

ART2 신경회로망을 이용한 밀링공정의 공구마모 진단

윤 선 일, * 고 태 조, ** 김 희 술**

Tool Wear Monitoring in Milling Operation Using ART2 Neural Network

Sun-Il Yoon, * Tae-Jo Ko, ** Hee-Sool Kim**

ABSTRACT

This study introduces a tool wear monitoring technology in face milling operation comprised of an unsupervised neural network. The monitoring system employs two types of sensor signal such as cutting force and acceleration in sensory detection state. The RMS value and band frequency energy of the sensor signals are calculated for the input patterns of neural network. ART2 neural network, which is capable of self organizing without supervised learning, is used for clustering of tool wear states. The experimental results show that tool wear can be effectively detected under various cutting conditions without prior knowledge of cutting processes.

Key Words : Tool wear(공구마모), Monitoring(감시), Face milling operation(면삭밀링),
Cutting force(절삭력), Acceleration(가속도), ART2 Neural network(신경회로망)

1. 서 론

최근의 기계가공 공정은 수요자들의 다양한 제품 요구에 부응하기 위하여 FMC(flexible manufacturing cell), FMS(flexible manufacturing system)와 같은 유연 생산시스템을 많이 채택하고 있다. 이러한 디폴드 생산시스템의 생산성을 향상시키기 위해서는

무인운전 상태하에서 절삭과정의 채터진동이나 공구마모와 파손등의 이상상태(malfunction)를 자동적으로 감지할 수 있는 시스템의 개발이 필수적이다. 절삭과정에서 발생하는 여러가지 이상상태 중 공구마모는 주기적이고 지속적으로 발생하여 가공 정밀도와 생산성에 가장 큰 영향을 주는 항목이다. 전통적인 생산시스템에서는 경험을 가진 작업자가 마모를 감지하여 조치를 취

* 영남대학교 기계공학과 대학원(정희원)

** 영남대학교 기계공학과(정희원)

하거나, 일정한 회수의 가공후 획일적으로 공구를 교환하는 방식을 취해 왔다. 그러나 공장 자동화나 무인화를 실현시키기 위해서는 공구마모를 효과적으로 진단할 수 있는 방안이 마련되어야 하며, 이에 대한 연구도 활발히 진행되고 있는 실정이다.^{[1], [2]}

가공상태를 감시하기 위한 최근의 연구동향은 단일센서 혹은 센서융합(sensor fusion)을 하는 방법으로 가공대상에 적절한 센서의 선정, 진단대상에 민감한 특징을 추출하기 위한 신호처리(signal process) 방법, 가공상태를 효과적으로 분류할 수 있는 패턴분류기(pattern classifier)의 개발 등으로 집약된다.

공구마모를 진단하기 위한 센서의 선정과 신호처리에 관한 연구로서 Micheletti는 가속도계를 이용하여 측정한 진동을 스펙트럼 분석하여 마모와 진동의 상관관계를 조사하였으며^[3], Weller등은 가속도계로 측정한 신호를 필터링하여 고주파와 저주파의 크기 비로 공구마모를 진단하였다.^[4] Lindstrom등은 동절삭저항을 해석하여 공구상태를 진단하였고^[5], Mackinnon등은 절삭저항의 3방향 분력비를 이용하여 공구마모를 인식하였다.^[6] 최근에는 전류센서나 AE(acoustic emission)센서를 이용한 공구마모진단에 관한 연구도 많이 이루어지고 있다.^{[7], [8]}

공구의 마모상태를 분류하는 패턴분류기로서 최근 신경회로망(neural network)과 퍼지추론(fuzzy inference)에 의한 연구가 활발히 진행되고 있다.^{[9]-[14]} 신경회로망은 학습방법에 의해 감독형 학습알고리듬(supervised learning algorithm)과 무감독형 학습알고리듬(unsupervised learning algorithm)으로 대별된다. 현재까지 공구마모진단에 주로 사용하는 신경회로망은 입력층, 은닉층, 출력층의 구조로 된 다층퍼셉트론(multilayer perceptron)의 감독형 학습알고리듬이다. 여기에 일반화된 델타 규칙(generalized delta rule)을 적용한 오차역전파(error back propagation) 학습알고리듬을 사용하여 공구마모진단에 많은 성과를 거두고 있다. 그러나 감독형의 오차역전파 신경회로망은 상태를 분류하기 위해서 사전에 많은 양의 예비절삭 데이터로 학습을 시켜야 한다. 이것은 다품종을 소량생산하여 절삭환경이 수시로 변하는 FMS와 같은 유연 생산시스템에 적용시키는데 장애요인이 되고 있다.

