

신경회로망 모델을 이용한 선삭 공정의 실시간 이상진단 시스템의 개발

이 상 석*

Development of In-process Condition Monitoring System on Turning Process using Artificial Neural Network.

Sang-Seog Lee

Abstract

The in-process detection of the state of cutting tool is one of the most important technical problem in Intelligent Machining System.

This paper presents a method of detecting the state of cutting tool ,in turning process, by using Artificial Neural Network. In order to sense the state of cutting tool, the sensor fusion of an acoustic emission sensor and a force sensor is applied in this paper.

It is shown that AERms and three directional dynamic mean cutting forces are sensitive to the tool wear. Therefore the six pattern features that is, the four sensory signal features and two cutting conditions are selected for the monitoring system with Artificial Neural Network.

The proposed monitoring system shows a good recognition rate for the different cutting conditions.

Keywords : Tool monitoring(공구상태 감시), Artificial Neural Network(신경회 로망), Sensor fusion(센서융합)

1. 서론

기계가공에 있어서 제품의 정밀도와 생산성 및 가공시스템의 신뢰성 향상을 위하여 가공시스템의 무인화, 자동화 기술의 필요성이 요구되고 있다.

가공시스템의 자동화와 무인화를 실현하기 위해서는 가공 중 수시로 변화하는 가공시스템의 전반에 걸친 현상

태에 대한 모니터링(monitoring)기술이 필수적이며 특히 가공 중 수시로 변화하는 절삭공구의 이상상태를 실시간으로 검출하고 공구의 교환시거나 그 상태변화를 검출하여 작업자(operator)의 구체적인 조작이 없이도 기계가공을 행하고 감시하는 지능형 공작시스템의 구성은 가공기술인의 최대 목표로 되고 있다.

기계가공 중 발생하는 공구의 이상상태로서는 절삭공구

* 경북실업전문대학 기계설계과

의 파손, 공구마모, 칩핑, 및 채터진동 등이 있으며 공구의 파손이나 칩핑, 채터진동 등은 가공조건이나 절삭공구를 적절히 선정하면 피할 수 있으나 공구의 마모는 칩의 발생과 더불어 피할 수 없는 요소이다.

이러한 절삭공구의 이상상태를 모니터링하기 위해 지금까지 많은 연구자들에 의하여 다양한 방법들이 제시되어 왔다.

일반적으로 공구상태 검출을 위한 센싱(sensing)방법은 직접적인 방법과 간접적인 방법으로 분류할 수 있다. 전자는 절삭공구의 마모나 파손 등으로 기인되는 공구의 기하학적 형상변화를 직접 측정하는 방법이고 후자는 절삭계에서 그와 밀접히 관련된 변수(parameter)를 찾아 그 변수의 변화상태를 이용하여 절삭공구의 상태를 진단하는 방법이다. 직접측정법으로는 ITV카메라[1], 광학센서[2], 전기저항센서[3] 등을 이용하는 방법이 있고 간접측정법으로는 압력[4]이나 온도의 변화[5], 스피들모터의 전류[6,7], 회전속도[8,9], AE(acoustic emission)[10], 절삭중의 음향[11] 및 절삭력(cutting force)[12,13] 등을 들 수 있다. 이중 직접적인 측정방법은 센서의 설치의 어려움 때문에 실시간 공구모니터링을 위해서는 간접적인 측정방법이 널리 이용되고 있다.

측정대상에 따라 단일센서를 이용하여 공구상태의 정보를 획득할 수 있으나 계측의 신뢰성향상과 다양한 범위의 계측을 위하여 복수센서를 이용한 센서융합(sensor fusion) 시스템으로 발전되어가고 있다.

가공 중 공구상태의 변화를 복수센서를 통해 신호를 검출하고 이를 모니터링하기 위해서는 센서신호의 특징을 추출하고 이 특징을 분류하여 공구상태를 판별할 수 있는 패턴인식시스템이 필요하다.

