1	1	805
2	1	2	2	2	537
3	1	3	3	3	403
4	2	1	2	3	686
5	2	2	3	1	457
6	2	3	1	2	342
7	3	1	3	2	639
8	3	2	1	3	426
9	3	3	2	1	320

A : number of hidden layer (5, 10, 15)

B : learning rate (0.2, 0.3, 0.4)

C : momentum (0.3, 0.5, 0.7)

Table 4 Result of learning condition with optimization

Learning algorithm		Back-Propagation Learning Algorithm
Number of learning pattern		40
Number of nodes of each layer	Input	7
	hidden layer	15
	Output	2
Learning rate, α		0.3
Number of Iteration (epoch)		426
Momentum, η		0.5

3.3 예측결과

신경망 학습을 위해 40개의 pattern을 만들었으며, 학습에 사용되지 않은 40개의 pattern을 이용하여 연삭결과를

예측하였다. 최적화된 신경망구조를 이용하여 학습한 결과 Fig 6과 같은 학습에러와 반복수(epoch)를 나타내었다. 연삭조건에 따라 연삭시편에 열변형부 발생여부(Fig 5참조)를 신경망을 통하여 예측한 결과는 Fig 7과 같다. 학습결과 연삭시편의 표면상태(정상상태, 비정상상태)을 목적패턴과 출력패턴간의 상대오차 0.3%로 모두 정확하게 예측하였다.




Fig 6 The graph of error convergence

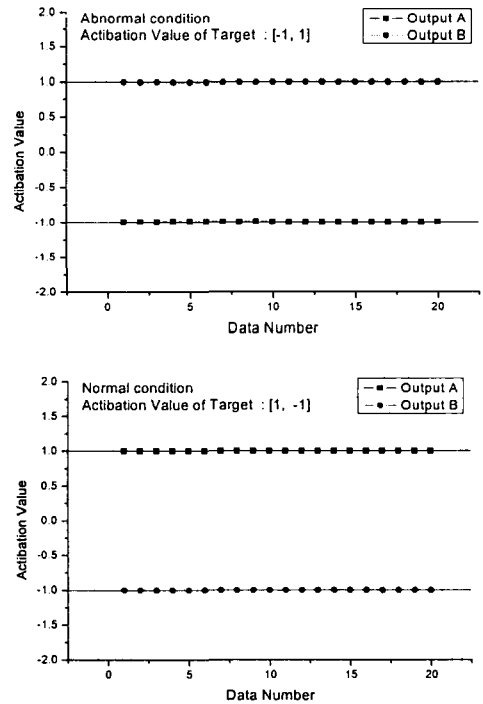


Fig 7 Result of prediction on Surface condition

3.4 민감도분석

생산시스템의 자동화 공정을 위하여 생산공정을 모니터링하거나 실험을 위하여 측정하고자 하는 시스템에 가능한 많은 부위에 센서를 사용하는 것이 바람직하다. 센서수의 증가는 보다 큰 신뢰성과 신속한 모니터링을 할 수 있게 하는 반면 비용의 증가와 처리 데이터의 증가에 따른 분석소요시간의 증가를 가져온다. 그러므로 시스템의 특성에 큰 영향을 미치지 않는 센서의 수를 줄임으로 보다 효율적인 측정을 할 수 있을 것이다. 이를 위하여 신경망을 활용하여 각 입력인자간의 중요도 분석을 통하여 최적화된 입력인자를 산출하였다. 만일 입력인자가 줄어들어도 예측결과가 큰 오차를 발생하지 않는다면 그 인자의 민감도는 낮은 것으로 볼 수 있을 것이다. 입력층 뉴런수를 7개에서 각각 한개씩 줄여가면서 40개의 학습패턴과 40개의 테스트패턴을 통해 민감도를 분석하였다. 각 입력인자의 값을 삭제하여 예측을 비교한 결과는 Table 5와 같다. 민감도 분석결과 입력층(input layer)의 두 번째 뉴런(Neuron)의 경우 삭제되어도 예측결과에 큰 영향을 주지 못하였으므로 민감도가 가장 낮은 것을 알 수 있다.

Table 5 Result of learning condition with optimization

Removed Input neuron NO.	No of Iteration	Training error (%)	Test error (%)
X ₁	479	0.643%	0.236%
X ₂	462	0.640%	0.185%
X ₃	431	0.727%	0.255%
X ₄	446	0.689%	0.246%
X ₅	450	0.683%	0.238%
X ₆	597	0.603%	0.253%
X ₇	467	0.707%	0.250%

4. 결론

본 연구를 통해 얻은 결론은 다음과 같다.

- (1) 실험계획법과 분산분석을 통하여 최적화된 신경망 구조를 만들었으며, 이를 통해 학습시간의 단축 등 보다 효율적인 신경망구조를 설계할 수 있다.
- (2) 복잡한 이론이나 많은 데이터 없이도 단순한 학습법에 의한 신경망으로 연삭조건에 따른 연삭시편의 상태를

모두 정확하게 예측하였으며, 목적패턴과 출력패턴의 상대오차는 1%이내였다.

- (3) 예측결과에 영향을 미치는 각 입력인자를 분석하여 적은 입력인자로 적절한 예측을 할 수 있게 함으로서 보다 효율적인 신호분석을 할 수 있는 민감도 분석방법을 제시 하였다.

참고 문헌

- (1) Song Min Yoo and Young Jin Kim, 2000, "Flexible Disk Grinding Process," Journal of the Korea Society of Machine Tool Engineers, Vol. 9, No. 5, pp. 13~24.
- (2) Min Yang Yang, Hyum Chul Kim and Cheol Woong Byun, 2002, "Development of an Optimal Cutting Condition Decision System by Neural Network," Journal of the Korea Society of Precision Engineers, Vol. 19, No. 9, pp. 111~117.
- (3) Sang-Woon Shin, Choog-Seug Gal and Doo-Sung Ahn, 1996, "A Study on the Automation of Deburring Process Using Expert's skills," Journal of the Korea Society of Precision Engineers, pp. 685~688.
- (4) Sung Jun Kim, 2000, "A study on the Flexible Disk Grinding Process and Burr Analysis by using Neural Networks and Image processing," Kyunghee Univ., pp. 1~43.
- (5) D. Dornfeld, and He Gao Cai, 1984, "An Investigation of Grinding and Wheel Loading Using Acoustic Emission," ASME Journal of Engineering for Industry, Vol. 106.