

신경망에 의한 공구 이상상태 검출에 관한 연구

신형곤* · 김태영**

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

Hyung-Gon Shin and Tae-Young Kim

Key Words: Drill wear(드릴마멸), Backpropagation neural networks(오류역전파 신경회로망)

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. One important aspect in controlling the drilling process is monitoring drill wear status. Accordingly, this paper deals with Basic system and Online system. Basic system comprised of spindle rotational speed, feed rates, thrust, torque and flank wear measured tool microscope. Online system comprised of spindle rotational speed, feed rates, AE signal, flank wear area measured computer vision. On-line monitoring system does not need to stop the process to inspect drill wear. Backpropagation neural networks (BPNs) were used for on-line detection of drill wear. This paper deals with an on-line drill wear monitoring system to fit the detection of the abnormal tool state.

1. 서론

드릴가공은 드릴날, 다양한 속도 그리고 절삭 각들의 복잡한 기하학들에 기인하는 어려운 가공이며, 전반적인 가공과정들 중에서 가장 많이 사용되기 때문에 생산 현장에서 가장 혼란 과정들 중의 하나이다. 그러므로 드릴파손으로 인한 제품 손상 및 정지시간의 증가는 경제적으로 큰 손실을 초래한다. 따라서 공구의 과도한 마멸 및 파손을 가공도중 자동적으로 판단하는 시스템의 개발이 시급한 과제로 남아 있다. 특히 드릴가공 중 발생하는 공구의 상태는 가공물의 표면거칠기와 가공정밀도 등에 영향을 미치므로 절삭 중 공구마멸 상태를 미리 진단함으로써 가공물에 이상

이 발생하기 전의 적절한 시기에 공구를 교환할 수 있어야 한다.

예측 시스템의 성능은 적절한 감시 신호와 신뢰성 있는 진단 알고리즘의 선정에 크게 의존되며, 현재 사용되는 신호로는 모터 전류, 절삭력, AE 신호, 광학 센서를 이용한 방법들이 있다.[1,2] 본 실험에서는 공구동력계를 사용하여 얻어지는 절삭력 신호와 공구현미경으로 공구 마멸의 측정하는 가장 기본적인 시스템을 구성하였고, 또한 가공과정에서 자동적으로 모니터 되어지는 AE 신호와 CCD 카메라를 사용하여 영상신호로 플랭크 마멸면적을 측정하도록 온라인 시스템을 구성하였다.

한편, 예측 진단 알고리즘으로는 지적 정보처리 기술로서 지식이나 경험을 바탕으로 한 전문가 시스템과 추론에 의한 퍼지 및 신경망 모델 등이 있다.[3,4] 이 중에서도 신경회로망 분야는 다양한 알고리즘의 영향으로 최근 연구가 활발히 수행되고 있다. Govkar와 Grabec[3]는 자기 조직

* 전북대강사

** 전북대 기계공학부

신경회로망을 모우멘트와 절삭력 신호들로부터 플랭크 마멸을 분석하는데 적용하였다. S. Rangwala와 D.A. Dornfeld[4]는 AE와 절삭력 센서의 융합에 의한 신경망 모델을 이용하여 공구상태 진단을 성공적으로 수행하였다.

본 연구에서는 공구동력계와 현미경으로 구성된 기본시스템과 AE 신호와 영상신호로 구성된 온라인 시스템을 통해서 추출된 패턴을 분석하여 신경회로망의 입력패턴으로 제시하였고, 신경 회로망의 학습을 효과적으로 수행하기 위한 학습규칙으로는 오류 역전파(back-propagation) 학습 규칙을 사용하였다. 구성된 두 가지 시스템으로부터 특징들을 추출하고 비교하여 보았고, 드릴 가공 중 공구 이상상태를 온라인 상에서 효과적으로 예측이 가능한지를 신경회로망을 이용하여 제시하였다.