본 연구에서는 밀링의 면삭가공에서 자기구성으로 무감독 학습이 가능한 ART2 신경회로망을 사용하여 공

구의 마모상태를 진단하고자 한다. 이를 위하여 공구동력계와 가속도계를 사용하여 절삭중에 절삭력과 가속도 신호를 각각 측정한다. 측정된 신호들을 먼저 신호처리기에 보내서 잡음 제거와 증폭을 하기 위한 전처리를 한후, 주파수분석과 통계적분석을 행하여 공구마모에 민감한 특징을 추출한다. 추출된 특징들을 ART2 신경회로망에 입력시켜서 공구상태를 군분류(clustering)한다. 이러한 시스템을 통하여 절삭환경이 바뀐 상태에서도 학습과정을 거치지 않고 직접 공구마모를 진단할 수 있는 방법을 제시하고자 한다.

2. ART2 신경회로망 이론

ART2 신경회로망은 Carpenter와 Grossberg에 의해 제시된 적응공진이론(adaptive resonance theory)을 기초로한 무감독 학습기능을 가진 신경회로망이다.^[15] 이 신경회로망은 유사한 패턴을 인식하고 처리하는 어텐셔널 서브시스템(attentional subsystem)과, 이미 알고 있는 패턴과 차이가 큰 새로운 패턴에 대해서 어텐셔널 서브시스템을 리셋(reset)시켜서 이 패턴을 인식하도록 하는 오리엔팅 서브시스템(orienting subsystem)으로 구성되어 있다. 이러한 구조에 의하여 새로운 환경에서 주어지는 입력패턴을 무감독으로 집단화(clustering)시킬 수 있다. ART 신경회로망은 단기기억(STM:short term memory)과 장기기억(LTM:long term memory)으로 구성되어 있다. 입력패턴은 단기기억에 의해서 받아 들여지고, 이것을 정규화, 이득조절, 경쟁, 학습과정을 거쳐서 가중치의 형태로 장기기억에 저장한다. 단기기억은 F1층과 F2층으로 나누어져 있으며, F1층에서는 정규화, 이득조절, 학습을 하게 되고 F2층에서는 경쟁을 하여 승자를 선택하고 이 노드를 소속그룹으로 간주한다.

적응공진이론 신경회로망 중에서 ART1은 이진수로 된 입력패턴만 사용할 수 있으나, ART2는 이진수 뿐만 아니라 아날로그(analog) 값이나 벡터 컴포넌트(vector component)도 입력패턴으로 처리할 수 있다. 이러한 능력을 갖추기 위해서 F1층의 구조가 더 복잡하게 되어 있다. ART2의 F2층은 ART1과 같으나, F1층은 여러개의 하부층과 이득제어 시스템으로 구성되어 있다.

Fig. 1은 ART2 신경회로망의 시스템 구조이다. F1층은 w, x, u, v, p 및 q의 6개 층으로 나누어져

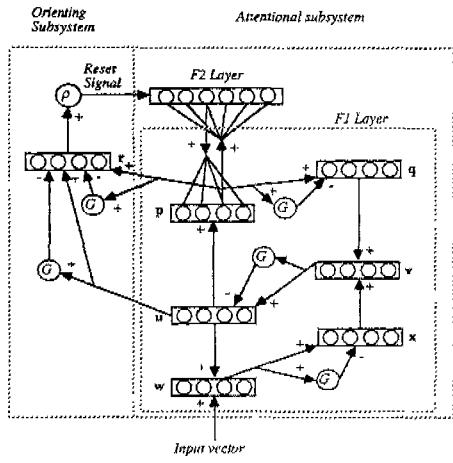


Fig. 1 Overall structure of the ART2 neural network

있다. 또한 각 층의 G는 금지신호를 진행방향 층의 노드에 보내 이득제어(gain control)를 한다. F1층의 모든 하부층과 오리엔팅 서브시스템의 r층은 동일한 수의 노드를 가지고 있다. 또 F1층의 각 하부층은 유니트와 유니트끼리 연결되어 있을 뿐 상향과 하향 가중치처럼 모든 노드끼리 연결되어 있지는 않다.

F1층의 6개 하부층에 대한 활성값은 다음과 같은 식으로 나타낼 수 있다.

$$w_i = I + \alpha u_i \quad (1)$$

$$x_i = \frac{w_i}{e + \|w\|} \quad (2)$$

$$v_i = f(x_i) + bf(q_i) \quad (3)$$

$$u_i = \frac{v_i}{e + \|v\|} \quad (4)$$

$$p_i = u_i + \sum_j g(y_j)z_{ij} \quad (5)$$

$$q_i = \frac{p_i}{e + \|p\|} \quad (6)$$

함수 $f(x)$ 는 F1층에서 일어나는 잡음을 감소시키는 역할을 하며

$$f(x) = \begin{cases} 0, & x \leq \theta \\ x, & x > \theta \end{cases} \quad (7)$$

로 되고 θ 는 1보다 작은 양의 수이다. a, b, e는 상수로서 문제에 적합한 값으로 결정해야 한다.