종래의 패턴인식시스템은 기본적으로 선형식별함수(Linear Discriminant Function)를 이용하여 입력패턴과 출력패턴을 비교하여 인식하는 단순한 과정으로 이루어졌다. 그러나 절삭과정과 같이 특성이 비선형적이고 복잡한 경우에는 정확한 상태진단이 어려우며 다양한 조건에서 많은 량의 학습데이터를 이용해야만 안정된 상태진단이 가능하다고 사료된다.

본 연구에서는 이러한 단점을 극복하기 위하여 다중센서로부터 입력정보를 집합적으로 처리할 수 있고(sensor fusion), 미학습 입력신호에 대해서도 축적된 내적 지식을 이용하여 적절한 출력을 낼 수 있는 적응성(adaptability)을 갖고 있으며 최소한의 입력정보로서도 최적의 출력을 낼 수 있는 신경회로망 모델을 절삭공정의 감시에 이용하

고자 한다. 이러한 신경회로망 모델은 자기학습(self learning)기능과 병렬처리에 의한 장점 때문에 실시간 감시에도 비교적 유용한 기법으로 보고되고 있다[14,15,16].

본 연구에서 사용된 신경회로망 모델은 시그모이드 함수(sigmoidal function)를 활성화 함수(activation function)로 다층구조를 가지며 학습규칙은 지도형 학습방법에 의한 오차역전파(error back propagation) 학습규칙을 채택하였다[17]. 이러한 오차역전파 학습규칙은 경사하강법(Gradient Descent Technique)에 의하여 학습이 수행되며 학습이 수렴될 때까지는 많은 반복횟수가 요구되는 단점을 가지고 있어 이러한 단점을 보완하기 위해서 1개의 은닉층을 가지는 것보다 2개의 은닉층을 가짐으로 인식률의 향상과 학습에서 수렴속도가 더 빠르다는 것이 제시되고 있다[18].

본 연구에서는 선삭공정 중 발생하는 절삭공구의 이상상태(공구마멸)를 검출하기 위하여 절삭력 센서와 AE 센서를 이용하여 절삭신호를 분석하여 신경회로망 입력특징을 추출하였으며 추출된 입력특징을 이용하여 신경회로망 모델을 구성하고 네트-웍의 변화에 따른 인식률의 변화를 고찰하여 선삭공구의 이상상태를 진단하기 위한 감시시스템을 제시하였다.

2. 절삭실험 및 신호처리

Fig. 1은 본 연구에서 사용된 실험장치의 개략도를 나타내며 table 1은 실험장치에 대한 사양을 나타낸다. 피삭재는 일반구조용 압연강재인 SM45C를 사용하였으며 절삭공구는 공구마모를 용이하게 관찰하기 위하여 P20재종의 코팅되지 않은 인서터를 사용하였다. AE센서는 vacuum grease를 이용하여 절삭공구의 홀더의 측면에 부착하였으며 pre-amplifier에서 60dB로 증폭하여 100KHz의 샘플링신호를 획득하였다. 공구동력계는 NC 선반의 터릿에 고정구를 제작하여 부착하였으며 공구마모 검출을 위한 절삭력 신호는 정적성분보다는 동적성분이 신뢰성이 있어 본 연구에서는 절삭력의 동적성분(dynamic cutting force)을 5 KHz로 샘플링하여 디지털 오실로스코프를 이용하여 획득하였다.

신경회로망 학습을 위하여 AE 및 절삭력 신호를 측정 후 그때의 공구 마모량을 공구현미경을 이용하여 측정하였다.

일정한 절삭속도와 이송속도의 변화에 따른 센서신호의 변화와 절삭공구의 마모를 관찰하기 위하여 table 2와 같

은 3가지 절삭조건으로 가공하였다.

