

예측감시 시스템에 의한 드릴의 마멸검출에 관한 연구

신형곤*, 김태영**

A Study on the Wear Detection of Drill State for Prediction Monitoring System

Hyung-Gon Shin*, Tae-Young Kim**

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. There are two systems, Basic system and Online system, to detect the drill wear. Basic system comprised of spindle rotational speed, feed rates, thrust, torque and flank wear measured by tool microscope. Online system comprised of spindle rotational speed, feed rates, AE signal, flank wear area measured by 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. The output was the drill wear state which was either usable or failure. This paper deals with an on-line drill wear monitoring system to fit the detection of the abnormal tool state.

Key Words : Drill Wear(드릴마멸), Backpropagation Neural Networks(오류역전파 신경회로망)

1. 서 론

드릴가공은 생산현장에서 흔히 사용되는 기계가공이지만 드릴날과 절삭각이 기하학적으로 복잡하고 다양한 가공속도 등으로 가공하기 어려운 가공 중 하나이다. 드릴가공 중 발생되는 드릴의 상태는 가공물의 표면거칠기와 가공정밀

도 등에 영향을 미치므로 절삭 중 공구마멸 상태를 미리 진단함으로써 가공물에 이상이 발생하기 전의 적절한 시기에 공구를 교환할 수 있어야 한다. 만약 드릴파손으로 인한 제품 손상이 발생하거나 정지시간이 증가하면 경제적으로 큰 손실을 초래한다. 따라서 공구의 과도한 마멸 및 파손을 가공도중 자동적으로 판단하는 예측 시스템의 개발이 시급한

* 전북대학교 강사
(신형곤 vimission@hanmail.net)
** 전북대학교 기계공학부

과제로 남아 있다.

예측 시스템의 성능은 적절한 감시신호와 신뢰성 있는 진단 알고리즘의 선정에 크게 의존되고, 현재 사용되는 신호로는 모터전류, 절삭력, AE 신호, 광학센서를 이용한 방법들⁽¹⁻³⁾이 있으며, 예측 진단 알고리즘으로는 지적 정보처리 기술로서 지식이나 경험을 바탕으로 한 전문가 시스템과 추론에 의한 퍼지 및 신경망 모델 등이 있다⁽⁴⁻⁸⁾. 이 중에서도 신경회로망 분야는 다양한 알고리즘의 영향으로 최근 연구가 활발히 수행되고 있다. Govekar와 Grabec⁽⁴⁾는 자기 조직 신경회로망을 모우멘트와 절삭력 신호들로부터 플랭크 마멸을 분석하는데 적용하였다. S. Rangwala와 D.A. Domfeld⁽⁵⁾는 AE와 절삭력 센서의 융합에 의한 신경망 모델을 이용하여 공구상태 진단을 성공적으로 수행하였다.

본 연구에서는 예측 감시신호들을 이용하여 두 가지 시스템을 구성하였다. 첫 번째는 간접적인 측정장치인 공구동력계를 사용하여 얻어지는 절삭력 신호와 공구현미경으로 공구마멸을 측정하는 가장 기본적인 시스템을 구성하였다. 이 시스템은 감시 신호의 신뢰성, 정확성 등 여러 가지 장점을 가지고 있으나 가장 큰 단점은 산업현장 즉, 온라인 상에서 불가능하다는 것이다. 그래서 두 번째로 가공과정에서 자동적으로 모니터 되어지는 AE 신호와 CCD 카메라를 사용하여 영상신호로 플랭크 마멸면적을 측정하도록 온라인 시스템을 구성하였다.

두 가지 시스템 즉, 공구동력계와 공구현미경으로 구성한 기본시스템과 AE 신호와 영상신호로 구성한 온라인 시스템을 통해서 추출된 패턴을 분석하고 신경회로망의 입력패턴으로 제시하였으며, 신경 회로망의 학습을 효과적으로 수행하기 위한 학습규칙으로는 오류 역전파 (back-propagation) 학습규칙을 사용하였다. 또한, 구성된 두 가지 시스템으로부터 특징들을 추출하여 비교하여 보았고, 드릴가공 중 공구 이상상태를 온라인 상에서 효과적으로 예측이 가능한지를 신경회로망을 이용하여 제시하였다.

