

복합 신경회로망을 이용한 채터진동의 인프로세스 감시(Ⅱ)

김 정 석,* 강 명 장,** 박 철***

In-Process Monitoring of Chatter Vibration using Multiple Neural Network(Ⅱ)

Jeong-Suk Kim,* Myeong-Chang Kang,** Cheol Park***

ABSTRACT

The In-process monitoring of the chatter vibration is necessarily required to an automatic manufacturing system. In this study, we constructed a multi-sensing system using tool dynamometer, accelerometer and AE(Acoustic Emission) sensor for a more credible detection of chatter vibration. And a new approach using a multiple neural network to extract the features of multi-sensor for the recognition chatter vibration is proposed. With the Back-propagation training process, the neural network memorize and classify the features of multi-sensor signals. As a result, it is shown by multiple neural network that the chatter vibration can be monitored accurately, and it can be widely used in practical unmanned system.

Key Words : Chatter Vibration(채터진동), Multi-sensor(다중센서), Multiple Neural Network(복합 신경회로망), In-process Monitoring(인프로세스 감시)

1. 서 론

최근에 생산 시스템의 변화에 따라 설계 기술 및 가공 기술의 유연성이 많이 강조되고 있으며, 공장 자동화 및 무인화 공장을 실현시키기 위한 시스템의 감시 기술 및 제어 기술의 필요성이 증가하고 있다.

절삭가공 중에 발생하는 채터진동(Chatter Vibration)은 절삭가공면의 정밀도, 공작기계 및 공구의 수명, 가공 공정의 생산성에 영향을 미치며, 공작기계 부

품의 설계 및 구성, 가공 공정의 자동화에 중요한 변수로 작용하고 있다. 무인 자동화 가공시스템의 실현을 위해서는 인간의 패턴인식 기술과 감각 기능을 성공적으로 묘사하는 능력을 가진 다중센서를 기초로 하는 지능형 검출시스템의 개발이 필수적이다.

가공상태 검출에 대한 연구가 여러 연구가들에 의해 수행되었으나, 하나의 센서로 광범위한 가공조건에 걸쳐 신뢰성있는 신호의 검출은 불가능하며, 또한 가변하는 가공상태에서 하나의 센서정보로 가공상태에 대해

* 부산대학교 정밀기계공학과, 정밀정형 및 금형가공 연구센터

** 부산대학교 기계기술연구소

*** 부산대학교 정밀기계공학과 대학원

신뢰성있는 의사결정을 한다는 것이 어렵다는 결론에 도달하게 되었다.^[1] 이에 대한 방안으로 최근에는 다중 센서를 이용하는 방법이 대두되고 있는데, 가공상태를 최종 결정하는데 있어서 각 센서의 출력결과에 대해 각각 얼마의 가중치를 두고, 명확한 판단기준을 어떻게 선정하는가 하는 문제점을 가지고 있다. 이러한 문제를 해결하기 위한 접근방법으로 신경회로망, 퍼지이론, 데 이타처리 총괄법 등^[2,3]이 있으나, 퍼지이론이 규칙의 형태로 구성되어져 있는 알고리듬과는 달리, 신경회로망은 사전 지식이나 내부 시스템의 동작에 대한 지식이 거의 없고 주어진 샘플들로부터의 학습경험에 바탕을 두고, 새로운 유사 입력패턴들이 주어질 경우에 그 출력패턴을 추정할 수 있도록 자기 조작화하고 센서융합하는 장점을 가지고 있다.

이상과 같은 관점에서, 전보에서는 채터진동의 인프로세스 감시를 위한 실시간 복합 계측시스템을 구성하여 각 센서 신호에 따른 검출정보의 신뢰성을 높이고, 인프로세스 감시 가능성을 보고하였다.^[4]

따라서, 본 연구에서는 이러한 다중센서를 이용한 실시간 검출 결과로부터 채터진동 발생점의 인프로세스 감시를 위하여 패턴 인식을 위한 특징 추출부에 신경회로망을 채택하여 다중센서의 고유 패턴을 추출하도록 하였고, 신경회로망을 모델링할 때 학습 수렴속도를 향상시키기 위하여 2개의 은닉층을 가지도록 구성하고, 모멘텀 계수를 도입하였다. 이렇게 구성된 신경회로망을 통해 각 센서에 대한 고유 패턴을 추출하였고, 다중 센서에서 추출된 고유 패턴은 다시 신경회로망에 입력되어 가공 상태를 최종 결정하는 복합 신경회로망 (Multiple Neural Network)을 구축하였다. 이 복합 신경회로망은 각 센서에서 나오는 고유 패턴을 종합 분석하여 실시간 영역에서 채터진동의 발생 유무를 판별하여 작업자에게 알려줄 수 있도록 구축하였다.

