

신경망을 이용한 절삭가공 시

Chatter vibration의 감시

Using Neural Network Approach for Monitoring of Chatter Vibration in Turning Operations

남용석(국방품질관리소), 조종래(창원대 대학원), 정윤교(창원대)

Yong-Seak Nam(Defense Quality Assurance Agency), Jong-Rae Cho(Graduate School, Changwon Univ).

Youn-Gyo Jung(Changwon Univ)

Abstract

The monitoring of the chatter vibration is necessarily required to do automatic manufacturing system. To this study, we constructed a sensing system using tool dynamometer in order to the chatter vibration on cutting process. And a approach to a neural network using the feature of principal cutting force signals is proposed. With the error back propagation training process, the neural network memorized and classified the feature of principal cutting force signals. As a result, it is shown by neural network that the chatter vibration can be monitored effectively

Key Words : Monitoring(감시), Chatter vibration(채터진동), Tool dynamometer(공구동력계), Neural network(신경망), Error back propagation(오차 역전파)

1. 서론

절삭가공 중에 발생하는 채터진동은 공구와 공작물 사이에서 발생하는 심한 상대진동 현상으로서, 채터의 발생은 가공 정밀도, 공작기계 및 공구의 수명, 가공 공정의 생산성에 영향을 미치며, 공작기계 부품의 설계 및 구성, 가공 공정(Process Automation)의 자동화에 중요한 변수로 작용하고 있다.

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.

무인 자동화 가공 시스템의 실현을 위해서는 인간의 패턴인식 기술과 감각 기능을 성공적으로 묘사하는 능력을 가진 기능형 검출 시스템의 개발이 필수적이다. 가공상태 검출을 위한 센서들 중에서 대표적인 것으로 절삭력 센서와 음향방출(Acoustic Emission) 센서가 있다. 절삭력 센서는 절삭시 발생

되는 절삭저항을 측정하여 그 변화 패턴을 이용하는 방법이고, 음향방출 센서^(1, 2)는 작업시 발생하는 미세한 음향의 변화로 인하여 RMS (Root mean square)값이 변하는 특징을 이용한 방법이다.

근래에는 센서들에서 얻어진 신호를 이용, 보다 정확하고 신뢰성 있는 결과를 얻기 위해 특별한 처리를 하는 알고리즘으로 신경망, 퍼지이론, 데이터처리 총괄법⁽³⁾ 등이 있다. 퍼지이론이 규칙의 형태로 구성된 사전정보를 가진 상태에서의 학습방법인 알고리즘인 반면에 신경망은 사전 지식이나 내부 시스템의 동작에 대한 지식이 거의 없고 주어진 표본으로부터의 학습경험에 의해 주어진 표본에 적합한 신경망을 형성하고 새로운 유사 입력패턴들이 주어질 경우에 그 출력패턴을 추정할 수 있는 장점을 가지고 있다.

패턴인식, 의사결정 등에서 뛰어난 능력이 증명된 신경망은 패턴인식, 문자인식, 신호처리 분야에 폭넓게 사용되어 왔다. 금속가공 분야에서는 절삭시 발생하는 센서신호들이 특징적인 패턴들을 신경망에

학습시킨 후, 실제 가공시 발생하는 신호들에 대한 출력을 연구하는 논문들이 발표되고 있다^(2,5). 절삭력 센서에서 나온 신호들의 변화는 가공상태를 반영하며, 변화하는 특징들은 가공상태를 예측하게 한다. 따라서, 본 논문에서는 탄소강과 초경공구를 사용한 절삭실험을 행하여 채터진동 발생시 나타나는 절삭력신호의 변화를 이용하여, 신경회로망에 채터진동 발생의 유무에 따른 절삭력신호의 특징들을 기억시킨 후, 실제 절삭시 얻어지는 절삭력신호를 이용해 절삭 중 채터진동의 발생 유무를 판단하도록 하고자 한다.

2. 기초이론

2.1 신경망

신경망은 생체신경계(Biological nervous system)에서 영감을 얻었다. 인간의 뇌는 많은 단순한 처리기(뉴런)들로 구성된 망으로 각 뉴런은 지역 메모리(Local memory)를 갖고 있다. 뉴런들은 데이터를 이동시킬 수 있는 통신채널(Connection)에 의해 연결되어 있으며, 뉴런은 연결을 통해 입력을 받아 자신의 지역 데이터만을 작동시킨다.

