

신경망과 절삭력신호 특성을 이용한 공구이상상태 감지에 관한 연구

임근영*, 문상돈**, 오성훈**, 김성일***, 김태영****

A Study on Damage Detection of Cutting Tool Using Neural Network and Cutting Force Signal

Keun-Young Lim*, Sang-Don Mun**, Seong-Hun Oh**, Seong-Il Kim***, Tae-Young Kim****

ABSTRACT

A useful method to detect tool breakage using neural network of cutting force signal is proposed and implemented in a basic cutting process. Cutting signal is gathered by tool dynamometer and normalized as a preprocessing. The cutting force signal level is continually monitored and compared with the predefined level. The neural network has been trained normalized sample data of the normal operation and catastrophic tool failure using backpropagation learning process. The developed system is verified to be very effective in real-time usage with minor modification in conventional cutting processes.

Key Words : cutting force(절삭력), neural network(신경회로망),
damage detection of cutting tool (공구이상상태감지)

1. 서론

공작기계를 이용한 금속가공 분야에서 자동화와 무인화에 대한 연구가 활발히 진행되고 있다. 금속가공의 자동화에서는 특히 공구의 상태에 따라 유연하게 대처할 수 있는 시스템 구성의 필요성이 제기되고 있는데, 그 이유는 공구의 상태변화 즉, 마모 및 파손이 제품의 마무리 가공상태나 치수변화 등에 큰 영향을 미치기 때문이다. 그러므로 공구상태는 금속 가공분야에서 가공공정 감시의 주된 대상이 된다.¹⁾

따라서 생산현장에서 무인화, 자동화를 이루기 위해서는 공구의 상태변화를 정확하며 신속하게 검출해 내는 방법의 연구 개발이 시급한 과제로 되어 있다.¹⁾²⁾³⁾

공구상태 감지를 위한 센서들 중에서 대표적인 것으로 절삭력 센서와 AE 센서가 있다. 절삭력 센서는 절삭시 발생하는 절삭저항을 측정하여 그 변화패턴을 이용하는 방법이고, AE 센서는 작업시 발생하는 미세한 음향의 변화로 인하여 RMS 값이 변하는 특징을 이용한 방법이다.

근래에는 센서들에서 얻어진 신호를 이용, 보다 정확하고 신뢰성 있는 결과를 얻기 위해 특별한 처리를 하는 알

* 광전자 반도체(주)
** 전북대학교 대학원
*** 대불대학교
**** 전북대학교 공과대학

고리들이 개발되고 있다.⁴⁾ 그 중에서도 신경회로망 분야가 다양한 알고리즘의 개발로 최근 관심을 끌고 있으며, 이 분야의 연구가 활발히 수행되고 있는 실정이다.⁵⁾

패턴인식, 의사결정 등에서 뛰어난 능력을 가진 신경회로망은 패턴인식, 문자인식, 음성분석 등에 폭넓게 사용되어 왔다. 금속가공 분야에서는 절삭시 발생하는 센서신호들의 특징적인 패턴들을 신경회로망에 학습시킨 후, 실제 가공시 발생하는 신호들에 대한 출력을 연구하는 논문들이 발표되고 있다.⁶⁾⁷⁾ 여러 연구 결과들에서 신경회로망의 다양한 알고리즘이 제안되었고,⁸⁾ 그 중에서도 BP(backpropagation) 신경망은 최근에 각광을 받기 시작한 것으로 인공지능 분야에서 개발되어 여러 분야에 적용되고 있는 신뢰성 있는 알고리즘이다.

절삭력 센서에서 나온 신호들의 변화는 공구상태를 반영하며, 변화하는 특징들은 상태를 예측하게 한다. 따라서 본 논문에서는 고경도재료와 세라믹 공구를 사용한 절삭실험을 행하여 공구마모와 파손시 나타나는 절삭력의 변화를 규명한 후 실제 작업환경에서 적용할 수 있도록 하였다. 또한 신경망으로 하여금 절삭력신호 패턴을 인식하도록 시도하였는데 공구의 정상상태, 이상상태의 특징들을 기억시킨 후 실제 절삭시 얻어지는 절삭력신호를 통해 절삭시 공구상태를 마모, 파손 등의 상태로 분류 판단하는 과정을 거치게 된다. 이 과정을 반복함으로써 무인화된 공정작업시 작업자가 없어도 공구 이상상태에 따라 시스템을 정지시키고 공구를 교환시킬 수 있는 환경이 조성될 수 있다. 결과적으로 본 연구는 고경도재료의 밀링작업에 세라믹 공구를 사용했을 때의 공구 상태변화와 그에 따른 절삭력 변화를 규명하며, 공구상태 자동 감지에 절삭력신호를 이용한 신경회로망이 효과적으로 쓰일 수 있음을 밝혔다.

