한국기계가공학회지, 제14권, 제6호, pp.1~6(2015.12) ISSN 1598-6721(Print)
Journal of the Korean Society of Manufacturing Process Engineers, Vol.14 No.6, pp.1~6(2015.12) ISSN 2288-0771(Online)

http://dx.doi.org/10.14775/ksmpe.2015.14.6.001

이송모터 전류신호를 이용한 공구파손 검출

정영훈*,#
*경북대학교 기계공학부

Tool Breakage Detection Using Feed Motor Current

Young Hun Jeong*,#
*School of Mechanical Engineering, Kyungpook National University

(Received 26 November 2015; received in revised form 30 November 2015; accepted 2 December 2015)

ABSTRACT

Tool condition monitoring plays one of the most important roles in the improvement of both machining quality and productivity. In this regard, various process signals and monitoring methods have been developed. However, most of the existing studies used cutting force or acoustic emission signals, which posed risks of interference with the machining system in dynamics, fixturing, and machining configuration. In this study, a feed motor current signal is used as a process signal representing process and tool states in tool breakage monitoring based on an adaptive autoregressive model and unsupervised neural network. From the experimental results using various cases of tool breakage, it is shown that the developed system can successfully detect tool breakage before two revolutions of the spindle after tool breakage.

Keywords : Feed Motor Current(이송모터전류), Milling Process(밀링공정), Tool Condition Monitoring(공구상태감시), Tool Breakage(공구파손)

1. 서 론

무인 및 지능가공은 전통적인 방법인 작업자에 의한 가공공정 상태감시 및 최적화를 자동화 및 무인화 하여 생산성 및 품질을 높이고 생산현장의 작업환경 개선을 이루고자 하는 것이다[1]. 특히, 최근 플랜트 산업의 성장, 항공우주 산업의 중요성이 증가에 따라 내열성 합금, 특수강, 탄소섬유강화플라스틱 등 극심한 공구파손과 공구마모를 일으키는 고가 소재의 가공기술[2]에 대한 수요가 증가하면서 이러한 무인지능가공에 대한 중요성도 증가하고 있다. 대표적인 무인지능가공의 예로 공구상태 감시기술이 있으며, 이는 크게 공구파손을 검출하는 것과 공구의 마모량을 추정하는 두 가지로 나눌 수 있다. 이 중 공구 파손의 검출은 절삭공구의 날이 파손될 때 이를 감지하고 가공을 중지시켜 공구파손에 의한 가공품질의 급작스런 저하를 최소화 하고자 하는 것으로 높은 파손 검출 정확도와 속도가 요구된다.

대표적인 공구파손의 검출은 현미경 또는 비전에 기반한 직접적인 방법[3,4]과 다양한 공정신호를 이용한 간접적인 방법으로 구분된다[5]. 특히 간접적인 방법을 이용한 다양한 연구가 진행되고 있다. Ko 등은 공구동력계를 이용한 절삭력 신호를 자기회귀모델과 신경망회로(neural network)를 이용하여 공구의 파손과 마모를 검출해낸 바 있다[6,7].

# Corresponding Author : yhjeong@knu.ac.kr
Tel: +82-53-950-5577, Fax: +82-53-950-6550

Copyright Ⓒ The Korean Society of Manufacturing Process Engineers. This is an Open-Access article distributed under the terms of the Creative Commons Attribution-Noncommercial 3.0 License (CC BY-NC 3.0 http://creativecommons.org/licenses/by-nc/3.0) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

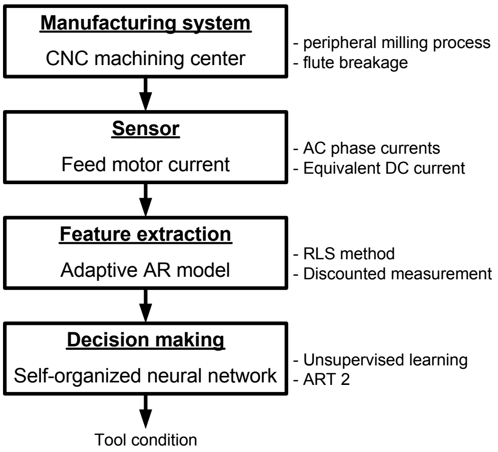
Manufacturing system
CNC machining center
- peripheral milling process
- flute breakage
Sensor
Feed motor current
- AC phase currents
- Equivalent DC current
Feature extraction
Adaptive AR model
- RLS method
- Discounted measurement
Decision making
Self-organized neural network
- Unsupervised learning
- ART 2
Tool condition

Fig. 1 Schematics of tool breakage monitoring based on feed motor current

Lee 등은 이송모터의 전류 신호를 공정신호로 할 경우 자기회귀모델 파라미터로부터 공구의 파손을 확인할 수 있음을 보였다[8]. Li 등은 음향방출 센서와 전류 신호의 이산 웨이브렛 변환을 통해 높은 신뢰도의 공구파손 검출이 가능함을 보였다[9].

