

신경회로망을 이용한 챠터진동의 인프로세스 감시

(In-process monitoring of chatter vibration using Neural Network)

박 칠*, 강명창 (부산대 정밀기계과 대학원)

김정식 (부산대 정밀기계과, 정밀정형 및 금형가공 연구센타)

ABSTRACT

Chatter vibration is an unwanted phenomenon in metal cutting and it always affects surface finish, tool life, machine life and the productivity of machining process. The In-process monitoring & control of chatter vibration is necessarily required to automation system. In this study, we constructed the multi-sensing system using Tool Dynamometer, Accelerometer and AE(Acoustic Emission) sensor for the credible detection of chatter vibration. And a new approach using a neural network to process the features of multi-sensor for the recognition of chatter vibration in turning operation is proposed. With the back propagation training process, the neural network memorize and classify the feature difference of multi-sensor signals.

1. 서 론

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

절삭가공 중에 발생하는 챠터진동(Chatter Vibration)은 절삭 가공면의 점밀도, 공작기계 및 공구의 수명, 가공 공정의 생산성에 영향을 미치며, 공작기계 부품의 설계 및 구성, 가공 공정의 자동화에 중요한 변수로 작용한다. 따라서, 챠터진동의 발생점을 효과적으로 인프로세스 감시하기 위해 챠터진동 발생점에 대한 명확한 규명이 있어야 하며, 실시간 검출 방법이 마련되어야 한다.^[1]

무인 기계가공 공정에 사용되고 있는 각종 센서에 대한 특성 검토가 이루어진 이래 센서 검출 신호의 신뢰성 및 신호처리 기법에 의한 감시 가능성이 밝혀져 실용화되고 있는 것도 있으나, 측정 대상의 변화에 따른 센서의 적용 범위 확대와 센서의 감도 저하에 따른 진단 정보의 신뢰성 등이 문제로 제기됨에 따라 앞으로도 해결할 과제들이 많이 남아 있는 실정이다.^[2,3]

가공 상태를 센서를 통해 검출하고, 판단하기 위해서는 신호의 고유패턴을 추출하기 위한 패턴 인식 시스템이 필요하다. 초기의 패턴 인식 시스템은 저장된 템플릿(Template)과 입력패턴을 비교하여 인식하는 단순한 과정으로 이루어졌다. 이러한 패턴 인식 시스템은 구현하기 쉬운 장점이 있으나 별도의 템플릿 저장 공간이 필요하고 잡음이나 패턴의 손실 또는 왜곡 등으로 인해 인식률이 저하되는 단점이 있다.

이러한 패턴 인식 기법이 갖는 단점을 보완하고, 패턴의 위치, 크기, 방향 등의 변화를 극복하는 방법은 패턴이 변화더라도 일정한 값을 유지하는 특징을 추출하고 이 특징을 이용하는 것이다. 이 방법은 패턴의 위치, 크기, 방향등의 변화에 무관하게 인식할 수 있고, 패턴의 손실 및 왜곡에 강하다는 장점이 있어 실시간 인식 시스템에 적합하다.

신경회로망의 학습은 역전파 학습 규칙(Back propagation Learning Rule)을 채택하였다. 이 역전파 학습 규칙은 경사하강법(Gradient Descent Technique)에 의해 수행되는데 학습이 수렴할 때 까지는 많은 횟수의 반복 학습이 필요하다는 단점을 가지고 있다.

