

〈論 文〉

자기구성 신경회로망을 이용한 면삭밀링에서의 공구파단검출

고태조* · 조동우**

(1993년 12월 15일 접수)

Tool Breakage Detection in Face Milling Using a Self Organized Neural Network

Tae Jo Ko and Dong Woo Cho

Key Words : Milling Process(밀링공정), Adaptive Signal Processing(적응신호처리), Tool Breakage(공구파단), Feature(특징), Model Parameter(모델계수), Self Organized Neural Network(자기구성 신경회로망)

Abstract

This study introduces a new tool breakage detecting technology comprised of an unsupervised neural network combined with adaptive time series autoregressive(AR) model where parameters are estimated recursively at each sampling instant using a parameter adaptation algorithm based on an RLS(Recursive Least Square). Experiment indicates that AR parameters are good features for tool breakage, therefore it can be detected by tracking the evolution of the AR parameters during milling process. An ART 2(Adaptive Resonance Theory 2) neural network is used for clustering of tool states using these parameters, and the network is capable of self organizing without supervised learning. This system operates successfully under the wide range of cutting conditions without a priori knowledge of the cutting process, with fast monitoring time.

1. 서 론

공장자동화의 최하위 단위인 절삭가공기계(공작기계)에 대한 무인화의 실현은 장래에 완성될 IMS(intelligent manufacturing system)시스템의 구축에 있어서 필수적이다. 이러한 무인화를 이루기 위해서는 공구의 마모 또는 파단의 검출이 중요한 부분으로 인식되고 있다.

공구의 마모나 파단을 검출하기 위한 방법은 여러가지가 발표되어 있으나,^(1~3) 대부분의 경우는 단절인을 사용하는 선삭가공에 대한 연구였다. 특히, 공구의 파단(breakage)은 그 상황의 심각성때

문에 발생 즉시, 예를 들면 면삭작업에서 1회전 이내의 공구회전이내에 이를 검출하고 기계를 정지시켜야 한다.

밀링가공에서 공구의 파단을 검출하기 위해서 Altintas 등은 공구의 회전에 동조시킨 절삭력의 평균값에 대한 1차 및 2차 차분값을 이용하였다.⁽⁴⁾ 유사한 연구는 Tarn과 Tomizuka⁽⁵⁾에 의해 수행되었는데 그들은 절삭력에 대해 각종 통계적 신호처리를 한 후 여기서 나오는 특징을 이용하는 감시법을 제안했다. 이러한 기법들은 1회전당 절삭력의 평균값을 필요로 하기 때문에 본질적으로 1회전 이상의 시간지연이 불가피하다.

주목할 만한 연구는 시계열방법을 이용하여 절삭력을 28차 AR 모델링한 Sata 등의 연구인데,⁽⁶⁾ 그들은 모델의 잔류오차가 공구의 파단과 밀접한 관

*정회원, 대우중공업(주)

**정회원, 포항공과대학교 기계공학과

계가 있다고 발표했다. 이 연구는 Lan 등에 의해서 계속되어졌고,⁽⁷⁾ 그들은 모델에 기초한 적응신호처리기법을 이용한 15차 AR 모델링으로 매순간 절삭력 데이터를 샘플링할 때마다 모델을 갱신하는 방법으로 모델계수와 잔류오차를 구했으며, 이들 값은 공구의 파단을 잘 대변한다고 했다. 따라서 비록 높은 차수의 모델이지만 빠른 시간으로 감시가 필요한 밀링공구의 파단검출에 적합한 신호처리 방법임을 주장했다.

그러나 상기의 방법들은 공구의 상태를 판정하기 위해서 분류기를 사용할 때, linear classifier⁽⁸⁾나 신경회로망⁽⁹⁾ 등의 학습을 위해서 혹은 임계치의 결정을 위해서 사전에 많은 예비절삭데이터를 필요로 한다. 이러한 사전 절삭데이터의 생성 또는 학습은 소량의 부품을 가공하는 다품종 소량생산의 경우에는 어려운 일이 되고 있다.

본 연구에서는 적응 시계열 모델을 이용한 신호처리기와 무감독 학습으로 자기구성을 하는 신경회로망을 사용하여 공구의 파단을 검출하는 새로운 방법을 제시한다. 먼저 밀링절삭에서 면삭(face milling) 과정중 공구의 상태를 대변하는 절삭력의 변동을 잡음에 민감하지 아니한 feature로 만들기 위해서 시계열 데이터분석법을 이용하여 모델링하는 데, 적응 시계열 모델을 이용하여 매순간 데이터가 샘플링될 때마다 절삭력을 모델링하여 모델의 파라미터를 구하게 된다. 여기서 나오는 모델계수를 이용하여 ART 2 신경회로망을 자기구성 시켜 비슷한 패턴은 동일그룹에 속하도록 하는 군분류(cluster)를 하게 하여 공구의 상태를 계속 감시하게 된다. 따라서 본 연구에서 제시되는 새로운 공구파단의 검출방법은 절삭과정에 대한 사전지식이나 학습을 필요로 하지않고 또한 빠른 작동이 가능하므로 실제의 적용가능성이 매우 높을 것으로 기대된다.