본 연구에서는 공정신호로서 이송모터의 전류를 선정하고 이를 이용하여 공구파손을 감시하고자 하였다. 이는 많은 문제점[3,8]을 가진 공구동력계를 대체할 수 있는 장점을 제공할 수 있다. 또한 이송모터 전류로부터 공구상태의 특성을 반영한 특성신호를 추출하기 위해 적응 자기회귀모델을 구성하고 이를 바탕으로 적응공명이론 기반의 신경망회로를 이용하여 밀링가공 시 공구의 파손을 검출할 수 있음을 보였다.

2. 공구파손 검출 시스템의 구성

공구상태의 감시를 위한 시스템은 크게 센서, 특성추출(feature extraction), 결정 알고리즘(decision making)으로 구성된다. 본 연구에서는 센서는 회전 및 정지방향 이송모터의 전류로 하였으며, 특성검출과 결정 알고리즘을 각각 적응 자기회귀모델(adaptive autoregressive model)[6]과 자기구성 신경망회로(self-organized neural network)[7]로 하였다. 이를 이용하여 밀링공정에서 공구의 파손을 검출하고자 하였다. Fig. 1은 본 연구의 공구파손 검출 시스템의 구성을 도식적으로 보여준다.

2.1 가공장비와 이송모터 전류신호

이송모터는 절삭이송 시 이송계의 동역학적 거동과 함께 밀링 가공에 의한 절삭력에 영향을 받는다. 특히 이송모터의 전류는 토크상수를 선형계수로 하여 토크와 비례관계를 가지며, 볼스크류의 힘-토크 변환 특성에 의해 절삭력은 이송모터의 전류와 비례하는 것을 기존 연구들을 통해 확인된 바 있다[10]. 모터의 구동전류를 포함하여 이송계의 힘과 토크와의 관계는 (1)과 같이 고려될 수 있다.

$$I_m = \frac{1}{K_t}\left[T_{pt} + \frac{P}{2\pi\varepsilon}\left(F_{ext} + F_{friction}\right)\right] \qquad (1)$$

여기서, I_m, K_t, T_{pt}은 각각 모터의 구동전류(A), 토크상수(Nm/A), 볼스크류의 예압토크(Nm)이다. 한편 P, ε, F_{ext}, $F_{friction}$은 각각 볼스크류의 피치(m), 기계적 효율(-), 이송계의 외력(N), 이송테이블 LM 가이드의 마찰력(N)으로서 정지 시는 0이다.

특히, 공작기계 이송계의 외력은 절삭력에 해당하며, (1)로부터 외력이 전류를 통해 직접적으로 추정되기 위해서는 볼스크류의 예압토크와 이송계의 마찰력이 제거될 필요가 있다. 따라서, 볼스크류의 예압토크는 마찰토크로 작용하므로 이송계 마찰력과 함께 무부하 조건에서 정속이송 시의 전류를 측정하여 그 영향을 미리 제거할 수 있다.

2.2 공정감시와 파손검출 모델

일반적으로 비선형 특성을 가지는 자기회귀이동평균(autoregressive moving average) 모델에 비해 자기회귀모델은 선형 특성을 가져 계산 부하가 낮은 장점이 있으며, 신호 특성의 변화를 반영할 수 있도록 순환최소자승법 기반 적응알고리즘이 반영된 모델을 구성하였다. 일반적으로 n차의 자기회귀모델은 (2)와 같이 표현될 수 있다.

$$x_t = \sum_{i=1}^{n} \phi_i x_{t-i} + w_t \qquad (2)$$

여기서, x_t, ω_t, ϕ_i는 t번째 시간에 얻어진 신호와 신호의 백색잡음, 자기회귀모델의 파라미터이다. 이러한 자기회귀모델을 이용하여 매 측정순간마다 파라미터를 수정하면서 적응시킬 경우 모델은 다음의 선형대수식으로 표현이 가능하다.