이러한 단점을 보완하기 위한 최근의 연구 결과에 의하면 2개의 온너층을 가지는 BP 신경회로망의 경우 1개의 온너층을 가지는 BP신경회로망의 경우보다 더 많은 분류 경계를 가짐으로 분류기능이 뛰어나고, 학습 수렴속도가 더 빠르다는 것이 보고 되었다.^[4]

또한, 복수의 센서로 부터 검출된 센서의 정보를 통합하여 가공상태를 최종 결정하기 위한 최근 방법으로는 Neural Network, Fuzzy Set Theory, GMDH 등이 있으나 그 중에서도 신경회로망을 이용하는 방법이 인프로세스 감시에 비교적 유용한 것으로 보고되고 있다.^[5]

따라서, 본 연구에서는 패턴 인식을 위한 특정 추출부에 신경회로망을 채택하여 디중센서의 고유패턴을 추출하도록 하였고, 신경회로망을 모델링할 때 학습시 학습 수렴속도를 향상시키기 위하여 2개의 온너층을 가지도록 신경회로망을 구성하고, 모멘텀 계수를 도입하였다. 이렇게 구성된 신경회로망을 통해 각 센서에 대한 고유패턴을 추출하였고, 디중센서에서 추출된 고유패턴은 다시 신경회로망에 입력되어 가공 상태를 최종 결정하는 복합 신경회로망(Multiple Neural Network)을 구축하였다.

이 복합 신경회로망은 각 센서에서 '나오는 고유패턴을 종합 분석하여 실시간 영역에서 챠터진동의 발생 유무를 판별하여 작업자에게 알려줄 수 있도록 구축되었다.

2. 신경회로망 (Neural Network)

Trusty & Andrews에 의해 각종 센서에 대한 특성검토가 이루어진 이래로 일부 센서는 실용화되고 있는 것도 있으나, 측정 대상의 변화에 따른 센서의 적용 가능성과 센서의 감도 저하에

따른 검출 정보의 신뢰성 문제 등이 새롭게 제시되고 있다.

이 점을 보완하기 위하여 최근 많이 검토되고 있는 것이 Fig.1과 같은 다중센서를 이용한 복합계측 시스템(Multi-sensing System)이다. 이는 가공 공정의 상태에 관련된 정보의 양을 크게 늘려서 검출 정보의 질을 향상시키려는 태 목표를 두고 있으며, 감시 시스템의 유효 검출 범위를 크게 늘리는 효과도 기대할 수 있는 장점이 있다.^[6]

따라서, 본 연구에서는 다중센서(공구동력계, 가속도센서, AE 센서)를 이용하여 채터진동 발생에 따른 고유특징을 추출하고, 신경회로망을 이용하여 고유패턴을 검출하였다.

신경회로망은 많은 양의 센서 정보에서 중요한 특징을 자기 조정에 의해 추출해낼 수 있으며(Feature extraction), 다중센서로부터의 정보를 적합적으로 처리할 수 있고(Sensor fusion), 또 학습되지 않은 입력에 대해서도 적절된 내적지식을 통하여 적절한 출력을 낼 수 있는 적응성(Adaptability)을 갖고 있기 때문에 그 용용 범위가 증가하고 있는 실정이다.^[7]

많은 경우에 있어서 학습은 입력과 출력사이의 연관적인 맵핑(Mapping)관계를 수행함으로써 순진적으로 형성되어간다. 이러한 연관적인 맵핑(Associative Mapping)관계의 형성을 위하여 신경회로망내의 내부 구조를 수정해 나가는 과정을 인관 학습(Associative Learning)이라 하고, 본 연구에서는 신경회로망을 목적패턴을 이용하여 입력신호에 대해 적절한 출력을 낼 수 있도록 감독 학습(Supervised Learning)을 수행하였다.

입력층의 뉴우런이 S개일때 신경회로망의 입력은 $X_0, X_1, \dots, X_k, \dots, X_{n-1}$ 이 되고, 뉴우런들의 연결은 연결가중치(Connection Weight) W_i 를 가지며 서로 연결되어 있다.

신경회로망 내의 뉴우런은 Fig.2에서처럼 연결되어 있는 아래층으로 부터의 출력들에 연결 강도를 곱하여 그 합을 구한 후, 그 값에 임계치 $t_{i,k}$ 를 빼서 k번재 층 i번째 뉴우런으로의 입력인 $NET_{i,k}$ 를 식 (1)과 같이 구한다.