2. 적응 AR모델을 이용한 밀링공정 모델링

시스템이 선형 미분방정식으로 모델링이 된다면, 이산신호로부터 Autoregressive Moving Average (ARMA : 자동회귀 이동평균) 형태의 스토캐스틱 차분방정식을 구할 수가 있다.⁽¹⁰⁾ t 가 이산신호를 나타내는 지수이고, 시계열 x_t 에 대한 n 차 AR모델을 사용한다면, 현재의 값에 대한 예측은 Fig. 1과 같이 n 단계 이전 값들의 선형조합으로 표현이

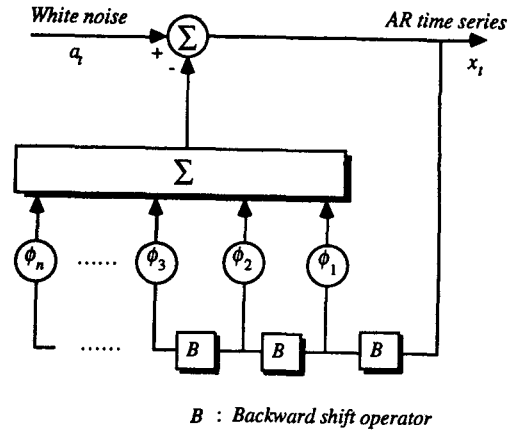


Fig. 1 AR time series model

가능하다. 즉 AR(n) 모델은

$$x_t - \phi_1 x_{t-1} - \phi_2 x_{t-2} - \dots - \phi_n x_{t-n} = a_t \quad (1)$$

로 표현된다.

여기서 x_t 는 계의 응답, $\phi_1, \phi_2, \dots, \phi_n$ 는 자동회귀 계수, 그리고 a_t 는 평균이 0(zero)이고 분산이 σ_a^2 인 백색잡음이다. 만일 백색잡음에 대한 계의 응답이 stationary stochastic과정이라면 식(1)로 주어지는 AR(n)모델의 계수들은 평균자승오차(mean-square error)를 최소화함에 의해 최적화할 수가 있다. 본 연구에서 사용되는 최소화방법은 RLS(recursive least square)법으로서, 순환 적응 모델이기 때문에 신호의 사전 통계적 성질을 필요로 하지 않고, 또한 새로운 데이터가 들어올 때마다 모델계수들을 새롭게 개선하므로 batch 모델에 비하여 적은 메모리로 모델링이 가능하고 계산시간이 빠르며, in-process적용이 쉬워진다.^(9,14) 망각지수를 사용하는 RLS모델링 알고리즘은 Ljung⁽¹¹⁾의 자료에 잘 나타나 있다.


3. 실험방법

공구의 파단실험은 컴퓨터로 제어가능하도록 구조를 변경시킨 범용 knee형 수직밀링머신에서 Fig. 2와 같이 수행했다. 6개의 초경으로 된 인서트 팁(P20)을 등간격으로 균일하게 삽입시킨 밀링커터가 사용이 되었으며, 이중 2개의 인서트가 실제 절삭에 참여하게 된다. 인서트의 삽입시에 과도한 반경방향 및 축방향의 runout는 신호처리에 나쁜 영향을 미치므로 이러한 현상을 방지하기 위하여 인

서트의 삽입시에는 다이얼게이지를 이용하여 정확한 삽입이 공구몸체에 이루어지도록 했다.

사용공작물은 SM45C(폭 60 mm, 길이 70 mm)로서, 절삭조건은 절삭속도 350~1100 rpm, 이송속도 30~90 mm/min, 절삭깊이 0.5~0.8 mm로 변경되면서 행해졌으며 Table 1에 공구의 상태와 함께 정리되어 있다.

절삭과정중에 실제의 공구파단과 같은 상황을 만들기 위해서 인서트에는 Fig. 3(a)와 같이 노즈 끝단에서 0.5 mm 떨어진 위치에 깊이 0.8 mm의 홈을 와이어 방전가공하여 만들고 이 인서트를 커터에 끼워 절삭했다. Fig. 4는 홈을 갖는 인서트를



(a) Normal insert (b) Broken insert

- ① Data recorder ② Filter
- ③ Oscilloscope ④ Charge amplifier
- ⑤ Computer ⑥ Servo drive unit
- ⑦ Servo motor ⑧ Tool dynamometer
- ⑨ Cutter ⑩ Milling machine
- ⑪ Accelerometer

Fig. 2 Photograph of experimental setup

Table 1 Cutting conditions used in the experiments.

Cut no.	Cutting speed (rpm)	Feed rate (mm/min)	Depth of cut (mm)	Tool state	Cut no.	Cutting speed (rpm)	Feed rate (mm/min)	Depth of cut (mm)	Tool state
1	1100	60	0.5	New	22	350	90	0.5	Broken
2	1100	60	0.8	New	23	350	60	0.8	Broken
3	1100	90	0.5	New	24	350	90	0.8	Broken
4	1100	90	0.8	New	25	650	60	0.8	Broken
5	650	30	0.5	New	26	650	90	0.8	Broken
6	650	30	0.8	New	27	1100	60	0.8	Broken
7	650	60	0.5	New	28	1100	90	0.8	Broken
8	650	60	0.8	New	29	1100	90	0.5	Chipped
9	650	90	0.5	New	30	1100	90	0.5	Chipped
10	650	90	0.8	New	31	1100	60	0.8	Chipped
11	350	60	0.5	New	32	1100	60	0.8	Chipped
12	350	60	0.8	New	33	650	30	0.5	Chipped
13	350	90	0.5	New	34	650	60	0.5	Chipped
14	350	90	0.8	New	35	650	90	0.5	Chipped
15	1100	60	0.5	Broken	36	650	30	0.8	Chipped
16	1100	90	0.5	Broken	37	650	60	0.8	Chipped
17	650	60	0.5	Broken	38	650	90	0.8	Chipped
18	650	90	0.5	Broken	39	350	60	0.5	Chipped
19	650	30	0.5	Broken	40	350	90	0.5	Chipped
20	350	30	0.5	Broken	41	350	90	0.8	Chipped
21	350	60	0.5	Broken	42	350	60	0.8	Chipped

