

선삭가공 중 신경망을 이용한 채터진동의 감시

남용석*, 조종래**, 김재실***, 정윤교***

Monitoring of Chatter Vibration using Neural Network in Turning Operation

Yong Seak Nam*, Jong Rae Cho**, Chae Sil Kim***, and Youn Gyo Jung***

ABSTRACT

Monitoring of the chatter vibration is necessarily required to do automatic manufacturing system. Therefore, we constructed a sensing system using tool dynamometer in order to monitor of chatter vibration on cutting process. Furthermore, an application of neural network using behavior of principal cutting force signals is attempted. With the error back propagation training process, the neural network memorized and classified the feature of principal cutting force signals. From obtained result, it is shown that the chatter vibration can be monitored effectively by neural network.

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

1. 서론

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 트러블에는 여러 가지가 있으나 그 중 채터진동은 공구와 공작물 사이에서 발생하는 심한 상대진동 현상으로 가공 정밀도, 공작기계 및 공구의 수명, 가공 공정의 생산성에 영향을 미치며, 공작기계 부품의 설계 및 구성, 가공 공정의 자동화에 중요한 변수로 작용하

고 있다. 따라서, 이러한 채터의 발생을 모니터링 하기 위하여 여러 종류의 센서에 의해 다양한 연구가 수행 중에 있다.⁽¹⁻²⁾

무인 자동화 가공시스템의 실현을 위해서는 인간의 패턴인식 기술과 감각 기능을 성공적으로 묘사하는

능력을 가진 기능형 검출시스템의 개발이 필수적이다. 가공상태 검출을 위한 센서들 중에서 대표적인 것으로 절삭력 센서와 음향방출(acoustic emission) 센서⁽³⁻⁴⁾가 있다. 절삭력 센서는 절삭시 발생하는 절삭저항을 측정하여 그 변화패턴을 이용하는 방법이고, 음향방출센서는 작업시 발생하는 미세한 음향의 변화로 인하여 RMS 값이 변하

* 국방품질관리소

** 창원대학교 기계공학과 대학원

*** 창원대학교 기계공학과

는 특징을 이용한 방법이다.

근래에는 센서들에서 얻어진 신호를 이용, 보다 정확하고 신뢰성 있는 결과를 얻기 위해 특별한 처리를 하는 알고리즘으로 신경망, 퍼지이론, 데이터처리 총괄법⁽⁶⁾ 등이 있다. 퍼지이론이 규칙의 형태로 구성된 사전정보를 가진 상태에서의 학습방법 알고리즘인 반면에, 신경망은 사전 지식이나 내부 시스템의 동작에 대한 지식이 거의 없고 주어진 표본으로부터의 학습경험에 의해 주어진 예제에 적합한 신경망을 형성하고 새로운 유사 입력패턴들이 주어질 경우에 그 출력패턴을 추정할 수 있는 장점을 가지고 있다. 패턴분류, 함수근사 등에서 뛰어난 능력이 증명된 신경망은 패턴인식, 문자인식, 신호처리 분야에 폭넓게 사용되어 왔다.

금속가공 분야에서는 절삭시 발생하는 센서신호들의 특징적인 패턴들을 신경망에 학습시킨 후, 실제 가공시 발생하는 신호들에 대한 출력을 연구하는 논문⁽⁶⁻⁷⁾들이 발표되고 있으나, 채터진동에 대한 신경망의 적용사례는 희소한 실정이다.

따라서, 본 연구에서는 공작물로서 SM45를 대상으로 초경공구로서 선삭가공을 수행할 때 채터진동의 거동을 절삭력의 주분력 거동으로 패턴을 결정된 후, 이 패턴을 신경망에 적용시킴으로서 채터진동의 발생 유무를 판단하도록 하는 시스템을 구축하고자 한다. 이러한 시스템을 채터진동의 인 프로세스감시의 기초를 마련할 수 있을 것으로 사료된다.

2. 신경망 구축

신경망의 일반적인 형태는 입력층, 은닉층, 출력층으로 구성되어 있다. 입력층은 신경망의 외부로부터 입력을 받아들이며, 은닉층은 하나 혹은 그 이상 층으로 구성되고, 입력된 정보의 패턴을 분석하는 역할을 한다. 출력층은 은닉층에서 처리된 정보가 주어진 목표값에 근사한 값을 갖도록 변환되어 신경망 외부로 전송한다.