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

식 (1)에 의해 구해진 $NET_{i,k}$ 를 식 (2)와 같이 각 활성함수의 입력으로 취하고 k번재 층 i번째 뉴우런의 출력 $O_{i,k}$ 를 구한다.

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

여기서, $O_{i,k}$ = k번재 층 i번째 뉴우런의 출력이고, θ 는 최대 출력을 결정짓는 파라미터로 뉴우런의 최대 출력을 제한하며, β 는 시그모이드 함수의 기울기로 곡선의 기울기를 제한한다.

식 (2)에 의해 계산된 출력은 같은 층의 다른 뉴우런에서의 출력들과 함께 다음 층의 입력으로 사용하게 되며 이러한 과정은 역전파 학습 규칙에 의해 학습 오차가 수렴할 때까지 반복된다.

역전파 학습 규칙은 학습패턴 중 한 입력이 주어졌을 때 신경회로망이 주어진 입력에 대해 목적패턴과 일치되는 출력을 생성할 수 있도록 자신의 내부조직을 구성해나간다. 일단 신경회로망이 학습 샘플의 입력패턴과 목적패턴 사이의 맵핑관계를 학습하면 전에 알려지지 않은 새로운 입력이 가해졌을 때 출력은 학습 샘플에 의해 내적으로 축적된 지식에 기초해서 가장 유사한 출력패턴을 발생시킨다.

BP 신경회로망은 한개의 은닉층을 가지는 경우가 폭넓게 이

용되고 있으나 최근의 연구에 의하면 2개의 은닉층을 가지는 BP 신경회로망의 경우 더 많은 분류 경계를 가짐으로 분류기능이 뛰어나고, 학습 수렴속도가 더 빠르다고 보고되고 있다.

따라서, 본 연구에서는 Fig.3과 같이 각 센서에서의 고유패턴을 추출하기 위해 신경회로망을 2-4-4-1의 형태를 가지고도록 구성하였다. Fig.3과 같이 2개의 은닉층을 가지는 경우 신경회로망의 출력층에서 뉴우런의 수가 n개 있을 때 출력층에서 기대되는 패턴이 $d_{p,0}, d_{p,1}, \dots, d_{p,n-1}$ 이고, 출력패턴이 $O_{p,0}, O_{p,1}, \dots, O_{p,n-1}$ 일 때 오차 함수 E_p 는 식 (3)과 같이 표현된다.

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

이 오차 E_p 를 최소화하기 위해 신경망이 반복될 때마다 연결가중치 W_{ijk} 와 임계치 $t_{i,k}$ 는 η_w 와 η_t 가 각각 임계치와 연결가중치의 학습율(Learning rate)일 때 식 (4), 식 (5)와 같이 조정된다.

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

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

이러한 과정이 순회적으로 역전단에 의해 계산되어지며, 최종적으로 연결가중치와 임계치는 식 (4)와 식 (5)에 의해 조정되고, 이렇게 조정된 연결가중치와 임계치, 뉴우런의 값이 주어진 입력에 대해 적절한 출력을 내는 것이다.

학습 오차를 수렴시키기 위해 가장 많이 사용되고 있는 방법은 경사하강법(Gradient Descent Technique)이나, 경사하강법에서는 주어진 파라미터들에 대하여 오차함수 E_p 의 편미분의 양에 비례하도록 신경회로망의 파라미터들을 변화시킨다. 이 관계를 수식으로 나타내면 식 (6)과 같다.

$$\Delta R(T+1) = -\eta \frac{\partial E_p}{\partial R} \quad (6)$$

여기서, T는 BP 신경회로망의 반복 횟수이고, R은 신경회로망의 파라미터이다. 만일 학습된 패턴들이 있다면 BP 알고리듬을 수행하는 대 배치 학습(Batch Learning)으로 모든 패턴들의 오차들을 구한 후에 신경회로망의 파라미터들을 변경하는 경우 식 (6) 대신에 식 (7)로 대체할 수 있다.