$$e_t = x_t - X_t^T \Phi_{t-1} \tag{3}$$

e_t, X_t, Φ_{t-1}는 각각 t번째 시간에서의 추정오차, x_{t-1}부터 x_{t-n}까지의 측정신호로 구성되는 신호벡터, ϕ_1부터 ϕ_n으로 구성된 $t-1$번째 시간에서 추정된 모델 파라미터 벡터이다. 특히 매순간 추정되어 모델이 측정신호에 적응하도록 하는 모델 파라미터의 적응전략은 다음의 식들로 표현될 수 있다[6].

$$\begin{aligned}
&\Phi_t = \Phi_{t-1} + k_t e_t \\
&k_t = \frac{R_{t-1} X_t}{\lambda_t + X_t^T R_{t-1} X_t} \\
&R_t = \left(I - \frac{R_{t-1} X_t X_t^T}{\lambda_t + X_t^T R_{t-1} X_t} \right) \frac{R_{t-1}}{\lambda_t} \\
&R_0 = \alpha I \\
&\lambda_t = \lambda_0 \lambda_{t-1} + (1 - \lambda_0)
\end{aligned} \tag{4}$$

여기서, k_t, R_t, λ_t, λ_0, α, I는 각각 파라미터의 적응이득벡터, 신호벡터의 공분산행렬, 망각계수(forgetting factor), 망각률(forgetting rate), 공분산행렬의 초기치인 공분산 및 단위대각행렬이다. (4)에서 보인 바와 같이 식들은 순환형태를 가지고 샘플링 순간마다 갱신되어 적응구조에 효과적임을 알 수 있다. 특히 본 연구에서는 기존의 절삭력 신호를 이용한 공구파손 검출에 성공적으로 활용된 8차의 적응 자기회귀모델[7]을 이용하였다. 또한 파라미터의 초기치는 모두 0으로 하였다.

상태판단 및 분류에 의한 추론 방법의 하나로서의 신경망회로는 강력한 학습과 분류기능을 가지고 있다[11]. 본 연구에서는 선행학습이 요구되지 않는 Grossberg의 적응공명이론(adaptive resonance theory, ART)[12]에 기반한 신경망회로를 이용하여 공구파손을 감시한 방법[7]을 채용하여 적응 자기회귀모델 기반의 공구파손의 검출을 수행하였다. 구성한 시스템은 ART의 핵심요소인 집중부(attentional system)과 지시부(orienting system)으로 나눠질 수 있으며, 집중부는 직전까지 학습된 경우와 유사성을 판별하여 유사한 경우 이를 동일한 경우로 인식하도록 하며, 지시부는 유사성이 인정되지 않은 경우 새로운 경우로 분류한다. Fig. 2는 본 연구의 ART 기반 신경망회로의 간단한 구조를 보여준다. 본 연구에서는 아날로그 출력이 가능한 ART-2형의 신경망회로를 이용하였다.

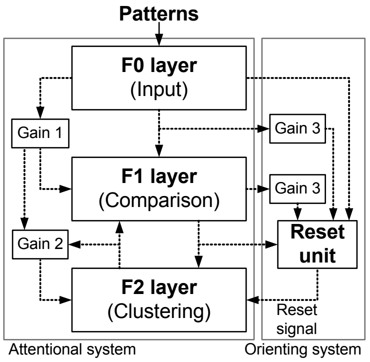

Fig. 2 Schematic of ART-based neural network

3. 실험결과 및 고찰

3.1 실험장치의 구성

본 연구에서는 FANUC-0M 제어기를 포함한 소형 수직형 CNC 머시닝센터를 이용하였다. 가공재는 알루미늄합금(AL2024)이었으며, 공구는 고속도강의 4날 평엔드밀로서 직경은 20 mm이었다. 가공방법은 외주가공이었다. 스핀들 회전속도는 225 rpm로서 이물림 주파수는 15 Hz, 절삭폭과 절삭깊이는 각각 5 mm와 2 mm이었다. 이송속도는 210~560 mm/min로 다양하게 실험하였다.