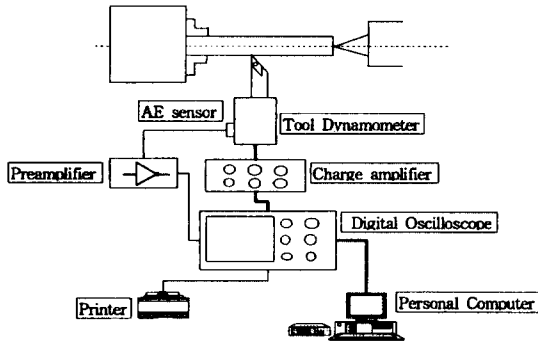


Fig.1 Block diagram for experimental setup.

Table. 1 The specifications of experimental instrument.

Instruments	Model	Maker
CNC Lathe	PUMA 8S	DAEWOO
AE sensor	PAC R15	PAC
Tool Dynamometer	9257BA	Kistler
Digital Oscilloscope	9304AM	LeCroy
Tool Holder	PCLNR2525	KOREA TUNGSTEN
Inserts	CNMG120408 P20	//
Preamplifier	PAC 1220A	PAC
Tool Microscope	176-811	Mitutoyo

Table 2 The cutting conditions

	case I	case II	case III
cutting speed(m/min)	200	300	300
feed rate(mm/rev)	0.2	0.2	0.3

Fig. 2는 절삭시간에 따른 공구마모의 변화를 나타내었다. 공구마모는 E. M. Trent가 제안한 바와 같이 크리이프 곡선(creep curve)의 형상과 유사한 공구마모곡선을 나타내고 있으며(19), 그림에서 알 수 있는 바와 같이 절삭속도와 이송속도가 빠를수록 절삭공구의 마모속도는 커지며 특히 절삭속도의 증가가 공구의 여유면 마모에 더 큰 영향을 미치고있음을 알 수 있다.

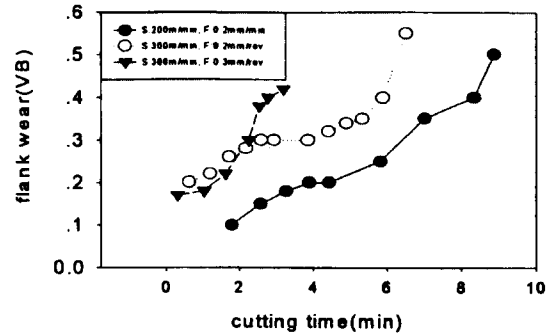


Fig. 2 The illustration of flank wear vs cutting length.

본 연구에서 AE와 절삭력 신호로부터 공구상태를 검출하기 위한 센서신호의 파라메타는 실효치 전압인 RMS전압을 이용하였다. 센서신호의 RMS전압은 식(1)과 같다

$$V_{rms}(t) = \sqrt{\frac{1}{\Delta t} \int_0^{\Delta t} V^2(t) dt} \quad (1)$$

Fig.3은 가공시간에 따른 3축방향 동절삭력의 RMS값의 변화를 나타낸다. 가공시간의 증가 즉 공구마모의 증가에 따라 주분력(Fx)의 변화가 크게 나타나고 있으며 절삭력의 동적성분은 점진적으로 증가함을 나타내고 있다.




Fig. 3 The variations of dynamic cutting forces according to cutting time.

Fig.4는 소재의 직경40mm 절삭속도 200m/min 이 송속도 0.2mm/rev일 때 공구마모에 따른 주 절삭력 신호를 FFT변환한 것이다. 절삭초기 정상공구(fresh tool) 상태에서는 주축 회전주파수(spindle rotational frequ-

ency)인 30Hz근방의 저주파수성분이 지배적으로 나타나고 있으나 공구가 마모됨에 따라 200Hz근방의 주파수성분이 크게 나타남을 알 수 있다. 이는 절삭공구가 마모됨에 따라서 절삭력의 동적 성분이 절삭공구 홀더의 고유진동(natural frequency)부근에서 큰 영향을 미쳐 파워 값이 크게 나타나는 것으로 사료된다.