F2층으로의 입력값은 입력벡터 p_i 와 상향가중치 z_{ij} 의 내적으로 구성된다.

$$T_j = \sum_i p_i z_{ij} \quad (8)$$

이들 각 노드의 값은 F2층에서 상호 경쟁으로 하나의 승리노드만 남김으로써, 소속되는 군을 나타내는 노드를 선택한 것이 된다.

F2의 출력함수는

$$g(y_i) = \begin{cases} d & \text{if } T_i = \max\{T_k\} \forall k \\ 0 & \text{otherwise} \end{cases} \quad (9)$$

로 되며, 이 식에서 집합 $\{T_k\}$ 는 오리엔팅 서브시스템에 의해서 리셋되지 않은 노드만 포함된다.

F1층의 p하부층에서는

$$p_i = \begin{cases} u_i & \text{if } F2 \text{ is inactive} \\ u_i + dz_j & \text{if the } J\text{th node on } F2 \text{ is active} \end{cases} \quad (10)$$

로 작동하게 된다.

LTM에서 만약 v_j 가 F2층의 승리노드라고 할 때, F1층의 v_j 에 대한 상향식과 F2층의 v_j 에서 F1층의 v_i 에 대한 하향식은 각각

$$z_j = z_{ij} = \frac{u_i}{1-d} \quad (11)$$

로 되며, 여기서 d 는 $0 < d < 1$ 이다.

오리엔팅 서브시스템은 주어진 경계계수를 이용하여, 새로운 패턴과 이미 알고 있는 패턴과의 불일치를 판정하는 것이다. 오리엔팅 서브시스템의 r층의 노드에 대한 활성값은 다음 식과 같다.

$$r_i = \frac{u_i + c p_i}{\|u\| + \|cP\|} \quad (12)$$

불일치에 의한 리셋의 조건은

$$\frac{\rho}{\|r\|} > 1 \quad (13)$$

이고 ρ 는 경계계수(vigilance parameter)이다.

가중치들의 초기값은 하향가중치는 $z_{ij}(0)=0$ 으로 하고 상향가중치는 다음 식과 같다.

$$z_{ij}(0) = \frac{1}{(1-d)\sqrt{M}} \quad (14)$$

만약 새로운 패턴이 소속되어지는 그룹과 불일치가 작아서 식(13)에 의해 리셋되지 않는다면 이 패턴을 학습하기 위해서 가중치를 식(11)에 따라 수정하게 된다. 만약 이미 만들어진 모든 노드에 대해서도 패턴의 유사성이 없으면 새로운 노드를 만들고, 패턴을 여기에 저장하게 된다.

3. 실험장치 및 실험방법

공구의 마모진단을 위한 실험은 knee형 수직밀링머신에서 Fig. 2와 같이 수행했으며, Table 1은 실험장치의 규격이다. 커터는 직경 100mm의 삽입식으로 6개의 초경 인서트를 삽입하여 건식으로 절삭하였다. 실험에 사용된 밀링커터와 인서트의 규격은 Table 2와 같다.

절삭소재는 밀링가공에 많이 사용되는 일반구조용 압연강재 SB41로 된 사각형 시편($138 \times 78\text{mm}$)을 사용했다. 절삭조건은 절삭속도, 이송속도 그리고 절삭깊이를 각각 $370\text{-}750\text{rpm}$, $61\text{-}127\text{mm/min}$, $0.8\text{-}1.2\text{mm}$ 로 변경시키면서 실험했다.

밀링의 공구마모는 인서트의 반경방향 및 축방향의 혼들림오차(runout) 때문에 주여유면(major flank) 및 부여유면(minor flank)의 마모량이 일정하지 않다. 이러한 혼들림오차를 고려한 공구마모의 기계적인 모델(mechanistic model)은 인서트를 1개만 사용한 모델^[16]과 여러개를 동시에 사용한 모델^[17]들이 개발되어 있다. 본 실험에서는 6개의 인서트를 동시에 끼워 실험하였으며, 인서트를 커터에 끼울 때 발생하는 혼들

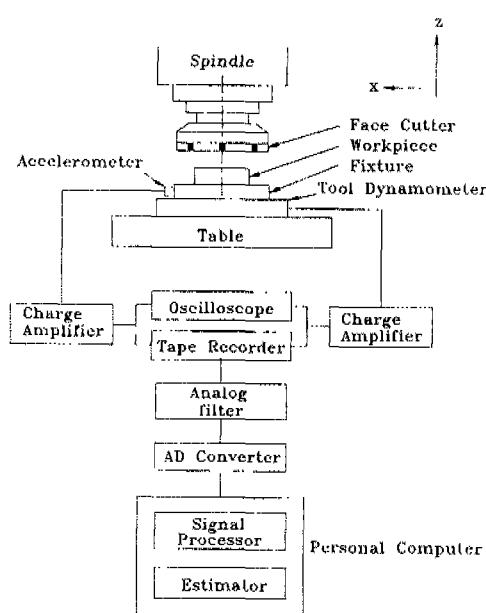


Fig. 2 Schematic diagram of experimental set-up

Table 1 Specification of experimental instruments

Milling machine	화천기계 HMV-F-1100
Tool dynamometer	Kistler type 9257-A
Accelerometer	Rion type PV36
Charge amplifier	Kistler type 5008EDPM-2300
AD converter	Data translation DT 2833
Personal computer	IBM PC 486DX-50
Oscilloscope	Tektronix 2202 storage
Tool microscope	Mitutoyo type B1-5