공작기계에 설치되어 있는 모터는 영구자석 동기모터이므로 교류전류로부터 실효치(root mean square)로 환산된 직류전류를 이용하였으며, 전류의 측정은 Hall효과 센서를 이용하였다. Fig. 3은 무부하 상태의 다양한 이송속도 조건에서 예압토크와 이송계 마찰에 해당하는 X축 이송모터 전류

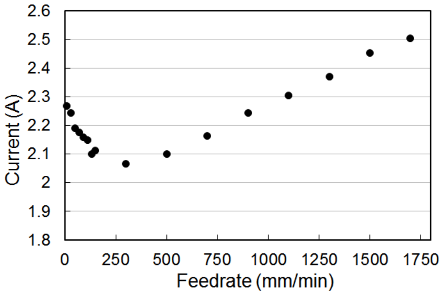

Fig. 3 Feed motor current levels under various feedrate conditions (friction torque)

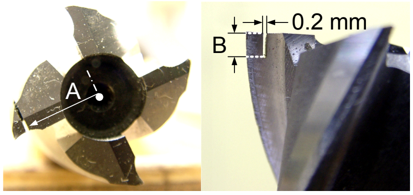

Fig. 4 Flat endmill with a breakage slot on a flute

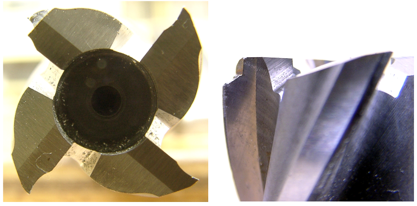

Fig. 5 Broken tool after machining

Table 1 Breakage slot on flute and feedrate conditions for tool breakage experiments

Tool	A (mm)	b (mm)	Feedrate (mm/min)
1	9.5	1	210
2	9	1	560
3	8.5	1.5	420
4	9	2	360
5	8.5	2	360
6	8	2	360

의 크기를 보여준다. 이 값을 절삭 시 측정된 전류신호에서 빼서 그 영향을 제거하고 절삭력에 의한 영향만이 존재하도록 하였다. 그림으로부터 실험장치가 가지는 X축의 마찰력에 해당하는 최소 전류는 약 2.07 A이며, 일반적 윤활마찰계의 특성인 Stribeck 곡선을 잘 따르고 있음을 알 수 있다.

공구의 파손을 위해 본 연구에서는 인위적으로 공구의 날에 미세한 홈을 내고 이 부분이 가공 중에 파손에 이르도록 하였다. 공구 날에의 미세 홈 가공은 정밀한 가공을 위해 와이어 방전가공을 이용하였으며, 가공된 미세홈의 폭은 0.2 mm이었다. Fig. 4는 실험에 사용된 공구의 날에 가공된 미세홈 및 홈의 위치와 깊이에 대한 정의를 보여준다. 다양한 공구파손에 대응하기 위해 다양한 미세홈의 위치와 깊이를 고려하였으며, 결정된 미세홈의 조건은 Table 1과 같다. Fig. 5는 가공실험을 통해 미세홈 부분에서 발생한 파손을 보여준다.

공구파손에 대한 높은 신뢰도와 빠른 응답을 얻기 위해서는 적응 자기회귀모델의 망각계수, 망각률, 공분산 등의 값을 적절히 결정하는 것이 요구된다. 본 연구에서는 응답속도가 빠르고 잔류오차가 최소가 되는 조건으로 이러한 값들을 선택하였다. Fig. 6과 Fig. 7은 각각 망각계수와 공분산 수치에 따른 모델의 첫 번째 파라미터의 변화를 보여준다. 그림들로부터 파라미터의 변화속도는 망각계수나 공분산 수치에 크게 영향을 받지 않으나 그 변동 폭이 직접적으로 영향을 받음을 알 수 있다. 따라서 잔류오차의 실효치가 최소가 되는 조건을 선택하였으며, 모델의 망각계수, 망각률, 공분산은 각각 0.99, 0.99, 10이었다.

Fig. 8은 본 연구에서 개발된 시스템을 이용한 공구파손 검출 예를 보여준다. Fig. 8(a)은 공구파손을 포함하는 가공 시 측정된 전류와 적응 자기회귀모델을 이용하여 샘플링 시간의 1 단계만큼 앞서 예측된 전류의 비교결과를 보여준다. 그림으로부터 실제 전류와 유사한 추세를 가지고 추종하고 있음을 볼 수 있다. 이때의 잔류오차의 실효치는 약 0.269 A이었다. Fig. 8(b)는 이때의 적응 자기회귀모델의 8개 파라미터들의 거동을 보여주며, 공구파손이 발생한 4.8초 시점에서 파라미터의 거동이 급격히 바뀜을 확인할 수 있다. 이로부터 구성된 적응 자기회귀모델이 공정 상태를 잘 반영하고 있음을 알 수 있다. Fig. 8(c)는 이때의 잔류 오차를 보여주며, 공구 파손 전후 잔류오차가 크게 달라짐을 확인할 수 있다. 또한 Fig. 8(d) 구성된

