

공구파단 검출을 위한 ART2 신경회로망

고 태 조*, 김 회 술 (영남대), 조 동 우 (포항공대)

ART2 Neural Network for the Detection of Tool Breakage

Tae Jo Ko*, Hee Sul Kim, Dong Woo Cho

ABSTRACT

This study investigates the feasibility of the real time detection of tool breakage in face milling operation. The proposed methodology using an ART2 neural network overcomes a cumbersome task in terms of the learning or determining a threshold value. The features taken in the research are the AR parameters modelled from a RLS, and those are proven to be good features for tool breakage from experiments. From the results of the off line application, we can conclude that an ART2 neural network can be well applied to the clustering of tool states in real time regardless of the unsupervised learning.

Key words : Tool breakage, Real time, Unsupervised learning, ART2 neural network

1. 서 론

무인자동화 운전을 위한 지능생산시스템의 개발은 아무리 강조하여도 지나치지 않는다. 절삭가공에서의 지능화를 위해서 최근 Fuzzy 기법을 이용한 공구마모 길이의 평가⁽¹⁻²⁾, 절삭칩의 형태판별⁽³⁾, 절삭력의 제어⁽⁴⁾에 관한 연구가 많이 진행되고 있다. 또한 공구마모 또는 공구파단의 검출⁽⁵⁾, 채터진동의 검출⁽⁶⁾, 공작기계의 열변형 보상⁽⁷⁾ 등을 위해서 신경회로망 기법이 사용되고 있다. 그 중에서 특히 공구의 파단은 공작기계, 공구, 가공물 등에 미치는 영향이 매우 크므로 이에 대한 연구는 많은 관심의 대상이 되고 있으며, 실시간하에서 어떻게 이를 검출할 것인가 하는 문제로 직결된다.

현재 공구의 파단검출을 위해서는 절삭시에 발생하는 적절한 신호의 선택과 처리, 신호 중에서 공구의 파단에 민감한 특징의 추출 그리고 그 특징을 활용한 패턴분류기의 개발로 대별되어 연구가 되고 있다.

밀링공구의 파단시에는 그 신호의 명확성 때문에 쉽게 공구의 파단을 검출할 수 있지만 컴퓨터를 이용하여 감시를 할 때에는 각각의 절삭조건에 대해서 Threshold값을 부여하든지 아니면 신경회로망이나 패턴감시기와 같은 도구를 이용하여 가능한 모든 경우의 공구파단 신호를 학습시켜 두어야 한다. 현재 널리 사용되고 있는 오차역전파 신경회로망과 같은 구조는 대부분 학습이라는 과정을 거쳐서 주어진 임무를 수행하도록 하여 많은

성공을 보이고 있다. 그러나 절삭공정의 학습은 소재, 공구, 절삭조건 등 무수히 많은 변수가 있기 때문에 건설한 분류기를 구성하는 것은 매우 어려운 문제 중의 하나이다.

이러한 관점에서, 본 연구에서는 적응 시계열 모델을 이용한 신호처리기법⁽⁸⁾과 무감독 학습으로 자기구성을 하는 신경회로망인 ART2 신경망⁽⁹⁾을 사용하여 실시간 공구파단의 가능성에 대해서 논의한다. 즉 정면밀링 공정중에서 공구의 파단을 잘 대변하는 특징을 만들기 위해, 적응 시계열 모델을 이용하여 매순간 데이터가 샘플링 될 때마다 절삭력을 모델링하여 모델의 파라미터를 구한다. 여기서 나오는 모델계수를 이용하여 ART2신경회로망을 자기구성시켜 비슷한 패턴은 동일 그룹에 속하도록 하는 군분류를 하게 하여 계속 공구의 상태를 감시하게 된다. 따라서 본 연구에서 제시되는 새로운 공구파단의 검출방법은 절삭과정에 대한 사전 지식이나 학습을 필요로 하지 않고 또한 빠른 동작이 가능하기 때문에 실제의 적용가능성이 높을 것으로 기대된다. 이때 무감독 자기구성 신경회로망의 적용에 있어서 문제가 될 수 있는 변수들의 영향을 토의하고자 한다.

