

## 드릴가공시 신경망에 의한 공구 이상상태 검출에 관한 연구

신형곤<sup>\*</sup>, 김민호(전북대 대학원), 김태영(전북대 기계공학부, 자동차신기술 연구소),  
김대성(기아자동차)

A Study on the Detection of the Abnormal Tool State for Neural Network in Drilling

H.G Shin\*, M.H. Kim(Graduate School, Chonbuk Nat'l Univ.), T.Y. Kim(Chonbuk Nat'l Univ.).  
D.S. Kim(KIA MOTORS)

### ABSTRACT

Out of all metal-cutting processes, the hole-making process is the most widely used. It is estimated to be more than 30% of the total metal-cutting process. It is therefore desirable to monitor and detect drill wear during the hole-drilling process.

In this paper, the vision system of the sensing methods of drill flank wear on the basis of image processing is used to detect the wear pattern by non-contact and direct method and get the reliable wear information about drill. In image processing of acquired image, median filter is applied for noise removal. The vision flank wear area of the drill was measured.

Backpropagation neural networks (BPNs) were used for on-line detection of drill wear. The neural network consisted of three layers, input, hidden and output. The input vectors comprised of spindle rotational speed, feed rates, vision flank wear, thrust and torque signals. The output was the drill wear state which was either usable or failure. Drilling experiments with various spindle rotational speed and feed rates were carried out. The learning process was performed effectively by utilizing backpropagation. The detection of the abnormal states using BPNs achieved 96.4% reliability even when the spindle rotational speed and feedrate were changed.

**Key Words** Drill wear(드릴마모), Backpropagation neural networks(오류역전파 신경회로망)

### 1. 서론

드릴가공은 드릴날, 다양한 속도 그리고 절삭작들의 복잡한 기하학들에 기인하는 어려운 가공이며, 전반적인 가공과정들 중에서 가장 많이 사용되기 때문에, 생산 현장에서 가장 흔한 과정들 중의 하나이다. 그러므로, 드릴파손으로 인한 제품 손상 및 정지시간의 증가는 경제적으로 큰 손실을 초래한다 특히 가공 중에 드릴 파손이 발생하게 되면 가공물을 버리거나 후처리하는데 시간적, 경제적으로 비용이 많이 들게 된다. 따라서 공구 마모상태에 대한 제반관리가 이루어져야 하며, 공구의 과도한 마모 및 파손을 감지 또는 예측할 수 있는 시스템 개발이 시급한 과제로 남아 있다. 그래서 많은 연구들이 행해졌는데, 최근에는 신경회로망을 이용한 연구가 진

행되고 있다. 신경회로망은 예측 작업과 분류, 검색 할 수 있는 컴퓨터 시스템들의 빙렬적인 연결이다. 이것은 높은 정밀도가 있고, 비선형 함수를 위한 모델링 뿐만 아니라, 소음에 의해 누락되어지는 데이터의 특성을 인식할 수 있다. 이런 확고성 때문에 신경망은 최근에 연구가들에게 많은 연구 과제로 떠오르고 있다. 기계 처리 과정을 자동적으로 모니터링하고 센서로 얻어진 불완전한 데이터를 다루기 위해 사용된다. Govekar와 Grabc<sup>1)</sup>는 자기 조직 신경회로망을 모우멘트와 절삭력 신호들로부터 플랭크 마모를 분석하는데 적용하였다.