2. 신경회로망을 이용한 패턴인식

인공 신경회로망은 생체 시스템과 마찬가지로 많은 양의 센서 정보에서 중요한 특징을 자기 조정에 의해 추출할 수 있으며(Feature Extraction), 다중센서로부터의 정보를 융합할 수 있고(Sensor Fusion), 또 학습되지 않은 입력에 대해서도 축적된 내적 지식을 통하여 적절한 출력을 낼 수 있는 적응성(Adaptability)

을 갖고 있기 때문에 그 용용 범위가 증가하고 있는 실정이다.^[5,6,7]

많은 경우에 있어서 학습은 입력과 출력사이의 연관적인 맵핑관계를 수행함으로써 점진적으로 형성되어가는데, 이것을 위하여 신경회로망 내의 내부 구조를 수정시켜 나가는 과정을 연관 학습이라고 한다. 연관 학습에는 학습이 어떻게 일어나는지에 따라 시스템에 입력/출력 패턴을 제시함으로써 연관 맵핑을 형성하는 감독 학습과 단지 입력·패턴만을 사용하는 무감독 학습이 있다.

본 연구에서는 신경회로망의 연관 학습을 이용하여 입력 신호에 대해 적절한 출력을 낼 수 있도록 감독 학습을 수행하였다.

입력층 뉴우런의 수가 S개일 때 신경회로망의 입력 벡터는 $X = (X_0, X_1, \dots, X_i, \dots, X_{s-1})$ 이 되고, 뉴우런의 연결은 연결 강도 $W_{i,j,k}$ 를 가지며 서로 연결되어 있다. 모든 $W_{i,j,k}$ 는 연결 강도 벡터 $W = (W_0, W_1, \dots, W_i, \dots, W_{s-1})$ 의 형태를 갖고, 부가 파라미터인 임계치 $t_{i,k}$ 가 있다.

신경회로망 내의 뉴우런은 Fig. 1에서 보는 바와 같이 연결되어 있는 아래층 뉴우런들의 출력에 연결 강도를 곱하여 그 합을 구한 후, 그 값에 임계치를 더하여 k번째층 i번째 뉴우런으로의 입력인 $NET_{i,k}$ 를 식 (1)과 같이 구한다.

$$NET_{i,k} = \sum_{j=0}^{s-1} X_j W_{i,j,k} - t_{i,k} \quad (1)$$

여기서,

$W_{i,j,k}$: (k-1)번째층 i번째의 뉴우런에서 k번째층 j 번째 뉴우런으로의 연결 강도

$t_{i,k}$: k번째층 i번째 뉴우런의 임계치

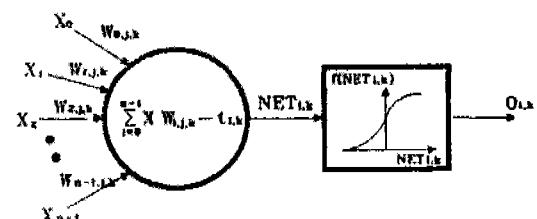


Fig. 1 Schematic Diagram of a Neuron in Neural Network

$NET_{i,k}$: k번쨰층 i번째 뉴우런으로의 입력
식 (1)에 의해 구해진 $NET_{i,k}$ 를 식 (2)와 같이 각 활성화 함수의 입력으로 취하고 k번쨰층 i번째 뉴우런의 출력 $O_{i,k}$ 를 구한다. 본 연구에서는 Fig. 2와 같은 시그모이드 함수를 활성화 함수로 선정하였다.

$$O_{i,k} = f(NET_{i,k}) = \frac{\Theta}{1 + e^{-\beta \cdot NET_{i,k}}} \quad (2)$$

여기서, Θ 는 최대 출력을 결정짓는 파라미터로 뉴우런의 최대 출력을 제한하며, β 는 시그모이드 함수의 기울기로 곡선의 기울기뿐만 아니라 뉴우런의 출력값이 최대-최소 범위를 벗어나지 않게 제한한다. 본 연구에서는 Θ 와 β 를 각각 1로 선정하였다.

식 (2)에 의해 계산된 출력은 같은 층의 다른 뉴우런으로부터의 출력들과 함께 다음 층의 입력으로 작용하게 되며 이러한 과정은 역전파 학습규칙(Back-propagation Learning Rule : BP)에 의해 학습 오차가 수렴할 때까지 반복된다.

BP 신경회로망은 1개의 은닉층을 가지는 경우보다도 2개의 은닉층을 가지는 경우가 더 많은 분류 경계를 가짐으로 분류 기능이 뛰어나고 수행 속도가 더 빠르므로⁽⁸⁾, Fig. 3과 같이 2개의 은닉층을 가지는 2-4-4-1의 신경회로망을 신호의 특징 추출부에 구성하였다.