2. 밀링공정 신호의 모델링

밀링가공에서 공구의 파단을 검출하기 위한 주목할 만한 연

구는 시계열 방법을 이용하여 절삭력을 28차 AR 모델링한 Sata⁽¹⁰⁾ 등의 연구로서, 그들은 모델의 잔류오차가 공구의 파단과 밀접한 관계가 있다고 제안하였다. 이 연구는 Lan⁽¹¹⁾ 등에 의해서 계속 되어졌고, 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 감사가 필요한 밀링공구의 파단검출에 적합한 신호처리임을 주장했다.

즉 시스템이 선형 미분방정식으로 모델링이 된다면, 이산신호로부터 ARMA형태의 스토캐스틱 차분방정식을 구할 수가 있다. t 가 이산신호를 나타내는 지수이고, 시계열 x_t 에 대한 n 차 AR모델을 사용한다면 현재의 값에 대한 예측은 n 단계 이전의 값들의 선형조합으로 표현이 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, $\phi_1, \phi_2, \dots, \phi_n$ 은 자동회귀계수, 그리고 a_t 는 백색잡음이다. 식 (1)로 주어지는 AR(n)모델의 계수들은 평균자승오차를 최소화함에 의해 최적화할 수가 있다. 본 연구에서 사용되는 최소화방법은 RLS법으로서, 순환적응모델이기 때문에 신호의 사전 통계적 성질을 필요로 하지 않고, 또한 새로운 데이터가 들어올 때마다 모델계수들을 새롭게 갱신하므로 batch모델에 비하여 비교적 적은 메모리로서 모델링이 가능하고, 계산시간이 빠르며, in-process적용이 쉬워진다. 망각지수를 사용하는 RLS모델링 알고리즘은 Ljung⁽⁸⁾의 자료에 잘 나타나 있다.

3. ART2 신경회로망

무감독 학습(Unsupervised learning)이 가능하도록 구성된 Carpenter와 Grossberg의 적응공진이론(Adaptive resonance theory)은 패턴을 인식하고 군분류 처리하는 attentional 시스템과, 군분류한 패턴과의 불일치에 대해서 attentional 시스템을 리셋팅시키는 orienting 시스템으로 되어 있다. 이는 무감독학습을 하면서 군분류를 하는 신경회로망의 일종이다.

즉, attentional 시스템은 입력패턴을 받아 들이고, 이것을 정규화, 이득조절, 경쟁을 하는 단기기억과, 학습과정을 거치면서 가중치의 형태로 저장하는 장기기억으로 구성되어 있다. 단기기억은 그림 1에서 처럼 F1층과 F2층으로 나누어져 있으며 F1층에서는 정규화, 이득조절을 하게하고 F2층에서는 경쟁을 하게 하여 승자를 선택하게 하고 이 노드를 소속그룹으로 간주하게 한다.

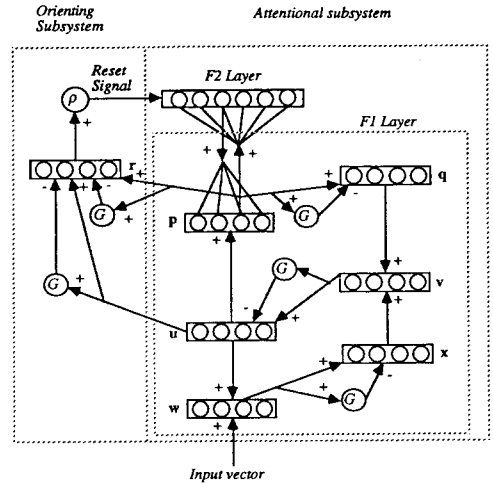



Fig. 1 The overall structure of the ART2 network.

적응공진이론 신경망 중에서 ART1은 {0,1}로 구성된 이진값만을 사용하지만 ART2신경망은 이진값 뿐만 아니라 일반적인 신호인 연속된 값을 처리할 수 있다. 이러한 능력을 지니기 위해서 F1층을 복잡하게 만든다. 즉, F2층의 구조는 ART1과 동일하다. 그러나 F1은 여러개의 하부층과 이득조절시스템으로 구성된다. 그림 1에서처럼 F1층은 w, x, u, v, p 그리고 q 의 6개 층으로 나누어져 있으며, 각 층에서 G 로 표시된 것은 금지신호를 진행방향 층의 노드에 보내는 gain-control을 나타낸다. F1층의 모든 하부층과 orienting 시스템의 r 층은 동일수의 노드를 가지고 있다. F1의 각 하부층은 유니트와 유니트끼리 연결되어 있을 뿐 상향과 하향 가중치처럼 모든 노드끼리 연결되어 있지는 않다. 각층에서의 신호처리과정은 참고문헌⁽⁹⁾에 잘 나타나있다.