가지고 절삭했을 때, 공구가 파단되는 순간을 포착한 것이다. 정상적인 절삭에서는 매 인서트마다 균일한 절삭력이 걸리다가 1.425초 이후에 힘이 파진 한개의 인서트가 부러진 후(Fig. 3(b)) 다음 인서트에는 과부하가 걸리고 이로 인하여 절삭력의 균일성이 없어진다. 따라서 절삭력의 특성이 공구파단에

에 의해서 바뀌어짐을 알 수 있다.

그리고 미소치핑의 신호를 얻기 위해서는 인위적인 치핑을 인서트에 만들어 절삭했으며, 또한 완전 파단의 신호를 만들기 위해서는 한개의 인서트를 커터에서 빼내고 절삭을 했다.

모든 실험과정동안, 공구의 상태(정상, 치핑, 파단)를 기록하면서, 공구동력계(Kistler type 9257 A)를 이용하여 이송방향의 절삭력을 측정하였으며, 이 신호는 off-line 신호처리를 위해서 신호증폭기(charge amplifier)를 통해 데이터기록계(VHS cassette data recorder)에 저장하였다.


4. 적응 AR모델링 결과

절삭조건과 절삭공구에 영향을 받는 절삭력의 DC성분 및 공구의 runout성분을 제거하기 위해서, 먼저 절삭력 신호에 대해서 2 Hz의 high pass 필터링을 했다. 이 신호는 off-line 신호처리를 위해 AD변환기를 통해서 1000개씩 PC로 읽어 들여졌다.

모델차수의 선택은 모델의 복잡성과 데이터의 정확한 모델링사이에 타협이 필요한 난이한 문제이다. 기본적인 방법은 서로 다른 모델차수에 대해서 모델의 성능을 비교하고 더 높은 차수의 모델이 가치가 있는지 판단하는 것이다. 그러나 실시간 감시가 필요한 경우에는, 계산시간의 측면에서 낮은 차수의 모델이 유리하고, 따라서 실시간 감시의 목적으로 밀링가공에서의 동적 절삭력을 모델링하기 위해서 8차의 모델을 사용했다.⁽¹⁴⁾

1초 동안 기록한 정상적인 공구로 절삭했을 때의 이송방향의 밀링 절삭력과 한단계 미리 예측한 예측값, 모델링 후의 잔류오차 그리고 첫번째부터 세번째 모델계수($\phi_1 \sim \phi_3$)의 수렴과정을 Fig. 5에 나타내었다. 그림에 의하면 시간에 따라서 오차가 감소하고 있음을 볼 수 있으며 최초로 모델계수가 수렴하는데는 0.3초가 걸리고 있다. 모델링과정에서 초기의 큰 변동은 처음계수의 임의추측(모든 모델계수를 영으로 함)과 함께 측정데이터가 들어오기 전까지는 측정값들을 영으로 하기 때문이다. Fig. 5(a)와 5(b)에서, 측정신호와 예측신호 사이에 큰 차이를 발견할 수 없으므로 모델이 측정데이터를 잘 추종하고 있음을 알 수 있다.

이송절삭력의 AR모델계수와 공구파단과의 상관관계를 조사하기 위해서 정상과 파단된 공구의 절



(a) Normal insert



(b) Broken insert

Fig. 3 Slotted insert machined by an electrical wire cutting machine,







Fig. 4 Details of cutting force signals at the moment of tool breakage.(Cutting speed : 650 rpm, Feed rate : 90 mm, Depth of cut : 1.0 mm)




(a) Feed directional cutting force signals



(b) One step ahead predicted values



(c) Residual error



(d) Convergence of first three parameters

Fig. 5 Modeling results

삭력에 대한 모델계수벡터 $[\phi_1, \dots, \phi_8]$ 값을 Fig. 6에 나타내었다. 두 상태(정상공구와 파단공구)는 잘 분리되고 있는 것을 알 수 있다.

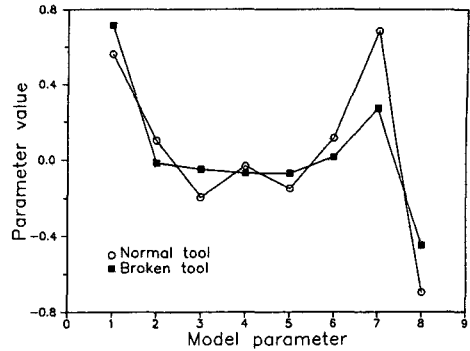


Fig. 6 Model parameters under different tool states. (Cutting speed : 1100 rpm, feed rate : 90 mm, Depth of cut : 0.5 mm)

