

신경회로망을 이용한 드릴공정에서의 칩 배출 상태 감시

김화영*, 안중환*

Chip Disposal State Monitoring in Drilling Using Neural Network

Hwa Young Kim* and Jung Hwan Ahn*

ABSTRACT

In this study, a monitoring method to detect chip disposal state in drilling system based on neural network was proposed and its performance was evaluated. If chip flow is bad during drilling, not only the static component but also the fluctuation of dynamic component of drilling torque increases highly. So these components could be a clue for monitoring the chip disposal state during drilling. Drilling torque is indirectly measured by sensing spindle motor power through a AC spindle motor drive system. Spindle motor power being measured drilling, four quantities such as variance/mean, mean absolute deviation, gradient, event count were calculated as feature vectors and then presented to the neural network to make a decision on chip disposal state. The selected features are sensitive to the change of chip disposal state but comparatively insensitive to the change of drilling condition. The 3 layered neural network with error back propagation algorithm has been used. Experimental results show that the proposed monitoring system can successfully recognize the chip disposal state over a wide range of drilling condition even though it is trained under a certain drilling condition.

Key Words : Chip disposal state monitoring(칩 배출 상태 감시), Drilling(드릴링), Neural network(신경회로망), Spindle motor power(주축모터 파워)

1. 서론

드릴가공은 선삭과 함께 가장 중요한 절삭 공정 중 하나로 전체 절삭 공정의 약 30%정도를 차지하고 있다⁽¹⁾. 일반적으로 드릴가공은 가공 특성상 이미 밀링이나 선삭과 같은 전가공이 상당히 진행된 단계에서 주로 수행되기 때문에 공구파손으로 인한

경제적 손실이 상당히 크고 또 파손된 드릴날이 공작물 안에 박혀 버리기 때문에 후처리도 굉장히 어렵다. 이 때문에 드릴 가공의 경우 가공 공정에 대한 높은 신뢰성이 요구된다.

드릴가공은 선삭이나 밀링공정과 달리 가공 중 발생된 칩이 드릴 홈이라는 제한된 공간을 따라 배출되기 때문에 칩배출이 원활하지 못한 경우가

* 부산대학교 기계공학부, 기계기술연구소

종종 발생한다. 이러한 칩 배출 불량은 가공면과의 마찰로 인한 절삭력 증가와 공구 끝단으로의 절삭 유 공급을 방해하여 절삭 날의 연화를 초래하고 그 결과 드릴파손 및 가공면의 정도 저하를 일으키게 된다⁽¹⁾.

드릴가공의 경우 칩 배출 상태에는 드릴파손, 드릴마멸, 과부하와 같은 이상 상태에 대한 정보를 포함하고 있으며 실제 현장 작업자의 경우 칩 배출 상태 및 색깔, 가공 부하, 가공음 등과 자신의 지식과 경험을 이용하여 공구상태를 포함한 드릴 가공 상태 전반에 대한 감시를 수행하고 있다. 따라서 공구상태 감시와 더불어 칩 배출 상태 감시를 같이 행함으로써 무인 운전에 대한 감시의 신뢰성을 높일 수 있다. 드릴가공에서의 칩 배출 불량은 주로 드릴마멸로 인한 칩 두께의 증가와 부적절한 절삭 조건으로 인한 과부하 등이 원인이 되어 일어난다. 드릴 가공시 처음에는 칩 배출 상태가 양호하나 어느 정도의 가공시간이 지나고 나면 칩 배출 불량 상태의 발생 빈도가 점차 커지는 경우는 드릴마멸이 원인이며 드릴교환 시점 결정 및 드릴 파손 예방에 대한 중요한 정보를 제공한다. 드릴마멸이 심각해질수록 칩 배출 불량 발생 빈도도 점차 커진다. 드릴 가공시 처음부터 칩 배출 상태가 나쁜 경우는 과부하로 인한 것으로 이는 부적합한 절삭조건이 주원인이다. 따라서 칩 배출 상태 감시 시스템은 이러한 비정상 상태로 인해 발생하는 칩 배출 불량 상태를 정상상태와 구별해 내는 능력을 지니고 있어야 한다. 또한 칩 배출 상태 감시 시스템은 산업현장에 쉽게 적용할 수 있어야 하며 가능한 한 넓은 가공조건에 걸쳐 신뢰성 있게 감시를 수행할 수 있어야 한다.