4. 절삭실험

공구파단실험은 수직형 밀링머신에서 이루어졌으며, 6개의 초경으로 된 인서트 팁(P20)을 균일하게 장착시킨 밀링커터를 사용하여 정면밀링하였다. 인서트의 삽입시에는 과도한 반경방향 및 축방향의 런아웃이 신호처리에 나쁜 영향을 미치므로, 이러한 현상을 방지하기 위해 인서트의 삽입시에는 다이얼게이지를 이용하여 정확한 장착이 되도록 하였다. 절삭과정중에 실제의 공구파단과 같은 상황을 만들기 위해서는 인서트에 그림 2(a)와 같이 노즈 끝단에서 0.5mm 떨어진 위치에 깊이 0.8mm의 홈을 와이어 방전가공하여 만들고 이 인서트를 커터에 끼워 절삭하였다.

그림 3은 홈을 갖는 인서트가 그림 2(b)처럼 파단되는 순간에서의 절삭력을 측정된 것이다. 정상적인 절삭에서는 매 인서트마다 균일한 절삭력이 걸리다가 1.425초 후에 홈이 파진 한개



(a) Normal insert



(b) Broken insert

Fig. 2 Slotted insert machined by an electrical wire cutting machine.




Fig. 3 Details of cutting force signal at the moment of tool breakage.

의 인서트가 부러진 후, 다음에 따라오는 인서트에는 과부하가 걸리고 이로 인하여 절삭력의 균일성이 깨어진다. 따라서 절삭력의 특성은 공구의 파단과 함께 급변함을 알 수 있다.

표 1과 같은 절삭조건으로 소재 SM45C를 가공하는 동안 공구의 상태(정상, 파단)를 기록하면서, 공구동력계를 이용하여 이송방향의 절삭력을 측정하였으며, 이 신호는 Off-line 신호처리를 위해 신호증폭기를 통해 데이터 기록계에 기록하였다.

5. 신호처리

절삭력 신호를 특징으로 사용하기 위해서는 공정변화에 민감하지 않은 신호로 만들고 신호의 차원을 낮출 필요가 있다. 이

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	15	1100	60	0.5	Broken
2	1100	60	0.8	New	16	1100	90	0.5	Broken
3	1100	90	0.5	New	17	650	60	0.5	Broken
4	1100	90	0.8	New	18	650	90	0.5	Broken
5	650	30	0.5	New	19	650	30	0.5	Broken
6	650	30	0.8	New	20	350	30	0.5	Broken
7	650	60	0.5	New	21	350	60	0.5	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

를 위해서 먼저 절삭조건과 절삭공구에 의하여 많은 영향을 받는 절삭력의 DC성분 및 절삭공구의 린아웃 성분을 제거한 다음, 절삭력 신호에 대해서 2Hz의 high pass 필터링을 하였다. 이 신호는 off-line 신호처리를 위해 AD변환기를 통해서 1000개씩 PC로 읽어 들었다.

AR모델링을 위한 모델차수의 결정은 모델의 복잡성과 신호의 정확한 모델링 사이에 타협이 필요한 난이한 문제이다. 기본적인 방법은 서로 다른 모델차수에 대해서 모델의 성능을 비교하고 더 높은 차수의 모델이 가치가 있는 것인지 판단하는 것이다. 그러나 실시간 감시의 경우에는 계산시간의 측면에서 낮은 차수의 모델이 유리하고, 따라서 실시간 감시의 목적으로 밀링 가공의 동적 절삭력을 모델링하기 위해서는 8차의 모델을 사용한다.

한편, 이송절삭력의 AR 모델계수와 공구파단과의 상관관계를 조사하기 위해서 정상과 파단된 공구의 절삭력에 대한 모델계수의 값 $[\phi_1, \phi_2, \dots, \phi_8]$ 을 그림 4에 나타내었다. 두 상태(정상공구와 파단공구)는 잘 분리되고 있는 것을 알 수 있다. 이때의 파라미터를 이용하여 구한 파워 스펙트럼이 그림 5이다. 여기서 알 수 있듯이 새로운 공구의 경우에는 모든 인서트에 균




Fig. 4 Model parameters under different tool states.

