

신경회로망 모델을 이용한 밀링채터의 실시간 감시에 대한 연구

윤 선 일,* 이 상 석,** 김 희 술***

In-process Monitoring of Milling Chatter by Artificial Neural Network

Sun-Il Yoon,* Sang-Seog Lee,** Hee-Sool Kim***

ABSTRACT

In highly automated milling process, in-process monitoring of the malfunction is indispensable to ensure efficient cutting operation. Among many malfunctions in milling process, chatter vibration deteriorates surface finish, tool life and productivity. In this study, the monitoring system of chatter vibration for face milling process is proposed and experimentally estimated. The monitoring system employs two types of sensor such as cutting force and acceleration in sensory detection state. The RMS value and band frequency energy of the sensor signals are extracted in time domain for the input patterns of neural network to reduce time delay in signal processing state. The results of experimental evaluation show that the system works well over a wide range of cutting conditions.

Key Words : Milling Process, In-process Monitoring, Chatter Vibration, Cutting Force, Acceleration, RMS, Band Frequency Energy, Neural Network

1. 서 론

최근 가공시스템을 무인화·자동화함에 따라 가공정밀도와 생산성의 향상을 위해 가공시스템 전반에 걸친 현상태의 자동인식의 필요성이 강조되고 있다. 즉 가공 중에 발생하는 각종 이상상태에 대한 실시간(In-process)감시는 지능형 공작시스템의 구현을 위해 필수적인 요소이다.

가공공정중에서 큰 비중을 차지하고 있는 밀링공정의 이상상태로서는 채터진동, 공구마모, 공구파손 등으로 대별할 수 있다. 이중 공구마모와 공구파손에 대한 연구는 많이 이루어지고 있으나 채터진동의 실시간감시에 대한 연구는 미흡한 실정이다. 밀링공정의 절삭과정에서 발생하는 채터진동(Chatter Vibration)은 가공물의 표면정밀도를 저하시키고 공구와 공작기계의 손상을 유발할 수 있다. 따라서 가공중에 발생하는 채터진동의

* 영남대학교 기계공학과 대학원(정회원)

** 경북실전 기계설계과(정회원)

*** 영남대학교 기계공학과(정회원)

효과적인 감시방법에 대한 필요성이 제기된다.

절삭공정의 감시에 관한 최근의 연구동향은 적합한 센서의 선정과 이를 센서의 융합(Sensor Fusion), 적절한 신호처리기법에 의한 특징추출(Feature Extraction), 패턴분류기(Pattern Classifier)의 개발 등으로 대별된다. 이러한 연구로서 S. Rangwala, D. Dornfeld는 선반에서 절삭력의 크기 및 AE센서 신호의 RMS, Variance, Standard Deviation값 등을 신경회로망모델의 입력특징으로 사용하여 공구상태 진단방법을 제시하였으며,⁽¹⁾ T. Moriwaki등은 선반에서 절삭력센서와 AE센서를 융합하여 특징을 추출하고 이를 신경회로망모델에 적용시켜 절삭상태 인식에 관한 연구하였다.⁽²⁾ Y. Miyoshi는 선삭가공에서 가속도신호의 자기회귀계수를 특징으로 추출하여 신경회로망모델에 적용시켜 절삭 이상상태의 검출을 연구하였다.⁽³⁾ 최근에는 절삭력 및 AE센서의 융합에 의한 AR계수의 변화를 신경회로망모델에 적용시켜 선삭공구의 감시시스템에 관한 연구하였다.⁽⁴⁾ 그러나 현재까지의 연구는 단절인을 사용하는 선삭가공의 경우가 많았으나 앞으로 단절인을 사용하는 밀링가공에 대해서도 많은 연구의 필요성이 대두되고 있다.

본 연구에서는 정면밀링가공시 발생되는 채터진동의 진단을 위해서 절삭력센서와 진동센서를 이용하여 측정하고, 측정된 센서신호는 통계적 분석방법인 RMS값과 특정대역 주파수성분의 에너지값을 나타내는 대역주파수에너지법에 의한 신호처리방법을 이용하여 분석하고, 채터진동과 관련된 가장 민감한 특징을 추출한다. 이러한 특징변화들을 오차역전파(Back Propagation of Error)학습알고리즘의 신경회로망(Artificial Neural Network)모델에 적용시켜 밀링가공시 발생되는 채터진동을 용이하게 감시할 수 있는 진단방법을 제시하고자 한다.