신경회로망의 출력층에서 뉴우런의 수가 n개 있을 때 출력층에서 기대되는 패턴이 $D = (D_{p,0}, D_{p,1}, \dots, D_{p,n-1})$ 로 표현되고, 실제 출력 패턴이 $O = (O_{p,0}, O_{p,1}, \dots, O_{p,n-1})$ 로 표현될 때 학습 오차함수 E_p 는 식 (3)과 같이 표현되고 이 오차함수 값이 최소화되도록 학습

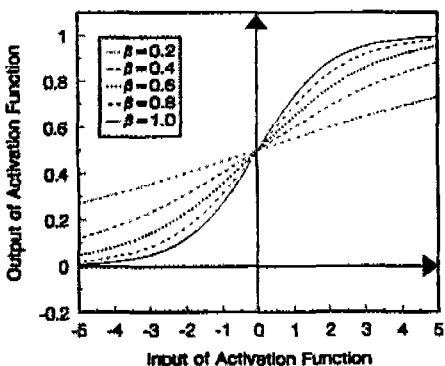


Fig. 2 Sigmoid Function as Activation Function

된다.

$$E_p = \frac{1}{2} \sum_{i=0}^{n-1} (d_{p,i} - O_{p,i})^2 \quad (3)$$

여기서, $O_{p,i}$: 출력 패턴, $d_{p,i}$: 목적 패턴

이 학습오차 E_p 를 최소화하기 위해 신경회로망이 반복될 때마다 연결 강도 $W_{i,j,k}$ 와 임계치 $t_{i,k}$ 는 η_t 와 η_w 가 각각 임계치와 연결 강도의 학습율일 때 식 (4)와 식 (5)로 조정된다.

$$\begin{aligned} W_{i,j,k}(n+1) &= W_{i,j,k}(n) - \eta_w \left(\frac{\partial E}{\partial W_{i,j,k}} \right) \\ &= W_{i,j,k}(n) - \eta_w \delta_{i,k} O_{j,k} \end{aligned} \quad (4)$$

$$\begin{aligned} t_{i,k}(n+1) &= t_{i,k}(n) - \eta_t \left(\frac{\partial E}{\partial t_{i,k}} \right) \\ &= t_{i,k}(n) - \eta_t \delta_{i,k} \end{aligned} \quad (5)$$

여기서, η_t : 임계치의 학습율, η_w : 연결 강도의 학습율

단, 출력층과 중간층에서의 뉴우런의 델타 $\delta_{i,N}$ 과 $\delta_{i,k}$ 는 다음과 같다.

$$\delta_{i,N} = (T_i - O_{i,N}) O_{i,N} (1 - O_{i,N}) \quad (6)$$

$$\delta_{i,k} = O_{i,k} (1 - O_{i,k}) \sum_{j=1}^N W_{i,j,k} \delta_{j,k+1} \quad (7)$$

학습과정에서 학습 샘플의 입력 패턴은 입력층에 제시되고, 신경회로망을 통하여 출력이 생성된다. 그리고 출력층에 대한 델타 $\delta_{i,N}$ 이 식 (6)에 의해 계산되고 중간층에 대한 델타 $\delta_{i,k}$ 는 식 (7)에 따라 순환적으로 역전달법에 의해 계산된다. 이렇게 조정된 연결 강도와 임계치, 뉴우런의 값이 주어진 입력에 대하여 적절한 출력을 내는 것이다.

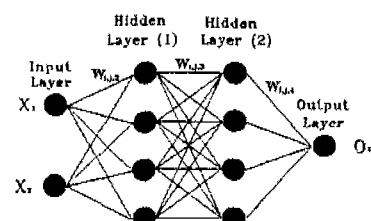


Fig. 3 Neural Network of Feature Extraction

학습오차를 수렴시키기 위한 경사 하강법은 주어진 파라미터들에 대하여 오차 함수 E_p 의 편미분 양에 비례하도록 신경회로망의 파라미터들을 변화시켜 가는데, 이 관계를 수식으로 나타내면 식 (8)과 같다.

$$\Delta R(T+1) = -\eta \frac{\partial E_p}{\partial R} \quad (8)$$

여기서, T는 BP 신경회로망의 반복 횟수, η 는 학습율, R은 신경회로망의 파라미터

만일 학습된 패턴들이 있다면 BP 알고리듬을 수행하는데 배치 학습으로 모든 패턴들의 오차들을 구한 후에 신경회로망의 파라미터들을 변경하는 경우 식 (8) 대신에 식 (9)로 대체할 수 있다.

$$\Delta R(T+1) = -\eta \sum_p \frac{\partial E_p}{\partial R} \quad (9)$$

BP 신경회로망의 학습 수렴 속도를 향상시키기 위해서 모멘텀 계수를 사용할 경우 식 (9)는 식 (10)으로 대체할 수 있다.

$$\Delta R(T+1) = -\eta \sum_p \frac{\partial E_p}{\partial R} + r * \Delta R(T) \quad (10)$$

여기서, r은 모멘텀 계수로서 $0 \leq r < 1$ 로 정의된다.

따라서, 본 연구에서는 이 BP 신경회로망의 학습 수렴 속도를 향상시키기 위해서 모멘텀 계수를 도입하고, 위의 수식들을 이용하여 각 센서에서 고유 패턴을 추출하기 위한 신경회로망을 구성하였다.