신경망의 구조는 뉴런들간 연결로 구성이 된다. 여러개의 뉴런들은 무리(Group)를 이루어서 하나의 층(Layer)을 이루고, 하나 이상의 층들이 서로 연결되어 인공 신경망(Artificial neural network)을 이룬다. 같은 층 내에 있는 뉴런들은 모두 동일한 결합함수, 활성화 함수 및 학습방법을 가진다.

신경망의 일반적인 형태는 다층으로 구성되어 있으며, Fig. 1과 같이 입력층, 은닉층, 출력층으로 구성되어 있다. 입력층(Input layer)은 신경망의 외부로부터 입력을 받아들이며, 은닉층(Hidden layer)은 하나 혹은 그 이상의 층으로 구성되며 입력된 정보를 완전히 표현해 줄 수 있는 역할을 한다. 출력층(Output layer)은 은닉층에서 처리된 정보가 주어진 목표값에 근사한 값을 갖도록 변환되어 신경망 외부로 전송한다.

신경망의 학습방법은 신경 세포들의 연결이 갖는 가중치의 변화로써 신경망을 학습시킬수 있다는 1949년 Hebb의 제안에 그 기초를 두고있다. 신경망의 학습이란 특정 문제에 대한 입력이 주어졌을 때 원하는 출력이 나오도록 연결강도 즉 가중치(Weight)를 조절하는 과정을 말한다.

함수근사(Function approximation) 혹은 회귀분석(Regression analysis)에서 현재 가장 많이 이용되고 있는 학습규칙은 학습율과 수렴성이 가장 좋은 교사

학습(Supervised learning) 방법인 오차 역전파(Error back propagation) 학습 알고리즘이다.




Fig. 1 Multi-layer neuron

가장 일반적으로 사용되는 최급감소법(Steepest descent method)은 주어진 목표 값과 신경망의 출력 값 사이의 오차 값이 최소가 되도록 신경망의 가중치를 감소시키는 방향으로 값을 조정하는 것으로 오차 역전파 학습알고리즘과 같지만, 신경망이 단층에서 다층으로 확장되었을 경우 출력 뉴런과 연결되어 있는 뉴런의 가중치를 조정할 수가 없었다. 그러나 오차 역전파 학습알고리즘은 출력 뉴런의 오차를 출력 뉴런에 연결된 이전 은닉층 뉴런으로 역전파시키는 것이다. 이런 과정은 입력에 이르기까지 반복하게 된다. 오차 역전파 학습알고리즘은 일반화된 델타 규칙(Generalized delta rule) 이라고 한다.

2.2 오차 역전파 학습알고리즘

오차 역전파 학습 알고리즘⁽⁶⁾은 교사학습으로써 통상 입력패턴과 그에 대한 목표출력으로 이루어진다. 목표출력은 대개 정확한 해답 또는 입력패턴에 대한 정확한 분류이다. 이런 예제들로부터 신경망은 내부적인 연결강도를 조정한다. 오차 역전파 학습 알고리즘은 다층 전향 퍼셉트론의 실제 출력과 기대되는 출력간의 평균 제곱 오차를 최소화하도록 설계된 일종의 반복적 기울기 알고리즘으로 연속적이며 미분 가능한 비선형 함수를 필요로 한다.

역전파 알고리즘을 이용한 학습단계는 일반화된 델타 규칙을 사용하며, Fig. 2의 순서로 진행된다.

오차 역전파 알고리즘을 이용하는 학습단계가 신경망의 적절한 가중치를 얻기 위해 적용된다. 입력되는 패턴이 신경망을 통해 forward propagation되어 출력되며 망의 출력패턴이 예상된 출력패턴과 비교

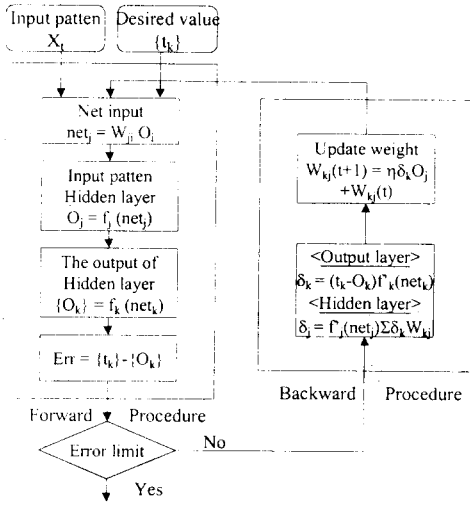


Fig 2 Learning algorithm of generalized delta rule

되며 그 square오차 E_p 는 다음과 같이 나타낼 수 있다.

$$E_p = \left(\frac{1}{2}\right) \sum_k (t_{pk} - O_{pk})^2 \quad (1)$$

여기서, k 는 출력패턴의 수, p 는 p 번째 학습패턴이다.