2. 절삭실험

본 실험에서 사용된 실험장치의 사양은 Table 1과 같다.

절삭실험에 사용된 밀링머신은 수직형이며, 커터는 100mm의 삽입식으로 6개의 초경인서트를 삽입하여 전식 절삭하였다. 인서트 삽입은 치구를 사용하여 축방향과 반경방향의 오차를 최소화하였다. 이송테이블 위에 공구동력계를 장착하고, 그 위에 고정구와 공작물을 장

Table 1 Specification of experimental instruments

Milling Machine	화천기계 HMV-F-1100
Workpiece	SB41(138×78)
Face Cutter	대한중석 M415SP04R-12
Insert	대한중석 SPGN 1203 P20
Tool Dynamometer	Kistler(Type 9257-A)
Accelerometer	Rion(Type PV36)
A/D Converter	Data translation DT 2833 Resolution:12 Bit Input Range: $\pm 10\text{ V}$
Personal Computer	IBM PC(i486DX-50)
Charge Amplifier	Kistler(Type 5008EDPM-2300)

착하고, 고정구에 가속도계를 부착하였다. X, Y축으로 측정된 절삭력과 가속도신호는 전하증폭기(Charge Amplifier), 대역필터(Band Pass Filter), A/D 변환기를 통하여 PC에 저장된다. 데이터는 4KHz로 나이키스트 샘플링(Nyquist Sampling)하였다. 본 실험에서 행한 절삭조건은 Table 2와 같다.

Table 2 Experimental cutting condition

RPM	180, 280, 370, 520, 750
Feed	15, 22, 41, 61, 87, 127, 187 (mm/min)
Depth	0.1 - 4.0 (mm)

3. 신호처리 및 특징추출

Fig. 1은 주축회전수 370rpm, 이송속도 87(mm/min), 절삭깊이 0.5mm일 때 공구동력계로 부터 0.25초 동안 측정한 X, Y축 방향의 절삭력성분을 시간영역 및 주파수영역으로 나타낸 것이다. 시간영역의 절삭력에서는 커터의 회전에 따라 단속절삭에 의한 일정한 간격의 주기적인 절삭력패턴이 나타난다. 주파수영역에서는 저주파수와 고주파수에서 두개의 모우드를 나타내고 있다. 저주파수에서 나타나는 모우드는 주축회전수 370rpm에서 6개 인서트에 의한 37Hz의 하아모닉성분들로서 절삭조건과 커터의 기하학적 형상에 의해 결정된다. 900Hz 근방의 고주파수에서 나타나는 모우드는 절삭과정에서 공작물과 절삭공구의 상대운동에 의해 발생되는 동적성분(Dynamic Component)을 나타낸다. 이동적성분은 이송방향인 Y축 방향에서 가장 민감하게 나

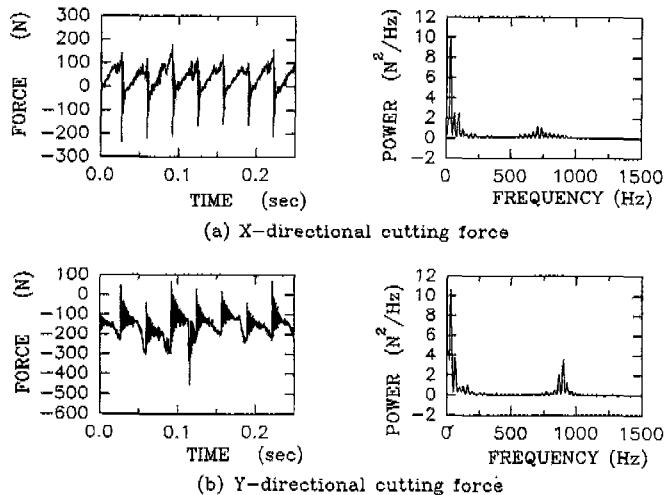


Fig. 1 Cutting force in time and frequency domain (RPM:370, Feed:87mm/min, Depth:0.5mm)