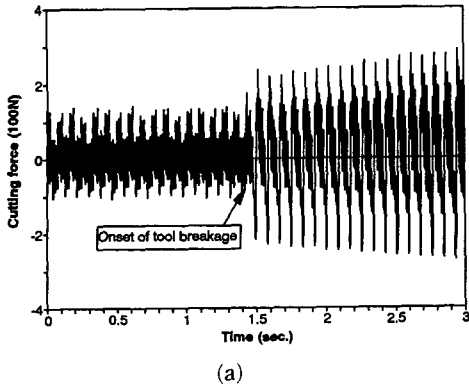
한편 정상상태로 가공중 갑자기 공구가 파단한 신호에 대해 모델링한 결과가 Fig. 7이다. Fig. 7(a)는 절삭과정중에서 파단이 일어났을 때의 신호이고 Fig. 7(b)는 이 신호를 연속적으로 모델링해 나갈 때의 모델계수의 변화이며 Fig. 7(c)는 모델의 잔류오차를 나타낸다. 그림에서 알 수 있듯이 Sata와 Lan의 주장대로 계수가 수렴한 후 갑자기 공구가 파단되면서 모델의 오차가 급격히 변하고 있음을 알 수 있다.

한편, Fig. 6의 파라미터를 이용하여 구한 파워스펙트럼^(10~11)을 Fig. 8에 나타냈다. 여기서 알 수 있는 것은, Fig. 8(a)에서 새로운 공구의 경우 모든 인서트에 대해서 균일한 절삭력이 걸리기 때문에 공구통과 주파수가 파워스펙트럼에서 지배적이었으나, Fig. 8(b)처럼 공구가 파단되었을 때는 파단된 인서트의 다음에 있는 인서트에 큰 힘이 걸리면서 절삭력의 균일성이 깨어지고 따라서 공구의 runout 성분이 지배적으로 나타난다는 것이다.

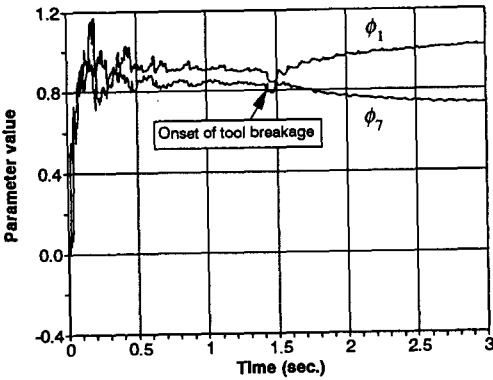
이상에서 살펴 보았듯이, AR모델계수를 계속적으로 추종함으로써 공구의 상태를 효과적으로 감시할 수 있다는 것을 확인하였다.

5. 적응공진이론


Carpenter와 Grossberg⁽¹²⁾는 Grossberg의 적응공진이론(adaptive resonance theory 2 : ART 2)⁽¹²⁾(즉, 회로망으로의 입력과 되먹임에 의한 예상치가 일치할 때 공진이 일어남)⁽¹³⁾을 기초로 경쟁학습이 가능한 신경망을 제시했다. 이 신경회로망은 유사한 패턴을 인식하고 처리하는 attentional시스템



(a)




(b)




(c)

Fig. 7 (a) Raw cutting force signal, (b) Model parameters, (c) Residual errors.(Cutting speed : 1100 rpm, Feed rate : 90 mm, Depth of cut : 0.5 mm)

과, 이미 알고 있는 패턴과 차이가 나는 새로운 패턴에 대해서는 attentional 시스템을 리셋시켜서 이 패턴을 인지하도록 하는 orienting 시스템으로 구성되어 있다. 이것은 무감독분류기(unsupervised classifier)로 작동되면서 패턴을 집단화(cluster-



(a)



(b)

(a) Normal tool, (b) Broken tool.(Cutting speed ; 650 rpm, Feed rate : 60 mm, Depth of cut : 0.5 mm)

Fig. 8 Variation of power spectral density with respect to the tool states

ing) 시키는 형태의 신경회로망이다. 적응공진이론 신경망은 단기 기억(STM: short term memory)과 장기 기억(LTM: long time memory)으로 구성되어 있다. 입력패턴은 단기 기억에 의해서 받아들여지고, 이것을 정규화, 이득조절, 경쟁, 학습과정을 거쳐 가중치의 형태로 장기 기억에 저장한다. 단기 기억은 F1층과 F2층으로 나누어져 있으며 F1층에서는 정규화, 이득조절, 학습을 하게 되고 F2층에서는 경쟁을 하게 하여 승자를 선택하고 이 노드를 소속그룹으로 간주한다.

적응공진이론 신경망중에서 ART 1⁽¹²⁾은 {0, 1}로 구성된 값만을 사용할 수 있으나 ART 2는 이진값 뿐만 아니라 일반적인 신호인 연속된 값을 처리할 수 있다. 이러한 능력을 지니기 위해서는 F1층을 복잡하게 만든다. 즉, ART 2의 F2층은 여러개의 하부층과 이득조절 시스템으로 구성되어 있다. F2