Table 2 Details of cutter and insert for cutting experiment

Cutter	1. Maker : Korea Tungsten 2. Model : M415SP04R-12 3. Specification : Lead angle : 15 deg. Radial rake angle : 0 deg. Axial rake angle : 7 deg. Insert number : 6
Insert	1. Maker : Korea Tungsten 2. Model : SPGN 1203P20 3. Specification : Material : Tungsten Carbide(P20) Tool nose radius : 0.8mm Flank relief angle : 11 deg.

림오차를 줄이기 위해 지그(jig)와 다이얼케이지를 이용하여 0.01mm 이내로 조정하였다.

공구의 마모량은 인서트 텁의 수명평가에 가장 중요한 기준이 되는 주여유면 마모(이하 여유면 마모)를 공구현미경으로 측정했다. 측정된 6개 인서트의 마모량은 다음과 같이 평균처리하였다.

$$VB_n = \frac{1}{n} \sum_{i=1}^n VB(i) \quad (15)$$

본 연구에서 공구의 마모량은 ISO 규정에 따라서 노즈부와 절입경계부를 제외한 나머지 절인부 마모의 평균폭을 여유면 마모량 VB 로 하여 측정하였다. 공구수명의 판별기준은 여유면 마모량이 0.3mm 이하일 때는 정상상태(normal state), 0.3mm 이상일 때는 비정상상태(abnormal state)로 분류하였다.

절삭과정 동안 가속도계와 공구동력계를 이용하여 이송방향의 가속도와 절삭력을 측정하였다. 모든 신호는

Table 3 Cutting conditions used in the experiment

Cut no.	Cutting speed (rpm)	Feed rate (mm/min)	Depth of cut (mm)	Tool state VB(mm)
1-9	370	61	0.8	0-0.8
10-18	370	61	1.2	0-0.8
19-27	370	87	0.8	0-0.8
28-36	370	87	1.2	0-0.8
37-45	520	87	0.8	0-0.8
46-54	520	87	1.2	0-0.8
55-63	520	127	0.8	0-0.8
64-72	520	127	1.2	0-0.8
73-81	750	87	0.8	0-0.8
82-90	750	87	1.2	0-0.8
91-99	750	127	0.8	0-0.8
100-108	750	127	1.2	0-0.8

신호증폭기(charge amplifier)를 통해 증폭한 후 오실로스코프(oscilloscope)로 관찰하면서, 데이터를 off-line으로 처리하기 위해 데이터 레코더(VHS cassette data recorder)에 저장하였다. 저장된 데이터는 절삭과정의 여러가지 잡음에 의한 DC성분과 공구의 runout 성분을 제거하기 위해서 30-1200Hz의 대역통과(band pass) 필터링을 했다. 이 신호는 AD변환기 를 통해서 4KHz로 샘플링되어 2048개씩 PC로 읽어 들여졌다.

Table 3은 본 실험에서 실시한 절삭조건을 나타내었다.

4. 신호처리 및 특징추출

일반적으로 센서의 출력신호에는 가공상태에 대한 정보외에 여러가지 잡음성분이 포함되어 있으므로 필터링 과 증폭을 통해 신호의 S/N 비(signal/noise ratio)를 높이는 전처리(preprocessing)가 필요하다. 이렇게 전 처리된 신호에 대해 특징추출(feature extraction)을 위해 사용되는 방법으로서 시간영역의 통계적분석법, 주파수영역의 스펙트럼(spectrum)분석법, 시계열(time series)분석법 등 다양한 신호처리를 행해진다. 여기서 많은 계산을 필요로 하는 주파수분석법이나 복잡한 통계적분석법 등은 신호처리 시간이 길고 메모리

의 용량을 많이 차지하여 종래에는 기피되어 온 것이 사실이다. 그러나 최근에는 반도체 기술이 급진적으로 발전되고 있으며 마이크로 프로세서나 DSP와 같은 빠른 신호처리 장치의 발달로 이러한 문제점은 큰 장애가 되지 않을 것으로 판단된다.