3. 실험 방법 및 실시간 신호처리

3.1 실험 방법

채터진동의 발생점을 인프로세스 감시하기 위한 실험 장치를 Fig. 4와 같이 구성하였고, 절삭실험은 범용선반을 개조하여 DC모터로부터 주축과 이송축을 무단변속할 수 있게 만든 선반에서 행하였으며, 절삭방법은 원통절삭의 상황으로 행하였다. 공작물은 중탄소강 (SM45C)으로 가변 절삭폭의 형태를 이루기 위하여 6° 의 테이퍼를 갖는 형태로 제작하여 사용하였고, 공작물의 외경은 75[mm], 높이에는 150[mm]로 하였다.

사용한 공구는 경납땜한 P20 계열의 소결공구로서

기하학적 형상은 ISO 규정에 의한 표시로 (0, 6, 6, 6, 15, 0, 0.4)이다. 절삭조건은 Table 1과 같이 구성인선이 발생하지 않고, 공구 경사면을 따라 유출되는 칩의 형태가 유통형이 되도록 설정하였다.

본 실험에 들어가기 전에 공작물의 편심을 제거하기 위하여 전가공을 수행하였고, 절삭유는 사용하지 않았다.

3.2 실시간 신호처리 방법 및 결과

채터진동 발생점을 실시간 검출하기 위해 공구동력계, 가속도 센서, AE 센서를 공구홀더에 부착하여 사용하였다. 전보에서 시간에 따른 각 센서의 신호를 오실로스코프로 검출하여 신호의 특성을 파악한 후 A/D 변환기를 이용하여 데이터를 받아 신호처리하여 그 변화량을 조사함으로써 채터진동 발생점을 실시간 검출하였다. 또한, 절삭조건의 변화에 따른 채터진동의 특성을 파악하기 위하여 채터진동이 발생할 때의 절삭폭을 한계 절삭폭으로 정의하고 그 변화량을 측정하였다. 절삭과정이 안정할 때는 절삭력, 가속도 신호 및 AE 센

Table 1 Cutting Conditions

Cutting Speed [m/min]	80, 90, 100
Feed Rate [mm/rev]	0.10, 0.12, 0.14
Width of Cut [mm]	1.0

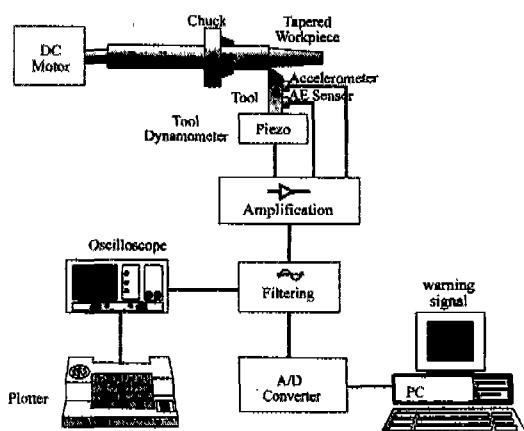


Fig. 4 Experimental Set-up for the In-Process Monitoring

서에서 나오는 신호를 RMS 전압으로 변환한 값의 변화량이 작으나 채터진동이 시작됨과 동시에 각 신호의 변화량이 두드러지게 증가하는 시점을 감시함으로써 채터진동의 발생점을 실시간 검출할 수 있다고 보고하였다.^[4] 또한 인프로세스 감시의 가능성을 제시하였는데 그 가속도 신호의 예가 Fig. 5에 나타나 있다.

본 연구에서는 복합 신경회로망에 의한 인프로세스 감시를 위하여 각 센서에서 구해진 신호의 변화량 (Variation)과 변동계수(Coefficient of Variation)의 값을 신경회로망의 입력층값으로 제시하였다.

신호의 변화량 Y_i 는 N개의 입력 데이터에 있어서 신호의 최대값과 최소값의 차이로서 다음과 같이 정의했다.

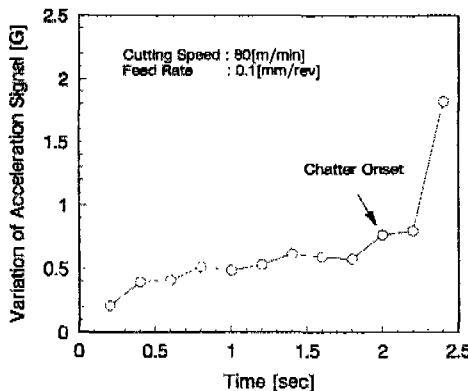


Fig. 5 Variation by Acceleration Signal

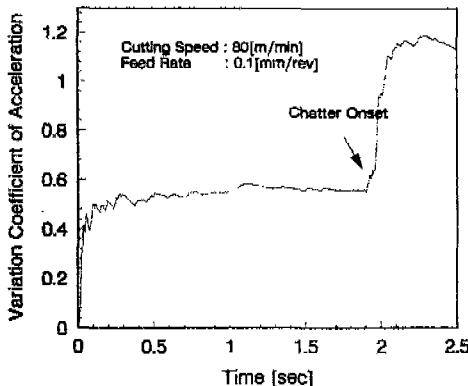


Fig. 6 Coefficient of Variation by Acceleration Signal

Table 2 Coefficient of Variation versus Cutting Speed (Feed Rate: 0.1[mm/rev])

Signal Type	Cutting Speed [m/min]	Coefficient of Variation	
		without Chatter	with Chatter
Cutting Force	80	0.34	0.65
	90	0.35	0.69
	100	0.36	0.74
Acceleration	80	0.27	0.67
	90	0.29	0.75
	100	0.34	0.83
Acoustic Emission	80	0.47	0.67
	90	0.48	0.73
	100	0.55	0.78

$$Y_i = |Y_{\max} - Y_{\min}| \quad (11)$$

여기서, Y_{\max} 는 N개의 입력 데이터 중 최대값, Y_{\min} 은 N개의 입력 데이터 중 최소값이다.