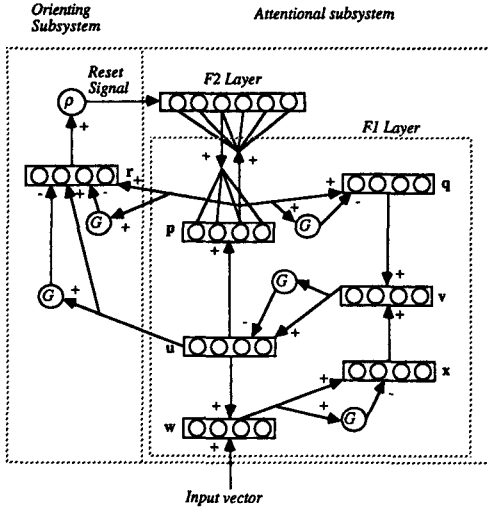


Fig. 9 The overall structure of the ART 2 network

층의 구조는 ART 1과 동일하다. Fig. 9는 ART 2 회로망으로서 F1층은 w, x, u, v, p 그리고 q 의 6개의 층으로 나누어져 있으며, 각 층에서 G 로 표시된 것은 금지신호를 진행방향 층의 노드에 보내는 gain-control을 나타낸다. F1층의 모든 하부층과 orienting 시스템의 r 층은 동일 수의 노드를 가지고 있다. F1의 각 하부층은 유니트와 유니트끼리 연결되어 있을 뿐 상향과 하향 가중치처럼 모든 노드끼리 연결되어 있지는 않다. F1층의 6개 하부층에 대한 활성값은 다음과 같은 식을 사용한다.

$$w_i = I_i + au_i \quad (2)$$

$$x_i = \frac{w_i}{e + \|w\|} \quad (3)$$

$$v_i = f(x_i) + bf(q_i) \quad (4)$$

$$u_i = \frac{v_i}{e + \|v\|} \quad (5)$$

$$p_i = u_i + \sum_j g(y_j) z_{ij} \quad (6)$$

$$q_i = \frac{p_i}{e + \|p\|} \quad (7)$$

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

$$f(x) = \begin{cases} 0, & 0 \leq \theta \\ x, & x > \theta \end{cases} \quad (8)$$

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

F2층으로의 입력값은 입력벡터 p_i 와 상향중치 z_{ji} 의 내적으로 구성된다.

$$T_j = \sum_i p_i z_{ji} \quad (9)$$

이들 각 노드의 값은 F2층에서 상호경쟁으로 하나의 승리노드만 남음으로써 소속되는 군을 나타내는 노드를 선택한 것이 된다.

F2의 출력함수는

$$g(y_i) = \begin{cases} d & \text{if } T_j = \max_k \{T_k\} \forall k \\ 0 & \text{otherwise} \end{cases} \quad (10)$$

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

F1층의 p 하부층에서는

$$p_i = \begin{cases} u_i & \text{if F2 is inactive} \\ u_i + dz_{ij} & \text{if the } j\text{th node on F2 is active} \end{cases} \quad (11)$$

로 작동하게 된다.

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

$$z_{ji} = z_{ij} = \frac{u_i}{1-d} \quad (12)$$

로 되며, 여기서, d 는 $0 < d < 1$ 이다.

Orienting 시스템은 주어진 경계계수를 이용하여, 새로운 패턴이 이미 알고있는 패턴과의 불일치를 판정하는 것이다. Orienting 시스템의 r 층의 노드에 대한 활성값은 다음과 같으며

$$r_i = \frac{u_i + cp_i}{\|u\| + \|cp\|} \quad (13)$$

불일치에 의한 리셋의 조건은

$$\frac{\rho}{\|r\|} > 1 \quad (14)$$

이고 ρ 는 경계계수(vigilance parameter)이다.

가중치들의 초기값은 하향가중치는 $z_{ji}(0) = 0$ 으로 하고 상향가중치는 다음 식과 같이 하는데

$$z_{ji}(0) \leq \frac{1}{(1-d)\sqrt{M}} \quad (15)$$

만약 새로운 패턴이 소속되어지는 그룹과 불일치가 적어서 식(14)에 의해 리셋되지 않는다면 이 패턴을 학습하기 위해서 가중치를 식(12)에 따라 수정

하게 된다. 만약 이미 만들어진 모든 노드에 대해서도 패턴의 유사성이 없으면 새로운 노드를 만들고 패턴을 여기에 저장하게 된다.

6. 신경회로망의 적용

면삭밀링가공중 일어나는 공구의 파단을 감지하기 위하여 이송방향의 절삭력 신호에 대해 AR모델링으로 전처리한 모델계수를 ART 2 신경회로망에 제시하여 패턴분류를 시켰다. 여기에서 사용한 상수값은 $a=0.4$, $b=0.4$, $c=0.6$, $d=0.6$, $e=0.001$ 그리고 $\theta=0.3$ 이다.

먼저 Table 1의 서로 다른 절삭조건인 14개 정상공구(Cut no. 1~14)와 14개의 파단공구(Cut no. 15~28)에 대한 모니터링 결과가 Table 2이다.

Table 2(a)는 경계계수 0.96일때의 결과인데 1번째부터 14번째의 정상공구는 class 1(정상)로 분류되다가 15번째인 파단공구부터 class 2(공구파단)로 잘 분류시키고 있음을 알 수 있다. 여기서, 경계계수를 바꾸어서 0.9로 하였을 때는 Table 2(b)처럼 패턴의 불일치에 대한 민감도가 떨어져서 모든 패

턴을 class 1로 분류해내고 있다. 또한 Table 2(c)와 같이 경계계수를 더욱 증가시켜 0.99로 하였을 때는 13번째의 절삭조건은 class 2, 17번째의 절삭조건은 class 4로 분류하는 등 신경회로망의 민감도가 증가하고 있다. (class 3~5는 정의되지 아니했음.)