2. 신호의 처리과정

2.1 신호의 획득


드릴가공에서 절삭력의 해석은 절삭조건, 절삭 공구의 형상과 재질, 공구의 마모, 피삭재의 재질과 형태 등이 관계가 되어 복잡하지만 공작기계의 부품과 공구의 마모 및 파손의 검출을 위해서는 가장 기본적으로 사용되는 것이 절삭력이다. 그래서 공구의 이상상태를 알기 위한 감시신호의 인자로 공구동력계를 통한 절삭력 신호인 트러스트와 토오크를 택하였다.

드릴 가공시 발생하는 절삭력 모델링과 음향에너지와의 관계는 절삭력 또는 AE(Acoustic Emission)에 근거를 둔 절삭과정 모니터링의 기본적인 방법이다.[5] AE 신호의 진동수는 공구의 동적인 행동과 함께 방출되어지는 진동수보다 크기 때문에 그 신호는 오로지 절삭과정과 관계되어 있다. 산업현장에 적용하기 위해 기계가공 과정을 상대적으로 쉽게 모니터링하는 방법이 제시되고 있으며, AE 센서에 의해 검출되는 출력신호는 신뢰할 수 있고, 진행되어지는 절삭과정의 특성을 검출할 수 있는 장점을 가지고 있어서 AE 신호를 감시 신호의 인자로 선택하였다.

한편, 영상처리 기법은 드릴마멸의 영향을 직접적으로 측정하기 때문에 신뢰성과 정확성이 높다. 실시간으로 CCD(charge coupled device)를 통해 가공구멍수의 증가에 따라서 마멸된 드릴날 영상을 촬영하였다. 획득한 영상은 필터링 기법

을 이용하여 잡음을 제거하고, 배경과 마멸부분을 흑과 백의 2치처리를 수행한 후 드릴의 마멸면적을 구하였다. 드릴의 마멸면적은 전체 마멸면적의 70%를 플랭크 마멸로 규정한 면적을 계산하는 알고리즘을 개발하여 측정하였다.

Fig. 1은 절삭회전수 $N=1000\text{rpm}$, 이송량 $f=0.12\text{mm/rev}$ 의 조건으로 가공하였을 때, 드릴 파괴가 일어나기 직전인 1200번째의 공구마멸 원영상과 2진영상을 나타내고 있다. (a)의 원영상을 인테레이싱 작업과 미디안 필터링을 하였고, 필터링 과정을 거친 후 플랭크 마멸의 에지 검출을 용이하게 하기 위해서 2진 영상으로 만들었다. (b)는 변환한 후의 영상을 보여주고 있는데, 흑과 백의 2진 영상으로 변환되었음을 알 수 있다. 이 2진영상을 마멸면적으로 계산할 수 있도록 프로그램을 개발하여 플랭크 마멸면적을 구하였다. 여기서 구한 플랭크 마멸면적을 감시신호의 인자로 선택하였다.



(a) Original image (b) binary image

Fig. 1 Original image and binary image of flank wear ($N=1000\text{rpm}$, $f=0.12\text{mm/rev}$, $n=1200$)

2.2 신호의 전처리과정

여러가지 절삭작용에서 절삭력은 그 크기나 방향이 절삭방법, 가공재료 및 기타의 절삭조건에 따라 달라진다. 드릴 가공에서의 절삭력은 그 절삭 파라미터가 변함에 따라 변화가 심하므로 신경회로망을 이용한 분류 예측기에 그대로 입력시킬 수 없다. 그래서 시그모이드(sigmoid)함수의 포화를 방지하기 위해 신경회로망의 입력 데이터는 0에서 3까지의 값을 갖도록 정규화하는 특별한 전처리 과정이 필요하다.