2. 관련 이론

2.1 정면밀링 가공시 절삭력신호 특성

절삭가공에서 절삭력의 해석은 가공상태의 기하학적 조건과 피삭재의 재질 절삭조건 등이 관계가 되어 복잡하다. 특히 정면밀링은 절삭인의 절입시의 충격, 이탈시의 급격한 에너지 해방을 가지는 단속절삭이며 피삭재의 이송으로 인하여 절삭두께가 변하고 주기적으로 절삭과 비절삭을 수행함에 따라 절삭력신호가 주기적으로 나타난다.

2.2 신경회로망

신경회로망⁹⁾¹⁰⁾은 이론적으로 인간뇌의 작용을 수학적으로

로 모델링한 것으로 artificial neural network 등으로 불린다. 일반적인 관점에서 신경망이란 처리요소(processing element)로 구성된 분산화된 지식처리시스템이라고 정의할 수 있다.

신경회로망은 Fig. 1에서 나타난 것처럼 일반적으로 입력층 은닉층 출력층으로 구분할 수 있다. 입력층 노드는 외부의 패턴들을 입수하는 부분이고, 출력층 노드는 외부에 출력을 생성하며 은닉층 노드는 외부에 직접적으로 작용하지 않게 하는 부분이다. 즉, 은닉층 노드들의 역할은 입력층에서 나타내어진 패턴의 내부적 표현을 형성하는 것이다.




Fig. 1 Typical back-propagation network

2.3 역전파(backpropagation) 알고리즘⁶⁾

역전파(backpropagation) 학습 알고리즘은 지도학습으로써 통상 입력패턴과 그에 대한 목표출력으로 이루어진다. 목표출력은 대개 정확한 해답 또는 입력패턴에 대한 정확한 분류이다. 이런 예제들로부터 신경망은 내부적인 연결강도를 조정한다. 역전파 훈련 알고리즘은 다층전향 퍼셉트론의 실제 출력과 기대되는 출력간의 평균 제곱 오차를 최소화하도록 설계된 일종의 반복적 기술기 알고리즘으로 연속적이며 미분 가능한 비선형 함수를 필요로 한다.

신경회로망의 입력은 Fig. 2에서 처럼 다음과 같이 표현된다.

$$net_{pj} = \sum_i W_{ji} O_{pi} \quad (1)$$

여기서, net_{pj} : 모든 입력신호들에 대한 합계 함수
 W_{ji} : i번째 노드에서 j번째 노드까지의 가중치
 O_{pi} : i번째 노드의 출력(중간층 출력)




Fig. 2 Back-propagation processing element

입출력 거동은 시그모이드 특성을 갖는 함수로 기술된다. 즉,

$$O_{pj} = \frac{1}{1 + e^{-(net_{pj} + b_j)}} \quad (2)$$

여기서, b_j : 시그모이드 함수의 bias

다음에 역전파 알고리즘을 이용하는 학습단계가 신경회로망의 적절한 가중치를 얻기 위해 적용된다. 지도된 학습 과정이기 때문에 입출력 패턴의 예들은 네트워크를 훈련할 필요가 있다. 실제 출력패턴이 예상된 출력패턴과 비교되며 그 square오차(E_p)는 다음과 같이 쓸 수 있다.

$$E_p = \frac{1}{2} \sum_j (T_{pj} - O_{pj})^2 \quad (3)$$

여기서, T_{pj} : j 번째 노드의 기대되는 출력값
 O_{pj} : j 번째 노드의 네트워크 출력값

전체오차(E)를 일괄적으로 고려하면, 다음과 같은 또 다른 식을 얻을 수 있다.