$$\Delta R(T+1) = -\eta \sum_{p=1}^P \frac{\partial E_p}{\partial R} \quad (7)$$

BP 신경회로망의 학습 수렴 속도를 향상시키기 위해서 모멘텀 계수(Momentum Factor)를 사용할 경우 식 (7)은 식 (9)로 대체할 수 있다.

$$\Delta R(T+1) = -\eta \sum_{p=1}^P \frac{\partial E_p}{\partial R} + r * \Delta R(T) \quad (8)$$

여기서, r 은 모멘트 계수이고, $0 \leq r < 1$ 로 정의된다. 따라서, 본 연구에서는 이 BP 신경회로망의 학습 수렴 속도를 향상시키기 위해서 모멘트 계수를 도입하고, 위의 수식들을 이용하여 각 센서에서 고유패턴을 추출하기 위한 신경회로망을 구성하였다.

3. 실험 장치 및 실험 방법

신경회로망을 이용한 채터진동의 인프로세스 감시를 위해 실험장치를 Fig.4와 같이 구성하였고, 실험에 사용한 장비 및 공구 그리고, 실험조건은 Table 1과 Table 2에 나타내었다.

Table 1. Specification of Experimental Instrument

| Instruments | Model | Co.,Ltd |
|------------------------------|------------|---------------------------------|
| Lathe | 2640 | Round Top |
| Dual Channel Signal Analyzer | Type 2304 | B & K |
| Oscilloscope(2 Ch) | Type 9400A | LcCroy |
| AE sensor | R-15 | PAC |
| Accelerometer | Type 4344 | B & K |
| Tool Dynamometer | Type 9257A | KISTLER |
| Conditioning Amplifier | Type 2626 | B & K |
| Charge Amplifier | Type 5007 | KISTLER |
| RM ^C Converter | Type 2511 | B & K |
| A/D Converter | PCL - 718 | Advantech HEWLETT PACKARD |
| Plotter | Type 7440A | KOREA |
| Tool Holder | CTGPR-2525 | TUNGSTEN |
| Tool Holder Tip | TPGN | KOREA TUNGSTEN |

Table 2. Cutting Conditions

| | |
|-----------------------|------------------------|
| Cutting Speed [m/min] | 80, 90, 100, 110, 120 |
| Feed Rate [mm/rev] | 0.08, 0.10, 0.12, 0.14 |

절삭실험은 범용선반을 개조하여 DC모터로부터 주축과 이송축을 무단변속할 수 있게 만든 선반에서 행하였으며, 절삭방법은 원통절삭의 상황으로 행하였다. 공작물은 중단소강(SM45C)으로 가변 절삭폭의 형태를 이루기 위하여 6°의 테이퍼를 갖는 형태로 제작하여 사용하였고, 칫으로부터 돌출된 길이(Overhang)는 150mm로 하였다.

4. 채터진동 발생점의 실시간 검출

신경회로망에 의한 채터진동의 인프로세스 감시 가능성을 알아보기 위해 각 센서에 의한 채터진동 발생점의 실시간 검출 가능성을 조사하였다.

다중센서를 이용하여 절삭과정이 안정할 때 채터진동이 발생할 때의 신호를 오실로스코프로 감시하여 Fig.5~Fig.7에 나타내었다.

Fig.5에 보이는 바와 같이 절삭과정이 안정할 때는 그 진동력의 변화량이 작으나 채터진동이 시작되고 동시에 절삭력의 변화량이 두드러지게 증가하고 있음을 알 수 있는데 이 시점을 감시함으로써 채터진동의 발생점을 실시간 검출 할 수 있다.

또한, Fig.6에서 보는 바와 같이 절삭과정이 안정할 때는 그 가속도의 변화량이 작으나 채터진동이 발생함과 동시에 가속도

의 변화량이 두드러지게 증가하고 있음을 알 수 있다. 따라서, 이 시점을 감시함으로써 채터진동의 발생점을 실시간 검출할 수 있다.