본 연구에서는 많은 장점을 가진 신경망을 이용하기 위해, 공구동력계와 컴퓨터 영상처리를 통해서 추출된 패턴을 종합 분석하여, 공구 이상상태를 최종 결정하기 위한 신경회로망의 입력패턴으로 제시

되었다. 또한, 신경 회로망의 학습을 효과적으로 수행하기 위한 학습규칙으로 오류 역전파(back-propagation) 학습규칙을 사용하였다. 이 오류 역전파 학습 방법은 다층 퍼셉트론을 위한 학습 알고리즘으로서 신경 회로망의 학습패턴 중 한 입력이 주어졌을 때 주어진 입력에 대해 기대되는 패턴과 일치되는 출력을 생성할 수 있도록 자신의 내부 조직을 구성해 나간다. 일단 신경 회로망이 학습 샘플의 입력 패턴과 출력 패턴 사이의 맵핑 관계를 학습하면 전에 알려지지 않은 새로운 입력이 행해졌을 때 학습에 의해 내적으로 축적된 지식에 기초해서 가장 유사한 출력패턴을 발생시킨다. 그러나 이 역전파 학습규칙은 학습이 수렴할 때까지 많은 횟수의 반복 학습이 필요하다는 단점을 가지고 있다. 이러한 단점을 보완하기 위한 연구결과 1개의 은닉층을 가지는 경우보다 2개의 은닉층을 가지는 경우가 더 많은 분류 경계를 가짐으로 분류 기능이 뛰어나고, 학습 수렴 속도가 더 빠르다는 것이 보고되었다.

따라서 본 연구에서는 2개의 은닉층을 가지고도록 신경 회로망을 모델링하였다. 이렇게 구축된 신경회로망에 각 센서에서 나오는 신호를 종합 분석하여 공구 이상상태를 효과적으로 알려준다.

## 2. 실험장치 및 방법

### 2.1 시험편 및 사용공구

본 실험에 사용한 재료는 인장강도  $80\text{kg/mm}^2$ 급의 고장력 열연강판이며, 그 각각의 화학적 성분 및 기계적인 성질은 Table 1 및 Table 2에 나타내었다. 시험편은 열연강판을  $200 \times 130 \times 7\text{mm}$ 이 되도록 만들었으며, 하나의 시험편에 40회의 가공을 하였고, 실험에 사용한 드릴은 Φ6인 고속도강 드릴로 실험하였다.

Table 1 Chemical compositions of workpiece(wt %)

Material	C	Si	Mn	P	S	Nb	Ti	Mo
specimen	0.10	0.15	2.00	0.02	0.005	( )	( )	( )

Table 2 Mechanical properties of workpiece

Material	Yield strength ( $\text{kg/mm}^2$ )	Tensile strength ( $\text{kg/mm}^2$ )	Elongation (%)	Hardness (Hv)
specimen A	65	80	14	215

### 2.2 실험방법

본 실험에 사용한 공작기계는 CNC 밀링머신(HNC-150)이다. 주축에 드릴을 고정시켰으며, 시험편 설치는 테이블에 공구 동력계를 연결하고, 그 위에 시험편을 고정시킨 jig를 부착하여 드릴 가공하였

다. 실험에서 사용한 장비는 CCD 카메라, 화상입력보드(Data Translation, DT3155), 컴퓨터로 구성하였다. 획득된 절삭력 데이터는 데이터 분석 프로그램에 의해 X와 Y축에 평균값을 신호 획득 시간으로 환산하여 컴퓨터에 저장하였다. 얻어진 값을 가져야 하므로 전처리 과정을 거친다. 한편, 드릴의 마모량 측정은 드릴작업이 멈추면 공압시스템의 ON 스위치를 작동시켜 실린더에 부착되어 있는 CCD 카메라가 이동하여 플랭크 마모를 측정한다. 마모의 영상은 CCD 카메라를 통해 프레임 그레이버(frame grabber)에 의해 256 밝기 등급으로 컴퓨터에 저장되며 이 영상을 컴퓨터에서 분석하였다. 플랭크 마모의 영상을 획득하고, 마모 면적을 계산한 후 절삭회전수, 이송량, torque, thrust 공구마모의 인자를 인공신경망 프로그램에 매입하여 공구의 마모를 판성하였다. Fig 1은 CNC 밀링머신과 각 장비의 배치를 보여준다.