모든 입력과 출력패턴의 쌍(Pair)에 대해서 전체 시스템의 평균오차(Average system error)는 다음과 같다.

$$E = \left(\frac{1}{2P}\right) \sum_p \sum_k (\{t_{pk}\} - \{O_{pk}\})^2 \quad (2)$$

오차를 줄이기 위해 뉴런을 연결하고 있는 가중치가 조절되며, 이를 조절하는 방법으로 역전파(Back propagation)를 사용하며 이는 오차 역전파(Back propagation of error)의 출입말로 역으로 전파되면서 가중치를 줄여가는 방법이다.

$$W^{new} = W^{old} + \Delta W \quad (3)$$

$$\Delta W_{kj} = -\eta \frac{\partial E}{\partial W_{kj}} \quad (4)$$

여기서, Δw_{kj} 는 j 번째 뉴런에서 k 번째 뉴런까지 가중치가 증가한 변화량, η 는 학습율이다.

학습율은 계산된 가중치의 변화 중에서 얼마만큼이

교정을 위해 사용될 것인가를 결정하며 가장 좋은 값은 오차표면 즉, w_{kj} 에 대한 E 의 특성에 의존한다.

결과적으로 임의의 초기치로 설정된 모든 가중치들은 예상된 출력과 실제 출력들의 오차를 최소화하기 위해 근사적으로 조정될 수 있다.

이렇게 감독된 학습이 완료된 후에 신경회로망은 새로운 입력패턴을 받을 준비를 하게 되고, 새 입력패턴과 훈련된 패턴 사이의 유사성에 기초해서 관련된 출력패턴을 만들어 낸다.

3. 실험장치 및 실험방법

채터진동을 감시하기 위한 실험장치는 Fig. 4와 같이 구성하였으며, 주축모터의 소비동력이 7.5kW인 CNC 선반을 사용하였다. 절삭력 신호는 Kistler사의 9257B의 압전소자형 공구동력계를 사용하여, A/D 변환기와 PC를 이용하여 측정하였으며, A/D 변환기의 데이터 샘플링은 100Hz로 하였다.

공작물의 표면조도는 Mitutoyo사의 SV-624 접촉식 표면조도계로 측정길이 75mm, 측정속도 2.0mm/s로 측정하였다. 실험에 사용한 공작물은 직경 23mm, 길이 160mm인 SM45C 탄소강을 사용하였으며, 편심을 제거하기 위하여 전 가공을 실시하였다.

실험조건은 Table 2와 같은 조건으로 CNC 선반의 주축속도를 주축도 일정제어로 하여 공작물의 외주를 80mm 가공하였으며, 절삭유는 사용하지 않았다. 척으로부터 채터 발생점까지의 공작물 길이를 채터 임계 거리(l_c)라고 정의하여 Neural network의 성능을 평가하였다.

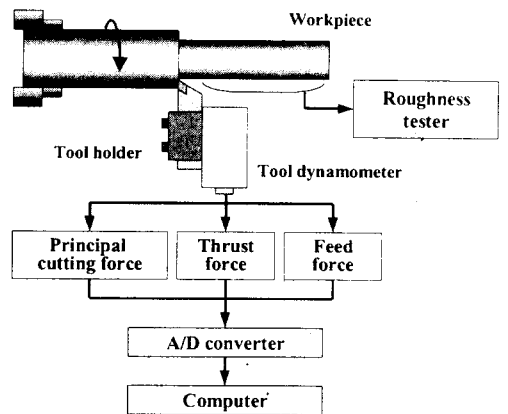


Fig. 4 Experimental setup

Table 1 Experimental equipments

Instrument	Specification
CNC lathe	Hi-ECO 10(Hwacheon Co.)
Workpiece	SM45C(D:25mm, L:160mm)
Tool holder	PCLNL 2525 M12(Taegu Tec)
Insert tip	NC330 CNMG 120404 B25(Korloy Inc)
Tool dynamometer	Piezo type 9257B(Kistler Co.)
Charge amplifier	5019A(Kistler Co.)
A/D converter	PCL-812PG(Advantech Co. Ltd.)
Roughness tester	SV-624(Mitutoyo)