$$E = \sum_p E_p \quad (4)$$

오차는 출력측에서 입력측으로 전파된다. 오차를 최소화하기 위해서 노드의 가중치를 반영하는 오차의 경사도가 노드의 가중치를 수정하기 위해 쓰인다.

$$\Delta w_{ji} = -\eta \frac{\partial E_p}{\partial w_{ji}} \quad (5)$$

여기서, Δw_{ji} : i 번째 노드에서 j 번째 노드까지 가중치가 증가한 변화량
 η : 학습율

학습율은 계산된 가중치의 변화 중에서 얼마만큼이 교정을 위해 사용될 것인가를 결정하며 가장 좋은 값은 오차표면 즉, w_{ji} 에 대한 E 의 특성에 의존한다.

결과적으로 임의의 초기치로 설정된 모든 가중치들은 예상된 출력과 실제 출력들의 오차를 최소화하기 위해 근사적으로 조정될 수 있다.

이렇게 지도된 학습이 완료된 후에 신경회로망은 새로운 입력패턴을 받을 준비를 하게 되고, 새 입력패턴과 훈련된 패턴 사이의 유사성에 기초해서 관련된 출력패턴을 만들어 낸다.

2.4 절삭력신호의 전처리⁶⁾

밀링에서의 절삭력은 그 절삭파라미터가 변환에 따라 변화가 심하므로 신경회로망을 이용한 분류 예측기에 그대로 입력시킬 수 없다. 절삭력 값들의 분포는 공구마모가 공구수명에 도달한 경우에도 그 평균값의 2배에 이르지 못한다는 점에 착안하여 전처리를 하게 되는데, 또한 신경회로망의 내부 처리 과정상의 입력 데이터로 0에서 2사이 값을 갖게 된다.

그 과정중 첫 번째에서는 얻어진 데이터들의 평균값들을 취하게 된다.

$$F_{xavg} = \frac{\sum_{i=1}^n F_{xi}}{n} \quad (6)$$

$$F_{yavg} = \frac{\sum_{i=1}^n F_{yi}}{n} \quad (7)$$

$$F_{zavg} = \frac{\sum_{i=1}^n F_{zi}}{n} \quad (8)$$

여기서 $F_{x^r}, F_{y^r}, F_{z^r}$: i 번째 X, Y, Z 축 방향의 절삭력
 n : 비절삭시 들어온 신호를 제외한 샘플수
 $F_{xavg}, F_{yavg}, F_{zavg}$: X, Y, Z 축 방향의 평균 절삭력

다음 단계는 앞에서 구한 각 방향의 평균 절삭력을 원래의 힘들에 대해 나누어주는 단계로서 이때 만들어진 새로운 값을 절삭력 상수(P_x, P_y, P_z)라 정의한다.

$$P_{xj} = \frac{F_{xj}}{F_{xavg}} \quad (9)$$

$$P_{yj} = \frac{F_{yj}}{F_{yavg}} \quad (10)$$

$$P_{zj} = \frac{F_{zj}}{F_{zavg}} \quad (11)$$

여기서, P_{xj}, P_{yj}, P_{zj} : j번째 데이터의 X, Y, Z방향의
절삭력 상수

F_{xj}, F_{yj}, F_{zj} : j번째의 X, Y, Z방향의 절삭력

$F_{xavg}, F_{yavg}, F_{zavg}$: X, Y, Z축 방향의 평균 절삭력

3. 실험장치 및 실험방법

본 실험에서 사용한 절삭 가공 재료는 대표적인 금형재인 STD11강이었다. Table 1은 STD11강의 화학적 성분을 보여주고 있다. 절삭실험을 위하여 STD11 시편의 가공경화된 부분은 band sawing machine을 사용하여 제거하고 150×65×16^T mm의 규격으로 절단한 시편을 지그(jig)에 고정시키기 위하여 드릴링(drilling) 작업을 하였다. 가공 후 시편에 열처리를 실시하여 H_RC 50으로 경도를 높였다.