감시 시스템의 성능은 적절한 감시 신호와 신뢰성 있는 진단 알고리즘의 선정에 크게 의존한다. 현재 가공 상태 감시를 위한 신호로는 절삭력, 모터전류, AE, 진동, 회전수 등 다양한 신호가 이용되고 있으며⁽²⁾⁽³⁾, 본 연구에서는 주축모터 드라이브 시스템으로부터 검출한 모터 파워 신호를 감시 신호로 선정하였다. 모터 드라이브 시스템을 센서로 사용하여 가공 중 소비되는 모터전류(파워)로부터 절삭력을 간접적으로 측정하는 방법은 비록 공구동력계 보다는 성능은 떨어지나 센서가 동작기계에 내장되어 있어 센서 설치에 따른 동작기계 구조물의 변경이 필요 없고 유연성이 뛰어나기 때문에 산업현장에 적합한 간접 절삭력 측정 방법이다⁽⁴⁾⁽⁵⁾.

감시 진단 알고리즘으로는 신경회로망, 퍼지인식과 같은 인공지능 기법이 많이 쓰이고 있다. 이중 신경회로망은 Rangwala와Dornfeld⁽⁶⁾가 선삭에서의 공구상태 감시에 대한 연구에 처음 도입한 이후 많은 연구자들에 의해 절삭상태 감시⁽⁷⁾⁽⁸⁾에 이용되고 있으며 드릴 파손 및 마멸 감시에 신경회로망을 이용한 연구 결과도 몇몇 연구자들에 의해 발표되었다⁽⁹⁾⁽¹⁰⁾. 본 연구에서는 칩 배출 상태 감시 진단 알고리즘으로 오차 역전과 학습알고리즘을 가진 신경회로망⁽¹¹⁾을 이용하였다.

드릴 가공 중 칩 배출이 나빠지면 칩과 가공면 사이의 마찰증가와 불규칙한 칩 배출로 인해 토크의 정적성분이 증가하고 또 동적 성분의 변동도 커지게 된다. 따라서 드릴 가공 중 검출된 절삭토크에는 칩 배출 상태에 대한 유용한 정보가 포함되어 있으며 주축 모터 파워로부터 절삭토크를 간접적으로 측정함으로써 칩 배출 상태에 대한 정보를 추출할 수 있을 것으로 추정된다. 이를 위해 동작기계의 AC주축모터 드라이브 계를 센서로 사용하여 주축모터 파워를 검출하였으며, 주축모터 파워에 대한 진폭영역 신호처리로부터 칩 배출 상태를 잘 나타내는 특징들을 추출하고 신경회로망을 이용하여 드릴가공중의 칩 배출 상태를 실시간 감시하였다.

2. 신호처리와 특징추출

칩 배출 상태 감시에 사용될 특징들은 칩 배출 상태 변화에 민감하고 절삭상태의 변화와 같은 주위 환경의 변화에 대해서는 둔감한 성질을 갖는 특징들을 선택해야 한다. Fig. 1은 드릴 가공 중 검출된 주축 모터 파워 신호의 일반적 거동을 나타낸다. 드릴공정은 3단계로 분류할 수 있다. A는 치출에지가 공작물과 접촉해서 센터 위치를 잡고 가공을 시작하는 도입(entry) 단계, B는 주절삭날이 완전히 공작물 안으로 파고 들어가 본격적인 가공이 일어나는 정상상태(steady state)단계, C는 드릴날이 가공구멍을 빠져 나가는 후퇴(exit)단계를 나타낸다. 드릴 가공 중 칩 배출 상태가 나빠지면, 주축모터파워에 급격한 변동이 생기게 되고 가공깊이가 깊어짐에 따라 변동폭이 점차 커지게 된다. 또 주절삭 날이 공작물 안으로 파고 들어감에 따라 드릴 마진부분과 가공면 사이의 마찰이 점차 증가하게 되며 이로 인해 정상상태 구간에서 주축모터 파워가 약간 증가하는 경향을 나타내는데 칩 배출이 나

빠지게 되면 증가하는 경향이 다소의 흠여짐을 가진 채 더 커진다. 본 연구에서는 진폭영역 신호처리 방법을 이용하여 칩 배출 불량시 일어나는 주축모터 파워의 이런 현상들로부터 감시를 위한 특징들을 추출하였다. 본 연구에서는 다음의 4개의 통계 값을 칩 배출 상태를 위한 특징들로 선택하였다.