타나고 있다. 앞선 연구^[5,6]에서 제시한 바와 같이 밀링 공정 중 발생되는 채터진동은 이러한 동적성분에서 그 영향이 잘 나타난다. Fig. 2는 Fig. 1과 동일한 절삭조건에서의 가속도신호를 시간영역 및 주파수영역으로 나타낸 것이다. Fig. 1의 절삭력신호와 Fig. 2의 가속도신호를 비교하여 보면 가속도신호에서는 절삭력신호에서 우월하게 나타나는 저주파수성분은 미미하지만 공구와 공작물의 상대운동인 동적성분이 우월하게 나타난다. 따라서 밀링공정 중 발생되는 채터진동을 검출하는데 절삭

력신호 보다 가속도신호가 더 유효하다고 판단된다.

Fig. 3(a), (b)는 주축회전수 370rpm, 이송속도 87mm/min 일때 절삭과정의 안정성을 고찰하기 위해서 절삭깊이를 점점 증가시키면서 절삭력과 가속도신호의 RMS(Root Mean Square)값의 변화를 나타낸 것이다. Fig. 3(a)의 절삭력신호는 절삭깊이가 깊어질수록 서서히 증가하는 경향을 보였고, (b)의 가속도신호는 절삭깊이 1.5 - 2.0mm에서 채터발생으로 인하여 RMS값의 급격한 상승을 보였다.

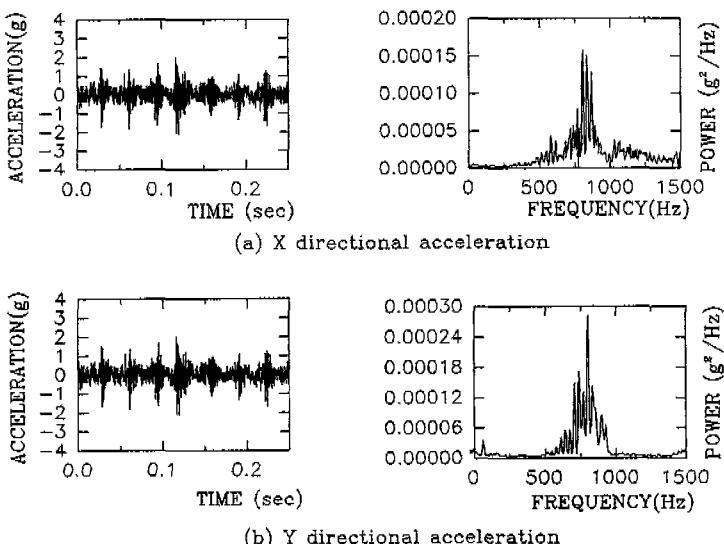


Fig. 2 Acceleration in time and frequency domain (RPM:370, Feed:87mm/min, Depth:0.5mm)

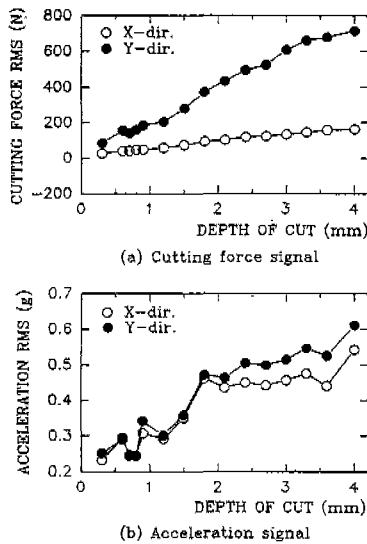


Fig. 3 The variation of RMS according to depth of cut in X, Y directions
(RPM:370, Feed:87mm/min)

Fig. 4, 5는 주축회전수 370rpm, 이송속도 87mm/min 일 때 여러 절삭깊이에서 X축, Y축방향의 가속도 신호를 주파수영역으로 나타낸 것이다. 이 때 고주파수 성분의 값을 추출하기 위해 대역주파수 에너지법(Frequency Band-Energy Method)⁽⁷⁾을 이용하면 다음 식과 같이 표시할 수 있다.

$$E_{x_{BPF}} = \int_{f_L}^{f_H} G_x(f) df \quad (1)$$

여기서 $G_x(f)$ 는 신호 $x(t)$ 의 파워스펙트럼 밀도함수이고; f_L, f_H 는 대역주파수 필터의 저주파 및 고주파의 컷 오프 주파수이다. 본 실험에서는 이 값을 600Hz, 1200Hz로 하였다.