2. 신호의 처리과정

2.1 신호의 획득

드릴가공에서 절삭력의 해석은 절삭조건, 절삭공구의 형상과 재질, 공구의 마모, 피삭재의 재질과 형태 등이 관계가되어 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

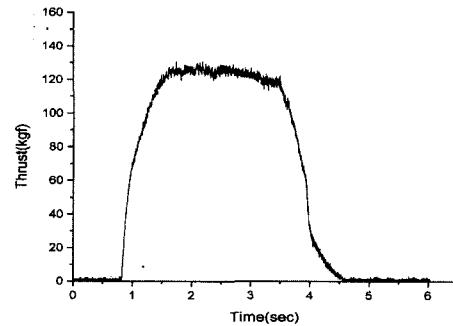


Fig. 1 Example of average thrust force

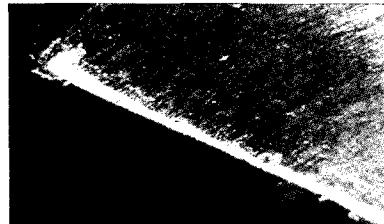
택하였다.

Fig. 1은 드릴 가공 중 검출된 절삭력 신호인 트러스트의 일반적인 거동을 나타낸다.

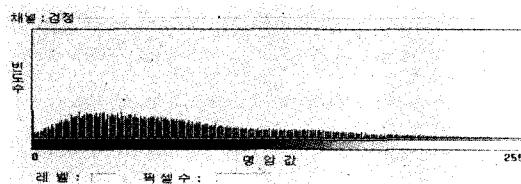
드릴 가공시 발생되는 절삭력 모델링과 음향에너지와의 관계는 절삭력 또는 AE(Acoustic Emission)에 근거를 둔 절삭과정 모니터링의 기본적인 방법이다⁽⁹⁾. AE 신호의 진동수는 공구의 동적인 거동과 함께 방출되는 진동수보다 크기 때문에 그 신호는 오로지 절삭과정과 관계되어있다. AE 센서는 작고 싸며, 일반적인 기계가공 과정에서 방해받지 않는 특징을 가지고 있으며 산업현장에 적용하기 위해 기계가공 과정을 상대적으로 쉽게 모니터링하는 방법이 제시되어 있다⁽¹⁰⁾. 더욱이 AE 센서에 의해 검출되는 출력신호는 임계값 이상의 마멸이나 파괴시에 신뢰할 수 있어 AE 신호를 감시 신호의 인자로 선택하였다.

한편, 영상처리는 컴퓨터를 이용하여 영상을 생성하고 처리하고 영상을 해석, 인식하는 영상과 관련된 모든 분야를 의미한다. 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 기법을 이용하여 잡음을 제거하고, 배경과 마멸부분을 흑과 백의 2차 처리를 수행한 후 드릴의 마멸면적을 구하였다. 드릴의 마멸면적은 전체 마멸면적의 70%를 플랭크 마멸로 규정한 면적을 계산하는 알고리즘을 개발하여 측정하였다⁽¹¹⁾.

Fig. 2는 본 실험에 적용한 하나의 예로서 절삭회전수 N = 1000rpm, 이송량 f=0.12mm/rev의 조건으로 가공하였을 때, 드릴 파괴가 일어나기 직전인 1200번짜의 공구마멸시 공구마멸 원영상과 히스토그램을 나타내고 있다. Fig. 2(b)에서 알 수 있듯이, 전반적으로 화소값들이 불균일하게 분



(a) Original image of 1200th



(b) Histogram of the 1200th image

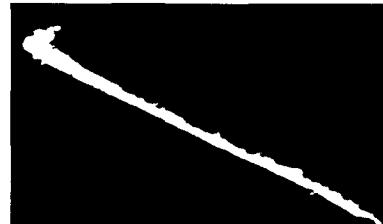
Fig. 2 Original image and histogram of flank wear
(N = 1000rpm, f = 0.12mm/rev)

포되어있다. 이 영상을 고대비에서 저대비로 변환하기 위하여 인터레이싱 작업을 하였고, 고주파 잡음을 감소시키기 위해서 미디안 필터링을 하였다. 필터링 과정을 거친 후 플랭크 마멸의 에지 검출을 용이하게 하기 위해서는 2진 영상으로 만들어 내는 작업이 절대적으로 필요하다. 2진 영상을 구성하는데는 쓰레쉬홀딩 값이 필요하게 되는데 각 절삭 조건에 따라 가공한 가공면의 영상에는 각기 다른 정보를 갖고 있으므로 이와 같은 조건에 따른 쓰레쉬홀딩 값을 100 으로 하여 적용하였다.