첫 단계는 얻어진 데이터들의 평균값들을 취하고, 이때 평균값은 실제 절삭시간에 대한 평균값이 된다.

$$F_{avg} = \frac{\sum_{i=1}^n F_{xi}}{n} \quad (1)$$

F_z : 순간적인 thrust

n : 비절삭시 들어온 신호를 제외한 1회 가공시 샘플수

F_{avg} : thrust의 평균 절삭력

다음 단계는 앞에서 구한 각 방향의 평균 트러스트와 토크를 원래의 힘들에 대해 나누어주는 단계로써 이 단계를 거치면 대부분의 절삭력이 0에서 3사이의 값이 되어 신경회로망의 입력에 적당한 데이터를 가지게 된다. 이때 만들어진 새로운 값을 절삭력 상수라 명명하기로 한다. 이와 같은 방법으로 구한 절삭력 상수와 일반화된 절삭 파라미터를 신경회로망에 입력시킨다.

$$P_{fj} = \frac{F_{xj}}{F_{avg}} \quad (2)$$

P_{fj} : j번째 데이터의 트러스트의 절삭력 상수

F_{xj} : j번째의 트러스트의 절삭력

F_{avg} : 트러스트의 평균절삭력

AE 신호와 영상신호도 동일한 방법으로 각각 AE 상수, 영상상수를 구한 후 신경회로망에 입력시킨다.

3. 실험장치 및 방법

본 실험에 사용한 재료는 인장강도 80kg/mm²급의 고장력 열연강판이다. 시험편은 열연강판을 200 × 130 × 7mm이 되도록 만들었으며, 하나의 시험편에 40회의 가공을 하였고, 실험에 사용한 공구는 $\Phi 6$ 인 고속도강 드릴이다. 드릴작업을 수행하기 위하여 CNC 밀링머신의 테이블 위에 드릴용 압전형 공구동력계(tool dynamometer : Kistler, 9271A)를 설치하였다. 가공형태는 5회씩 관통 가공하였으며, 공구의 수명 판단 기준은 플랭크 마멸 VB=0.3mm로 정하였다. 드릴의 돌출길이는 80mm이며, 건절삭을 수행하였다.

드릴 가공시 발생하는 AE 신호를 얻기 위해 AE 시스템을 사용하였고, AE 신호는 증폭기에서 100-300kHz의 plug-in filter를 사용하여 소음을 제거한 후 40dB로 증폭되었다. 이 신호는 AE 시스템에서 100-1200kHz의 필터를 통과한 후 시스템의 신호처리를 위해 A/D converter에서 디지털화

하여 컴퓨터로 분석하였다.

드릴의 마멸량 측정은 구멍을 5회 가공한 후 드릴작업이 멈추면 공압시스템의 스위치를 작동시켜 실린더에 부착되어 있는 CCD 카메라로 드릴의 플랭크 마멸면적을 측정하였으며 공구를 탈착하여 공구현미경으로도 측정하였다. 플랭크 마멸면적의 영상은 CCD 카메라를 통해 프레임 그라버(frame grabber)에 의해 256 밝기 등급으로 컴퓨터에 저장되며 이 영상을 컴퓨터에서 분석하였다.

4. 신경회로망의 설계

본 연구에서는 공구동력계를 사용하여 얻은 트러스트, 토크 인자와 공구현미경으로 측정된 플랭크 마멸을 인자로 하는 기본시스템의 입력패턴과 온라인 상에서 측정이 가능하도록 구성한 온라인 시스템 즉, AE 신호와 컴퓨터 영상처리를 이용하여 구한 플랭크 마멸면적을 입력 인자로 하는 입력패턴을 오류 역전파(backpropagation) 신경회로망을 사용하여 학습시켰다. Table 1은 신경망의 학습에 사용한 인자들을 보여준다.

신경회로망 학습을 위해 실험한 모든 특징 데이터들을 앞에서 설명한 것처럼 전처리를 하여 0에서 3사이로 정규화하였다. 전처리 과정을 수행한 후 온라인 시스템의 학습데이터를 Table 2에 나타내었다. 이 때의 절삭조건은 절삭회전수 N=1000rpm에서 이송량을 f=0.1, 0.12, 0.15mm /rev로 변화시키면서 가공한 것이며, 이와 같은 방법으로 절삭회전수 N=1200rpm과 N=1500rpm에서의 데이터도 학습을 시켰다.