한편 신경회로망에 새로운 패턴을 제시하면 처음 어떤 군을 창성하고 이어서 패턴이 계속 들어올 때마다 그전의 패턴과 차이가 많이 나면 새로운 군을 형성하고 그러하지 않으면 처음의 군으로 분류가 되고 있는데 이 과정에서 패턴사이의 약간의 불일치를 상향과 하향가중치를 수정함에 의해 수용을 하게 된다. 이러한 가중치의 변화를 보기 위하여 Table 2에서 사용한 28개의 절삭조건을 4번 반복하여 신경망에 제시하고 이때 변경되는 가중치의 합을 Fig. 10에 나타내었다. Fig. 10(a)에서 알 수 있듯이 동일 군의 패턴이 들어올 때는 이 패턴을 동일그룹으로 학습시키기 위한 상향가중치의 변화는 작으나, 15번째인 파단공구의 패턴이 들어올 때는 가중치의 변경이 크다. 다시 16번째의 패턴부터는 파단의 군을 나타내기 때문에 가중치의 변화가

Table 2 Classification results

(a) Vigilance number 0.96

Cut no.	Class1	Class2	Class3	Class4	Class5	Cut no.	Class1	Class2	Class3	Class4	Class5
1	1	0	0	0	0	15	0	1	0	0	0
2	1	0	0	0	0	16	0	1	0	0	0
3	1	0	0	0	0	17	0	1	0	0	0
4	1	0	0	0	0	18	0	1	0	0	0
5	1	0	0	0	0	19	0	1	0	0	0
6	1	0	0	0	0	20	0	1	0	0	0
7	1	0	0	0	0	21	0	1	0	0	0
8	1	0	0	0	0	22	0	1	0	0	0
9	1	0	0	0	0	23	0	1	0	0	0
10	1	0	0	0	0	24	0	1	0	0	0
11	1	0	0	0	0	25	0	1	0	0	0
12	1	0	0	0	0	26	0	1	0	0	0
13	1	0	0	0	0	27	0	1	0	0	0
14	1	0	0	0	0	28	0	1	0	0	0

(b) Vigilance number 0.9


Cut no.	Class1	Class2	Class3	Class4	Class5	Cut no.	Class1	Class2	Class3	Class4	Class5
1	1	0	0	0	0	15	1	0	0	0	0
2	1	0	0	0	0	16	1	0	0	0	0
3	1	0	0	0	0	17	1	0	0	0	0
4	1	0	0	0	0	18	1	0	0	0	0
5	1	0	0	0	0	19	1	0	0	0	0
6	1	0	0	0	0	20	1	0	0	0	0
7	1	0	0	0	0	21	1	0	0	0	0
8	1	0	0	0	0	22	1	0	0	0	0
9	1	0	0	0	0	23	1	0	0	0	0
10	1	0	0	0	0	24	1	0	0	0	0
11	1	0	0	0	0	25	1	0	0	0	0
12	1	0	0	0	0	26	1	0	0	0	0
13	1	0	0	0	0	27	1	0	0	0	0
14	1	0	0	0	0	28	1	0	0	0	0

(c) Vigilance number 0.99


Cut no.	Class1	Class2	Class3	Class4	Class5	Cut no.	Class1	Class2	Class3	Class4	Class5
1	1	0	0	0	0	15	0	0	0	1	0
2	1	0	0	0	0	16	0	0	0	1	0
3	1	0	0	0	0	17	0	0	0	1	0
4	1	0	0	0	0	18	1	0	0	0	0
5	1	0	0	0	0	19	1	0	0	0	0
6	1	0	0	0	0	20	1	0	0	0	0
7	1	0	0	0	0	21	1	0	0	0	0
8	1	0	0	0	0	22	1	0	0	0	0
9	1	0	0	0	0	23	1	0	0	0	0
10	1	0	0	0	0	24	1	0	0	0	0
11	1	0	0	0	0	25	1	0	0	0	0
12	1	0	0	0	0	26	1	0	0	0	0
13	0	1	0	0	0	27	1	0	0	0	0
14	0	0	1	0	0	28	1	0	0	0	0

작다가 29번째의 새로운 공구의 패턴이 반복됨에 따라서 가중치의 변화는 다시 커진다. Fig. 10(b)는 하향가중치의 합의 변화를 나타낸 것으로 그 학습

추이는 상향 가중치의 경우와 비슷하나, 상향가중치는 서서히 수렴하는 성질을 보이는 대신 하향가중치는 진동을 하고 있음을 알 수 있다.



(a) Bottom-up weights



(b) Top-down weights

Fig. 10 Variation of sum of absolute weights




Fig. 11 Recall capability of the classifier

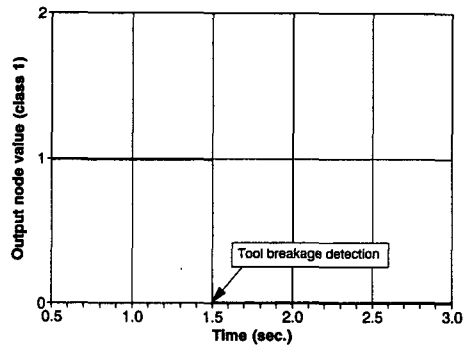


Fig. 12 Monitoring result to the continuous cutting force signals (Cutting speed : 650 rpm, Feed rate : 90 mm, Depth of cut : 1.0 mm)

이렇게 학습이 무감독으로 계속 진행되는 신경회로망의 회상(recall) 능력을 조사해 보기 위해서 먼저 Table 2의 28개의 패턴을 분류한 후 다시 28개의 동일한 절삭데이터를 반복하여 신경회로망에 제시한 결과가 Fig. 11이다. 초기 패턴이 제시되었을 때는 경계계수 0.96의 값에서 완벽하게 분류를 시켰으나 다시 동일한 패턴이 제시되었을 때는 학습중에 일어난 가중치의 심한 변경으로 인하여 화살표로 표시한 처음 몇개의 패턴을 잘못 분류해 내고 있으나 그 이후는 다시 완벽하게 분류를 해내고 있다.