Table 2 Experimental condition

Items	Condition
Cutting velocity(m/min)	130, 160, 190, 210
Feed (mm/rev)	0.10, 0.15, 0.20, 0.25
Depth of cut(mm)	0.10, 0.15, 0.20, 0.25
Coolant	Dry

4. 신경망의 적용

채터진동을 실시간 검출하기 위해, 채터진동에 의해 발생한 절삭력 신호를 민감하게 측정할 수 있는 공구 동력계를 공구홀더에 부착하여 사용하였다. 채터진동이 발생했을 때, 공구와 공작물의 상대변위의 변화에 따라 절삭저항의 3분력 또한 변화하고 있는 것을 보여주는 그림이 Fig. 5이다. 채터진동이 발생할 때는 절삭력 신호의 변화가 크고, 절삭과정이 안정할 때는 절삭력 신호의 변화가 작은 것을 알 수 있다. 또한 Fig. 6의 표면조도 그림에서도 마찬가지로 채터진동 발생 유무에 따라 표면조도의 차가 큼을 알 수 있다.

채터진동이 발생했을 때, 3분력 모두가 변화하지만 주분력의 변화가 현저함을 알 수 있다. 또한 채터진동의 발생유무에 따라 주분력의 변동성분의 변화가 크므로, 주분력의 변동성분만 추출하여 정규화(Normalizing)한 다음, $y=2$ 로 위치이동 시킨 데이터를 신경망의 입력값으로 설정하였다(Fig. 7). 또한 신경망의 학습에 필요한 목표치는 Fig. 6의 표면조도 그래프를 이용하여 결정하였다.

신경망의 학습은 Fig. 7의 데이터를 이용하여 학습시켰다.




Fig. 5 Cutting force for chatter vibration




Fig. 6 Profile of surface roughness

채터진동 발생유무를 결정하기 위해, 입력층이 1개, 은닉층이 2개, 출력층이 1개인 1-10-10-1의 신경망을 구축하였다. 구축된 신경망의 은닉층 뉴런의 결정은 최적의 결과가 도출될 때까지 시행착오법에 의해 결정하였다.

학습은 Fig. 7과 같이 주어진 입력신호에 따라 채터진동이 발생할 때는 1의 신호를 출력하고, 채터진동이 발생하지 않을 경우는 0의 신호가 출력되도록 하였다. 학습과정이 진행됨에 따라 학습오차가 수렴되어 가는 과정을 Fig. 8에 나타내었다. 학습회수가 12회 반복 학습을 수행하였을 때, 이미 설정오차 0.05보다 작은 오차를 가짐을 알 수 있다.




Fig. 7 Learning & desired data of neural network




Fig. 8 Training error for number of step




Fig. 9 Output signals of learning data

학습 후, 입력신호에 대한 출력신호를 나타내는 그림이 Fig. 9로 채터진동이 발생했을 때는 출력값이 1부근에 나타나 있으며, 채터진동이 소멸해가는 천이영역에서는 출력신호가 약간의 변동을 보여주고 있으며, 절삭상태가 안정됐을 때는 출력신호가 0부근에 나타나 있다. 따라서, 채터진동의 발생유무는 출력신호값이 0.5이상일때는 채터진동이 발생한 영역으로, 0.5이하일때는 절삭상태가 안정된 영역으로 결정하였다.

5. 실험결과 및 고찰

본 연구에서 구축된 신경망의 채터진동 감시 타당성을 검증하기 위하여 정규화된 절삭력 신호에 대한 신경망의 출력신호를 나타내는 그림이 Fig. 10이다. 그림에서 보는 바와 같이 절삭상태가 안정화되면 신경망 출력값이 0에 접근함을 알 수 있다. 절삭길이 54mm 정도에서 절삭상태가 안정화되었으며, Fig. 11의 표면조도 그림에서도 신경망의 출력신호와 유사하게 절삭길이 54mm 부근에서 양호한 표면조도가 나타남을 알 수 있다.

본 연구에서 구축한 신경망의 채터진동 감시결과를 Fig. 12에 나타내었다.