그러나 식(1)과 같이 주파수영역에서의 에너지추출방법은 신호처리과정에서 FFT변환에 따른 시간지연이 커서 데이터를 실시간으로 처리하는데 문제가 있다. 따라서 데이터를 주파수영역에서 처리하지 않고 시간영역에서 에너지값을 구하면 다음식과 같다.⁽⁸⁾

$$\begin{aligned} E_{x_{BPF}} &= \lim_{T \rightarrow 0} \frac{1}{T} \int_0^T X^2(t)_{BPF} dt \\ &= \frac{1}{N} \sum_{n=1}^N X^2(t)_{BPF} \end{aligned} \quad (2)$$

여기서 $X(t)$ 는 측정신호의 시간 t 에서의 크기이고, N 은 이산신호의 샘플링수이다. 위식과 같은 방법으로 시간영역에서 에너지값을 추출하면 데이터를 빠른시간에 처리할 수 있어서 실시간 진단시스템 구성이 용이하다. Fig. 6은 주축회전수 370rpm, 이송속도 87mm/min의 절삭조건에서 절삭깊이의 변화에 따른 가속도신호를 시간영역의 대역주파수 에너지값으로 나타내었다. 그림에서 알 수 있는 바와 같이 대역주파수 에너지값도 절삭깊이가 커질수록 서서히 증가하다가 절삭깊이 1.5-2.0mm에서 채터발생으로 인하여 급격한 상승세를 보인다. 따라서 본 연구에서 채터발생 판정은 에너지값의 증가율이 급격하게 점프(Jump)현상을 일으키는 시점으로 하였다.⁽⁹⁾ 이와 같이 에너지값이 특징적으로 변화