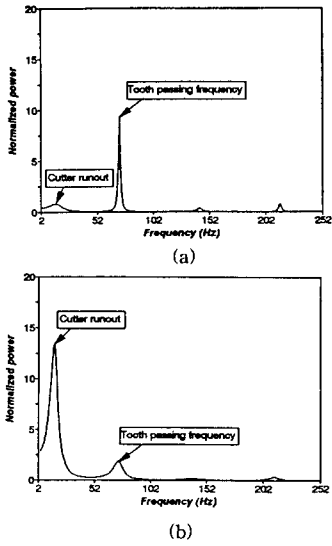


Fig. 5 Variation of power spectral density with respect to the tool states.

일한 절삭력이 걸리기 때문에 공구통과주파수가 파워 스펙트럼에서 지배적이었으나(그림 5(a)), 그림 5(b)처럼 공구가 파단되었을 때는 파단된 인서트의 다음에 있는 인서트에 큰 힘이 걸리면서 절삭력의 균일성이 깨어지고 따라서 공구의 런아웃 성분이 지배적으로 나타난다.

이상에서 살펴 보았듯이 AR모델계수를 계속적으로 추종함으로써 공구의 상태를 효과적으로 감지할 수 있음을 확인하였다.

6. 신경회로망의 적용

정면밀링가공중 일어나는 공구의 파단을 감지하기 위하여 이송방향의 절삭력 신호에 대해 AR모델링으로 전처리한 모델계수를 ART2신경회로망에 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. a , b , c , d , e , θ 는 각각 F1층내의 sublayer의 출력값을 결정하는데 영향을 미치는 계수값들이다. 이들 값은 ART2 신경망을 구성할 때 off-line 상태에서 tuning해야 하는 값으로, 통상 아래와 같은 구속조건이 있고 이들 구속조건을 만족하면서 최적의 값을 구하는 것은 몇번의 시행착오를 필요로 한다.

$$\begin{aligned}
 & a, b > 0 \\
 & 0 \leq d \leq 1 \\
 & \frac{cd}{1-d} \leq 1 \\
 & 0 \leq \theta \leq 1 \\
 & 0 \leq \rho \leq 1 \\
 & e \ll 1
 \end{aligned} \tag{2}$$

표 1의 서로다른 절삭조건인 14개 정상공구와 14개의 파단공구에 대한 모니터링 결과가 표 2이다. 표 2(a)는 경계계수가 0.96일 때의 결과인데 1번째부터 14번째의 정상공구는 Class1(정상공구)로 분류되다가 15번째인 파단공구부터 Class2(공구파단)로 잘 분류되고 있음을 알 수 있다. 여기서 경계계수를 바꾸어서 0.9로 하였을 때는 표 2(b)처럼 패턴의 불일치에 대한 민감도가 떨어져서 모든 패턴을 Class1로 분류해내고 있다. 또한 표 2(c)처럼 경계계수를 더욱 증가시켜서 0.99로 하였을 때는 13번째의 절삭조건은 Class2, 17번째의 절삭조건은 Class4로 분류되





Fig. 6 Variation of sum of absolute weights.

는 등 신경회로망의 민감도가 증가하고 있다. 이처럼 최적의 경계계수를 결정하는 것은 또하나의 어려움으로 남는 일 중의 하나이다. 그러나 이는 현장 작업자가 어떤 임의의 초기값으로 경계계수를 설정한 후, 너무 민감하게 공구의 파단을 감지해낼 때, 혹은 공구의 파단을 잘 검출하지 못할 때마다 현장에서 약간씩 경계계수를 조절만 하면 되는 문제로 해결은 가능할 것이다.

한편 신경회로망에 새로운 패턴을 제시하면 처음 어떤 군을 창성하고 이어서 패턴이 계속 들어올 때마다 그전의 패턴과 차이가 많이 나면 새로운 군을 형성하고 그렇지 않으면 처음의 군으로 분류가 되고 있는데 이 과정에서 패턴사이의 약간의 불일치를 상향과 하향가중치를 수정함에 의해 수용을 하게 된다. 이러한 가중치의 변화를 보기 위해 표 2에서 사용한 28개의 절삭조건을 4번 반복하여 신경망에 제시하고 이때 변경되는 가중치의 값을 그림 6에 나타내었다. 그림 6(a)에서 알 수 있듯이 동일 군의 패턴이 들어 올 때는 이 패턴을 동일 그룹으로 학습시키기

Table 2. Classification results.