Table 1 Learning data set for training neural network

| system | Input nodes | Output nodes |
|---------------|--|---------------------------------------|
| Basic system | 1. cutting speed(rpm) 2. feedrate(mm/rev) 3. thrust(kgf) 4. torque(kgf · cm) 5. flank wear(mm) | Abnormal tool state (non-wear / wear) |
| Online system | 1. cutting speed(rpm) 2. feedrate(mm/rev) 3. AE RMS(mv) 4. flank wear area(mm ²) | |

Table 2 Input data for training a neural network (online system)

| rpm | feedrate | AE RMS | wear area | out |
|-----|----------|--------|-----------|-----|
| 0.5 | 0.5 | 0.54 | 0.53 | 0 |
| | 0.5 | 0.85 | 0.8 | 0 |
| | 0.5 | 1.26 | 1.09 | 0 |
| | 0.5 | 1.62 | 1.93 | 1 |
| | 1 | 0.58 | 0.64 | 0 |
| | 1 | 0.93 | 0.93 | 0 |
| | 1 | 1.35 | 1.43 | 0 |
| | 1 | 1.72 | 2.01 | 1 |
| | 1.5 | 0.94 | 0.98 | 0 |
| | 1.5 | 1.38 | 1.43 | 0 |
| | 1.5 | 1.81 | 2.08 | 1 |

기본시스템 다층인자의 구조는 입력 5, 은닉층 1이고 노드는 7, 출력은 1인 5-7-1 구조를 사용하였고, 온라인에서 다층인자의 구조는 입력 4, 은닉층 1이고 노드는 5, 출력은 1인 4-5-1 구조를 사용하였다. Fig. 2는 온라인 신경회로망 구조를 나타내고 있다. 출력층은 학습률을 0.8로 하여 신경회로망의 출력값이 0.8미만이면 정상이고, 0.8을 넘어서 1에 가까운 값을 가지면 공구의 플랭크 마멸 $V_B=0.3\text{mm}$ 이상에 이르러 마멸이나 파손 등이 일어났음을 나타낸다. 모멘텀은 0.8, 반복학습은 10,000회로 제한하였으며, 전체 최대오차가 0.0005보다 작게 학습하였다.




Fig. 2 Structure of the proposed neural network

5. 실험결과 및 고찰

5.1 절삭특성 및 드릴마멸의 분석

Fig. 3는 가공 구멍수의 증가에 대하여 공구현미경으로 측정된 플랭크 마멸의 변화와 컴퓨터 비전을 이용하여 측정된 플랭크 마멸면적과의 관계를 비교한 것이다. 두 그래프 모두 가공구멍수의 증가에 따라 플랭크 마멸과 플랭크 마멸면적이 증가하며, 마멸의 증가하는 경향은 모든 가공 과정에서 길이와 면적의 비만큼의 차이를 두고

대부분 일치함을 보여준다. 따라서, 온라인 상에서 공구마멸의 측정방법의 하나로 컴퓨터 비전을 이용하여 플랭크 마멸의 면적을 측정하는 방법도 유용하다는 것을 알 수 있었다.(12)




Fig. 3 Comparison of flank wear and flank wear area measurement by tool microscope and computer vision(N=1200rpm, f=0.1mm/rev)

Fig 4는 가공 구멍수의 증가에 대해 컴퓨터 비전을 사용하여 촬영한 플랭크 마멸면적과의 결과를 나타내었다. 그림에서 컴퓨터 비전으로 측정된 플랭크 마멸면적이 가공구멍수의 증가에 대해 각각의 절삭회전수에서 모두 증가하는 경향을 보여주었다. 또한 플랭크 마멸이 서서히 증가하는 곳에서나 급격히 증가하는 곳에서 플랭크 마멸면적으로 검출이 가능하다는 것도 알 수 있다. 따라서 컴퓨터 비전을 이용한 마멸면적의 평가가 마멸에 대해 민감한 반응을 보여주므로 온라인 상에서 공구의 이상상태를 예측하는데 적합함을 알 수 있었다.