Fig. 4 The dynamic cutting force spectrums according to flank wear.

Fig. 5는 공구가 마모됨에 따른 AE신호의 변화를 나타내고 있으며 RMS값이 증가하고 AE신호는 공구마모 곡선과 유사한 특성을 나타내고 있음을 알 수 있다.




Fig. 5 The variations of AErms signals according to cutting time

3. 신경회로망모델을 이용한 진단시스템의 구성

Fig.6은 신경회로망 모델을 이용한 진단시스템의 개략도를 나타내고 있으며 진단시스템은 준비단계(preparation stage), 학습단계(learning stage) 및 생산단계(production stage)로 구성한다.

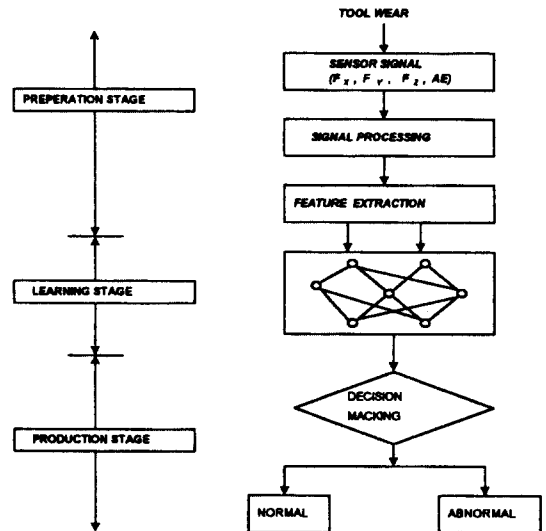


Fig. 6 Schematic diagram for the recognition of tool states on Artificial Neural Network.

3.1 준비단계(preparation stage)

인서트의 마모에 따른 측정신호를 적절한 신호처리 방법에 의하여 인서트의 상태와 관련된 가장 민감한 특징을 추출하여 신경회로망 모델의 입력패턴을 구성한다. 입력신호는 공구상태에 가장 큰 영향을 미치는 요소를 선정하며 본 연구에서는 절삭속도 이송속도와 3방향의 절삭력신호 및 AE신호의 RMS값등 6개의 파라메타를 신경회로망의 입력패턴(input pattern)으로 하였다.

신경회로망 모델의 각 입력패턴은 뉴런의 활성화 함수(activation function)로 사용된 시그모이드(sigmoid)함수의 초기 포화(saturation)를 방지하기 위하여 각 입력패턴의 최대값으로 나누어 표준화(normalize)하였다.

3.2 학습단계(Learning stage)[17]

Fig.7은 3개의 층들이 병렬로 연결된 다층 퍼셉트론

(multi-layer perceptron)의 구조를 나타낸다.

이러한 신경회로망의 학습규칙은 학습률과 수렴성이 가장 좋은 지도형 학습법(supervised learning)으로서 오차역전파 학습알고리즘인 Generalized Delta Rule 이용하며 GDR의 학습알고리즘은 Fig.8과 같다.

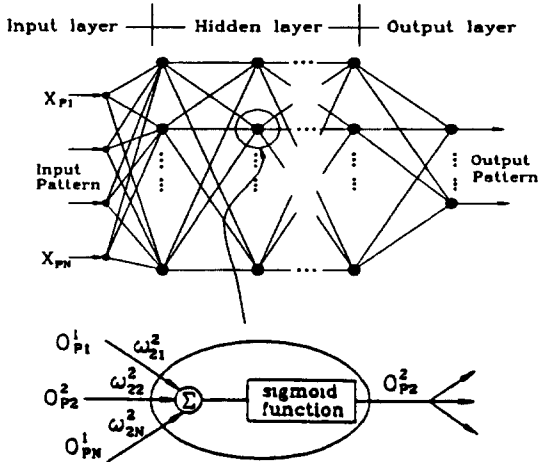


Fig.7 The multilayer perceptron.