신호의 변동계수 φ_i 는 다음 식에 의해 계산된다.

$$\varphi_i = \frac{\sigma_j}{m_j} \quad (12)$$

여기서, σ_j 는 j번째 데이터까지의 표준편차 ($j = 1, 2, \dots, N$), m_j 는 j번째 데이터까지의 평균 ($j = 1, 2, \dots, N$)이다.

변동계수의 특성을 알아보기 위해 채터진동이 발생할 때의 가속도 센서에 의한 변동계수의 특성을 Fig. 6에 나타내었다. 채터진동이 발생함에 따라 가속도 신호가 증가하고, 이 때의 변동계수 또한 두드러지게 증가함을 알 수 있다. 따라서, 변동계수가 채터진동의 발생 유무를 잘 나타내고 있음을 알 수 있다.

예비 실험을 통하여 검출된 안정영역 및 불안정영역에서의 변동계수의 값을 Table 2에 나타내었다. 채터진동이 발생함에 따라 변동계수의 값이 안정영역에서보다 1.4 ~ 2.4배 증가함을 알 수 있고, 절삭속도가 증가함에 따라 변동계수의 값이 더 크게 나타남을 알 수 있다.

Table 3 Mapping of input pattern & target pattern in feature extraction

Sensor Type		Input Pattern		Target Pattern
Tool Dynamometer	X_1	0.1~0.4	X_2	0
		0.6~0.9		1
Accelerometer	X_2	0.1~0.4	X_4	0
		0.6~0.9		1
Acoustic Emission	X_5	0.1~0.4	X_6	0
		0.6~0.9		1

4. 인프로세스 감시를 위한 소프트웨어 구축

다중센서에 의해 입력된 신호들에 대해 채터진동의 고유특징의 패턴을 추출(Feature Extraction)하기 위한 전처리 단계와 전처리 단계에서 추출된 특징들을 이용하여 채터진동 발생 유무를 판단하는 의사 결정부(Decision Making)에 신경회로망을 채택하여 복합신경회로망에 의한 채터진동 인프로세스 감시 시스템을 구축하였다.

4.1 신호처리 및 특징 추출부

일반적으로 센서에서 검출된 신호에는 많은 외란이 포함되어 있기 때문에 인프로세스 감시를 실현하는 데 있어 필요한 특징만을 추출하기 위한 신호처리 및 특징 추출의 전처리 단계가 고려되어야 한다. 따라서, 앞 장에서 채터진동에 상응하는 각 센서 특징들의 실시간 검출 방법 및 결과를 보였다.

본 연구에서는 각 센서에 의해 검출된 신호의 변화량과 변동계수를 고유 패턴을 결정하는 인자로 사용하였고, 특징 추출부에는 2-4-4-1의 신경회로망을 채택하였다. 다중센서에 의해 검출된 신호를 N개씩 입력하고, 입력된 신호는 비교가 용이하게 하기 위해 노말라이징(Normalizing)하였다.

각 센서에서 검출된 신호의 변화량과 변동계수는 특징 추출부에 있는 첫번째 신경회로망의 입력층에서 입력 패턴 $X_1, X_2, X_3, X_4, X_5, X_6$ 으로 제시된다. 특징 추출부에 입력이 주어지면 신경회로망은 출력층에서 각 센서의 고유 패턴을 출력시키고, 이 출력 패턴들은 종합 분석하여 채터진동 발생 유무를 최종 판단하기 위해

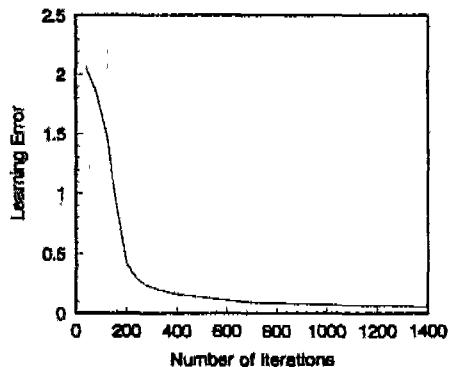


Fig. 7 Convergence of Learning Error versus Number of Iterations in the Training Process

의사 결정부의 두번째 신경회로망에 입력 패턴으로 제시된다.

본 연구에서 구현한 특징 추출부의 신경회로망은 각 절삭 조건에 대해 안정영역과 불안정영역에서의 신호 변화량과 변동계수를 구하여 Table 3과 같은 출력 패턴을 생성시키도록 연관 학습시켰다.