학습 알고리즘은 여러 종류가 있지만, 본 연구에서 사용되어진 오차역전파 학습 알고리즘은 현재 많이 이용되고 있는 학습규칙으로, 학습결과 수렴성이 좋은 교사학습방법이다. 이 학습 알고리즘은 오차를 줄이기 위해 뉴런을 연결하고 있는 가중치를 조절하는데, 이를 조절하는 방법으로 역전파를 사용한다.

본 연구에서 사용된 신경망 구조는 Fig. 1에서 보는 바와 같이, 입력층에 1개의 입력변수를, 2개의 은닉층 각각에는 5개의 뉴런을, 출력층에 1개의 출력변수를 가진 1-5-5-1의 신경망 구조를 가지고 있다.




Fig. 1 Multi-layer neuron

학습방법은 오차역전파 학습 알고리즘, 활성화 함수는 시그모이드함수를 사용하여 학습데이터의 오차가 0.005이하가 될 때까지 학습시키는 것으로 하였다. 구축된 신경망의 은닉층 뉴런 수의 결정은, 다양한 구조의 신경망을 시행한 결과, 가장 목표치와 결과치가 근접한 구조가 도출될 때까지 시행착오법에 의해 결정하였다. 학습단계는 오차 역전파 학습알고리즘을 이용하여 Fig. 2의 플로차트 순서로 진행된다.

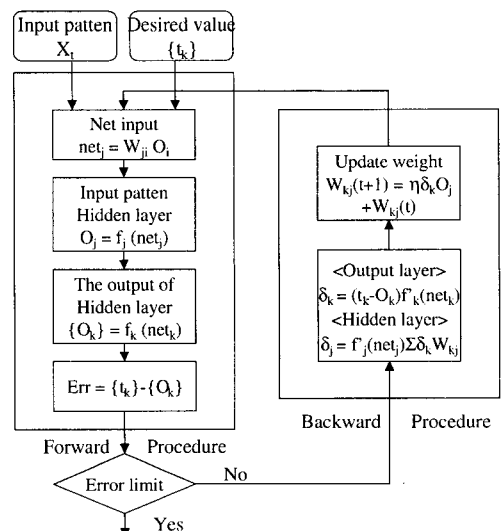


Fig. 2 Learning algorithm of generalized delta rule

3. 실험장치 및 실험방법

채터진동을 감시하기 위한 실험장치는 Fig. 3과 같이 구성하였으며, 주축모터의 소비동력이 7.5kW 인 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 2.0 mm/s로 측정하였다. 실험에 사용한 공작물은 직경 23mm, 길이 160mm인 SM45C 탄소강을 사용하였으며, 편심을 제거하기 위하여 전 가공을 실시하였다.

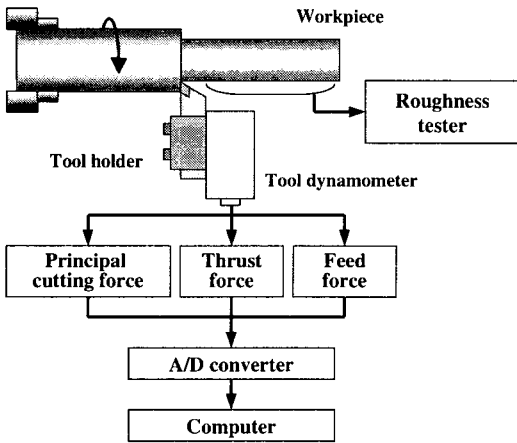


Fig. 3 Experimental setup

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 conditions

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

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 신경망의 성능평가 척도로 사용하였다.

4. 신경망의 적용

Fig. 4는 공작물의 선단에서부터 척으로 이송하면서 선삭가공을 수행하였을 때의 절삭저항의 3분력 즉, 주분력, 배분력 및 이송분력의 변화추이를 나타낸 그림이다. 그림에서 보는바와 같이 3분력중에서 주분력의 변동폭이 가장 크며, 또한 공작물의 선단에서 40mm까지는 공작물의 고정 강성으로부터 기인하는 것으로 생각되어지는 채터진동과 관련된 절삭저항의 변동이 격심하게 나타났으며, 40mm 이후의 절삭과정에서는 공작물의 고정강성이 크기 때문에 안정된 절삭상태를 보여주고 있음을 알 수 있다. 이러한 사실은 가공물의 표면조도를 측정함으로써 간접적으로 증명할 수 있다.