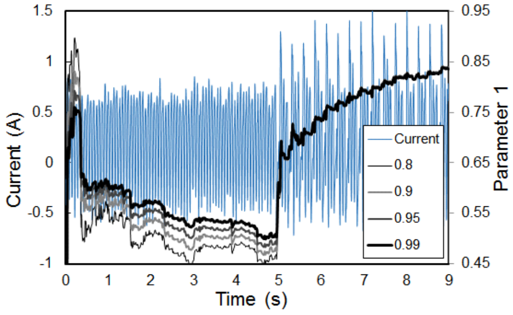

Fig. 6 Current and the first parameters modeled under various forgetting factor conditions

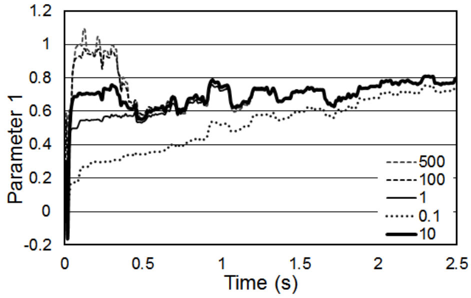

Fig. 7 First parameters modeled under various initial value (α) conditions of covariance matrix

적응공명이론이 포함된 신경망회로를 통해 공구상태가 다른 경우인 것으로 판단한 결과를 보여준다. 특히 공구파손이 발생한 후 0.33초가 지나 검출되어 비교적 빠른 시간 안에 공구파손을 적절히 검출하였음을 확인할 수 있었다. Table 2는 실험에 활용된 6가지 경우의 공구파손 검출결과를 보여준다. 표로부터 공구파손량이 가장 작은 1번의 경우를 제외하고는 공구파손을 성공적으로 검출하였음을 확인할 수 있으며, 특히 스핀들이 2 회전하기 전에 파손을 검출함으로써 빠른 대응이 이뤄졌음을 알 수 있다. 특히 검출정확도의 향상은 망각계수, 망각률, 공분산의 조절을 통한 민감도 강화를 통해 이뤄질 수 있을 것으로 기대된다.

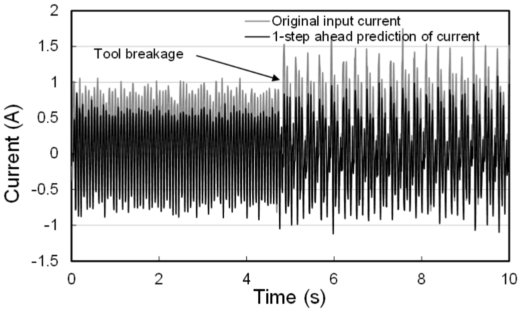

(a) Original and 1-step ahead predicted currents

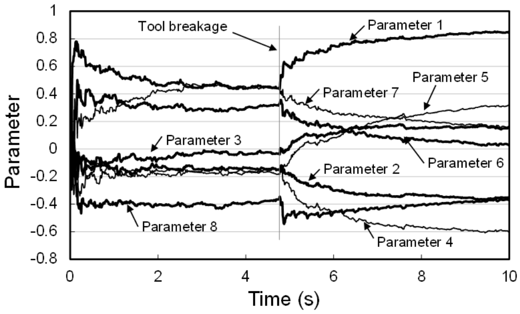

(b) Parameters

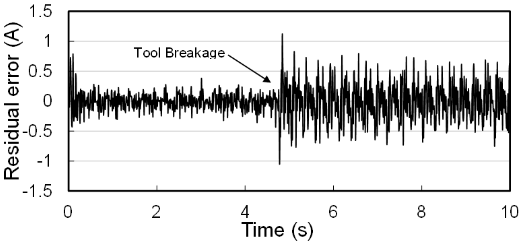

(c) Residual error

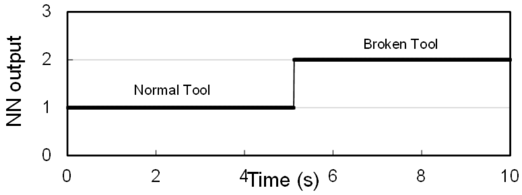

(d) Neural network output (tool state estimation)