학습과정이 진행됨에 따라 학습 오차가 수렴되어가는 과정을 Fig. 7에 나타내었다. 학습과정에서 반복 학습을 위하여 20번씩 반복 학습시킨 후 실제 출력 패턴과 기대되는 패턴을 비교하여 오차를 나타내었다. 신경회로망의 반복 학습을 200번 수행하였을 때까지는 학습 오차의 변화량이 급격히 줄어들다가 반복 횟수가 증가함에 따라 점진적으로 감소하여 수렴해 가는 것을 알 수 있다.

본 연구에서 구현한 신경회로망은 1400번까지 반복 학습시킴에 따라 오차가 0.05까지 줄어들고, 학습 패턴을 입력으로 제시하여 출력 패턴을 조사한 결과 학습이 성공적임을 알 수 있었다.

4.2 신경회로망에 의한 의사 결정부

각 센서의 특징 추출부에서 추출한 고유 패턴을 종합 분석하여 채터진동 발생 유무를 결정하기 위해 Fig. 8과 같은 복합 신경회로망을 구축하였다. 각 센서에 연결된 첫번째 2-4-4-1의 신경회로망은 특징 추출부로 작용하여 고유 패턴을 출력시키고, 두번째 3-4-1의 신경회로망은 의사 결정부로 채터진동의 발생 유무를 판단한다.

의사결정부의 신경회로망은 특징 추출부의 신경회로

망에 의해 추출된 고유 패턴에 대해 채터진동 발생 유무에 따라 두 가지 출력 패턴을 갖도록 학습시켰고, 사용된 입력 패턴과 출력 패턴의 맵핑 관계는 Table 4에 나타내었다. 의사 결정부의 신경회로망에서 입력 층의 뉴우런이 가질 수 있는 모든 경우의 수는 $8 (= 2^3)$ 가지이고, 8 가지의 입력 패턴에 대해 출력 패턴이 두 가지로 맵핑되도록 하였다. 또한, 단일 센서에 의해서만 검출되는 패턴보다 두 개 이상의 센서에서 검출된 패턴에 대해 더 가중치를 두고 분류하여 학습시켰다.

학습은 주어진 8개의 입력 패턴에 대하여 출력 패턴에 대한 오차가 0.05이하일 때까지 반복 학습시켰고, 학습된 후에는 학습 패턴을 입력으로 사용하여 신경회로망의 신뢰성 여부를 판별하였다. 채터진동이 발생하지 않았을 때 신경회로망은 0의 패턴을 출력하고, 채터진동이 발생할 경우 1의 패턴을 출력하도록 하였다.

Table 4 Mapping of Input Pattern & Output Pattern

Input Pattern	Output Pattern	Input Pattern	Output Pattern
0 0 0		0 1 1	
0 0 1	0	1 0 1	
0 1 0		1 1 0	1
1 0 0		1 1 1	

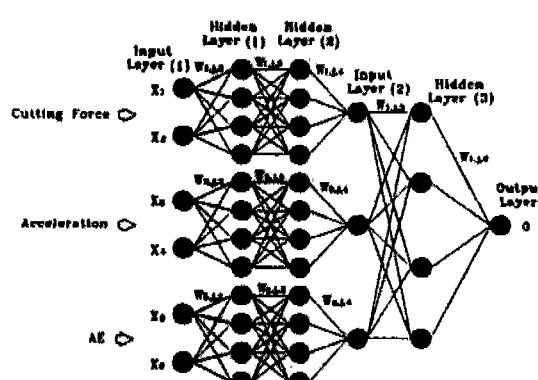


Fig. 8 Multiple Neural Network for the In-Process Monitoring

4.3 인프로세스 감시 알고리듬

본 연구에서 구현한 복합 신경회로망을 이용하여 채터진동을 인프로세스 감시할 수 있는 알고리듬을 Fig. 9와 같이 구축하였다.

먼저 사용자 정의부에서는 입력받을 데이터의 갯수 N과 절삭 조건, 신경회로망의 파라미터(학습율, 모멘텀 계수, 연결가중치의 극한값, ...)를 입력한다. 사용자 정의부에서 입력된 신경회로망의 파라미터에 의해 복합 신경회로망이 구축되고, 연관 학습을 수행하면서 복합 신경회로망의 파라미터들이 초기화된다. 데이터 입력부에서는 다중센서에서 A/D 변환기로 N개씩 데이터를 검출하고, 검출된 데이터는 비교가 용이하도록 노말라이징을 수행한다. 노말라이징된 데이터는 신호처리부에서 각 센서의 변화량 Y_1, Y_2, Y_3 과 변동계수 $\varphi_1, \varphi_2, \varphi_3$ 를 계산한다. 신호처리부에서 계산된 값들은 첫번째 신경회로망의 입력 패턴으로 작용하여 고유 패턴을 출력시키고, 이 출력패턴은 다시 두번째 신경회로망에 입력 패턴으로 제시된다. 의사 결정부의 신경회로망은 다중 센서에 의해 검출된 패턴을 분석하여 0과 1 중 하나의 출력을 생성시키고, 출력 패턴이 1이 아닌 경우에는 데