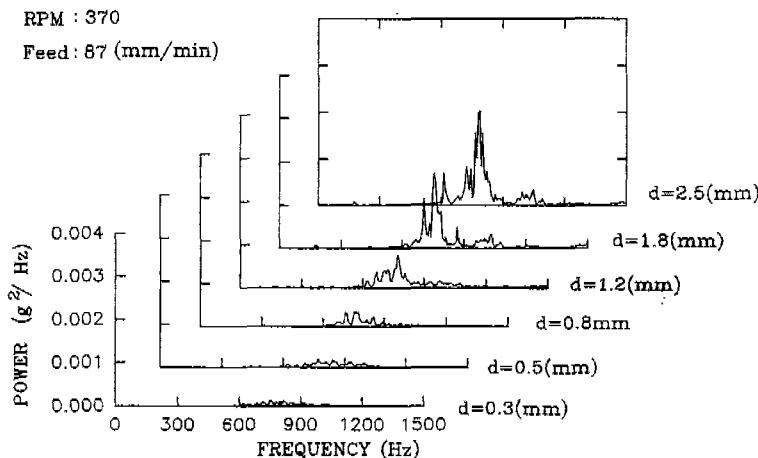


Fig. 4 X-directional acceleration in the frequency domain

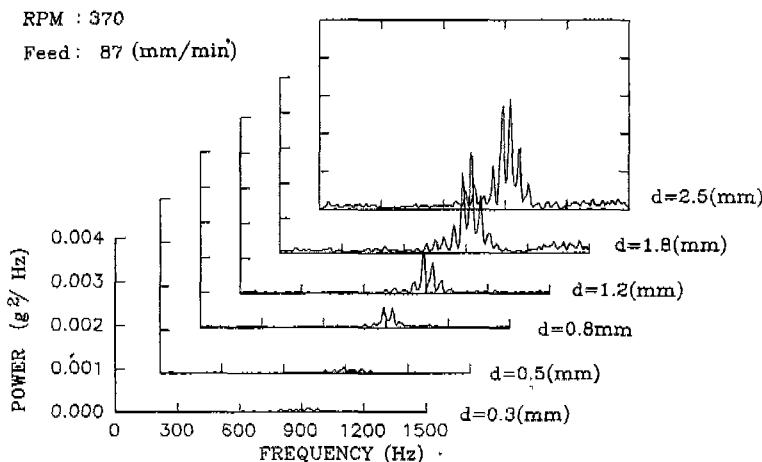


Fig. 5 Y-directional acceleration in the frequency domain

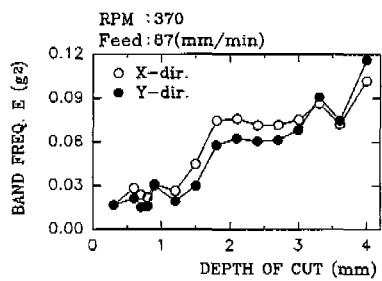


Fig. 6 Band frequency energy according to depth of cut in X, Y-direction (acceleration in time domain)

하므로 다른 입력패턴과 함께 채터진동을 감시할 수 있는 유효한 신경회로망의 입력패턴으로 사용할 수 있다.

4. 신경회로망모델에 의한 진단시스템

4. 1 진단시스템 구성

생체신경계를 모델화한 신경회로망은 강력한 자기학습 및 분류기능을 가지고 있기 때문에 최근 여러분야에 걸쳐 이용되고 되고 있으며, 특히 기계공학 분야에서는 기계의 상태진단 및 제어(control)분야에 유용한 기법으로 적용되고 있다. 신경회로망은 다중퍼셉트론의 기본단위인 뉴런(Neuron)으로 구성되고, 이 뉴런들이 상호 결합하여 학습을 통해 결합강도를 조정하고, 이 결합강도를 이용하여 입·출력간의 수학적으로 표현하기 어려운 복잡한 함수관계(Mapping)를 해결할 수 있다.

본 연구에서는 신경회로망모델의 입력패턴으로 사용

하기 위해서 다음과 같이 9개의 특징을 선정하였다.

- 주축회전수(RPM), 이송속도(Feed), 절삭깊이(Depth)
- X, Y축방향 절삭력의 RMS값(F_x , F_y)
- X, Y축방향 가속도의 RMS값(A_x , A_y)
- X, Y축방향 가속도의 대역주파수 에너지값(EA_x , EA_y)

시그모이드함수의 특성에 의한 조기포화 방지를 위해 채터가 일어나지 않은 안정한 상태를 0.1로, 채터가 일어나서 불안정한 상태를 0.9로 하여 출력범주를 정하고 입력값은 다음 식과 같이 표준화(Normalizing)하였다.

$$\frac{[(0.9 - 0.1)/\{Value(max) - Value(min)\}]}{(Value - Value(min) + 0.1)} \quad (3)$$

여기서 $Value(max)$ 은 네트워크에 입력되는 최대값을 의미하고, $Value(min)$ 은 입력되는 최소값을 의미한다.

Neural network 구조중 입력층(Input Layer)과 출력층(Output Layer)의 Node수가 결정되면 변화시킬 수 있는 것은 은닉층(Hidden Layer)의 Node수이다. 대상으로 하는 문제에 대해서 은닉층의 Node수가 너무 작으면 충분한 학습이 이루어지지 않아 성능이 저하된다. Node수가 너무 많으면 은닉층의 Node들 사이에 유사한 출력특성을 가진 Node가 나타나게 된다. 이런 유사한 Node들은 정보전달적으로 거의 같은 작용을 하고 있어 학습과정에서 부작용을 발생시킨다. 거의 같은 출력값을 나타내는 Node들은 학습과정에서 허용오

차 범위내로 수렴하는데 오히려 장애가 되어 학습시간을 느리게하거나 발산하게 한다. 따라서 2개 Node사이 출력의 상관관계를 정량적으로 취급하기 위해서 다음식으로 정의되는 상관계수 R_{ij} 를 도입했다.⁽²⁾

$$R_{ij} = \frac{\frac{1}{n} \sum_{p=1}^n [(O_i^p - \bar{O}_i)(O_j^p - \bar{O}_j)]}{\sqrt{\frac{1}{n} \sum_{p=1}^n (O_i^p - \bar{O}_i)^2} \cdot \sqrt{\frac{1}{n} \sum_{p=1}^n (O_j^p - \bar{O}_j)^2}} \quad (4)$$