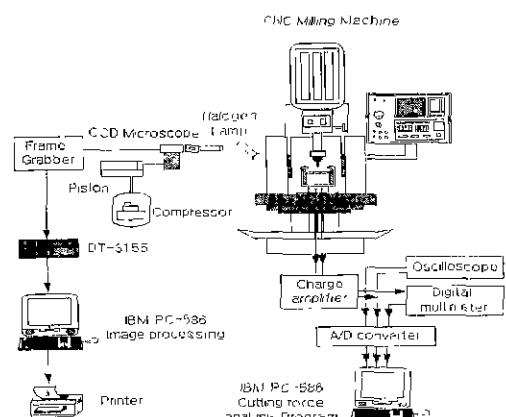


Fig. 1 Block diagram of the data acquisition system

## 3. 실험결과 및 고찰

### 3.1 영상처리를 이용한 드릴마모의 분석

본 실험에서는 실시간으로 드릴마모를 분석하기 위해서 컴퓨터 영상 처리 시스템을 사용하였다. 실시간으로 CCD(charge coupled device) camera를 통해 가공구멍 횟수의 증가에 따라서 마모된 드릴날 영상을 촬영하였다. 획득한 영상은 이론부에서 거론한 필터링 기법을 이용하여 잡음을 제거하고, 배경과 마모부분을 흑과 백의 2치처리를 수행한 후, 마모면적을 구한다. 드릴 마모 면적은 Fig 2-3 (b)와 같이 전체 마모 면적의 70%를 플랭크 마모로 규정한 면적을 계산하는 알고리즘을 개발하여 측정하였다.

Fig. 2(a)는 절삭회전수  $n=1000\text{rpm}$ , 이송량  $f=0.12\text{mm/rev}$ 의 조건으로 가공하였을 때, 드릴 파괴가 일어나기 직전인 1200번 째의 공구마모 영상을 보

여룬다 전반적으로 화소값들이 불균일하게 분포되어 있어 인터페이스 이 영상을 고대비에서 저대비로 변환하기 위하여 인터레이싱 작업을 하고, 고주파 잡음을 감소시키기 위해서 미디안 필터링을 하였다. 2진 영상을 구성하는데는 쓰레스홀딩 값이 필요하게 되는데 각 절삭 조건에 따라 가공한 가공면의 영상에는 각기 다른 정보를 갖고 있으므로 이와 같은 조건에 따른 쓰레스홀딩 값을 100으로 하여 적용하였다 Fig 2(b)는 쓰레스홀딩한 2진 영상을 나타내고 있다

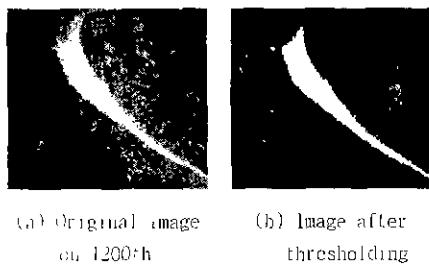


Fig. 2 Image processing procedure

본 논문에서는 필터링 작업을 행한 2진 영상으로부터 공구 마모 면적을 계산하는 알고리즘을 개발하였다. Fig 3은 절삭회전수  $n=1200\text{rpm}$ 으로 고정시키고 이송량을  $f=0.10\text{mm/rev}, 0.12\text{mm/rev}, 0.15\text{mm/rev}$ 로 변화시켰을 때, 컴퓨터 영상 시스템을 이용한 공구마모 면적을 나타내었다. 그림에서 나타난 것처럼, 가공구멍수의 증가에 따라 플랭크 마모면적이 증가함을 알 수 있으며, 절삭회전수 및 이송량의 증가에 따라서 플랭크 마모가 증가함을 알 수 있다 이는 많은 연구들과 비슷함을 알 수 있다.