Fig. 4 Variation in flank wear area with number of holes on specimen A(d=6mm, f=0.1mm/rev)

5.2 신경회로망에 의한 데이터 분석

Fig. 5는 기본 시스템에서 절삭력 신호의 하나인 트러스트를 전처리하는 과정이다. 절삭회전수

$N=1000\text{rpm}$, 이송량 $f=0.15\text{mm/rev}$ 의 절삭조건으로 가공할 때의 트러스트 값이 $110\sim 130\text{kgf}$ 를 일정하게 유지하다가 239번째 이후 $25\sim 250\text{kgf}$ 의 값으로 급격히 변화한다. 절삭조건과 가공구멍수의 증가에 따라 트러스트 값의 범위가 심하게 변하므로 이 값을 그대로 신경회로망에 입력하여 처리하기에는 많은 시간이 낭비될 뿐만 아니라 처리하기도 쉽지 않아 전처리 과정을 행하였다.




Fig. 5 Cutting force($N=1000\text{rpm}$, $f=0.15\text{mm/rev}$)

Fig. 6은 Fig. 5의 트러스트 값을 전처리하여 얻은 절삭력 상수의 그래프이다. 절삭력 상수의 값은 $0\sim 1.5$ 사이의 값을 나타내고 있으며, Fig. 5의 특성을 그대로 유지하고 있음을 알 수 있다. 그리고 신경회로망의 입력조건에서 처리시간의 이익을 얻고 계산이 복잡해짐을 피하기 위하여, 0과 3 사이의 값들로 정규화 되도록 제시한 조건에 부합됨도 알 수 있다. 이와 같은 결과로 신경회로망에 입력되는 모든 인자들에 전처리 과정을 행하였다.




Fig. 6 Graph of preprocessed data ($N=1000\text{rpm}$, $f=0.15\text{mm/rev}$)

Fig. 7은 온라인 시스템에서의 학습과정이 진행됨에 따라 학습오차가 수렴되어 가는 과정을 나타내었다. 온라인 시스템 신경회로망의 반복 학습을

20번까지 수행하였을 때 학습 오차의 변화량이 급격히 줄어들다가 반복 횟수가 증가함에 따라 점진적으로 감소하여 수렴해 가는 것을 알 수 있다. 반복 학습횟수를 10,000회로 제한하였는데 신경회로망이 270까지 반복 학습시킴에 따라 오차가 0.0005까지 줄어들음을 알 수 있다.




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

Fig. 8은 Fig. 6의 조건을 오류 역전과 신경회로망에 적용하여 나타난 결과를 기본시스템과 온라인 시스템으로 보여주고 있다. 두 시스템 모두 정상상태일 때는 거의 일정한 값을 보여주며, 가공구멍수 $n=239$ 이상에서는 드릴작업을 더 이상 수행할 수 없음을 보여주는 값 즉, 학습에서 명명한 0.8 이상의 값을 보여주고 있다. 이는 공구마멸이 $VB=0.3\text{mm}$ 이상임을 알려주며, 학습과정을 거친 신경회로망이 두 시스템 모두 공구의 이상상태 신호패턴을 정확하게 분류하고 있음을 보여준다. 이와 같은 결과로 전처리 과정을 통한 학습패턴을 입력으로 제시하고 출력 패턴을 조사한 결과 학습이 성공적임을 알 수 있었다.