Fig. 5는 가공길이의 변화에 대한 표면조도의 변화를 보여주는 그림으로 절삭저항의 주분력의 변화추이와 그 양상이 동일함을 알 수 있다. 따라서, 표면조도의 변화는, 채터진동에 기인하여 절삭저항이 극심히 변동한다는 것을 뒷받침하고 있다고 사료된다.

본 연구에서는 절삭저항의 3분력중에서 채터진동에 가장 민감하다고 판단되어지는 주분력신호를 채터진동 판단의 입력신호로 채택하였으며, 이 신호의 변동성분만 추출하여 정규화(변동성분의 데이터중에서 극대값 및 극소값만 선택)한 데이터를 최종 신경망의 입력 데이터로 사용하였다. Fig. 6은 이러한 과정을 거쳐 선택된 입력신호를 학습시키기 위하여 채터가 발생한 경우에는 "1"의 신

호를 학습의 목표치로 하고, 채터가 발생하지 않는 경우는 “0”의 신호를 학습의 목표치로 하였다. “1”과 “0”의 경계를 결정짓는 요소로서는, Fig. 5의 표면조도의 변화로 판단하였으며, 표면조도의 극심한 변동이 현저히 줄어드는 가공길이 40mm 부근을 “1”과 “0”의 경계로 설정하였다.




Fig. 4 Cutting force for chatter vibration




Fig. 5 Profile of surface roughness

Fig. 7은 학습회수에 따라 학습오차가 줄어드는 과정을 보여주는 그림이다. 본 논문에서는 학습오차가 0.005이하가 되면 충분한 학습이 이루어졌다고 판단하였다. Fig. 6의 학습 데이터로서는 학습회수 약 16회 정도에서 0.005이하로 되어 학습을 중단하는 것으로 하였다.

Fig. 8은 Fig. 6의 데이터를 학습하여 전송된 신경망의 출력신호를 나타낸 그림이다. 주분력의 변동값이 심한 구간에서는 신경망 출력신호가 “1”을 지시한 구간으로 채터진동이 발생한 구간이며, 출력신호가 “0”을 지시한 구간은 절삭상태가 안정된 구간으로 판단되어진다. 또한 “1”과 “0”의 천이영역에서도, 본 신경망 구조에서는 명료한 결과를 보여주고 있다. 또한 Fig. 8의 신경망 출력신호의 변화패턴은 Fig. 5의 표면조도의 변화패턴 뿐만 아니라 Fig. 6의 학습데이터와 거의 일치되는

것을 알 수 있다.

이러한 결과로부터, 본 연구에서 구축되어진 채터진동 감시를 위한 신경망 알고리즘은 채터진동 감시에 있어서 유용하게 활용할 수 있음을 나타내고 있다.




Fig. 6 Learning & desired data of neural network




Fig. 7 Training error for number of step




Fig. 8 Output signals of learning data

5. 실험결과 및 고찰

본 연구에서 구축된 신경망의 채터진동 감시의 타당성을 검증하기 위하여, 임의의 절삭조건

(Cutting velocity: 160m/min, Feed rate: 0.10mm/rev, Depth of cut: 0.15mm)으로 절삭가공을 수행하였을 때, 변동되는 주분력 신호를 정규화시켜 신경망의 입력신호로 전송하였을 경우, 신경망의 출력신호를 나타내는 그림이 Fig. 9이다. 그림에서 보는 바와같이, 절삭길이 54mm정도에서 절삭상태가 안정화되어 신경망 출력값이 "0"에 접근함을 알 수 있으며, Fig. 10의 표면조도 변화패턴도 신경망의 출력신호와 유사하게 절삭길이 54mm부근에서 양호한 표면조도가 나타남을 알 수 있다. 이러한 사실로부터 임의의 절삭조건으로 가공하는 경우, 본 신경망 알고리즘을 사용하면 채터의 유무를 인 프 로세스로 감지할 수 있는 가능성을 시사한다고 볼 수 있다.