Fig. 1 Example of spindle motor power and threshold method

2.1 분산/평균(Variance/Mean)비, 평균절대편차(Mean Absolute Deviation)

분산과 평균절대편차는 신호의 흠여짐 정도를 나타내는 대표적인 통계 값이다. 분산의 경우 절삭조건에 따라 절대값의 차이가 크므로 절삭조건 변화에 따른 영향을 없애기 위해 평균으로 나눈 분산/평균 비를 특징으로 선택하였다.

$$\text{평균} : \bar{x} = \frac{1}{N} \sum_{i=0}^N x_i$$

$$\text{분산} : s^2 = \frac{\sum_{i=0}^N (x_i - \bar{x})^2}{N}$$

$$\text{평균절대편차} : d = \frac{1}{N} \sum_{i=0}^N |x_i - \bar{x}|$$

여기서, x_i 는 i 번째 데이터 값, N 은 전체 데이터 개수이다.

2.2 이벤트 카운트(Event count)

이벤트 카운트는 Fig. 1와 같이 정의된 한계치 H_{th} , H_H 를 벗어난 신호의 발생 빈도를 나타낸다. 드릴의 치를 예지가 공작물 안으로 파고 들어간 후

드릴 날이 빠져 나올 때까지 T_m 시간 동안 샘플링 주기 Δt 로 $N_m = (T_m / \Delta t)$ 개의 데이터를 취한 다음 평균치를 구하고 평균치를 중심으로 한계치 H_{th} , H_H 를 설정한 후 한계치 밖의 데이터 수를 계수 한다.

$$\text{Event count} = \frac{N_t}{N_m}$$

여기서, N_t 는 한계치 밖에서 계수된 데이터 개수이고 N_m 는 총 데이터 개수이다. 본 연구에서는 평균의 $\pm 20\%$ 를 각각 한계치로 설정하였다.

2.3 기울기(Gradient)

정상상태구간에서의 주축모터파워의 기울기를 특징으로 선택하였으며 강인 추정법(Robust Estimation Method)⁽¹²⁾을 이용하여 기울기를 구하였다. 강인 추정법을 이용하면 순간적인 과부하나 센서 잡음 등으로 인한 급격한 신호 변동 성분의 영향을 감소시킬 수 있어 칩 배출로 인한 점진적 변화의 경향을 보다 정확히 구할 수 있다. 강인 추정법을 이용하여 기울기를 구하는 방법에 대해서는 부록에 소개하였다.

3. 실험장치 및 방법

Fig. 2는 실험 장치도를 나타낸다. 드릴링 작업은 수직형 머시닝 센터(Daewoo AV-30)에서 수행하였으며, 오프라인 분석을 위해 주축모터 파워신호를 비디오카세트 데이터레코더(Local V-store)에 기록하였다. 주축모터 파워 신호는 NC장치 내의 로드미터 단자로부터 검출하였으며, 고주파 성분을 제거하기 위해 저역통과필터(LPF; cut-off freq. 30Hz)를 거친 후 샘플링 주파수 500Hz로 샘플링하였다. 공작물은 S45C(경도 187 H_B)를 사용하였으며 드릴은 직경 6mm 표준 트위스트 고속도강 드릴을 사용하였다. Table 1은 실험에 사용한 절삭조건을 나타낸다. 드릴링 작업은 주어진 절삭조건하에서 새 드릴이 심각하게 마멸되어 공구교환을 할 때까지 계속적으로 수행하였으며, 한 개의 구멍가공이 끝난 후 특징 값들을 구한 다음 신경회로망을 이용하여 칩 배출 상태를 실시간으로 진단하였다.