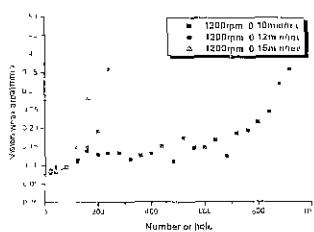


Fig. 3 Vision wear area after filtering by Computer image System( $n=1200\text{rpm}$ )

### 3.2. 신경회로망에 의한 데이터 분석

본 연구에서는 thrust와 torque와 컴퓨터 영상처리 시스템을 이용한 비전 마모 면적을 신경회로망에 입력하여 공구 파손을 감지하는 기법을 시도하였다.

드릴에서의 절삭력은 절삭조건에 따라 심하게 변화하므로, 직접 신경회로망에 입력하기가 매우 까다롭다 따라서 모든 thrust와 torque 데이터는 전처리 방식을 거쳐서 신경회로망에 입력된다 본 연구에서는 구멍가공후의 평균 thrust와 평균 torque를 구한 후 각각 1회 가공시의 데이터를 나누는 방법을 선택하였다 전처리 방식을 거친 데이터는 신경회로망의 입력에 알맞은 값의 범위로 변환되며 절삭력 상수로 적절하게 일반화되었다

Fig 4는 철삭 회전수  $n=1000\text{rpm}$ , 이송량  $f=0.15\text{mm/rev}$ 의 조건으로 가공할 때의 드릴 thrust를 나타내고 있다. 그림에서 thrust가 110~130kgf 값을 일정하게 유지하다가 238번째 이후 25~250kgf의 값으로 급격히 변화한다 따라서 절삭조건에 따라 그 전체적인 값들이 변하므로 그대로 신경회로망에 입력하여 처리하기에는 많은 시간이 낭비될 뿐만 아니라 처리하기도 쉽지 않다 따라서 전처리 과정이 필요하다

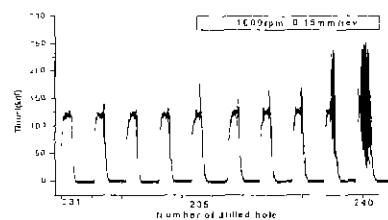


Fig. 4. Cutting force( $n=1000\text{rpm}$ ,  $f=0.15\text{mm/rev}$ )

Fig. 5는 전처리 방식을 Fig 4에 적용했을 때, 얻어지는 절삭력 상수를 나타낸 그래프이다 절삭력 상수의 값이 0~2사이의 값을 나타낸다 신경회로망의 입력조건에서 처리시간의 이익을 얻고, 계산이 복잡해짐을 피하여 0과 2 사이의 값들로 입력하도록 제시한 조건에 부합되었다

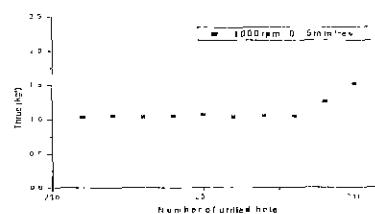


Fig. 5 Graph of preprocessed data( $n=1000\text{rpm}$ ,  $f=0.15\text{mm/rev}$ )

본 연구에서는 thrust, torque, spindle rotational speed, feed 인자와 컴퓨터 영상처리 시스템을 이용하여 구한 마모 면적을 입력으로 하는 오류 역전파

(backpropagation) 신경회로망을 사용하였다. Fig. 6은 본 실험에 사용된 신경회로망 구조를 나타내고 있다. 다중인자의 구조는 입력 5, 은닉층 2이고 노드는 7과 3, 출력은 1인 5-7-3-1 구조를 사용하였다. 노드 수는 20번의 실험을 거쳐 가장 최적의 노드수를 택하였다. 출력층은 0에 가까운 값을 가지면 정상상태를 1에 가까운 값을 가지면 공구의 풀랭크 마모 VB=0.3에 이르는 마모나 파손 등이 일어났음을 나타낸다. 학습률은 0.8 모멘텀은 0.6으로 하였으며 반복 학습은 10,000회로 제한하였다. 전체 최대오차가 0.0005보다 작게 학습하였다.