일반적으로 AE 센서는 100 ~ 1000 [KHz]의 AE 신호를 검출하여 공구의 마모나 재료의 특성을 감지하기 위해 주로 사용되어왔는데 본 연구에서는 AE센서에 의한 채터진동 발생점의 검출 가능성을 조사하기 위해 RMS (Root Mean Square) 전압을 채택하였다. AE신호의 RMS 전압은 다음 식과 같이 주어진다.

$$V_{RMS}(t) = \sqrt{\frac{1}{dt} \int_0^{dt} V^2(t) dt} \quad (9)$$

AE 센서에서 나오는 신호를 RMS 전압으로 변환하고, 절삭과정이 안정할 때와 채터진동이 발생한 때의 신호를 검출하여 Fig.7에 나타내었다. 절삭과정이 안정할 때는 신호의 변화량이 작으나 채터진동이 발생할 때 따라 RMS 전압이 두드러지게 증가함을 알 수 있다. 따라서, 이 시점을 감시함으로써 AE 센서에서도 채터진동의 발생점을 실시간 검출할 수 있다.

5. 채터진동 인프로세스 감시 알고리듬

다중센서에 의해 채터진동을 효과적으로 인프로세스 감시하기 위해서는 각 센서에 의해 인식된 신호의 특징들을 추출하는 부분(Feature Extraction)과 채터진동의 발생유무와 정도를 판단할 수 있는 최종 의사결정부(Decision Making)가 있어야 한다.

본 연구에서는 다중센서에 의해 인식된 신호들에 대해 채터진동의 고유특징들의 패턴을 추출하는 부분과 각 센서에서 추출된 특징들을 종합 분석하여 채터진동의 발생유무와 정도를 판단하는 의사 결정부 모두 신경회로망으로 구성하여 복합 신경회로망에 의한 인프로세스 감시 시스템을 구성하였다.

5.1 신호처리 및 특징 추출부

일반적으로 센서에서 검출된 신호에는 많은 외관이 포함되어 있기 때문에 인프로세스 감시를 실현하는 데 있어 필요한 특징만을 추출하기 위한 신호처리 및 전처리단계가 고려되어야 한다.

따라서, 본 연구에서는 앞 절에서 보인 실시간 검출 방법을 바탕으로 신호 처리부에서 신호의 변화량 Y_r 과 변동계수 (Coefficient of Variation) φ_i 를 계산하여 각 센서의 고유패턴을 결정하는 인자로 사용하고, 특징추출부에 Fig.3과 같은 신경회로망을 채택하였다.

검출된 신호는 샘플링 시간마다 N 개씩 입력되고, 입력된 신호는 비교가 용이하게 하기 위해 노말라이징된다. 프로그램 내에서 노말라이징된 신호의 변화량과 변동계수는 식 (10)과 식 (11)에 의해 구해진다.

$$Y_r = |Y_{\max} - Y_{\min}| \quad (10)$$

$$\varphi_i = \frac{\sigma_i}{m} \quad (11)$$

변동계수의 특성을 알아보기 위해 채터진동 발생시 가속도 센서에 의한 변동계수의 특성을 조사하여 Fig.8에 나타내었다. Fig.8에서 보는 바와 같이 채터진동이 발생함에 따라 가속도센서의 신호가 증가하고, 이 때의 변동계수 또한 두드러지게 증가

함을 알 수 있다.

각 센서에서 구해진 변화량의 값과 변동계수의 값은 특징추출부의 신경회로망의 입력층에서 $X_1, X_2, X_3, X_4, X_5, X_6$

으로 제시된다. 특징 추출부에 위하여 주어지면 신경회로망은 출력층에서 각 센서의 고유패턴을 출력시키고, 이 출력패턴들은 다시 종합 분석하여 채터진동 발생 유무를 판단하기 위한 의사 결정부에 입력패턴으로 제시된다.

본 연구에서 구현한 신경회로망은 각 철삭조건에 대해 안정영역과 불안정영역의 신호의 변화량과 변동계수를 구하여 Table. 3과 같은 출력패턴을 생성시키도록 하였다.