Fig. 2 Schematic diagram of experimental setup

Table 1 Drilling conditions (drill dia.=6mm)

Test No.	cutting speed (rpm)	feedrate (mm/rev)
1	1900	0.15
2	1800	0.12
3	1900	0.17
4	1900	0.2

4. 신경회로망의 설계

본 연구에서는 오차 역전파 알고리즘에 의해 신경회로망을 학습시켰다. 신경회로망의 학습을 위해 먼저 No. 1 절삭조건하에서 학습 실험을 수행하였으며 실험으로부터 얻은 특징 벡터 중 칩 배출 정상과 불량 사이가 뚜렷이 구별되는 특징 벡터 30개-칩 배출 양호 15개, 칩 배출 불량 15개-를 학습




Fig. 3 Structure of the proposed neural network

데이터로 선택하여 신경회로망을 학습하였다. 또한 시그모이드(sigmoid)함수의 포화를 방지하기 위해 모든 특징 벡터들을 0.1-0.9사이로 정규화 시켰다.

Table 2 Learning data set for training neural network

Input nodes	Output nodes	Learning conditions
① Var./mean	Chip disposal state (good /bad)	Input node number 4
② Gradient		Output node number 1
③ Event count		Sample pattern number 30
④ Mean absolute deviation		Learning tate 0.9 Momentum rate 0.7 Shape factor 1.0 Error bound 0.01

Fig. 3은 칩 배출 상태 감시를 위해 사용된 신경회로망의 구조를 나타내며 Table 2는 신경회로망의 학습에 사용된 학습 데이터이다. 입력층의 노드 (node)수는 입력 특징의 숫자와 같게 하였고 출력층은 칩 배출 상태-양호, 불량-를 나타내는 한 개의 노드로 하였다. 은둔층의 수와 각 은둔층에서의 노드의 수가 시스템의 성능에 크게 영향을 미치기 때문에 신중하게 결정해야 하는데, 본 연구에서는 예비실험을 통해 6개의 노드 수를 가지는 1개의 은둔

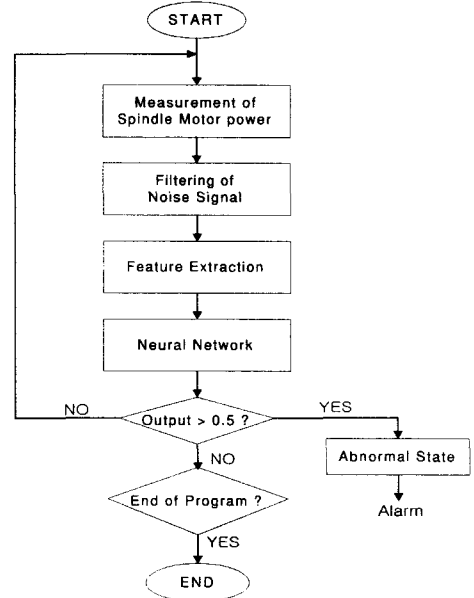


Fig. 4 Flowchart of chip disposal state monitoring algorithm

층을 선택하였다.

Fig. 4는 칩 배출 상태 감시 알고리즘을 나타낸다. 신경회로망의 출력값이 0.5를 넘으면 칩 배출 불량 상태로, 0.5이하이면 정상 상태로 진단하였으며, 진단 결과 칩 배출 불량인 경우 경보음(alarm)을 울려 작업자에게 알려주도록 하였다.


5. 실험결과 및 고찰

Fig. 5는 드릴 가공 중 검출된 주축모터파워 신호와 이때 배출된 칩들을 나타낸다. Fig. 5(a),(c)는 칩 배출이 양호한 상태에서 얻은 데이터이고 Fig.5(b),(d)는 칩 배출이 불량한 상태에서 얻은 데이터이다. 주축모터파워의 경우 두 신호 모두 주 절삭날이 공작물을 파고 들어가는 초기 단계에서는 칩 배출이 원활하므로 비교적 안정된 신호 특성을 나타내나 절입 깊이가 커짐에 따라 신호의 변동이 커지며 Fig. 5(b)의 경우가 더 심한데 이는 점차 칩 배출이 잘 되지 않기 때문이다. Fig. 5(c), (d)에서 연속형 칩은 주절삭날이 공작물을 파고 들어가기