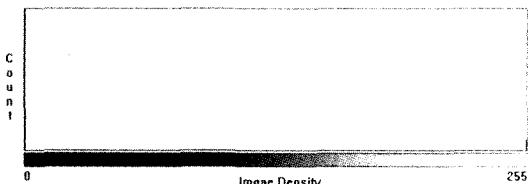
Fig. 3은 쓰레쉬홀딩한 2진 영상과 히스토그램을 나타내고 있다. Fig. 3(a)는 변환한 후의 영상을 보여주고 있는데, 흑과 백의 2진 영상으로 변환되었음을 알 수 있다. Fig. 3(b)는 히스토그램을 보여주고 있는데, 중간 화소값은 보이지 않고 흑(0)과 백(1)의 명암값만 나타낼 수 있다. 이 2진영상을 마멸면적으로 계산할 수 있도록 프로그램을 개발하여 플랭크 마멸면적을 구해내었다. 여기서 구한 플랭크 마멸면적을 감시신호의 인자로 선택하였다.

2.2 신호의 전처리과정

여러가지 절삭작용에서 절삭력은 그 크기나 방향이 절삭방법, 가공재료 및 기타의 절삭조건에 따라 달라진다. 드릴가공에서의 절삭력은 그 절삭 파라미터가 변함에 따라 변화가 심하므로 신경회로망을 이용한 분류 예측기에 그대로 입



(a) Image after thresholding



(b) Image histogram after thresholding

Fig. 3 Original image and histogram of flank wear
(N = 1000rpm, f = 0.12mm/rev)

력시킬 수 없다.

Fig. 1의 드릴가공 중 검출된 신호인 트리스트의 일반적인 거동에서 최대값과 최소값의 변동이 110~130kgf의 값으로 큼을 알 수 있다. 그러므로 시그모이드(sigmoid) 함수의 포화를 방지하기 위해 신경회로망의 입력 데이터는 0에서 3까지의 값을 갖도록 정규화하는 특별한 전처리 과정이 필요하다^(8,12).

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

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

$$M_{avg} = \frac{\sum_{i=1}^n M_{zi}}{n} \quad (2)$$

F_{zi}, M_{zi} : i번째 데이터의 순간적인 트리스트와 토오크

n : 비절삭시 들어온 신호를 제외한 1회 가공시 샘플수

F_{avg}, M_{avg} : 트리스트와 토오크의 평균 절삭력

다음 단계는 앞에서 구한 각 방향의 평균 트리스트와 토오크를 원래의 힘들에 대해 나누어주는 단계로써 이 단계를 거치면 대부분의 절삭력이 0에서 3사이의 값이 되어 신경

회로망의 입력에 적당한 데이터를 가지게 된다. 이때 만들어진 새로운 값을 절삭력 상수라 명명하기로 한다. 이와 같은 방법으로 구한 절삭력 상수와 일반화된 절삭 파라미터를 신경회로망에 입력시킨다.

$$P_{fj} = \frac{F_{xj}}{F_{avg}} \quad (3)$$

$$P_{mj} = \frac{M_{zj}}{M_{avg}} \quad (4)$$

P_{fj}, P_{mj} : j번째 데이터의 트러스트와 토오크의 절삭력 상수

F_{xj}, M_{zj} : j번째의 트러스트와 토오크의 절삭력

F_{avg}, M_{avg} : 트러스트와 토오크의 평균절삭력

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

3. 실험장치 및 방법

본 실험에 사용한 재료는 인장강도 80kg/mm^2 급의 고장력 열연강판이다. 시험편은 열연강판을 $200 \times 130 \times 7\text{mm}$ 이 되도록 만들었으며, 하나의 시험편에 40회의 가공을 하였고, 실험에 사용한 공구는 $\Phi 6\text{mm}$ 인 고속도강 드릴이다. 드릴작업을 수행하기 위하여 CNC 밀링머신의 테이블 위에 드릴용 압전형 공구동력계(tool dynamometer: Kistler, 9271A)를 설치하였다. Table 1은 실험의 절삭조건을 나타내고, 드릴의 고정은 Jacobs 척을 사용하였다. 가공형태는 5회씩 관통 가공하였으며, 공구의 수명 판단 기준은 플랭크 마멸 $V_B=0.3\text{mm}$ 로 정하였다. 드릴의 돌출길이는 80mm이며, 건절삭을 수행하였다.