Fig. 8 Example of tool breakage detection (Tool 3)

4. 결 론

본 연구에서는 공구파손의 감시를 위해 이송모터의 전류와 적응 자기회귀모델, 적응공명이론 기반 신경망회로로 구성된 감시시스템을 구성하였다. 특히 기존의 공구동력계를 이용한 절삭력 신호 대신 전류를 이용함으로써 공정 및 가공장비에

Table 2 Tool breakage detection results

Tool	Success of detection	Detection time	
		Time (s)	Spindle revolution
1	×	-	-
2	○	0.09	0.34
3	○	0.33	1.23
4	○	0.15	0.56
5	○	0.19	0.71
6	○	0.45	1.68

의 간섭을 줄이는 동시에 비용측면의 우수성을 확보하면서도 충분한 수준의 정확도로 공구파손을 검출할 수 있음을 확인하였다. 특히 구성된 시스템은 공구파손 후 주축이 2회전하기 전에 파손을 검출하여 빠른 응답속도를 가짐을 제시하였다.

후기

본 연구는 산업통상자원부 및 한국산업기술평가관리원의 미래산업선도기술개발사업의 일환으로 수행하였음. [10053248, 탄소섬유복합재(CFRP) 가공시스템 개발].

REFERENCES

1. Liang, S. Y., Hecker, R. L. and Landers, R. G., "Machining Process Monitoring and Control: The State-of-the-Art," J. Manuf. Sci. Eng., Vol. 126, No. 2, pp. 297-310, 2004.
2. Won, J.-S., Lim, E.-S. and Jung, Y.-G., "Estimation of Machinability for Super Heat-resistant Alloys Inconel 600 in Turning Process," J. Korean Soc. Manuf. Process Eng., Vol. 10, No. 6, pp. 1-8, 2011.
3. Byrne, G., Dornfeld, D., Inasaki, I., Ketteler, G., König, W. and Teti, R., "Tool Condition Monitoring (TCM)-The Status of Research and Industrial Application," CIRP Ann-Manuf. Technol., Vol. 44, No. 2, pp. 541-567, 1995.
4. Kim, S.-H. and Baek, W.-B., "Tool Monitoring System using Vision System with Minimizing External Condition," J. Korean Soc. Manuf. Process Eng., Vol. 11, No. 5, pp. 142-147, 2012.
5. Maeng, M.-J., "Fracture Detection of Milling Cutter Using Cutting Force and Acoustic Emission Signals," J. Korean Soc. Manuf. Process Eng., Vol. 3, No. 1, pp. 28-37, 2004.
6. Ko, T. J. and Cho, D.-W., "Cutting State Monitoring in Milling by a Neural Network," Int. J. Mach. Tools Manuf., Vol. 34, No. 5, pp. 659-676, 1994.
7. Ko, T. J., Cho, D.-W. and Jung, M. Y., "On-Line Monitoring of Tool Breakage in Face Milling Using a Self-Organized Neural Network," J. Manuf. Syst., Vol. 14, No. 2, pp. 80-90, 1995.
8. Lee, J. M., Choi, D. K., Kim, J. and Chu, C. N., "Real-Time Tool Breakage Monitoring for NC Milling Process," CIRP Ann-Manuf. Technol. Vol. 44, No. 1, pp. 59-62, 1995.
9. Li, W., Dong, S. and Yuan, Z., "Discrete Wavelet Transform for Tool Breakage Monitoring," Int. J. Mach. Tools Manuf., Vol. 39, No. 12, pp. 1935-1944, 1999.
10. Jeong, Y. H. and Cho, D.-W., "Estimating Cutting Force from Rotating and Stationary Feed Motor Currents on a Milling Machine," Int. J. Mach. Tools Manuf., Vol. 42 No. 14, pp.1559-1566, 2002.
11. Yoon, M.-C., Kim, Y.-G. and Kim, K.-H., "The Characteristics and Stability Boundary Analysis of Chatter using Neural Network," J. Korean Soc. Manuf. Process Eng., Vol. 5, No. 2, pp. 16-21, 2006.
12. Grossberg, S., "Adaptive Pattern Classification and Universal Recoding: I. Parallel Development and Coding of Neural Feature Detectors," Biol. Cybern., Vol. 23 No. 3, pp. 121-134, 1976.