Table 1 The chemical composition of STD11

Chemical composition (wt.%)								Hardness (H _R C)
C	Si	Mn	P	S	Cr	Mo	V	
1.4~1.6	0.4	0.6	0.03	0.03	11~13	0.8~1.2	0.2~0.5	50

공구는 Si₃N₄를 주성분으로 하는 ceramic 공구 SNGN120412)를 사용하였다. 이 공구는 충격에 약하므로 더블 네거티브(double negative)형 밀링 커터를 절삭에 적용하였다.

만능밀링머신을 사용하여 절삭을 수행하였으며 절삭력 측정을 위해 압전기식 공구동력계(KISTLER 9257B)를 사용하였다. 공구동력계에서 나온 신호는 증폭기(KISTLER 5017A)에서 증폭되었다.

증폭기를 거친 절삭력신호는 A/D converter를 통하여 1.5~2 kHz로 샘플링하여 PC에 저장되었다. 저장된 신호는 평균절삭력 및 표준편차 등을 구한 후 이론부에 소거한 전처리 방법을 거쳐 신경회로망에까지 사용된다. 절삭가공 후 공구의 이상 상태 여부를 확인 및 마모의 측정 을 위해 공구현미경을 사용하였다. 절삭조건은 Table 2

와 같고 Fig. 3은 본 실험에서 사용된 각 장비의 세부적인 배치와 획득된 신호의 처리과정을 나타내고 있다.

공구수명 판단 기준은 예비 실험을 통해 표면거칠기가 급격하게 나빠지는 최대 여유면 마모폭(VB_{max}) 0.3 mm로 하였다.

Table 2 The experimental conditions

RPM	520	715	990
Cutting speed(m/min)	163	224	311
Feed speed(mm/min)	41, 87, 127		
Feed rate(mm/tooth)	0.08	0.06	0.04
	0.17	0.12	0.09
	0.24	0.18	0.13
Depth of cut(mm)	0.3		
Environment	Dry		
Cutting method	Center milling		

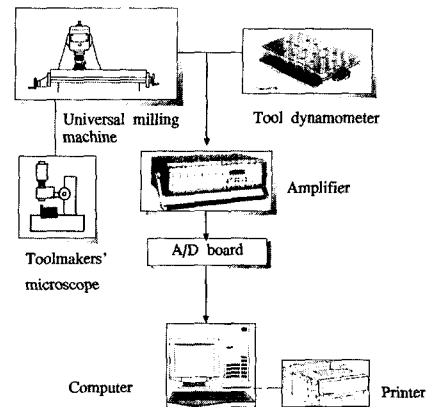


Fig. 3 The experimental apparatus and flow of signal

4. 실험결과 및 고찰

H_RC 50의 고경도 재료를 세라믹 공구를 사용하여 절삭했을 때 세라믹 공구의 특성과 단속절삭 작용으로 인한 영향 때문에 공구에는 칩핑(chipping), 노치 마모(notch wear), 갑작스러운 파손(fracture) 등이 주류를 이루었다. 공구의 여러 손상들은 대부분 복합적으로 발생하며 공구수명을 판단하는 중요한 인자이다.

Fig. 4는 주축회전수(RPM)가 715, 이송속도(feed speed)=127 mm/min, 절삭깊이(a_p)=0.3 mm 일 때의 평균 절삭력과 마모의 진전을 보여주고 있다. 공구의

최대 여유면 마모(VB_{max})가 진전할 때 절삭력도 비례적으로 상승함을 알 수 있다.

Fig. 5는 RPM=520, feed speed=87 mm/min, $a_p=0.3$ mm로 가공중 공구의 심한 파손이 발생했을 때의 절삭력신호이다.

밀링에서의 절삭력 레벨이 절삭조건에 따라 심하게 변하므로 신경회로망에 직접 입력하기가 매우 까다로운데 본 연구에서는 획득된 신호를 전처리하여 신경회로망에 입력하였다.

Fig. 6은 feed speed = 87 mm/min로 일정할 때 RPM이 변함에 따라 전체적인 절삭력 레벨의 변화를 나타내고 있다. RPM이 증가할수록 전체적인 절삭력의 레벨이 높아지고 있다. 따라서 절삭력신호를 그대로 신경회로망에 입력




Fig. 4 Average cutting force and increasing of flank wear(RPM=715, $f=127$, $a_p=0.3$)




Fig. 5 Cutting force signal of sudden tool breakage (RPM=520, $f=87$, $a_p=0.3$)

하여 처리하는 데는 많은 시간이 낭비될 뿐만 아니라 처리하기도 쉽지 않다. 그래서 전처리 과정이 필요하게 된다.