시작할 때 배출된 것이며 절입 깊이가 깊어짐에 따라 배출된 칩들로 전단형 칩 형태를 띄고 있다. Fig. 5(d)의 경우 칩 색깔이 Fig. 5(c)에 비해 약간 보라색을 띄고 있는데 이는 칩 배출이 원활히 되지 않아 절삭토크가 커지게 되고 이로 인해 절삭온도가 증가하여 미처 배출되지 못한 칩들이 타서 생긴 결과이다. Table 3은 Fig. 5(a),(b) 각각으로부터 특징 값을 추출하고 그것을 신경회로망의 입력으로 하였을 때의 출력 결과를 나타낸다. 각 특징 값들은 칩 배출이 양호한 경우에 비해 칩 배출이 불량할 때가 더 큰 값을 갖음을 보여 준다. 신경회로망

Table 3 Input and output values in neural network
(a) good chip disposal (b) bad chip disposal

	Var/mean	Gradient	Mean absolute deviation	Event count	Output node value
(a)	0.2	0.23	0.26	0.41	0.19
(b)	0.38	0.47	0.45	0.63	0.68




(a) motor power(good)



(b) motor power(bad)



(c) good chip disposal



(d) bad chip disposal

Fig. 5 Spindle motor power signal and photo of chips for good(a) and bad(b) chip disposal during drilling (spindle speed 1900rpm, feedrate 0.15mm/rev.)

을 이용한 감시 결과 Fig. 5(b)의 경우 신경회로망의 출력 값이 0.68로 칩 배출이 불량임을 나타낸다. 칩 배출 상태에 따른 신경회로망의 일반화 능력과 칩 배출 상태 감시 시스템의 유연성을 평가하기 위해, Table 1에 열거한 다양한 절삭조건하에서 칩 배출 상태 감시를 수행하였다. Fig. 6, 7, 8은 각각 No. 1, 2, 3 절삭조건에서의 가공 중 가공시간에 따른 특징벡터의 변화와 신경회로망의 감시 결과를 나타낸다.

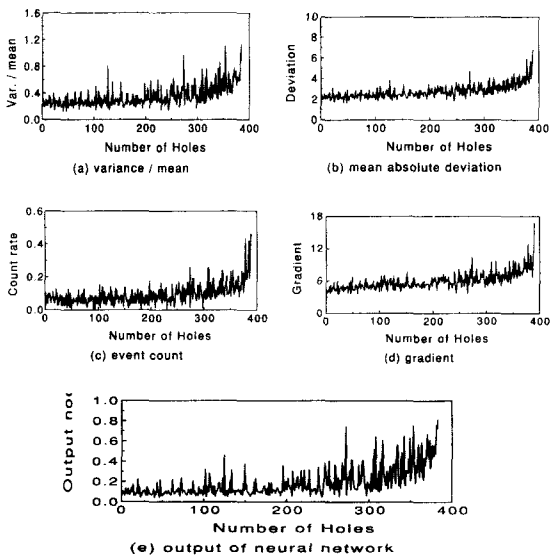


Fig. 6 Variation of features and the output of neural network with drilling time under No. 1 condition

Fig. 6은 학습조건과 같은 절삭조건하에서 수행된 감시 결과이며, Fig. 7, 8은 학습조건과는 다른 조건 수행된 작업에 대한 감시 결과이다. Fig. 6(a)-(d), Fig. 7(a)-(d), Fig. 8(a)-(d)를 비교해보면 비록 절삭조건이 서로 다르나 선택된 특징들이 절삭조건 변화에 대해서는 크게 영향을 받지 않고 칩 배출 상태가 점점 나빠짐에 따라 점차 커짐을 보여준다. 이는 선택된 특징들이 칩 배출 상태 변화에는 민감하나 절삭조건 변화에 대해서는 어느 정도 둔감함을 나타낸다. 또 처음에는 드릴마멸이 적기 때문에 칩 배출이 양호한 상태로 작업이 진행되나 가공시간이 증가함에 따라 드릴마멸이 점차 커지게 되어 칩 배출 상태도 점점 나빠짐을 알 수 있다. 각각

330번, 620번, 290번째 구멍 가공 후 초과 드릴 마멸로 인해 칩 배출 상태가 현저히 나빠졌다.