척으로부터 채터의 발생점까지의 공작물 길이를 채터 임계 거리(l_c)로 정의하였다. 채터 임계 거리가 길면 그 조건에서 채터에 대해 안정하다는 것이며 이 거리가 짧으면 채터에 민감하게 거동함을 의미한다. 따라서, 이 거리의 대소를 평가함에 의해 각 조건에서의 채터발생 용이성을 평가할 수 있으며,




Fig. 10 Output signal for input signal of neural network






Fig. 11 Profile of surface roughness

또한 표면조도가 양호해지는 지점과 비교함으로써 신경망의 성능을 평가할 수 있다.


Fig. 12 (a)는 이송 0.15mm/rev, 절삭깊이 0.15mm일 때 절삭속도의 변화에 따른 채터 임계거리와의 관계를 나타내는 그림이다. 그림에서 보는 바와 같이 절삭속도가 커짐에 따라 절삭상태가 불안정하게 되어 채터 임계 거리가 짧아짐을 알 수 있다. 또한 표면조도 값과 신경망의 출력값이 서로 비슷한 값을 가짐을 알 수 있다. Fig. 12 (b)는 절삭속도 160mm/min, 절삭깊이 0.15mm일 때 이송에 따른 채터 임계 거리를 나타내는 그림으로 이송이 크면 클수록 절삭시스템이 안정하게 작용함을 알 수 있으며, Fig. 12 (a)와 마찬가지로 표면조도 값과 신경회로망의 출력값이 비슷한 값을 나타내고 있다. Fig. 12 (c)는 절삭속도 160mm/min, 이송 0.15mm/rev일 때 절삭깊이에 따른 채터 임계 거리를 나타내는 그림으로 절삭깊이는 채터진동에 무관함을 알 수 있다.



(a) Critical distance for cutting velocity



(b) Critical distance for feed rate



(c) Critical distance for depth of cut

Fig. 12 Neural network of performance estimation

Fig. 12에서 보는 바와 같이, 본 연구에서 구축한 신경회로망은 채터진동을 효과적으로 감시할 수 있으며, 이상과 같은 연구결과는 자동화 시스템에 광범위하게 응용할 수 있을 것으로 사료된다.

6. 결론

신경망을 이용한 선삭가공 시 채터진동의 감시에 관한 연구를 통하여 다음과 같은 결론을 얻었다.

(1) 절삭력신호 중 주분력신호가 채터진동에 민감하게 변화한다. 채터진동의 발생유무에 따라 주분력의 변동성분이 급격히 변화하며, 이러한 특성으로부터 신경망의 입력신호로 선정하여 채터진동의 감시에 이용하였다.

(2) 절삭속도가 작을수록, 이송이 클수록 절삭시스템은 채터에 대해 안정하며, 절입깊이는 본 실험조건 범위내에서는 채터에 대해 영향이 크지 않았다.

(3) 주분력의 변동성분을 입력신호로 한 Error back propagation 신경망은 채터진동 감시에 효과적이었으며, 채터진동 안정영역과 불안정영역을 뚜렷이 구분하는 좋은 특성을 나타내었다.

후 기

본 연구는 한국과학재단지정 창원대학교 공작기계 기술연구센터의 지원에 의한 것입니다. 관계자에게 감사드립니다.

7. 참고문헌

1. T. Blum, I. Suzuki and I. Inasaki, "Development of a Condition Monitoring System for Cutting Tools Using an Acoustic Emission", Bull. Japan Soc. of Prec. Eng., Vol. 22, No. 4, pp. 301~308, 1988.
2. J. R. Cho, J. S. Won, Y. G. Jung, "A Study on the Behaviors of Acoustic Emission Signals and Cutting Forces by Flank Wear in Turning Process", J. KSPE, Vol. 16 No. 1, pp. 26-33, 1999
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. G. S. Hong, M. Rahman and Q. Zhou, "Using Neural Network for Tool Condition Monitoring Based on Wavelet Decomposition", Int. J. Mach. Tools Manufact, Vol. 36, No. 5, pp. 551~566, 1996
5. S. C. Lin and C. J. Ting, "Drill Wear Monitoring Using Neural Networks" Int. J. Mach. Tools Manufact, Vol. 36, No. 4, pp. 465~475, 1996
6. Jacek M. Zurada, "Introduction to Artificial Neural Systems", PWS Publishing Company, pp. 186~196, 1992