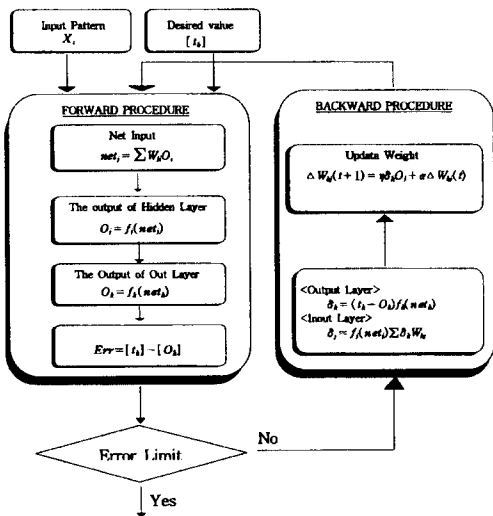


Fig.8 Learning algorithm of the Generalized Delta Rule.

본 연구에서 사용된 오차역전파 학습알고리즘인 GDR 은 패턴학습에서의 오차 즉 학습데이터의 네트워크 출력과 원

하는 출력과의 차에 따라 (2)식과 같이 가중치(weight)가 수정되며 이러한 과정을 계속하다가 총 시스템에러의 값이 허용범위 내에 들면 학습단계가 종료되고 그때의 입,출력 패턴 셀(set)의 전달특성(transfer characteristics)이 신경회로망에 저장된다.

본 연구에서는 공구마모에 따른 신경회로망의 학습을 위하여 각 절삭조건에서 40개의 학습데이터를 이용하여 신경회로망을 학습시켰다.

$$\Delta W_{kj}(n+1) = \eta \delta_k O_j + \alpha \Delta W_{kj}(n) \quad (2)$$

여기서 n : 반복회수(no. of iteration)

η : 학습률(learning rate)

α : 모멘텀률(momentum rate)

3.3 생산단계(production stage)

학습단계에서 획득된 신경회로망의 파라미터(parameters)를 이용하여 미학습 입력데이터를 신경회로망모델에 트레이닝(training)시킨다.

공구상태 검출을 위하여 절삭공구의 마멸상태는 ISO공구수명의 판정기준을 이용하여 Table 3에서 나타내는 바와 같이 여유면 마모량(VB)이 0.3mm를 기준으로 하여 정상공구(fresh tool)와 비정상공구(worn tool)를 분류하였다. 또한 신경회로망 출력노드를 2개의 노드를 정하여 첫 번째 노드에서 출력신호가 크면 정상상태(fresh state)로 두 번째 노드의 출력 값이 더 크면 비정상공구(worn state)로 판정하였다.

Table 3 Tool State Classifications

Tool State	Flank Wear	Network Output
Fresh Tool	$VB \leq 0.3\text{mm}$	[0.9 , 0.1]
Worn Tool	$VB > 0.3\text{mm}$	[0.9 , 0.1]

4. 진단시스템의 평가 및 고찰

절삭공구의 이상상태 검출을 위하여 절삭조건에 따른 절삭력 및 AE 복합센서로부터 40개의 입력신호를 획득하고 신경회로망을 학습시켰다. Fig.9는 학습과정에서 반복회수(iteration)의 증가에 대한 시스템의 평균오

차 수렴과정을 나타낸 것으로 학습초기에는 오차가 크며 반복횟수가 증가함에 따라서 출력값이 목표값으로 수렴함을 볼 수 있다.

학습된 신경회로망모델을 이용한 공구상태 진단시스템의 평가를 위하여 가공조건의 변화에 따라 정상상태 및 비정상상태의 절삭력 및 AE신호를 각각 30개씩 총 60개의 테스트신호를 획득하여 평가해 보았다.




Fig. 9 The convergence of system error.

Table 4는 신경회로망의 네트워크의 변화에 따른 진단시스템의 인식률의 변화를 나타내었다.