Fig. 3은 공구마모에 따른 절삭력신호의 주파수변환을 나타낸 것이다. 그림에서 절삭속도는 370rpm이고 인서트의 수가 6개 이므로 37Hz씩의 하모닉성분이 나타나고 있다. 공구가 마모됨에 따라서 이를 하모닉성분의 파워가 점점 증가함을 알 수 있다. 이 하모닉성분은 3번째까지 가장 특징적으로 잘 나타나므로 3번째 하모

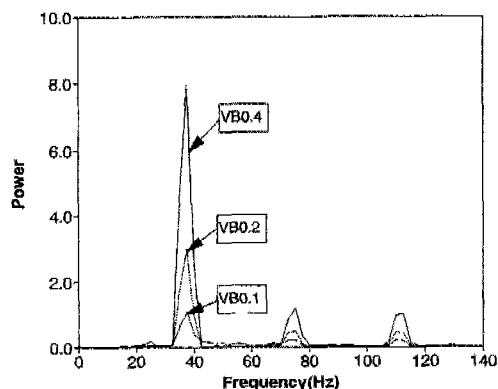


Fig. 3 Power spectral density of cutting force with the progress of tool wear
(Speed : 370rpm, Feed rate : 61mm/min)

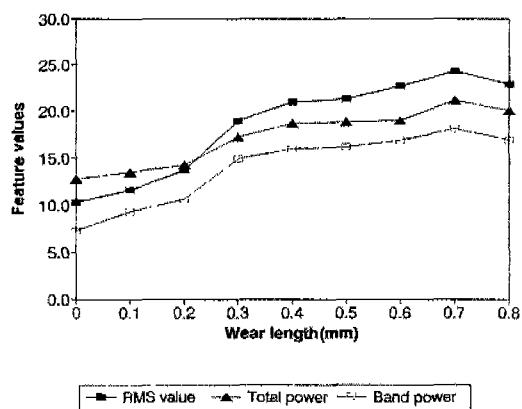


Fig. 4 Variation of cutting force with the progress of tool wear
(Speed : 370rpm, Feed rate : 61mm/min)

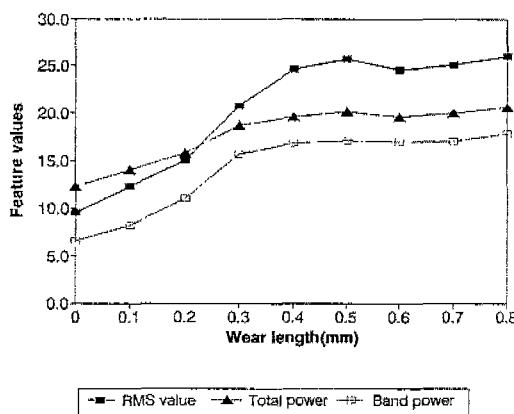


Fig. 5 Variation of cutting force with the progress of tool wear
(Speed : 520rpm, Feed rate : 87mm/min)

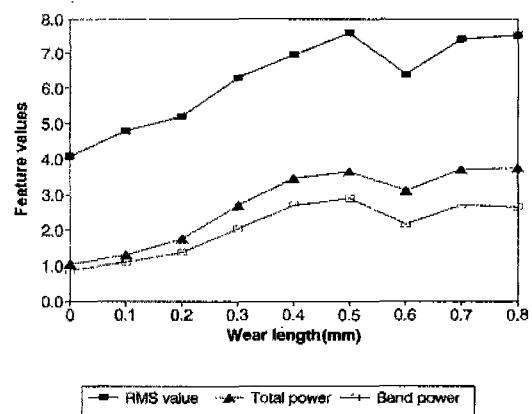


Fig. 7 Variation of acceleration with the progress of tool wear
(Speed : 520rpm, Feed rate : 87mm/min)

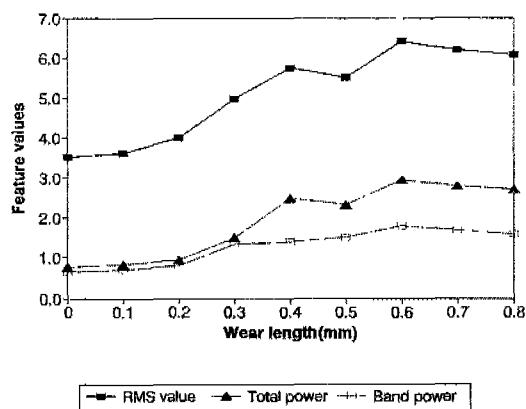


Fig. 6 Variation of acceleration with the progress of tool wear
(Speed : 370rpm, Feed rate : 61mm/min)

닉스분이 포함되는 130Hz까지의 대역주파수 에너지 (band frequency energy)값을 신경회로망 입력특징으로 사용하였다. 또한 Fig. 4와 Fig. 5에서 보듯이 공구마모가 진행됨에 따라 전주파수 에너지(total frequency energy)값과 시간영역의 RMS(root mean square)값도 특징적으로 증가하고 있다. 이 세 가지의 값들은 특히 여유면 마모량 VB가 0.3mm 이상 되는 시점에서 급격히 증가하는 경향을 보이므로 공구수명 평가에 좋은 입력특징으로 사용될 수 있다.