또한 구축한 채터진동 감시 알고리즘의 신뢰성을 평가하기 위하여, 다양한 절삭조건에 따라 절삭을 수행하였을 때 발생되어지는 주분력 성분으로 본 연구의 신경망 알고리즘을 이용하여 채터 감시를 수행한 결과로부터, 각종 절삭조건에 따른 채터 임계거리를 판단하여 나타낸 그림이 Fig. 11이다. 채터 임계거리가 길면 그 절삭조건에서 채

터에 대해 안정하다는 것이며, 이 거리가 짧으면 채터에 민감하게 거동함을 의미한다.

Fig. 11(a)는 이송 0.15mm/rev, 절삭깊이 0.15mm일 때 절삭속도의 변화에 따른 채터 임계거리와의 관계를 나타내는 그림으로 절삭속도가 증가함에 따라 채터 임계거리가 짧아짐을 알 수 있다. 즉, 절삭속도가 커질수록 채터에 민감하게 거동함을 알 수 있다. 또한 Fig. 11(b) 및 Fig. 11(c)는 각각, 이송에 따른 채터 임계거리의 변화와, 절삭깊이의 변화에 따른 채터 임계거리의 변화를 나타낸다. 그림에서 보는 바와 같이, 이송의 변화에 대해서는, 이송이 클수록 채터에 둔감하게




Fig. 9 Output signal for input signal of neural network






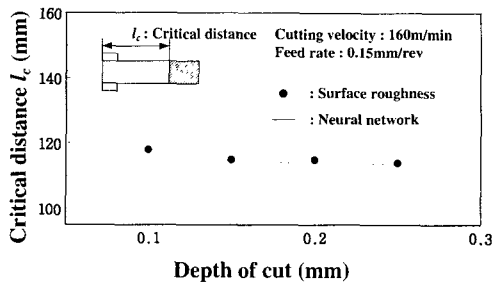
Fig. 10 Profile of surface roughness



(a) Critical distance for cutting velocity



(b) Critical distance for feed rate



(c) Critical distance for depth of cut

Fig. 11 Neural network of performance estimation

되어짐을 알 수 있다.

또한, 공작물의 표면조도에서 결정한 채터 임계거리와 신경망에서 출력된 채터 임계거리가 거의 일치함을 알 수 있다.

따라서, 본 연구에서 제안한 신경망에 의해 채터진동 감시의 결과가 신뢰성이 있음을 알 수 있었다.

6. 결론

선삭가공 중 신경망을 이용한 채터진동의 감시에 관한 연구를 수행한 결과 다음과 같은 결론을 얻었다.

1) 본 연구에서는 채터진동 감시를 위한 신경망 시스템을 구축하였다.

2) 절삭속도가 작을수록, 이송이 클수록 절삭 시스템은 채터에 대해 안정하며, 절삭깊이는 본 실험조건범위 내에서는 채터진동에 대해 영향이 크지 않았다.

3) 주분력 신호를 입력신호로 한 오차 역전파 신경망 알고리즘은 채터진동 감시에 효과적이었으며, 채터진동의 안정영역과 불안정영역을 뚜렷이 구분하는 좋은 특성을 나타내었다.

후기

본 연구는 창원대학교 메카트로닉스연구소의 지원에 의한 것입니다.

참고문헌

1. M. Rahman, "In-Process Detection of Chatter Threshold," Trans. ASME, Journal of Engineering for Industry, Vol. 110, pp. 44~50, Feb, 1988.
2. T. Delio, J. Tulsty, S. Smith, "Use of Audio Signals for Chatter Detection and Control," Trans. ASME, Journal of Engineering for Industry, Vol. 114, pp. 146~157, May, 1992.
3. 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.

4. J. R. Cho, J. S. Won, and 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.
5. S. Rangwala, D. A. Dornfeld, "Sensor Integration using Neural Networks for Intelligent Tool Condition Monitoring," Trans. ASME, Journal of Engineering for Industry, Vol. 112, pp. 219~228, 1990.
6. 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.
7. 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.
8. Jacek M. Zurada, "Introduction to Artificial Neural Systems," PWS Publishing Company, pp. 186~196, 1992.
9. 박재섭, 송지복, "신경회로망을 이용한 연삭가공의 트러블 인식(III)," 한국정밀공학회, 제15권, 제2호, pp. 162~169, 1998.
10. 김화영, 안중환, "신경회로망을 이용한 드릴공정에서의 칩 배출 상태 감시," 한국정밀공학회지, 제16권, 제6호, pp. 133~140, 1999.