드릴 가공시 발생하는 AE 신호를 얻기 위해 AE 시스템을 사용하였고, AE 신호를 검출하기 위한 센서로는 공진형 광대역 센서를 사용하였다. 이 신호는 100-300kHz band pass의 plug-in filter를 사용하여 소음을 제거한 후 pre-amplifier에

Table 1 Cutting condition for tests

Diameter of drill (mm)	6
Depth of cut (mm)	7
Feedrate (mm/rev)	0.1, 0.12, 0.15
Spindle speed (rpm)	1000, 1200, 1500

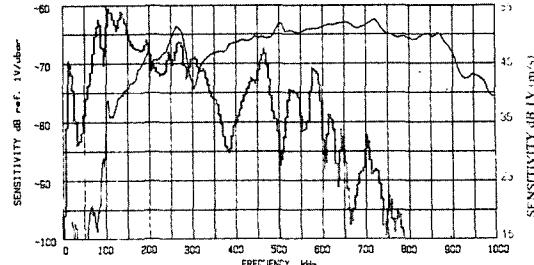


Fig. 4 Characteristic curve of AE sensor

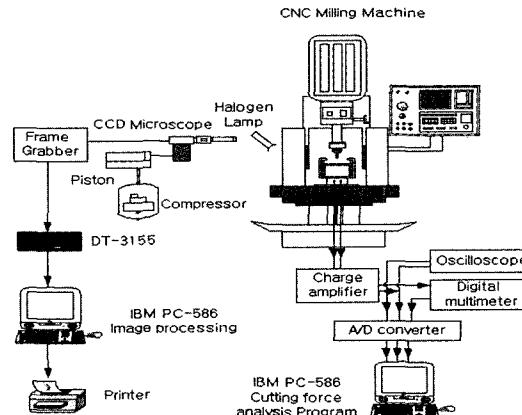


Fig. 5 Block diagram of the data acquisition system

서 40dB로 증폭되었고, AE 시스템에서 신호처리를 위해 A/D converter로 디지털화하여 컴퓨터로 분석하였다. Fig. 4는 AE 센서의 특성곡선을 보여준다.

드릴의 마멸량 측정은 구멍을 5회 가공한 후 드릴작업을 멈추고 공압시스템을 작동시켜 실린더에 부착되어 있는 CCD 카메라로 드릴의 플랭크 마멸면적을 측정하였으며 공구를 탈착하여 공구현미경으로도 측정하였다. 플랭크 마멸면적의 영상은 CCD 카메라를 통해 프레임 그레이(�frame grabber)에 의해 256 밝기 등급으로 컴퓨터에 저장되어 이 영상을 컴퓨터에서 분석하였다. Fig. 5는 실험장치의 배치를 보여준다.

획득된 절삭력, AE 신호, 영상신호는 데이터 분석 프로그램에 의해 X와 Y축에 평균값을 신호 획득시간으로 환산하여 컴퓨터에 저장하였다. 얻어진 값들은 신경회로망 처리를 하기 위해서 0에서 3의 값을 가지도록 전처리 과정을 수행하였다.

4. 신경회로망의 설계

본 연구에서는 공구동력계를 사용하여 얻은 트러스트, 토오크 인자와 공구현미경으로 측정한 플랭크 마멸을 인자로 하는 기본시스템의 입력패턴과 온라인 상에서 측정이 가능하도록 구성한 온라인 시스템 즉, AE 신호와 컴퓨터 영상 처리를 이용하여 구한 플랭크 마멸면적을 입력 인자로 하는 입력패턴을 오류 역전파(backpropagation) 신경회로망을 사용하여 학습시켰다. Table 2는 신경망의 학습에 사용한 인자들을 보여준다.

신경회로망 학습을 위해 Table 1의 조건으로 실험한 모든 특징 데이터들을 앞에서 설명한 것처럼 전처리를 하여 0에서 3사이로 정규화 하였다. 전처리 과정을 수행한 후 기본시스템과 온라인 시스템의 학습데이터를 Table 3과 Table 4에 나타내었다. 이 때의 절삭조건은 절삭회전수 $N=1000\text{rpm}$ 에서 이송량을 $f=0.1, 0.12, 0.15\text{mm/rev}$ 로 변화시키면서 가공한 것이며, 이와 같은 방법으로 절삭회전수 $N=1200\text{rpm}$

Table 2 Learning data set for training neural network

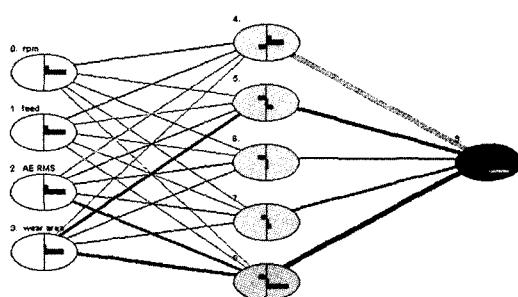
system	Input nodes	Output nodes
Basic system	1. cutting speed(rpm) 2. feedrate(mm/rev) 3. thrust(kgf) 4. torque(kgf · cm) 5. flank wear(mm)	Abnormal tool state (non-wear / wear)
Online system	1. cutting speed(rpm) 2. feedrate(mm/rev) 3. AE RMS(mv) 4. flank wear area(mm^2)	