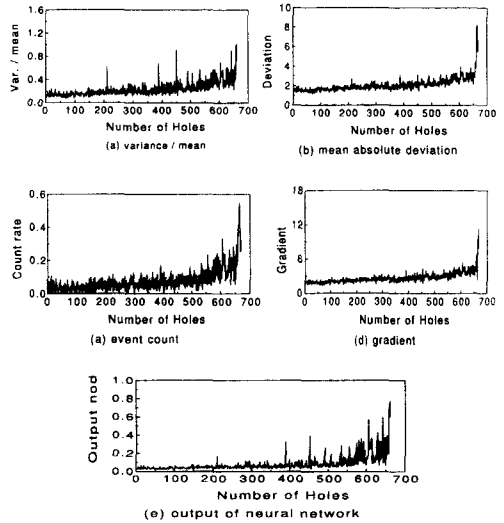


Fig. 7 Variation of features and the output of neural network with drilling time under No. 2 condition

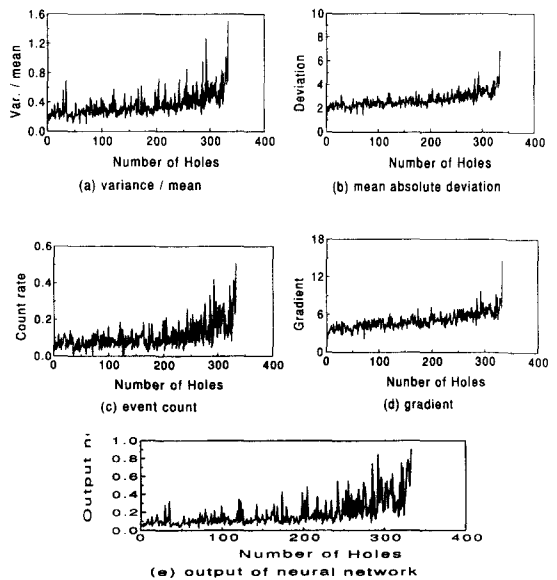


Fig. 8 Variation of features and the output of neural network with drilling time under No. 3 condition

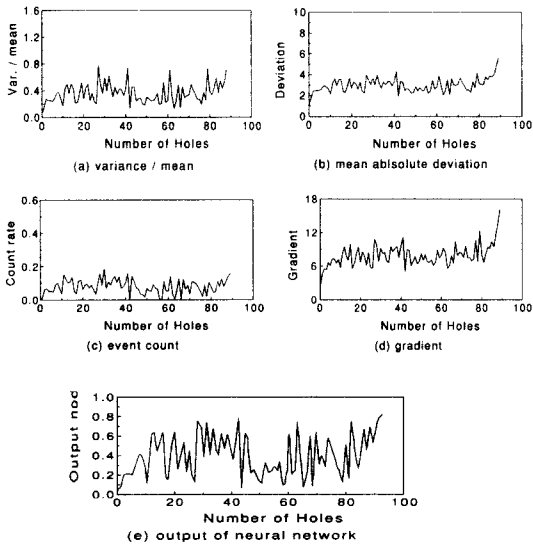


Fig. 9 Variation of features and the output of neural network with drilling time under No. 4 condition

Fig. 9는 큰 이송을 가진 No. 4 절삭조건에서 수행된 작업에 대한 감시 결과이다. 이 경우 큰 이송으로 인해 처음부터 칩 배출 상태가 나뻐지며 신경회로망의 출력 값도 처음부터 0.5보다 큰 값을 나타내는데 이는 이송이 크기 때문에 생긴 결과이다. 이 결과들로부터 제안한 칩 배출 상태 감시 시스템이 드릴 마멸 및 부적절한 절삭조건으로 인해 발생하는 칩 배출 불량 상태를 성공적으로 인식할 수 있고 선택된 특징들이 절삭조건 변화에 비교적 둔감하기 때문에 하나의 학습조건하에서 학습되었음에도 불구하고 비교적 넓은 절삭조건에 걸쳐 칩 배출 상태를 신뢰성 있게 감시해낼 수 있음을 보여준다.

6. 결론

주축모터파워 신호의 검출을 기초로 하는 신경회로망을 이용하여 드릴 가공 중 칩 배출 상태를 감시하는 칩 배출 상태 감시 시스템을 개발하였으며 그 성능을 평가하였다. 본 연구를 통해 얻은 결론은 다음과 같다.