(a) vigilance number 0.96						(b) vigilance number 0.9						(c) vigilance number 0.99					
Cut no.	class1	class2	class3	class4	class5	Cut no.	class1	class2	class3	class4	class5	Cut no.	class1	class2	class3	class4	class5
1	1	0	0	0	0	1	1	0	0	0	0	1	1	0	0	0	0
2	1	0	0	0	0	2	1	0	0	0	0	2	1	0	0	0	0
3	1	0	0	0	0	3	1	0	0	0	0	3	1	0	0	0	0
4	1	0	0	0	0	4	1	0	0	0	0	4	1	0	0	0	0
5	1	0	0	0	0	5	1	0	0	0	0	5	1	0	0	0	0
6	1	0	0	0	0	6	1	0	0	0	0	6	1	0	0	0	0
7	1	0	0	0	0	7	1	0	0	0	0	7	1	0	0	0	0
8	1	0	0	0	0	8	1	0	0	0	0	8	1	0	0	0	0
9	1	0	0	0	0	9	1	0	0	0	0	9	1	0	0	0	0
10	1	0	0	0	0	10	1	0	0	0	0	10	1	0	0	0	0
11	1	0	0	0	0	11	1	0	0	0	0	11	1	0	0	0	0
12	1	0	0	0	0	12	1	0	0	0	0	12	1	0	0	0	0
13	1	0	0	0	0	13	1	0	0	0	0	13	0	1	0	0	0
14	1	0	0	0	0	14	1	0	0	0	0	14	0	0	1	0	0
15	0	1	0	0	0	15	1	0	0	0	0	15	0	0	0	1	0
16	0	1	0	0	0	16	1	0	0	0	0	16	0	0	0	0	1
17	0	1	0	0	0	17	1	0	0	0	0	17	0	0	0	0	1
18	0	1	0	0	0	18	1	0	0	0	0	18	1	0	0	0	0
19	0	1	0	0	0	19	1	0	0	0	0	19	1	0	0	0	0
20	0	1	0	0	0	20	1	0	0	0	0	20	1	0	0	0	0
21	0	1	0	0	0	21	1	0	0	0	0	21	1	0	0	0	0
22	0	1	0	0	0	22	1	0	0	0	0	22	1	0	0	0	0
23	0	1	0	0	0	23	1	0	0	0	0	23	1	0	0	0	0
24	0	1	0	0	0	24	1	0	0	0	0	24	1	0	0	0	0
25	0	1	0	0	0	25	1	0	0	0	0	25	1	0	0	0	0
26	0	1	0	0	0	26	1	0	0	0	0	26	1	0	0	0	0
27	0	1	0	0	0	27	1	0	0	0	0	27	1	0	0	0	0
28	0	1	0	0	0	28	1	0	0	0	0	28	1	0	0	0	0

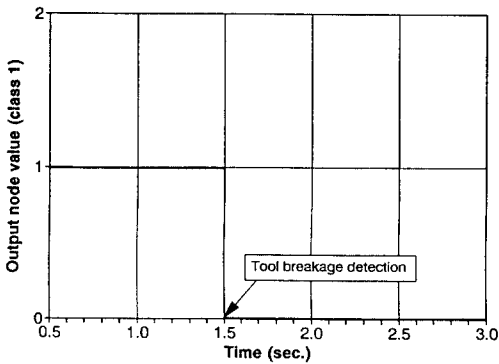


Fig. 7 Monitoring results to the continuous cutting force signals.

으로 그 학습추이는 상향 가중치의 경우와 비슷하나, 상향 가중치는 서서히 수렴하는 성질을 보이는 대신 하향 가중치는 진동을 하고 있음을 알 수 있다.