Table 3 Input data for training a neural network(basic system)

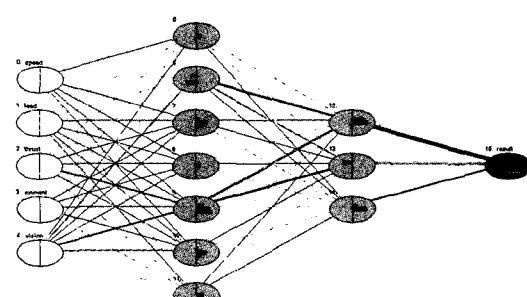
rpm	feedrate	thrust	torque	wear	out
0.5	0.5	0.86	0.84	0.27	0
	0.5	0.93	1.03	1.06	0
	0.5	1.02	1.26	1.12	0
	0.5	1.39	1.51	2.2	1
	1	0.92	0.85	0.32	0
	1	0.98	0.99	1.1	0
	1	1.26	1.05	1.22	0
	1	1.41	1.13	2.3	1
	1.5	0.93	0.92	1.09	0
	1.5	0.99	1.04	1.43	0
	1.5	1.24	1.31	2.07	1

Table 4 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



(a) Basic system



(b) Online system

Fig. 6 Structure of the proposed neural network

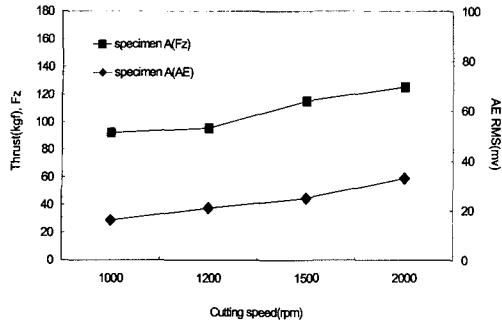


Fig. 7 Relation between cutting speed and cutting resistance
($d=6\text{mm}$, $f=0.1\text{mm/rev}$)

과 $N=1500\text{rpm}$ 에서의 데이터도 학습을 시켰다. Fig. 6은 신경회로망 구조를 나타내고 있다. Fig. 6(a)에서 다층인자의 구조는 입력 5, 은닉층 1이고 노드는 7, 출력은 1인 5-7-1 구조를 사용하였고, Fig. 6(b)에서 다층인자의 구조는 입력 4, 은닉층 1이고 노드는 5, 출력은 1인 4-5-1 구조를 사용하였다. 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, 반복 학습은 10,000회로 제한하였으며, 전체 최대오차가 0.0005 보다 작게 학습하였다.

5. 실험결과 및 고찰

5.1 절삭특성 및 드릴마멸의 분석

절삭회전수에 따른 절삭저항과 AE 신호의 특성을 비교하기 위해, 이송량은 $f = 0.1\text{mm/rev}$ 로 일정하게 하고 절삭

회전수를 $N=1000, 1200, 1500, 2000\text{rpm}$ 으로 변화시키면서 실험한 절삭저항과 AE RMS 값을 Fig. 7에 나타내었다. Fig. 7에서 트러스트와 AE RMS 값이 서서히 증가하는 것을 알 수 있다. 이는 드릴의 절삭회전수가 증가함에 따라 공작물과의 마찰을 일으키는 횟수가 증가하므로 마찰열이 발생하고 마멸이 증가하는데 이것이 AE RMS 값에 큰 영향을 준다고 생각한다.

Fig. 8은 절삭회전수 $N=1200\text{rpm}$ 과 이송량 $f=0.1\text{mm/rev}$ 의 절삭조건으로 가공한 결과이며, 가공 구멍수의 증가에 대하여 공구현미경으로 측정한 플랭크 마멸길이의 변화와 컴퓨터 비전을 이용하여 측정한 플랭크 마멸면적과의 관계를 비교한 것이다. 두 그래프 모두 가공구멍수의 증가에 따라 플랭크 마멸길이와 플랭크 마멸면적이 증가하며, 마멸의 증가하는 경향은 모든 가공과정에서 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⁽¹¹⁾.

Fig. 9는 이송량을 $f=0.1\text{mm/rev}$ 로 일정하게 하고, 절삭회전수를 $N=1000, 1200, 1500\text{rpm}$ 으로 변화시키는 가공조건으로 가공 구멍수의 증가에 대해 컴퓨터 비전을 사용하여 촬영한 플랭크 마멸면적과의 결과를 나타내었다. 컴퓨터 비전으로 측정한 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.