여기서 n 은 학습데이터의 입출력패턴쌍의 수이고, O_i^p , O_j^p 는 p 번째 학습데이터에 대한 은닉층 Node i , j 의 출력이고, \bar{O}_i , \bar{O}_j 는 전체 학습데이터에 대한 Node i , j 의 출력의 평균값이다. 이와 같이 구한 상관계수의 절대치 $|R_{ij}|$ 가 0.9 이상일 때 i 번째 Node는 삭감 가능하다. 이런 방법으로 실험데이터를 사용하여 은닉층의 수를 1개층으로 하여 검증해 본 결과 은닉층의 Node수는 Table 3과 같이 나타났다.

Table 3에서 상관계수를 도입하여 구한 Node수는 14이고, 14개 이상의 Node수에서는 두드러진 성능향상을 보지 못했다. 대상으로 하는 문제에 적절한 Node수는 최초에 설정한 Node수에서 삭감 가능한 수를 빼줌으로써 인식률이 좋은 적절한 Node수를 설정할 수 있다. 그리고 은닉층의 수(Number of Hidden Layer)는 1개층으로 구성하는 것 보다 2개층 이상으로 구성함으로써 보다 좋은 인식률(Recognition Rate)을 얻을 수 있었다.

4. 2 채터 진단 결과

Table 4-6은 입력특징(Feature)의 수가 변화함에 따라서, 또 같은 입력특징수에 대해서 은닉층의 구조가 변화함에 따라서 신경회로망의 인식률을 변화를 나타내었다. 이 결과 신경회로망의 입력특징수와 구조가 변화함에 따라서 인식률의 차이가 있음을 알 수 있다. 본 연

Table 3 The relation between number of nodes and correlation of output in hidden layer

은닉층에서의 Node 수	6	8	10	12	14	16	18
Error($\times 10^6$)	108.8	73.6	45.6	23.5	17.2	16.8	16.4
Number of high correlation(≥ 0.9)	0	0	0	0	0	2	4

Table 4 The performance of Neural Network for 6 features.

(Features: RPM, Feed, Depth, F_y , A_x , A_y)

Architectures	6	6	6	6
Learning	14	3-6	6-9	12-9-6
Testing	1	1	1	1
No. of errors	137	137	137	137
Recognition rate	51	51	51	51
No. of errors	4	2	2	2
Recognition rate	92%	96%	96%	96%

Table 5 The performance of Neural Network for 7 features.

(Features: RPM, Feed, Depth, F_x , F_y , A_x , A_y)

Architectures	7	7	7	7
Learning	14	12-5	15-5	14-15-14
Testing	1	1	1	1
No. of errors	137	137	137	137
Recognition rate	51	51	51	51
No. of errors	4	3	2	3
Recognition rate	92%	94%	96%	94%

구조에서는 컴퓨터 시뮬레이션에 의한 시행착오를 통해 은닉층의 수를 3개층으로 한 9-15-15-10-1의 구조가 가장 우수한 인식률을 보였다. Table 7은 이 때의 학습조건을 나타내었다.

Table 8은 9-15-15-10-1 네트워크에서 모멘텀률(Momentum rate)의 변화에 따른 인식률의 변화를 나타내었다. Fig. 7은 이 때의 학습과정에서 시스템오차의 수렴과정을 나타내었다. 이 결과 모멘텀률이 0.7인 경우 가장 좋은 인식률을 나타내었고, 모멘텀률이 더 큰 경우 수렴과정에서 큰 진동이 발생하여 오히려

Table 6 The performance of Neural Network for 9 features.