Table 3. Output Pattern of Neural Network

| 가공상태 | 출력패턴 | 출력패턴 |
|---------------|------|------|
| Chatter 발생 안함 | 0 | |
| Chatter 발생 | 1 | |

Fig.9는 하습과정이 진행됨에 따라 하습 오차가 수렴되어가는 과정을 보여준다. 하습과정에서 반복 하습을 위하여 20번씩 반복 하습 시킨 후 출력과 목적패턴을 비교하여 하습에 따른 오차를 나타내었다. 신경회로망의 반복하습을 200번 수행하였을 때까지는 하습 오차의 변화량이 규칙적 줄어들다가 반복횟수가 증가함에 따라 점진적으로 감소하여 수렴해 가는 것을 알 수 있다. 본 연구에서 구현한 신경회로망은 1400번까지 반복 하습 시킴에 따라 오차가 0.05까지 줄어들을 수 있고, 주어진 입력 패턴에 대하여 좋은 결과를 보임으로 하습이 성공적임을 알 수 있다.

5.2 의사 결정부

본 연구에서는 각 센서의 특징 추출부에 신경회로망을 구성하여 고유패턴을 추출하였고, 이 고유패턴을 종합 분석하여 채터진동의 발생유무와 정도에 따라 상태를 결정하기 위해 Fig.10과 같은 복합 신경회로망을 구성하여 채터진동의 발생유무에 따라 두가지의 출력패턴을 갖도록 하였다. 의사 결정부에서 사용된 입력패턴과 출력패턴의 맵핑관계는 Table 4에 나타내었다.

Table 4. Mapping of Input Pattern & Output Pattern

| 입력패턴 | 출력패턴 | 입력패턴 | 출력패턴 |
|-------|------|-------|------|
| 0 0 0 | | 0 1 1 | |
| 0 0 1 | | 1 0 1 | |
| 0 1 0 | 0 | 1 1 0 | |
| 1 0 0 | | 1 1 1 | 1 |

Table 4에서 보는 바와 같이 최종 의사 결정부에서 입력층의 뉴우런이 가질 수 있는 모든 경우의 입력패턴의 수는 8 ($=2^3$) 가지이고, 8가지의 입력패턴에 대해 출력패턴이 두가지로 맵핑되도록 하였다. 또한, 단일 센서에 의해서만 검출되는 패턴보다 두개 이상의 센서에서 검출된 패턴에 대해 더 가중치를 두고 분류하여 하습시켰다.

하습은 주어진 8개의 입력패턴에 대하여 출력패턴에 대한 오차가 0.05 이하일 때까지 반복 하습시켰고, 하습된 후에는 하습 패턴을 입력으로 사용하여 신경회로망의 신뢰성 여부를 판별하였다.

5.3 인프로세스 감시 알고리듬

본 연구에서 구현한 복합 신경회로망을 이용하여 채터진동을 인프로세스 감시할 수 있는 알고리듬을 Fig.11과 같이 구축하였다.

Fig.11에서 보는 바와 같이 먼저 사용자 정의부에서는 입력받은 데이터의 개수 N과 절삭조건, 신경회로망의 학습율과 모멘텀 계수, 연결가중치의 극한값 등을 입력한다. 데이터 입력부에서는 다중센서(공구동력계, 가속도 센서, AE 센서)에서 A/D 변환 기로 N개의 데이터를 검출하고, 검출된 데이터는 비교가 용이하게 하기 위해 노말라이징을 수행한다.

노말라이징된 데이터는 신호처리부에서 각 센서의 변화량 Y_1, Y_2, Y_3 과 변동계수 $\sigma_1, \sigma_2, \sigma_3$ 을 계산한다. 신호처리부에서 계산된 값들은 첫번째 신경회로망의 입력패턴으로 사용하여 고유패턴을 출력시키고, 이 출력패턴은 다시 두번째 신경회로망에 입력으로 제시된다.