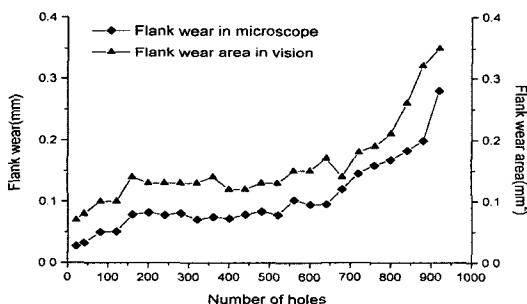


Fig. 8 Comparison of flank wear and flank wear area measurement by tool microscope and computer vision ($N=1200\text{rpm}$, $f=0.1\text{mm/rev}$)

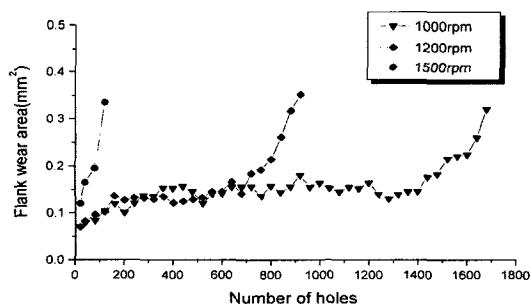


Fig. 9 Variation in flank wear area with number of holes
($d=6\text{mm}$, $f=0.1\text{mm/rev}$)

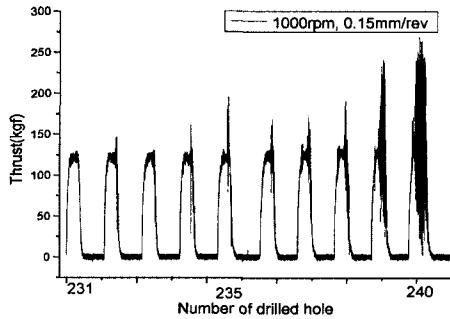


Fig. 10 Cutting force($N=1000\text{rpm}$, $f=0.15\text{mm/rev}$)

5.2 신경회로망에 의한 데이터 분석

본 연구에서는 기본 시스템과 온라인 시스템에서 구한 인자들을 신경회로망에 입력하여 공구마열 및 파손을 감시하는 기법을 시도하였다.

Fig. 10과 Fig. 11은 기본 시스템에서 절삭력 신호의 하나인 트러스트를 전처리하는 과정이다. Fig. 10에서 알 수 있듯이, 절삭회전수 $N=1000\text{rpm}$, 이송량 $f=0.15\text{mm/rev}$ 의 절삭조건으로 가공할 때의 트러스트 값이 110~130kgf를 일정하게 유지하다가 239번째 이후 25~250kgf의 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. 11은 Fig. 10의 트러스트 값을 전처리하여 얻은 절삭력 상수의 그래프이다. 절삭력 상수의 값은 0~1.5사이의 값을 나타내고 있으며, Fig. 8의 특성을 그대로 유지하고

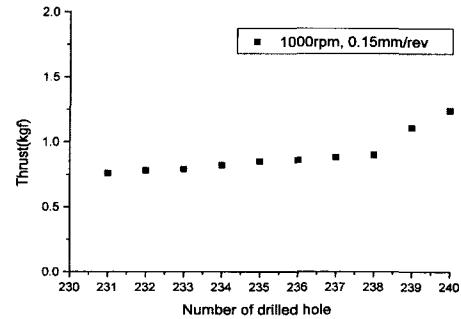
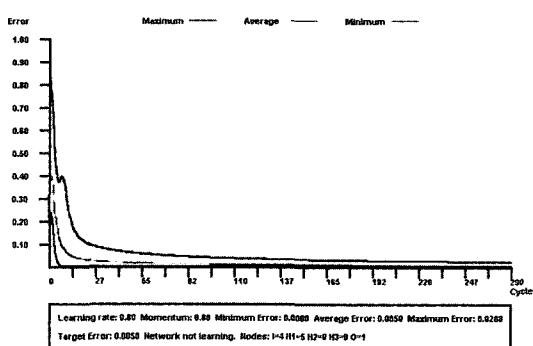


Fig. 11 Graph of preprocessed data ($N=1000\text{rpm}$, $f=0.15\text{mm/rev}$)

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.