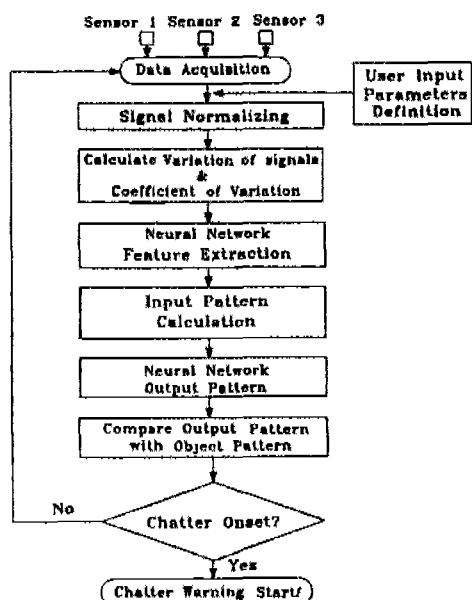


Fig. 9 Flow Chart for the In-Process Monitoring of Chatter Vibrations

이타 검출부로 가서 N개의 테이터를 다시 받아들이고 같은 과정을 반복하지만, 출력 패턴이 1인 경우에는 채터진동 발생 경보와 함께 모니터 상에 채터진동 발생 메세지를 나타낸다.

5. 인프로세스 감시 결과 및 고찰

본 연구에서 구현한 신경회로망의 학습율은 0.7, 모멘텀 계수는 0.9, 연결가중치의 극한값은 ±1로 설정하여 프로그램 내의 사용자 정의부에서 미리 정의하고, 채터진동 발생점의 실시간 검출 결과를 이용하여 학습 오차가 0.05이하가 될 때까지 신경회로망을 학습시켰다.

복합 신경회로망의 검출 타당성을 비교하기 위해, 노말라이징된 각 센서의 변화량과 변동계수를 조사해 본 결과를 Fig. 10과 Fig. 11에 각각 나타내었다. 각 센서에서 검출된 채터진동 발생점은 안정영역에서의 평균 변화량의 3.3 ~ 3.8배 정도가 되고, 변동계수 또한 채터진동의 특성을 잘 나타내고 있음을 알 수 있다.

복합 신경회로망을 이용한 채터진동의 인프로세스 감시 결과를 Fig. 12 ~ Fig. 14에 나타내었다. Fig. 12에서 보는 바와 같이 절삭속도가 80, 90, 100 [m/min]이고, 이송량이 0.1[mm/rev]일 때 복합 신경회로망에 의해 검출된 채터진동 발생점이 Fig. 10과 Fig. 11에서 검출된 채터진동 발생점과 잘 일치하고 있음을 알 수 있다. 또한, 절삭속도의 증가와 이송량의 증가에 따라 채터진동이 더 늦게 발생함을 알 수 있고, 안정영역과 불안정영역이 뚜렷하게 분리됨을 알 수 있다.

따라서, 복합 신경회로망은 채터진동 발생점을 효과적으로 검출할 수 있으며, 안정영역과 불안정영역이 뚜렷하게 구분됨으로 더 좋은 감시 특성을 나타냄을 알 수 있다.

이상과 같은 연구결과는 인프로세스 감시하기 위한 자동화 시스템에 광범위하게 응용할 수 있을 것으로 사료된다.

6. 결 론

복합 신경회로망을 이용한 채터진동의 인프로세스 감시에 관한 연구를 통하여 다음과 같은 결론을 얻었다.