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

Fig. 9는 학습조건과 다른 조건인 절삭회전수 $N=1300\text{rpm}$, 이송량 $f=0.15\text{mm/rev}$ 으로 가공구멍수 $n=31\sim 35$ 와 $n=61\sim 65$ 회 가공의 트러스트 형상과 그 때의 특징들을 신경회로망에 적용한 결과이다. 두 시스템 모두 안정적인 공구마멸이 진행되는 과정에서는 출력값이 0.8미만의 값인 0의 근처의 값으로 나타나고, 공구의 마멸이 상당히 진행되어 파손에 이르는 (b)의 과정에서는 출력값이 0.8이상의 값인 1 근처의 값을 가진다. 그러므로 두 시스템 모두 선택된 특징들이 절삭조건이 변화되었음에도 Fig. 8과 같은 경향을 보여주므로, 학습조건 범위 안에서는 절삭조건이 변화여도 선택된 특징들이 민감하지 않음을 알 수 있다. 이 결과들로부터 제안한 기본 시스템과 온라인 시스템 모두 공구 이상상태를 예측하는데 적합함을 보여줌으로써, 본 논문에서 제안한 생산현장에서 실시간으로 공구의 이상상태를 예측할 수 있는 온라인 시스템이 하나의 학습조건으로도 학습조건 전체범위 안에서는 비교적 넓은 절삭조건에 걸쳐 공구의 이상상태 예측을 신뢰성 있게 감지해낼 수 있음을 보여준다.



(a) Cutting force($n= 61\sim 65$)



(b) Output data of neural networks versus number of drilled hole

Fig. 9 Output data of neural network when tool damage was occurred($N=1300\text{rpm}$, $f=0.15\text{mm/rev}$)

5. 결론

고장력 열연관광이 드릴작업시 공구동력계와 현미경으로 구성된 기본시스템과 AE 신호와 컴퓨터 영상시스템을 통해서 구성된 온라인 시스템에서 추출된 패턴을 분석하여 신경회로망의 입력패턴으로 제시하고 비교하여 드릴가공 중 공구 이상상태를 온라인 상에서 효과적으로 예측이 가능한지를 평가해 본 결과 다음과 같은 결론을 얻을 수 있었다.

1. 기본시스템과 온라인 시스템에서 축출한 인자인 트러스트, 토오크, 플랭크 마멸, 절삭회전수, 이송량, 영상으로 측정된 플랭크 마멸면적, AE RMS 값을 서로 조합하여 적절한 시스템을 구성할 수 있음을 알 수 있었다.
2. 기본시스템과 온라인 시스템으로 구한 결과 값이 모두 같은 경향을 보여줌으로써, 온라인 시스템으로 구성하면 생산 현장에서 자동화, 무인화에 적용 가능성이 있음을 보여준다.
3. 두 시스템 모두 하나의 학습조건 하에서도 전체의 학습조건 안에서는 어떤 절삭조건에서도 신뢰성 있는 공구이상 상태를 예측할 수 있었다.

참고문헌

- (1) Koren, Y., Ulsoy, A. G. and Danai, K., "Tool Wear and Breakage Using A Process Model," Annals of the CIRP, Vol. 35, pp. 283-288, 1986.
- (2) Sadat, A. B. and Raman, S., "Detection of Tool Flank Wear Using Acoustic Signature Analysis," Wear, Vol. 115, pp. 265-272, 1987.
- (3) Govekar E. and Grabec, I., "Self-Organizing Neural Network Application to Drill Wear Classification," ASME Journal of Engineering For Industry, Vol.116, pp.233-238, May 1994.
- (4) S. Rangwala and D. A Dornfeld, "Sensor Integration Using Neural Networks for Intelligent Tool Condition Monitoring", Trans of the ASME, Journal of Engineering for Industry, Vol.112, pp.219~228, 1990.
- (5) Kuang-Jen Wang, "Drilling Process Evaluation by Predicting Drilled Hole Quality and Drill Bit Wear With On-Line Acoustic Emission Signals", Oregon State University, 1996.
- (6) T.I. Liu and W.Y. Chen, "Intelligent Detection of Drill Wear", Mechanical Systems and Signal Processing, Vol.12, pp.863-873, 1998.