Fig. 6과 Fig. 7은 공구마모가 진행됨에 따라 가속

도신호의 주파수 에너지값과 RMS값의 변화를 나타낸 것이다. 가속도신호는 절삭력신호처럼 저주파수에서 뚜렷한 하모닉성분을 나타내지는 않으나 공구마모가 진행됨에 따라서 전주파수 에너지값과 RMS값이 점점 증가하는 추세를 보였다. 특히 runout 성분이 지배하는 저주파수 영역과 잡음이 지배하는 고주파수영역을 제외한 500~1000Hz의 대역주파수 에너지값은 공구마모의 특징을 잘 나타내었다. 또한 시간영역의 RMS값도 공구마모가 0.3mm 이상에서 그 증가추세가 두드러지게 나타났다. 가속도신호는 공구가 과마모되면서 증가추세가 더 이상 계속되지 않고 둔화되었다. 이는 공구마모가 진행됨에 따라 마찰력의 증가로 인하여 진동이 감쇠되는 것으로 판단된다.

따라서 본 연구에서는 공구마모 진단을 위한 신경회로망의 입력패턴으로 다음 6가지의 특징을 선정하였다.

- 1) 절삭력신호의 전주파수 에너지값
- 2) 절삭력신호의 대역주파수 에너지값
- 3) 절삭력신호의 시간영역 RMS값
- 4) 가속도신호의 전주파수 에너지값
- 5) 가속도신호의 대역주파수 에너지값
- 6) 가속도신호의 시간영역 RMS값

5. 신경회로망의 적용

자기구성으로 무감독 학습을 하는 신경회로망에 대해서 공구마모의 감지능력을 평가하기 위해 여러가지 조

전으로 그 성능을 평가하였다. 공구마모 진단을 위해 절삭력과 가속도신호의 6개 특징을 ART2 신경회로망의 입력패턴으로 제시하여 패턴분류 시켰다. 먼저 입력에 사용한 절삭조건과 공구마모 상태는 Table 3과 같다. 공구의 마모상태는 주여유면 마모량을 0mm부터 0.8mm까지 9단계로 분류하였다.

ART2 신경회로망에서 식(1)부터 식(7)까지 제시된 상수값은 입력데이터의 크기나 형식에 따라 달라진다. 일반적으로 이 상수값은 많은 경험을 통해 결정된다. 본 실험장치에서는 여러가지의 절삭조건에서 이 상수값을 $a=0.4$, $b=0.4$, $c=0.6$, $d=0.6$, $e=0.001$, $\theta=0.6$ 으로 설정하였을 때 가장 정확한 분류성능을 나타내었다.

Table 4의 (a)에서 (h)까지는 신경회로망에 Table 3과 같은 절삭조건의 데이터를 입력시켰을 때 나타나는 출력군의 분류결과이다. 여기서 출력군을 4개의 그룹으로 나누었으나 그 이상 출력군의 수에서도 같은 결과를 나타내었다. 즉 출력군 1은 정상적인 공구상태, 출력군 2는 공구마모 상태를 나타내며 출력군 3과 출력군 4는 패턴의 불일치가 심할 경우를 대비하여 미리 만들어준

Table 4 Classification results of the ART2 neural network

(a) $\rho=0.95$, 370rpm, 61mm/min, 1.2mm

Cut no.	Class 1	Class 2	Class 3	Class 4
1	1	0	0	0
2	1	0	0	0
3	1	0	0	0
4	1	0	0	0
5	1	0	0	0
6	1	0	0	0
7	1	0	0	0
8	1	0	0	0
9	1	0	0	0

(b) $\rho=0.96$, 370rpm, 61mm/min, 1.2mm

Cut no.	Class 1	Class 2	Class 3	Class 4
1	1	0	0	0
2	1	0	0	0
3	1	0	0	0
4	0	1	0	0
5	0	1	0	0
6	0	1	0	0
7	0	1	0	0
8	0	1	0	0
9	0	1	0	0

(c) $\rho=0.995$, 370rpm, 61mm/min, 1.2mm

Cut no.	Class 1	Class 2	Class 3	Class 4
1	1	0	0	0
2	0	1	0	0
3	0	0	1	0
4	0	0	1	0
5	0	0	1	0
6	0	0	1	0
7	0	0	1	0
8	0	0	1	0
9	0	0	1	0

(d) $\rho=0.96$, 520rpm, 87mm/min, 1.2mm

Cut no.	Class 1	Class 2	Class 3	Class 4
46	1	0	0	0
47	1	0	0	0
48	1	0	0	0
49	0	1	0	0
50	0	1	0	0
51	0	1	0	0
52	0	1	0	0
53	0	0	1	0
54	0	1	0	0

임의의 출력군이다. Table 4(a)에서 Table 4(c)까지는 동일한 절삭조건에서 공구마모에 따른 입력특징값을 주고 신경회로망의 경계계수 ρ 만을 변경시켰을 때 출력값들의 변화를 나타내었다. 여기서 경계계수가 0.95이하에서는 패턴의 불일치에 대한 민감도가 떨어져 모든 입력패턴을 class 1으로 분류하였다. 경계계수를 높여서 0.96이상 0.99까지는 마모량 0.3mm이상인 공구를 class 2로 잘 분류하였다. 그러나 경계계수가 0.99이상 일때는 입력패턴의 변화에 너무 민감해져서 3개의 출력군으로 분류하였다. 즉 공구마모의 분류를 초기상태, 중간상태, 그리고 심하게 마모된 상태를 나타내는 상황으로 이해할 수가 있다.