의사 결정부의 신경회로망은 다중센서에 의해 검출된 패턴을 분석하여 0과 1중 하나의 출력을 생성시키고, 출력패턴이 1이 아닌 경우에는 데이터 검출부로 가서 N개의 데이터를 다시 받아들이고 같은 과정을 반복하지만, 출력패턴이 1인 경우에는 채터진동 발생경보와 함께 모니터상에 채터진동 발생 메세지를 나타내도록 구축하였다.

6. 실험 결과 및 고찰

본 실험에서 검출된 채터주파수는 193~212 [Hz]였고, 학습율은 0.7, 모멘텀 계수는 0.9, 연결가중치의 극한값은 ±1로 설정하였다. 신경회로망을 이용한 채터진동 인프로세스 감시를 위한 실험 결과를 Fig.12, Fig.13에 나타내았다.

복합 신경회로망의 검출 타당성을 비교하기 위해 노말라이징된 각 센서의 변화량도 함께 관측하였으며 복합 신경회로망의 출력값과 비교하여 Fig.12에 나타내었다. Fig.12에서 각 센서에서 검출된 채터진동 발생점은 안정영역에서의 평균변화량의 3~3.5배 정도가 됨을 알 수 있고, 복합 신경회로망의 출력이 채터진동 발생 유무를 잘 검출하고 있음을 알 수 있다.

Fig.13에서는 절삭속도의 증가에 따른 복합신경회로망의 채터진동 검출결과를 나타내고 있다. 절삭속도가 증가함에 따라 채터진동이 더 빨리 발생함을 알 수 있고, 본 연구에서 구현한 복합 신경회로망이 채터진동 발생점을 효과적으로 검출하고 있음을 알 수 있다.

7. 결론

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

- [1] 다중센서를 이용하여 채터진동 발생점의 실시간 검출이 가능하고, 이를 이용하여 인프로세스 감시에 응용할 수 있다.
- [2] 채터진동 발생점이 안정영역에서의 평균 변화량의 3~3.5배가 됨을 알 수 있다.
- [3] 복합 신경회로망을 이용하여 채터진동의 발생 유무를 인프로세스 감시할 수 있다.

참 고 문 헌

- [1] S. A. Tobias, "Machine Tool Vibration", Blackie & Son, London, 1965
- [2] H. Nakazawa, Y. Miyoshi, K. Shigemura, "Peak Interval Method for Detection Onsets of Chatter Vibrations", Bull. Japan Soc. of Prec. Engg., Vol. 18, NO. 3, pp. 243~248, 1984
- [3] M. Rahman, "In-Process Detection of Chatter Threshold", Trans. of the ASME, Vol. 110, pp. 44~50, 1988
- [4] D. Chester, "Why two hidden layers are better than one", Int. Joint. Conf. Neural Networks, Washington, IEEE, pp. 265~268, 1990
- [5] 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
- [6] S. Rangwala, D. A. Dornfeld, "Sensor Integration Using Neural Networks for Intelligent Tool Condition Monitoring", Trans. of the ASME, pp. 219~228, 1990
- [7] T. Warren Liao and L. J. Chen, "A Neural Network approach for Grinding processes : Modelling and Optimization", Int. J. Mach. Tools Manufact., Vol. 34, No. 7, pp. 919~937, 1994




Fig.1 Schematics of the In-Process Monitoring System




Fig.2 Schematics of a Neuron




Fig.3 Neural Network




Fig.4 Experimental Set-up




Fig.5 Cutting force signals for stable and unstable cutting




Fig.6 Acceleration signals for stable and unstable cutting




Fig.7 AE Sensor signals for stable and unstable cutting




Fig.8 Coefficient of Variation as chatter vibration onset




Fig.9 Convergence of learning error versus number of iterations in the training process




Fig.10 Multiple Neural Network for the In-Process Monitoring




Fig.11 Flow chart for the In-process Monitoring of Chatter Vibrations




Fig.12 Output of Multiple Neural Network
(Cutting Speed : 80 [m/min], Feed Rate : 0.1 [mm/rev])




Fig.13 Output of Multiple Neural Network