앞서 이론부에서 전개한 대로 전처리 방식을 사용했을 때의 얻어지는 절삭력 상수를 이용한 그래프가 Fig. 7에서 보여진다.




Fig. 6 The change of cutting force level with varying cutting condition, RPM($f=87$)

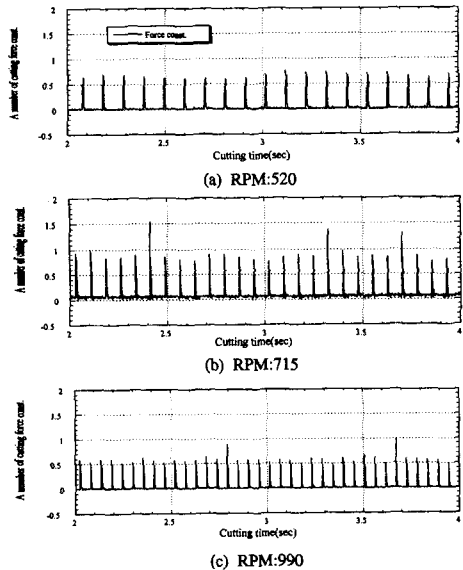


Fig. 7 The graph of preprocessed data with different cutting condition, RPM($f=87$)

실험에 사용된 신경회로망은 Fig. 8에서와 같이 2개의 은닉층을 가진 5-7-7-1의 BP(backpropagation) 신경회로망이었다. 입력층에는 x, y, z 각 방향의 절삭력 상수가 입력되고, 나머지 2개의 노드는 주축회전수(RPM)와 이송속도(feed speed)가 일반화되어 입력된다. 출력층은 1개의 노드를 가지는데 0에 가까운 값은 공구의 정상상태를 의미하며, 1에 가까운 값은 공구의 $VB_{max}=0.3$ 에 이르는 마모나 파손 등이 발생했음을 예측하게 된다.

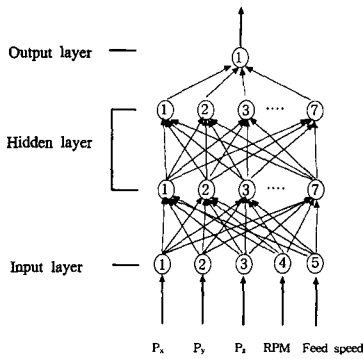


Fig. 8 Schematic of neural network for sensing tool damage

Table 3은 절삭과정에서 정상상태와 이상상태 공구들에서 발생한 대표적인 절삭데이터들의 변화를 신경회로망의 학습에 적용한 패턴들이다.

Table 3 Learning set of neural network

RPM	Feed speed (mm/min)	Data					Output
		Input					
		P_x	P_y	P_z	RPM	Feed speed	
520	41	0.86	1.36	1.38	1.0	0.5	1
		0.6	0.70	0.60	1.0	0.5	0
		0.8	0.89	0.97	1.0	0.5	1
		0.48	0.40	0.52	1.0	0.5	0
	87	1.40	1.00	1.22	1.0	0.5	1
		0.45	0.39	0.47	1.0	1.0	0
		1.79	1.88	1.35	1.0	1.0	1
		2.00	1.6	1.50	1.0	1.0	1
	127	0.59	1.80	0.34	1.0	1.5	1
		0.62	0.86	1.59	1.0	1.5	1
		0.38	0.56	0.47	1.0	1.5	0
		0.89	0.8	1.04	1.0	1.5	1
715	41	0.59	1.80	0.34	1.5	0.5	1
		0.62	0.86	1.59	1.5	0.5	1
		0.38	0.56	0.47	1.5	0.5	0
		0.89	0.80	1.04	1.5	0.5	1
	87	0.79	0.80	1.06	1.5	1.0	0
		0.77	0.52	1.74	1.5	1.0	1
		1.3	1.13	1.33	1.5	1.5	0
		1.4	1.15	2.00	1.5	1.5	1
	127	1.3	0.90	0.90	1.5	1.5	0
		0.50	1.09	0.45	2.0	0.5	0
		0.63	1.24	0.84	2.0	0.5	0
		0.40	0.51	0.60	2.0	0.5	0
990	41	1.50	1.25	1.29	2.0	0.5	1
		0.56	0.68	0.50	2.0	1.0	0
		0.28	0.68	0.40	2.0	1.0	1
		1.70	1.43	1.46	2.0	1.0	1
	87	1.79	1.5	1.62	2.0	1.5	1
		0.64	0.92	0.73	2.0	1.5	0
		1.80	1.80	1.20	2.0	1.5	1
		1.80	1.80	1.20	2.0	1.5	1