Table 4(d)와 Table 4(e)는 절삭속도와 이송속도가 다른 각각의 상태에서 동일한 경계계수를 유지하면서 입력값을 주었을 때 공구마모의 진행에 따른 출력값을 나타내었다. 약간의 오차는 있었으나 전반적으로 공구마모 상태를 잘 분류하였다.

(e) $\rho=0.96$, 750rpm, 127mm/min, 1.2mm

Cut no.	Class 1	Class 2	Class 3	Class 4
100	1	0	0	0
101	1	0	0	0
102	1	0	0	0
103	0	1	0	0
104	0	1	0	0
105	0	1	0	0
106	0	1	0	0
107	0	1	0	0
108	0	1	0	0

(f) $\rho=0.96$, 370rpm, 520rpm, 87mm/min, 0.8mm

Cut no.	Class 1	Class 2	Class 3	Class 4
19	1	0	0	0
20	1	0	0	0
21	1	0	0	0
22	0	1	0	0
23	0	1	0	0
24	0	1	0	0
25	0	1	0	0
26	0	1	0	0
27	0	1	0	0
37	1	0	0	0
38	1	0	0	0
39	1	0	0	0
40	0	1	0	0
41	0	1	0	0
42	0	1	0	0
43	0	1	0	0
44	0	1	0	0
45	0	1	0	0

Table 4(f)와 Table 4(g)는 한 절삭조건에서 공구가 완전히 마모될 때까지 절삭하고 새 공구로 교환함과 동시에 절삭속도를 변경시켜서 연속적으로 입력값을 주었을 때의 연속적인 분류성능을 나타내었다. Table 4(f)는 Table 3과 같은 절삭조건에서 절삭속도를 약간 변경시켰을 때는 동일한 절삭조건으로 입력했을 때와 유사한 연속 분류성능을 나타내었다. 그러나 Table 4(g)와 같이 절삭속도를 급격하게 변경시켰을 때는 공구의 상태를 class 1, class 2 그리고 class 3의 3개 그룹으로 분류하였다. 이는 입력특징 내부의 데이터 구조를 분석하여 출력을 배출한 결과로서 염밀한 의미에서 신경망의 민감도가 증가한 것으로 이해할 수 있다. 물론 class 2 이상을 공구마모 상태로 보면 class 3 역

(g) $\rho=0.96$, 370rpm, 750rpm, 87mm/min, 0.8mm

Cut no.	Class 1	Class 2	Class 3	Class 4
19	1	0	0	0
20	1	0	0	0
21	1	0	0	0
22	0	1	0	0
23	0	1	0	0
24	0	1	0	0
25	0	1	0	0
26	0	1	0	0
27	0	1	0	0
73	1	0	0	0
74	1	0	0	0
75	0	1	0	0
76	0	1	0	0
77	0	0	1	0
78	0	1	0	0
79	0	1	0	0
80	0	0	1	0
81	0	0	1	0

(h) $\rho=0.96$, 370rpm, 61mm/min, 0.8mm, 1.2mm

Cut no.	Class 1	Class 2	Class 3	Class 4
1	1	0	0	0
2	1	0	0	0
3	1	0	0	0
4	0	1	0	0
5	0	1	0	0
6	0	1	0	0
7	0	1	0	0
8	0	1	0	0
9	0	1	0	0
10	1	0	0	0
11	1	0	0	0
12	0	1	0	0
13	0	1	0	0
14	0	1	0	0
15	0	0	1	0
16	0	0	1	0
17	0	0	1	0
18	0	0	1	0

시 공구마모로 볼 수 있다. Table 4(h)는 절삭깊이를 변경시켜서 연속적으로 입력값을 주었을 때의 출력값을 나타내었다. 이 경우에도 먼저 입력된 절삭조건과 비교하여 출력되므로 뒤에 입력한 절삭조건의 분류성능은 민감도가 더욱 증가하여 3개의 그룹으로 분류하였다.

6. 결 론

밀링의 면삭가공에서 공구의 마모상태를 진단하기 위

해 자기구성으로 무감독 학습이 가능한 ART2 신경회로망을 적용하였다. 마모상태를 감시하기 위한 센서는 공구동력계와 가속도계를 사용하였다.

센서의 신호는 전처리하여 이송방향 절삭력과 가속도의 전주파수 에너지값, 대역주파수 에너지값, 시간영역의 RMS값을 각각 신호의 특징으로 추출하여 신경회로망의 입력패턴으로 사용하였다. 이 값들은 공구마모와 깊은 연관성을 가지고 있었으며, 공구마모를 진단하기 위한 유효한 특징임을 보여 주었다.