(Features: RPM, Feed, Depth, F_x , F_y , A_x , A_y , EA_x , EA_y)

Architectures	9	9	9	9
Learning	14	14-14	14-5	15-15-10
Testing	1	1	1	1
No. of errors	137	137	137	137
Recognition rate	51	51	51	51
No. of errors	6	4	2	1
Recognition rate	88%	92%	96%	98%

Table 7 Learning parameters for training Neural Network

Learning condition	No. of node	Output category
Learning rate :0.9	Input layer : 9	
Momentum rate :0.7	1st hidden :15	
Error limit :0.0005	2nd hidden :15	
Input samples :137	3rd hidden :10	
Shape factor :1.0	Output layer : 1	

Table 8 The performance of Neural Network to the variation of momemtum rates.

Architectures		9-15-15-10-1		
No. of samples	Learning	137	137	137
	Testing	51	51	51
Momentum rate	0.9	0.7	0.3	
Learning rate	0.9	0.9	0.9	
No. of errors	3	1	3	
Recognition rate	94%	98%	94%	

Table 9 The performance of Neural Network to the variation of learning rates.

Architectures		9-15-15-10-1		
No. of samples	Learning	137	137	137
	Testing	51	51	51
Momentum rate	0.7	0.7	0.7	
Learning rate	0.9	0.5	0.3	
No. of errors	1	4	4	
Recognition rate	98%	92%	92%	

인식률이 저하하였다.

Table 9는 9-15-15-10-1 네트워크에서 학습률(Learning rate)의 변화에 따른 인식률의 변화를 나타내었다. Fig. 8은 이 때의 학습과정에서 시스템오차의 수렴과정을 나타내었다. 이 결과 학습률이 0.9인 경우 가장 좋은 인식률을 나타내었고 수렴속도도 가장 빨랐다. 그러나 더 큰 학습률을 적용하면 수렴과정에서 진동을 유발하게 된다.

5. 결 론

밀링공정에서 발생되는 채터진동을 실시간 감시하기 위해서 신경회로망모델을 구성하여 진단해 본 결과 다음과 같은 결론을 얻었다.

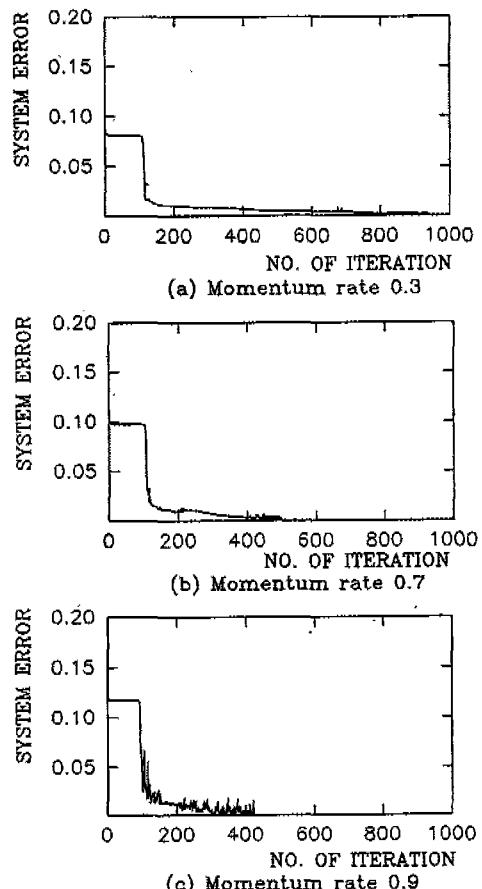


Fig. 7 The convergence of system error to the variation of momentum rate (learning rate 0.9)

(1) 절삭력신호와 가속도신호의 고유진동수 부근의 주파수성분은 채터발생에 따른 영향을 잘 나타내므로 채터발생의 판정기준이 될 수 있다.

(2) 가속도신호의 RMS값과 대역주파수에너지값은 절삭력신호의 값 보다 채터발생점에서 더 민감한 반응을 나타내었다.

(3) 신경회로망에서 1개의 온너층으로된 구조의 노드 수는 상관계수를 도입함으로써 적절한 노드수를 설정할 수 있었다.

(4) 본 연구조건 하에서 절삭조건(RPM, Feed, Depth)과 함께 절삭력과 가속도신호의 RMS값 및 대역주파수에너지값 등 입력특징의 수를 9개로 하고 온너층의 수를 3개로 한 9-15-15-10-1구조의 신경회로망을 구성하여 채터발생을 우수하게 인식하였다.