다음은 정상공구와 파단공구에 더불어 치핑이 있는 경우의 패턴을 신경회로망의 입력으로 제시한 결과가 Table 3이다. 경계계수가 0.96일 때의 결과가 Table 3(a)인데 37번째 이후의 패턴(37~39, 41, 42번째 패턴)이 정상공구로 취급된다. 그러나 경계계수를 증가시켜 0.97로 하였을 때는 Table 3(b)와 같이 마지막 4개의 패턴을 제외하고 10개의

치핑패턴이 파단을 나타내는 class 2를 나타내고 있다. 이것은 당연한 것으로, 미소치핑이 있을 때는 경우에 따라서는 절삭이 가능하기도 하고 또한 공구의 파단과 같이 더 이상 절삭이 불가능할 경우도 있는데 본 신경망을 이용하면 이들의 경계도 설정도를 살펴보면 절삭조건이 가벼운 상황이며 따라서 이때는 절삭이 가능하다. 마찬가지로 경계계수 0.9에 대한 결과가 Table 3(c)인데 Table 2(b)와 같이 모든 패턴을 동일 군으로 분류하고 있다.

다음은 정상 공구로 절삭도중 공구의 파단이 있었던 신호(Fig. 4)에 대해 모니터링의 결과를 조사한 것이 Fig. 12에 나타나 있다. 이때 모니터링은 모델링이 정상상태에 들어갔다고 보는 0.5초 이후에 실시한 것으로 그림에 보듯이 공구의 파단은 1.505초에 감지되었는데, 실제적인 공구파단이 1.425초에서 일어난 것을 감안하면 주축회전수가 650 rpm이므로 0.87회전의 지연후에 공구파단을 검출한 것이다.

Table 3 Classification results.

(a) Vigilance number 0.96

Cut no.	Class1	Class2	Class3	Class4	Class5	Cut no.	Class1	Class2	Class3	Class4	Class5
1	1	0	0	0	0	22	0	1	0	0	0
2	1	0	0	0	0	23	0	1	0	0	0
3	1	0	0	0	0	24	0	1	0	0	0
4	1	0	0	0	0	25	0	1	0	0	0
5	1	0	0	0	0	26	0	1	0	0	0
6	1	0	0	0	0	27	0	1	0	0	0
7	1	0	0	0	0	28	0	1	0	0	0
8	1	0	0	0	0	29	0	1	0	0	0
9	1	0	0	0	0	30	0	1	0	0	0
10	1	0	0	0	0	31	0	1	0	0	0
11	1	0	0	0	0	32	0	1	0	0	0
12	1	0	0	0	0	33	0	1	0	0	0
13	1	0	0	0	0	34	0	1	0	0	0
14	1	0	0	0	0	35	0	1	0	0	0
15	0	1	0	0	0	36	0	1	0	0	0
16	0	1	0	0	0	37	1	0	0	0	0
17	0	1	0	0	0	38	1	0	0	0	0
18	0	1	0	0	0	39	1	0	0	0	0
19	0	1	0	0	0	40	0	1	0	0	0
20	0	1	0	0	0	41	1	0	0	0	0
21	0	1	0	0	0	42	1	0	0	0	0

(b) Vigilance number 0.97

Cut no.	Class1	Class2	Class3	Class4	Class5	Cut no.	Class1	Class2	Class3	Class4	Class5
1	1	0	0	0	0	10	1	0	0	0	0
2	1	0	0	0	0	11	1	0	0	0	0
3	1	0	0	0	0	12	1	0	0	0	0
4	1	0	0	0	0	13	1	0	0	0	0
5	1	0	0	0	0	14	1	0	0	0	0
6	1	0	0	0	0	15	0	1	0	0	0
7	1	0	0	0	0	16	0	1	0	0	0
8	1	0	0	0	0	17	0	1	0	0	0
9	1	0	0	0	0	18	0	1	0	0	0

19	0	1	0	0	0	31	0	1	0	0	0
20	0	1	0	0	0	32	0	1	0	0	0
21	0	1	0	0	0	33	0	1	0	0	0
22	0	1	0	0	0	34	0	1	0	0	0
23	0	1	0	0	0	35	0	1	0	0	0
24	0	1	0	0	0	36	0	1	0	0	0
25	0	1	0	0	0	37	0	1	0	0	0
26	0	1	0	0	0	38	0	1	0	0	0
27	0	1	0	0	0	39	1	0	0	0	0
28	0	1	0	0	0	40	1	0	0	0	0
29	0	1	0	0	0	41	1	0	0	0	0
30	0	1	0	0	0	42	1	0	0	0	0