1. 선택한 특징들-분산/평균비, 평균 절대편차, 이벤트 카운트, 기울기-이 칩 배출 상태 변화에 민감하고 절삭조건 변화에는 상대적으로 둔감함을 알 수 있다.
2. 칩 배출 상태 감시를 위해 개발한 신경회로망이 드릴마멸 및 부적절한 절삭조건으로 인해 생기는 칩 배출 불량 상태를 성공적으로 인식하였다.
3. 하나의 학습조건하에서 학습했음에도 불구하고 제안한 칩 배출 감시 시스템이 비교적 넓은 절삭조건에 걸쳐 신뢰성 있게 칩 배출 상태를 감시하는 능력을 갖고 있음을 알 수 있다.

참고문헌

1. H. K. Tonshoff, W. Konig, "Machining of Holes Developments in Drilling Technology," Annals of the CIRP, Vol. 43., No. 2, pp. 551-561, 1994.
2. J. Tlustý, G. C. Andrews, "A Critical Review of Sensors for Unmanned Machining," Annals of the CIRP, Vol. 32., No. 2, pp. 563-577, 1983.
3. G. Byrne, D. Dornfeld, I. Inasaki, G. Ketteler, W. Konig, and R. Teti, "Tool Condition Monitoring(TCM)-The Status of Research and Industrial Application," Annals of the CIRP, Vol. 44, No.2, pp. 541-567, 1995.
4. J. L. Stein, C. H. Wang, "Analysis of Power Monitoring on AC Induction Drive Systems," Journal of Dynamic System, Measurement, and Control, Vol.112, pp. 239-248, 1990.
5. J. L. Stein, et al, "Evaluation of DC Servo Machine Tool Feed Drives as Force Sensors," ASME Journal of Dynamic Systems, Measurement, and Control, Vol. 108, DEC., pp. 279-288, 1986.
6. S. Rangwala, D. Dornfeld, "Learning and Optimization of Machining Operations Using Computing Abilities of Neural Networks," IEEE Transactions on Systems, Man and Cybernetics, Vol.19, No.2, pp. 299-314, 1989.
7. T. I. Liu and E.J. Ko, "On-line Recognition of Drill Wear via Artificial Neural Networks," ASME book Monitoring and Control For Manufacturing

- Process, pp. 101-110, 1990.
8. Tae Jo Ko and Dong Woo Cho, "Cutting State Monitoring in Milling By a Neural Network," Int. J. Mach. Tools Manufact, Vol. 34, No. 5, pp. 659-676, 1994.
 9. T. I. Liu and K. S. Anantharaman, "Intelligent Classification and Measurement of Drill Wear," ASME Journal of Engineering for Industry, Vol. 116, AUG., pp. 392-397, 1988.
 10. I. N. Tansel, et al, "Monitoring Drill Conditions with Wavelet Based Encoding And Neural Networks," Int. J. Mach. Tools Manufact, Vol. 33, No. 4, pp. 559-575, 1993.
 11. Pao, Adaptive Pattern Recognition and Neural Networks, Addison-Wesley, 1989.
 12. William H. Press, et al., Numerical Recipes in C -2nd Ed., Cambridge University Press, 1992.

부 록

A. 강인 추정법⁽¹²⁾

-절대 편차를 최소화하는 직선식 모델링-

주어진 일련의 측정 데이터 (x_i, y_i) 를 $\hat{y}_i = a + bx_i$ 로 직선화 하고자 할 때, 측정데이터와 직선식 모델 사이의 절대 편차의 합 $\sum_{i=1}^N |y_i - a - bx_i|$ 를 최소화하는 직선식 \hat{y}_i 는 다음 식들을 동시에 만족하는 a, b를 구하므로 얻을 수 있다.

$$a = \text{median} \{ y_i - bx_i \}$$

$$b = \frac{\sum_{i=1}^N x_i \text{sgn}(y_i - a - bx_i)}{N}$$

$$\begin{aligned} \text{sgn}(y_i - a - bx_i) > 0 \text{ 일때, } & 1 \\ \text{sgn}(y_i - a - bx_i) = 0 \text{ 일때, } & 0 \\ \text{sgn}(y_i - a - bx_i) < 0 \text{ 일때, } & -1 \end{aligned}$$

여기서, median{ }는 중앙값(median), N은 데이터 총 개수, (x_i, y_i) 는 i번째 측정 데이터를 나타낸다.