ART2 신경회로망으로 마모상태를 분류한 결과 ISO의 공구수명 기준이 되는 0.3mm 전후의 주여유면 마모에서 사전 학습과정을 거치지 않고도 우수한 군분류 성능을 나타내었다. 이러한 분류성능은 동일한 절삭조건으로 연속적인 가공을 행할 때 특히 우수한 성능을 보였다. 그러나 비슷한 절삭조건에서 연속적으로 진단하면 동일한 절삭조건과 유사한 분류성능을 보이지만 급변하는 절삭조건에서 연속적으로 입력값을 주었을 때는 민감도가 증가하여 정확한 분류성능이 저하하였다.

따라서 이러한 공구마모 진단시스템은 동일한 절삭조건으로 대량생산을 하는 공정에서 효과적으로 적용될 수 있으며, 절삭조건이 생산 로트에 따라 변하는 다품종 소량생산에서 같은 종류의 가공을 할 때는 약간의 신경회로망 상수와 경계계수를 조정하면 학습과정을 거치지 않고도 사용할 수 있을 것으로 사료된다.

참고문헌

- Dan,L., Mathew,J., "Tool wear and failure monitoring techniques for turning-A review", Int. J. Mach. Tools Manufact. Vol.30, No.4, pp.579-598, 1990.
- Tlusty,J., "A critical review of sensors for unmanned machining", Annals of the CIRP Vol.32, pp.563-572, 1983.
- Micheletti,G.F., "Tool wear and cutting force in the steel turning". Annals of the CIRP, Vol.16, pp.353-359, 1968.
- Weller,E.J., Schier,H.M., Weichbrodt,B., "What sound can be expected from a worn tools?", ASME J. Eng. Ind., Vol.91, pp.524-534, 1969.
- Lindstrom,B., Lindberg,B., "Measurement of dynamics cutting forces in the cutting process, a new sensor for in-process measurements", Proc. 24th MTDR Conf. pp.137-142, 1983.
- Nackinnon,R., Wilson,G.E., Pan L.X., "Real time monitoring of the dynamic process of tool wear in turning", Technical Report of Nanjing Aeronautical Institute, 1984.
- Mannan,M.A., "Monitoring and adaptive control cutting process by means of motor power and current measurements", Annals of the CIRP, Vol.38, No.1, pp.347-350, 1989.
- Liang,S.Y., Dornfeld,D.A., "Tool wear detection using time series analysis of acoustic emission", ASME J. Eng. Ind., Vol.111, pp.199-205, 1989.
- Jiaa,C.L., Dornfeld,D.A., "On-line tool condition monitoring in face milling with acoustic emission", Proceedings of the ASME Winter Annual Symposium on CAD and Manufacturing, pp.45-53, 1989.
- Elbestawi,M.A., Papazafiriou,T.A., Du,R.X., "In-process monitoring of tool wear in milling using cutting force signal", Int. J. Mach. Tools Manufact., Vol.31, No.1, pp.55-73, 1991.
- Teitenberg,T.M., Bayoumi,A.E., Yuce-san,G., "Tool wear modeling through an analytical mechanistic model of milling processes", Wear, Vol.154, pp.287-304, 1992.
- Rangwala,S., Dornfeld,D.A., "Sensor integration using neural networks for intelligent tool condition monitoring", ASME J. Eng. Ind., Vol.112, pp.219-228, 1990.
- Kouatli,I., Jones,B., "An improved design procedure for fuzzy control systems", Int. J. Mach. Tools Manufact., Vol.31, No.1, pp.107-122, 1991.

14. Ko,T.J., Cho,D.W., Lee,J.M., "Fuzzy pattern recognition for tool wear monitoring in diamond turning", Annals of the CIRP, Vol.41, No.1, pp.125-128, 1992.
15. Carpenter,G.A., Grossberg,S., "The ART of adaptive pattern recognition by a self-organizing neural networks", IEEE Computers, pp.77-88, March 1988.
16. Fu,H.J., DeVor,R.E., Kapoor,S.G., "A mechanistic model for the prediction of the force system in face milling operation", ASME J. Eng. Ind., Vol.106, pp.81-88, 1984.
17. Gu,F., Kapoor,S.G., DeVor,R.E., Bandyopadhyay,P., "An approach to on-line cutter runout estimation in face milling", Trans. NAMRI/SME, Vol.19, pp.240-247, 1991.
18. 고태조, 조동우, "자기구성 신경회로망을 이용한 면삭밀링에서의 공구파단검출", 대한기계학회논문집, 제18권 8호, pp.1939-1951, 1994.
19. 최기상, 최기홍, "ART2 신경회로망의 자기조정 기능을 이용한 선삭공정에서의 공구감시", 대한기계학회논문집, 제17권 4호, pp.763-775, 1993.