(c) Vigilance number 0.9

Cut no.	Class1	Class2	Class3	Class4	Class5	Cut no.	Class1	Class2	Class3	Class4	Class5
1	1	0	0	0	0	22	1	0	0	0	0
2	1	0	0	0	0	23	1	0	0	0	0
3	1	0	0	0	0	24	1	0	0	0	0
4	1	0	0	0	0	25	1	0	0	0	0
5	1	0	0	0	0	26	1	0	0	0	0
6	1	0	0	0	0	27	1	0	0	0	0
7	1	0	0	0	0	28	1	0	0	0	0
8	1	0	0	0	0	29	1	0	0	0	0
9	1	0	0	0	0	30	1	0	0	0	0
10	1	0	0	0	0	31	1	0	0	0	0
11	1	0	0	0	0	32	1	0	0	0	0
12	1	0	0	0	0	33	1	0	0	0	0
13	1	0	0	0	0	34	1	0	0	0	0
14	1	0	0	0	0	35	1	0	0	0	0
15	1	0	0	0	0	36	1	0	0	0	0
16	1	0	0	0	0	37	1	0	0	0	0
17	1	0	0	0	0	38	1	0	0	0	0
18	1	0	0	0	0	39	1	0	0	0	0
19	1	0	0	0	0	40	1	0	0	0	0
20	1	0	0	0	0	41	1	0	0	0	0
21	1	0	0	0	0	42	1	0	0	0	0

7. 결 론

밀링의 면삭절삭에서 공구의 파단에 대한 실시간 검출에 관한 연구를 시계열 모델링과 자기구성 무감독 학습이 가능한 적응공진이론을 이용하여 수행하였다. 본 연구에서는 동적 절삭력을 모델링하기 위해서 8차 AR모델을 사용했으며, 오차의 수렴방법으로는 데이터를 샘플링할 때마다 적응적으로 모델계수를 개선하는 순환 최소자승법으로 수행했다.

공구의 상태와 AR계수 사이에는 연관성이 있었으며, 이것은 AR계수가 공구의 상태를 감시하기 위한 유효한 특징임을 보여주는 것이다. 이들 모델 계수를 자기구성이 가능한 무감독 학습구조의 ART 2 신경회로망에 제시하여 패턴 분류능력을 평가하였다. 그 결과, 비록 넓은 범위의 절삭조건 일지라도 절삭깊이나 절삭조건이 급변하는 경우를 제외하고는 절삭신호에 대한 사전지식도 없이 약간의 경계계수 조정으로 쉽게 분류기를 구성할 수 있었다. 특히, 연속적으로 가공을 해 나가는 절삭신호에 대해 본 시스템으로 감시하였을 때, 공구회전 1회전 이내에서 공구의 파단을 견실하게 검출할 수 있었으며, 따라서 제안된 감시시스템을 밀링공구의 실시간 감시기로서 효과적으로 사용할 수 있을 것이다.

참고문헌

- (1) Dan, L. and Mathew, J., 1990, "Tool Wear and Failure Monitoring Technique for Turning-A Review," *Int. J. Mach. Tools Manufact.*, Vol. 30, No. 4, pp. 579~598.
- (2) Tlusty, J., 1983, "A Critical Review of Sensors for Unmanned Machining," *Annals of the CIRP*, Vol. 32, pp. 563~572.
- (3) 최기상, 최기홍, 1993, "ART 2 신경회로망의 자기조정 기능을 이용한 선삭공정에서의 공구감시," *대한기계학회논문집*, 제17권 제4호, pp. 763~775.
- (4) Altintas, Y., Yellowely, I. and Tlusty, J., 1988, "The Detection of Tool Breakage in Milling Operations," *ASME Journal of Engineering for Industry*, Vol. 110, pp. 271~277.
- (5) Tarn, J. H. and Tomizuka, M., 1989, "On-Line Monitoring of Tool and Cutting Conditions in Milling," *ASME Journal of Engineering for Industry*, Vol. 111, pp. 206~212.
- (6) Takata, S., Ogawa, M., Bertok, P., Ootsuka, J., Matushima, K. and Sata, T., 1985, "Real-Time Monitoring System of Tool Breakage Using Kalman Filtering," *Robotics & Computer-Integrated Manufacturing*, Vol. 2, No. 1, pp. 33~40.
- (7) Lan, M. S. and Naerheim, Y., 1986, "In-Process Detection of Tool Breakage in Milling," *ASME Journal of Engineering for Industry*, Vol. 108, pp. 191~197.
- (8) Elbestawi, M. A., Marks, J. and Papazafiriou, T. A., 1989, "Process Monitoring in Milling by Pattern Recognition," *Mechanical Systems and Signal Processing*, Vol. 3, No. 3, pp. 305~315.
- (9) Ko, T. J. and Cho, D. W., 1994, "Cutting State Monitoring in Milling by Neural Networks," *Int. J. Mach. Tools Manuf.*, Vol. 34, No. 5, pp. 659~676.
- (10) Pandit, S. M. and Wu, S. M., 1983, *Time Series and System Analysis with Applications*, John Wiley&Sons, Inc..
- (11) Ljung, L. and Söderström, T., 1987, *Theory and Practice of Recursive Identification*, Cambridge, MA.: MIT Press.
- (12) Carpenter, G. A., and Grossberg, S., 1987, "A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine," *Computer Vision, Graphics and Image Processing*, Vol. 37, pp. 54~115.
- (13) Grossberg, S., 1976, "Adaptive Pattern Classification and Universal Recoding I & II," *Biological Cybernetics*, Vol. 23, pp. 121~134, 187~202.
- (14) 고태조, 조동우, 1994, "밀링공정의 적응모델링과 공구마모검출을 위한 신경회로망의 적용," *한국정밀공학회지*, 제11권, 제1호, pp. 138~148.