역전과 알고리즘은 신경회로망을 통해 얻어진 출력값과 목표 출력값을 비교하여 그 차이를 감소하는 방향으로 연결강도를 조절하며 이러한 학습과정을 반복함으로써 원하는 결과를 얻게 된다. 또는 지정한 학습횟수만큼 학습을 하기도 할 수 있는데 본 연구에서는 학습횟수를 27000번으로 정하여 학습을 완료하도록 하였다. 학습율은 0.5를 사용하였다.

Table 4는 학습된 신경회로망이 임의의 작동상태에 대하여 적절한 공구상태를 출력하는 가를 살펴본 검증데이터이다. 공구의 상태에 대한 신경회로망의 출력이 적절한 가를 확인하기 위하여 공구현미경을 사용하여 신경회로망의 출력결과와 비교하였다. Table 4에서와 같이 신경회로망의 출력의 결과와 공구현미경을 통한 공구상태는 매우 양호하게 일치되고 있음을 확인할 수 있어 학습된 신경회로망이 임의의 데이터에 대하여 적절히 반응함을 확인할 수 있었다.

Table 4 Testing set of neural network

RPM	Feed speed (mm/min)	Data						
		Input				Output		
		P_x	P_y	P_z	RPM	Feed speed	Neural network	Micro scope
520	41	0.42	0.51	0.40	1.0	0.5	0	0
		1.14	0.92	1.02	1.0	1.0	1	1
	87	0.42	0.51	0.34	1.0	1.0	0	0
		1.21	1.01	1.10	1.0	1.0	1	1
	127	0.5	0.56	0.34	1.0	1.5	0	0
		1.02	0.90	0.96	1.0	1.5	1	1
715	41	0.33	0.26	0.26	1.5	0.5	0	0
		0.90	0.86	1.09	1.5	0.5	1	1
	87	0.76	0.62	1.77	1.5	1.0	1	1
		1.0	0.8	0.87	1.5	1.5	0	0
	127	1.45	1.2	1.90	1.5	1.5	1	1
		990	41	0.42	0.44	0.45	2.0	0.5
1.20	1.02			1.1	2.0	0.5	1	1
87	0.54		0.65	0.48	2.0	1.0	0	0
	1.67		1.40	1.45	2.0	1.0	1	1
127	0.57	0.71	0.6	2.0	1.5	0	0	
	1.67	1.48	1.6	2.0	1.5	1	1	

Fig. 9는 RPM=520, f=87, $a_p=0.3$ 의 조건에서 획득한 절삭력신호를 처리하여 신경회로망에 입력한 출력을 나타내고 있다. 이미 학습을 마쳤으므로 각각의 데이터에 대하여 적절한 출력이 나오며 0에 가까운 값들과 1에 가까운 값들로 나누어지는 것을 알 수 있다.




Fig. 9 Output data of neural network vs. cutting time (RPM=520, $f=87$, $a_p=0.3$)

Fig. 10은 공구상태가 정상일 때의 절삭력과 신경회로망의 출력으로써 절삭력은 실험시 들어오는 잡음 등과 더불어 비교적 고르지 못한 신호를 보이는 반면 신경회로망의 출력값은 고른 데이터 분포를 보임으로써 정상상태임을 확연히 드러내었다.