(1) 채터진동이 발생할 때 다중센서(절삭력, 가속도,

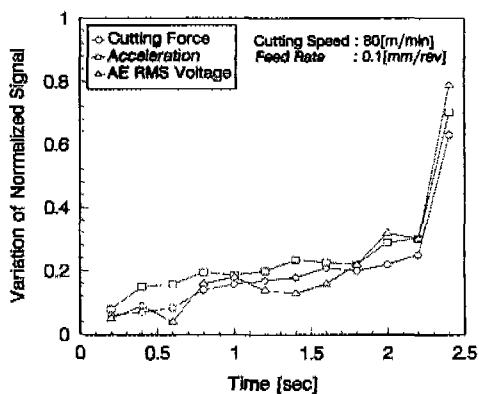


Fig. 10 Variation of Normalized Signal as Chatter Vibration Onset

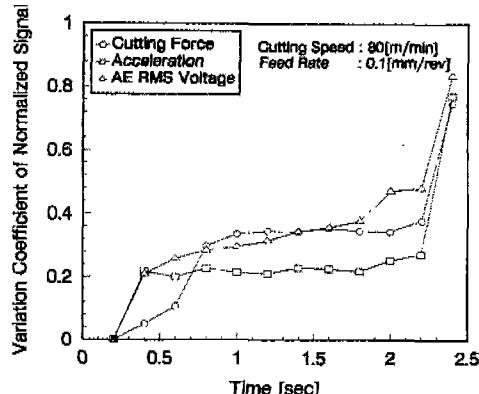


Fig. 11 Variation Coefficient of Normalized Signal as Chatter Vibration Onset

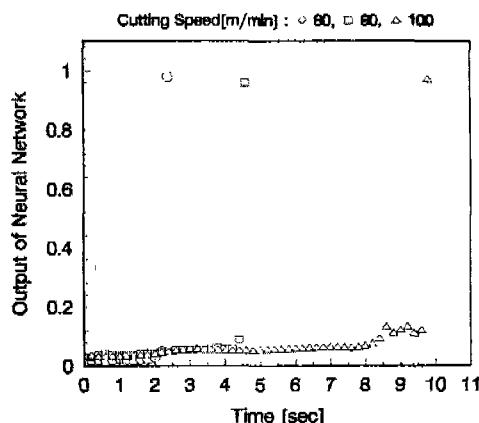


Fig. 12 Output of Multiple Neural Network
(Feed Rate: 0.10[mm/rev])

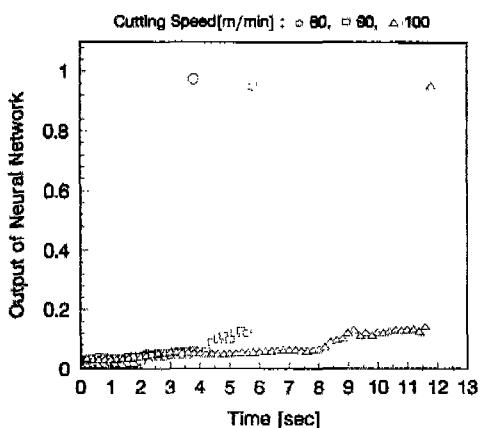


Fig. 13 Output of Multiple Neural Network
(Feed Rate: 0.12[mm/rev])

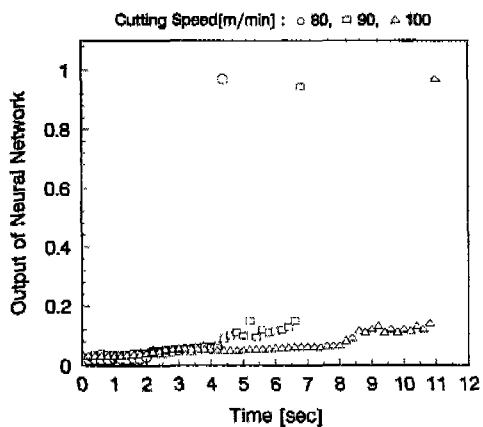


Fig. 14 Output of Multiple Neural Network
(Feed Rate: 0.14[mm/rev])

AE)의 신호 변화량과 변동계수는 절삭속도와 이송량의 증가에 따라 급격히 증가하는 경향을 보이며, 이러한 특성으로부터 신경회로망의 입력 파라미터로 선정하여 채터진동의 감시에 이용하였다.

(2) 다중센서를 이용한 복합계측 시스템에서 특정 추출부 및 의사 결정부에 복합 신경회로망을 구축하여, 채터진동 발생 유무를 인프로세스 감시할 수 있다.

(3) 복합 신경회로망은 채터진동 발생점을 효과적으로 감시하였으며, 안정영역과 불안정영역이 뚜렷하게 구분되는 좋은 감시 특성을 보인다.

참고문헌

1. S. C. Lin and M. R. Hu, "Low Vibration Control System in Turning", Int. J. Mach. Tools Manufact., Vol. 32, No. 5, pp. 629~640, 1992
2. D. Chester, "Why two hidden layers are better than one", Int. Joint. Conf. Neural Networks, Washington, IEEE, pp. 265~268, 1990
3. S. Rangwala, D. A. Dornfeld, "Sensor Integration using Neural Networks for Intelligent Tool Condition Monitoring", Trans. of the ASME, pp. 219~228, 1990
4. J. S. Kim, M. C. Kang, C. Park, "Real-time Multi-Sensing System for In-process Monitoring of Chatter Vibration(I)", J. KSPE, Vol. 12, No. 10, 1995
5. I. N. Tansel, A. Wagiman and A. Tzirinis, "Recognition of Chatter with Neural Networks", Int. J. Mach. Tools Manufact., Vol. 31, No. 4, pp. 539~552, 1991
6. Y. S. Tarn, T. C. Li and M. C. Chen, "On-line Drilling Chatter Recognition and avoidance using an ART2-A Neural Network", Int. J. Mach. Tools Manufact., Vol. 34, No. 7, pp. 949~957, 1994
7. Y. S. Tarn, Y. W. Hsieh and S. T. Hwang, "Sensing Tool Breakage in Face Milling with a Neural Network", Int. J. Mach. Tools Manufact., Vol. 34, No. 3, pp. 341~350, 1994
8. G. Chryssolouris and M. Domroese, "An Experimental Study of Strategies for Integrating Sensor Information in Machining", Annals of the CIRP, Vol. 38, No. 1, pp. 425~428, 1989