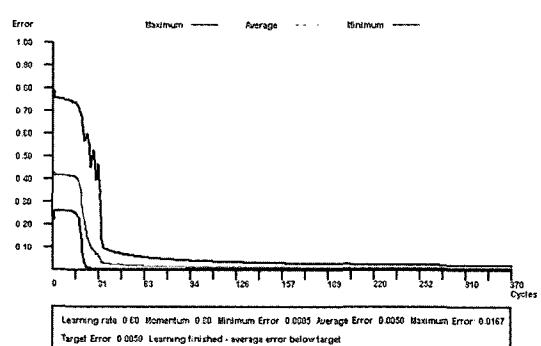
Fig. 12는 기본 시스템과 온라인 시스템에서의 학습과정이 진행됨에 따라 학습오차가 수렴되어 가는 과정을 나타내었다. Fig. 10에서 알 수 있듯이, 두 시스템 모두 신경회로망의 반복 학습을 20번까지 수행하였을 때 학습 오차의 변화량이 급격히 줄어들다가 반복 횟수가 증가함에 따라 점진적으로 감소하여 수렴해 가는 것을 알 수 있다. 반복 학습횟수를 10,000회로 제한하였는데 신경회로망이 Fig. 12(a)의 경우는 252번, Fig. 12(b)의 경우는 270까지 반복 학습시킴에 따라 오차가 0.0005까지 줄어듬을 알 수 있다.

Fig. 13은 Fig. 11의 조건을 오류 역전파 신경회로망(Fig. 12)에 적용하여 나타난 결과를 기본시스템과 온라인 시스



(a) Basic system

Fig. 12 Convergence of learning error versus number of iterations in the training process



(b) Online system

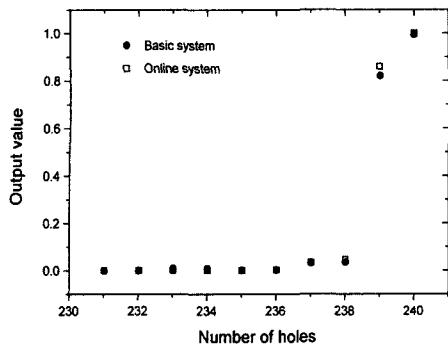
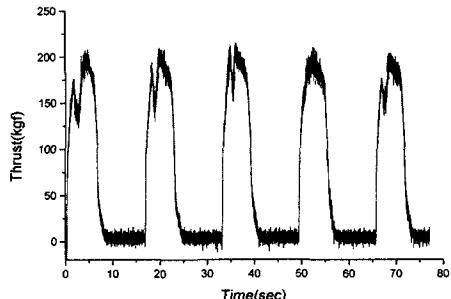


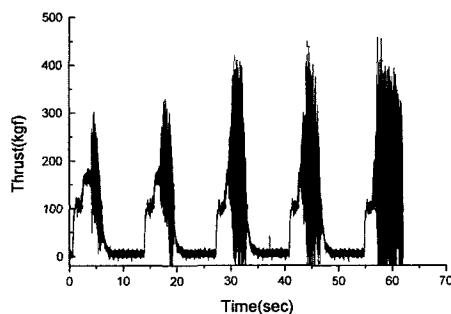
Fig. 13 Output data of neural network vs number of drilled hole

템으로 보여주고 있다. Fig. 13에서 알 수 있듯이, 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 $V_B=0.3\text{mm}$ 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.

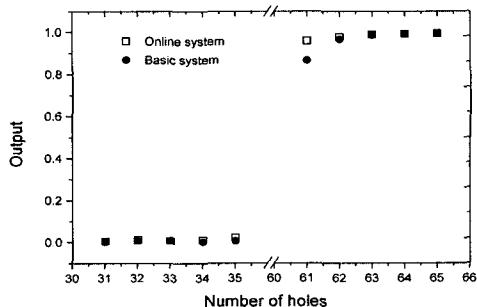
Fig. 14는 학습조건과 다른 조건인 절삭회전수 $N=1300\text{rpm}$, 이송량 $f=0.15\text{mm/rev}$ 으로 가공구멍수 $n=31\sim 35$ 와 $n=61\sim 65$ 회 가공의 트러스트 형상과 그 때의 특징들을 신경회로망에 적용한 결과이다. Fig. 14(a)는 트러스트가 일정한 모습을 보여주고, Fig. 14(b)는 공구의 마멸이 상당히 진행되어 트러스트가 급격히 상승함을 보여주며, 결국은 공구가 공작물과 충돌되는 가공불능 상태를 보여준다. Fig. 14(c)는 Fig. 14(a), (b)의 특징들을 전처리 과정을 통해 변환시킨 후, 신경 회로망에 대입하여 구한 출력값을 기본 시스템과 온라인 시스템으로 나타내었다. Fig. 14(c)에서 알 수 있듯이, 두 시스템 모두 안정적인 공구마멸이 진행되는 Fig. 14(a)의 과정에서는 출력값이 0.8미만의 값인 0의 근처의 값으로 나타나고, 공구의 마멸이 상당히 진행되어 파손에 이르는 Fig. 14(b)의 과정에서는 출력값이 0.8이상의 값인 1 근처의 값을 가진다. 그러므로 두 시스템 모두 선택된 특징들이 절삭조건이 변화되었음에도 Fig. 13과 같은 경향을 보여주므로, 학습조건 범위안에서는 절삭조건이 변하여도 선택된 특징들이 민감하지 않음을 알 수 있다. 이 결과들로부터 제안한 기본 시스템과 온라인 시스템 모두 공구