다음은 정상공구로 절삭도중 공구의 파단이 있었던 신호에 대해 모니터링의 결과를 조사한 것이 그림 7 및 그림 8에 나타나 있다. 이때 모니터링은 모델링이 정상상태로 들어갔다고 보는 0.5초 이후에 실시한 것으로 그림에서 보듯이 공구의 파단은 1.505초에 감지되었는데, 실제적인 공구의 파단은 1.425초에서 일어난 것을 감안하면 주축의 회전수가 650rpm이므로 0.87회전의 지연후에 공구파단을 검출한 것이다.

7. 결론

정면명령절삭에서 공구의 파단에 대한 실시간 검출에 관한 가능성을 시계열 모델링과 자기구성 무감독 학습이 가능한 적응 공진이론을 이용하여 수행하였다. 본 연구에서는 동적 전삭력은 모델링하기 위해서 8차 AR모델을 사용하였으며, 공구의 상태와 AR계수사이의 연관성으로부터 AR계수는 공구의 상태감지에 유효한 특징으로 사용할 수 있음을 확인하였다. 이들 모델계수를 자기구성이 가능한 무감독학습구조의 ART2 신경회로망에 제시하여 패턴분류능력을 평가하였다. 그 결과, 비록 넓은 범위의 전삭조건이라도 전삭깊이나 전삭조건이 급변하는 경우를 제외하고는 전삭신호에 대한 사전지식없이 약간의 경계계수조정으로 쉽게 분류기를 구성할 수 있었다. 특히 연속적으로 가공을 해나가는 전삭신호에 대해 본 시스템으로 감시를 하였을 때, 공구회전 1회전 이내에서 공구의 파단을 견실하게 검출할 수 있었으며, 따라서 제안된 감시시스템을 밀링공구의 실시간 감시기로서 효과적으로 사용할 수 있을 것이다.



Fig. 8 View of the tool wear monitoring system.

위한 상향 가중치의 변화는 작으나, 15번째인 파단공구의 패턴이 들어올 때는 가중치의 변형이 크다. 다시 16번째의 패턴부터는 파단의 균을 나타내기 때문에 가중치의 변화가 작다가 29번째의 새로운 공구의 패턴이 반복됨에 따라서 가중치의 변화는 다시 커진다. 그림 6(b)는 하향 가중치의 합의 변화를 나타낸 것

참고문헌

1. Tae Jo Ko, Dong Woo Cho, "Estimation of tool wear length in finish milling using a fuzzy inference algorithm," WEAR, Vol. 169, pp. 97-106, 1993.
2. Tae Jo Ko, Dong Woo Cho, "Tool wear monitoring in diamond turning by fuzzy pattern recognition," ASME J. of Engng. for Ind., Vol. 116, pp. 225-232, 1994.
3. Jawahir, I. S., Fei, J., "A comprehensive evaluation of tool inserts for chip control using fuzzy modeling of machinability parameters," Transactions of NAMRI/SME, Vol. 21, pp. 205-213.
4. Tarrng, Y. S., Cheng, S. T., "Fuzzy control of feed rate in end milling operations," Int. J. Mach. Tools Manufact. Vol. 33, No. 4, pp. 643-650, 1993.
5. Danai, K., Jammu, V. B., "Unsupervised neural network for tool breakage detection in turning," Annals of the CIRP, Vol. 42, No. 1, pp. 67-70, 1993.
6. Tansel, I. N., "Modeling workpiece vibrations with neural network," Journal of Intelligent Manufacturing, Vol. 4, pp. 95-107, 1993.
7. Moriwaki, T., Zhao, C., "Neural network approach to identify thermal deformation of machining center," PROLAMAT '92, June, Tokyo, 1992.
8. Ljung, L., Soderstrom, T., Theory and practice of recursive identification, Cambridge, MA:MIT Press., 1987.
9. Carpenter, G. A., Grossberg, S., "A massively parallel architecture for a self organizing neural pattern recognition machine," Computer Vision, Graphics and Image Processing, Vol. 37, pp. 54-115, 1987.
10. Takata, S., Ogawa, M., Bertok, P., Ootsuka, J., Matushima, K., Sata, T., "Real time monitoring system of tool breakage using Kalman filter," Robotics & Computer Integrated Manufacturing, Vol. 2, No. 1, pp. 33-40., 1985.
11. Lan, M. S., Nærheim, Y., "In process detection of tool breakage in milling," ASME J. of Engng. for Ind., Vol. 108, pp. 191-197, 1986.