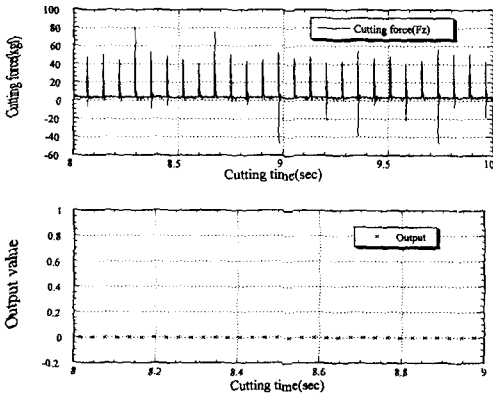


Fig. 10 Output data of neural network vs. cutting time (RPM=520, $f=87$, $a_p=0.3$)

Fig. 11은 RPM=990, $f=41$, $a_p=0.3$ 일 때의 절삭력과 신경회로망의 출력값을 보여준다. 공구마모가 진행됨에 따라 절삭력 그래프는 약간의 상승을 보일 뿐이지만 신경회로망은 갑자기 1근처로 튀어 오르는 값을 가지며 공구수명을 다한 상태임을 명확히 알 수 있었다.

5. 결 론

절삭력과 신경회로망을 이용하여 밀링에서의 공구 상태 변화를 감시하는 방법을 제안한 본 연구를 통하여 다음과 같은 결론을 얻었다.




Fig. 11 Output data of neural network when tool damage was occurred (RPM=990, $f=41$, $a_p=0.3$)

- 1) 절삭력 센서를 통한 신호를 이용하여 공구의 상태를 예측할 수 있었다. 마모시 절삭력이 증가하였으며 특히 파손의 경우에는 갑자기 감소하는 신호를 얻을 수 있었다.
- 2) 신경회로망에서 적절한 입력 데이터를 작성하기 위하여 전처리 과정이 필요하다. 본 연구에서는 순수 절삭 신호에 대한 평균을 이용하는 새로운 방식의 전처리 방법을 사용했으며 매우 효과적이었다.
- 3) 신경회로망 처리에 의하여 공구의 이상상태를 감지해 낼 수 있다. 공구마모가 진행하여 수명에 도달해짐에 따라 1에 가까운 값들을 출력함으로써 간접적으로 공구 상태를 감지하기에 충분하였다.
- 4) 절삭력 센서에 의한 신호를 신경회로망 처리에 의한 결과에서 신경회로망은 생산현장의 자동화, 무인화에 실제적인 적용 가능성이 있음을 보여 주었다.

참 고 문 헌

1. Altintas, Y., and Yellowley, I., "In-Process Detection of Tool Failure in Milling Using Cutting Force Models," ASME Journal of Engineering for Industry, Vol. 111, May, pp. 149-157, 1989.
2. Tarn, J. H., and Tomizuka, M., "On-Line Monitoring of Tool and Cutting Conditions in Milling," ASME Journal of Engineering for Industry, Vol. 111, Aug., pp. 206-212, 1989.

3. Cook, N. H., "Tool Wear and Tool Life," ASME Journal of Engineering for Industry, Nov., pp. 931-938, 1972.
4. Altintas, Y., Yellowley, I., and Tlustý, J., "Detection of Tool Breakage in Milling," ASME Journal of Engineering for Industry, Vol. 110, pp. 271-277, 1988.
5. Rangwala, S., and Dornfeld, D. A., "Sensor Integration Using Neural Networks for Intelligent Tool Condition Monitoring," ASME Journal of Engineering for Industry, Vol. 112, pp. 219-228, 1990.
6. Tarn, Y. S., Hsieh, Y. W., and Hwang, S. T., "Sensing Tool Breakage in Face Milling with A Neural Network," Int. J. Mach. Tools Manufact., Vol. 34, No. 3, pp. 341-350, 1994.
7. Ko, T. J., and Cho, D. W., "Cutting State Monitoring in Milling by a Neural Networks," Int. J. Mach. Tools Manufact., 1993.
8. Leem, C. S., Dornfeld, D. A., Dreyfus, S. E., "A Customized Neural Network for Sensor Fusion in On-Line Monitoring of Cutting Tool Wear," ASME Journal of Engineering for Industry, Vol. 117, May, pp. 152-159, 1995.
9. 김대수, "신경망 이론과 응용 I (Neural Networks Theory and Applications)," 1992.
10. Internet, URL: <ftp://ftp.sas.com/pub/neural/FAQ.html>