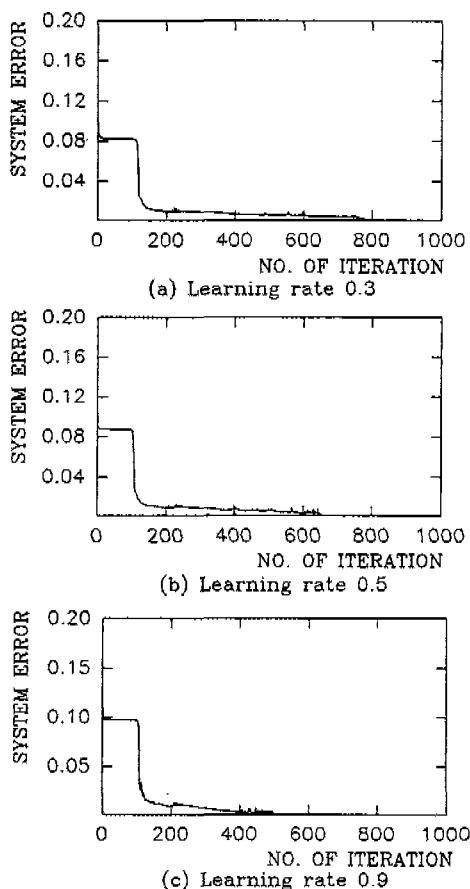


Fig. 8 The convergence of system error to the variation of learning rate (Momentum rate 0.7)

후기

본 연구는 1993년도 교육부 학술연구조성비(ME 93-E-11)에 의하여 수행되었으며, 이에 감사를 드립니다.

참고문헌

- Rangwala, S. S., Dornfeld, D. A., "Sensor Integration Using Neural Networks for Intelligent Tool Condition Monitoring", J. of Eng. for Ind., Vol. 112, pp. 219-228, Aug., 1990.
- Moriwaki, T., Mori, Y., "Recognition of Cutting State Based on Neural Network Sensor Fusion", JSPE Vol. 59 No. 5, pp. 779-784, 1993.
- Miyoshi, Y., "Detection of Abnormal Cutting Condition Using an Adaptive Filter and a Neural Network", JSPE Vol. 57 No. 10, pp. 1774-1779, 1991.
- 최기상, 최기홍, "선삭공작을 위한 지능형 실시간 공구감시 시스템에 관한 연구", 한국정밀공학회지, 제9권 4호, pp. 22-35, 1992.
- Das, M. K., Tobias, S. A., "The Relation between the State and Dynamic Cutting of Metals", Int. J. of M. T. D. R., Vol. 107, pp. 63-89, 1987.
- Ann, T. Y., Eman, K. F., Wu, S. M., "Identification of the Transfer Function of Dynamic Process - A Comparative Assessment", Int. J. of M. T. D. R., Vol. 25, pp. 75-90, 1986.
- Jiang, C. Y., Zhang, Y. Z., Xu, H. J., "In-Process Monitoring of Tool Wear Stage By the Frequency Band-Energy Method", Annals of the CIRP, Vol. 36, No. 1, pp. 45-48, 1987.
- 구연숙, 정의식, 남궁석, "선삭가공에 있어서 채터진동의 인-프로세스 검출에 관한 연구 (II)", 한국정밀공학회지, 제9권 3호, pp. 117-121, 1992.
- Zhang Sanle, "Chatter Detection in Milling Process", Master of Science, Univ. of Wisconsin Madison, 1986.
- 조동우, 고태조, "Adaptive Milling Process Modeling and Neural Networks Applied to Tool Wear Monitoring", 한국정밀공학회지, 제11권 1호, pp. 138-149, 1994.
- Yoh-Han Pao, "Adaptive Pattern Recognition and Neural Networks", Addison-Wesley Publishing Company Inc., N.Y., 1974.
- Rumelhart, D., McClelland, J., "Parallel Distributed Processing", Vol. 1, MIT Press, Cambridge, MA, 1986.