(a) Cutting force($n= 31 \sim 35$)



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



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

Fig. 14 Output data of neural network when tool damage was occurred($N=1300\text{rpm}$, $f=0.15\text{mm/rev}$)

이상상태를 예측하는데 적합함을 보여줌으로써, 본 논문에서 제안한 생산현장에서 실시간으로 공구의 이상상태를 예측할 수 있는 온라인 시스템이 하나의 학습조건으로도 학습조건의 전체범위 안에서는 비교적 넓은 절삭조건에 걸쳐 공구의 이상상태 예측을 신뢰성 있게 감시해낼 수 있음을 보여준다.

5. 결 론

고장력 열연강판의 드릴작업시 기본시스템과 온라인 시스템에서 추출된 패턴을 분석하여 신경회로망의 입력패턴으로 제시하고 드릴가공 중 공구 이상상태를 온라인 상에서 효과적으로 예측이 가능한지를 평가해 본 결과 다음과 같은 결론을 얻을 수 있었다.

- (1) 기본시스템과 온라인 시스템에서 추출한 인자인트러스트, 토크, 플랭크 마멸, 절삭회전수, 이송량, 영상으로 측정한 플랭크 마멸면적, AE RMS 값을 서로 조합하여 적절한 시스템을 구성할 수 있음을 알 수 있었다.
- (2) 공구의 이상상태를 예측하기 위해 개발한 신경회로망을 이용한 결과가 1에 가까운 값들을 출력함으로써 성공적임을 알 수 있다.
- (3) 기본시스템과 온라인 시스템으로 구한 결과값이 모두 같은 경향을 보여줌으로써, 온라인 시스템으로 구성하면 생산 현장에서 자동화, 무인화에 적용 가능성이 있음을 보여준다.
- (4) 두 시스템 모두 하나의 학습조건 하에서도 전체의 학습조건 안에서는 어떤 절삭조건에서도 신뢰성 있는 공구이상 상태를 예측할 수 있었다.

후 기

본 연구는 전북대학교자동차신기술연구소 지원에 의해 수행되었으며 이에 감사 드립니다.

참 고 문 헌

- (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) 유경곤, 전태옥, 박홍식, "ADI재의 드릴가공시 가공조건에 따른 절삭저항 및 AE신호 특성", 한국 공작기계학회지, 제7권, 제6호, pp. 90~96, 1998.
- (4) 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.
- (5) 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.
- (6) Sandeep S. Jaiswal "Prediction of Tool wear using Neural Networks", The University of Alabama in Huntsville, 1999.
- (7) 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.
- (8) 김화영, 안중환, "신경회로망을 이용한 드릴공정에 서의 칩 배출 상태 감시", 한국정밀공학회지, 제16권, 제6호, pp. 133~140, 1999.
- (9) 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.
- (10) Jones, B. E., "Sensors in Industrial Metrology", Journal of Physics. E, Scientific Instruments, Vol. 20, pp. 1113~1126, 1987.
- (11) 신형곤, 김성일, 김태영, "고장력 열연강판의 드릴 가공시 공구마멸에 관한 연구", 한국공작기계학회, Vol. 10, No.2, pp.10~17, 2001.
- (12) T.I. Liu and W.Y. Chen, "Intelligent Detection of Drill Wear", Mechanical Systems and Signal Processing, Vol. 12, pp. 863~873, 1998.
- (13) S. Chandrashekhar, R. H. Osuri and S. Chatterjee, "A Preliminary Investigation Into the Prediction of Drill Wear Using Acoustic Emission", In Fundamental Issues In Machining, PED Vol. 43 ASME. pp. 123~137, 1990.
- (14) E. Brinksmeier, "Prediction of Tool Fracture in Drilling", Annals of the CIRP, Vol. 39, No. 1, pp. 97~100, 1990.
- (15) 김성일, "유리섬유 강화 폴리에스터의 드릴가공특성" 한국공작기계학회지, 제9권, 제3호, pp. 90~95, 2000.