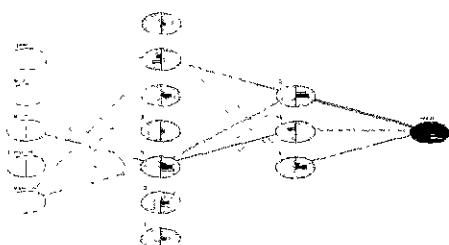


Fig. 6 Structure of the proposed neural network

학습 과정이 진행됨에 따라 학습 오차가 수렴되어 가는 과정을 Fig. 7에 나타내었다. 신경회로망의 반복 학습을 30번까지 수행하였을 때 학습 오차의 변화량이 급격히 줄어들다가 반복 횟수가 증가함에 따라 점진적으로 감소하여 수렴해 가는 것을 알 수 있다. 본 연구에서 구현한 신경회로망은 370번까지 반복 학습시킴에 따라 오차가 0.0005까지 줄어듬을 알 수 있고, 학습 폐편을 입력으로 제시하여 출력 폐편을 조사한 결과 학습이 성공적임을 알 수 있었다.

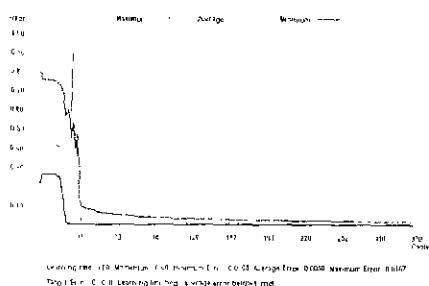


Fig. 7 Convergence of learning error versus number of iterations in the training process

Fig. 8은 오류 역전파 신경회로망을 이용한 결과를 나타내고 있다. 그림에서 보는 것처럼 정상상태일 때는 약간 증가하면서, 공구가 갑자기 파괴되는 부근에서 1 극치로 뛰어 오르는 값을 가지며 명확한 공구마모임을 알려주었다. 이것은 학습 과정을

거친 신경회로망이 정확한 신호 폐편 분류를 할 수 있음을 알려준다.

이상의 결과에서 보는 바와 같이 신경회로망은 공구의 상태를 감지하는데 있어서 매우 유용하게 쓰일 수 있다.

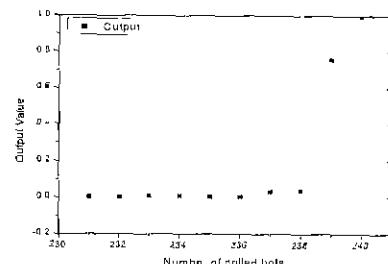


Fig. 8 Output data of neural network vs number of drilled hole

#### 4. 결 론

본 연구에서는 고장력 열연강판의 드릴작업시 신경회로망을 이용하여 공구마모를 검출하는 시스템을 구축하였다. 이번 연구를 통하여 다음과 같은 결론을 얻을 수 있었다.

1. 오류 역전파 신경회로망을 이용한 결과가 1에 가까운 값들을 출력함으로써 간접적으로 공구 상태를 감지하기에 충분하였다.
2. 공구동력계에 의한 신호와 컴퓨터 영상처리 시스템을 통해 구한 공구 마모를 입력으로 하는 오류 역전파 신경 회로망은 생산 현장에서 자동화, 무인화에 실제적인 적용 가능성이 있음을 보여준다.

#### 참고문헌

- 1 Govekar E and Grabec, I, "Self-Organizing Neural Network Application to Drill Wear Classification." ASME Journal of Engineering For Industry, Vol 116, May 1994, pp 233-238
- 2 Sandeep S. Jaiswal "Prediction of Tool wear using Neural Networks". The University of Alabama in Huntsville, 1999
- 3 J. Mou, "A Method of Using Neural networks and Inverse Kinematics for machine Tools Error Estimation and Correction". ASME Journal of manufacturing Science and Engineering , Vol 119, pp.247-254, 1997
- 4 Lum K Y "A Study on Cutting Tool Damage Detection using Neural Network and Cutting Force Signal", Chonbuk National University, 1997