본 연구에서는 은닉층이 1개이며 노드의 수가 3개인 6-3-2의 네트워크에서는 7개의 에러가 발생하여 88% 정도의 인식률을 나타내었다. 네트워크의 은닉층 노드의 수를 10개로 증가하였을 때에는 5개의 에러를 발생시켜 92%로 인식률의 증가를 나타내었다.

또한 은닉층의 수를 2개로 증가하여 6-12-6-2의 네트워크에서는 3개의 에러를 발생하여 좋은 인식률을 나타내었다. 여기서 발생되어진 에러는 주로 공구판정의 경계부분 마모량 0.3mm 경계부분에서 발생하였으며 이는 학습과정에서 출력신호의 범주(category) 경계부분에서 좀 더

Table. 4 The performance of ANN to the variation of architecture

	6-3-2 network	6-10-2 network	6-12-6-2 network
learning samples	40	40	40
test samples	60	60	60
no. of errors	7	5	3
recognition rate	88 %	92 %	95 %

많은 학습데이터를 이용하여 신경회로망을 학습시킨다면 더 좋은 인식률을 얻을 수 있을 것으로 사료된다.

Fig. 10은 가공조건의 변화에 따른 진단시스템의 인식률을 나타낸다. 그림에서 알 수 있는 바와 같이 절삭속도 및 이송속도가 적을 경우에는, 높을 경우보다 더 우수한 인식률을 나타내며 이는 MRR(Metal Removal Rate)의 증가에 따라서 외부 잡음이 센서신호에 영향을 미치기 때문으로 사료된다.

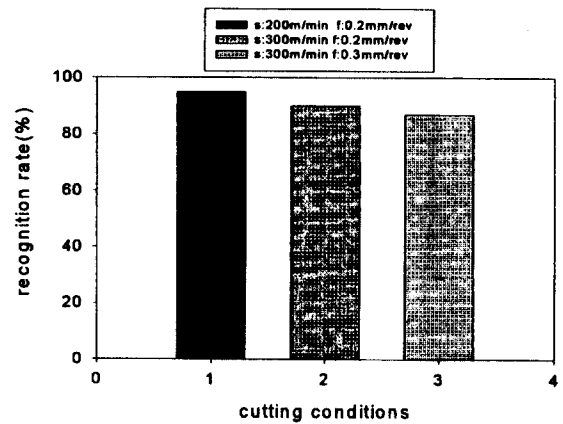


Fig. 10 The recognition rate on different cutting conditions.

5. 결론

본 연구에서는 신경회로망 모델을 이용하여 선삭공정에서의 공구상태 감시 시스템을 개발하고 이를 평가해 본 결과 다음과 같은 결론을 얻을 수 있었다.

- 1) 절삭력 신호, AE신호 및 절삭조건을 입력 특징으로 한 6-12-6-2 신경회로망모델은 선삭공정에서 발생하는 절삭공구의 이상상태를 진단할 수 있는 감시 시스템으로 우수한 성능을 나타내었다.
- 2) 절삭력 및 AE 복합센서 신호는 공구상태 검출신호로 적절하며 이 복합신호의 RMS값은 선삭 공구의 여유면 마모 모니터링을 위한 적절한 특징으로 사료된다.
- 3) 여유면 마모가 증가됨에 따라서 절삭력의 동적 성분은 주 절삭력 성분이 가장 민감하게 나타나며 공구가 정상상태에서는 주축의 회전주파수 성분이 크게

나타나다가 절삭공구가 마모됨에 따라서 200Hz근방의 성분이 증가됨을 알 수 있었다.

- 4) AErms 신호는 여유면 마모가 증가됨에 따라서 점점 증가하며 신호의 변화 패턴은 여유면 마모량의 변화와 비슷한 특성을 나타내고 있다

후 기

이 논문은 1996년도 한국학술진흥재단의 공모 과제연구비에 의하여 연구되었음.

6. 참고문헌

1. 上原邦雄 外2人, 1973 " 切削工具逃げ面摩耗のインプロセス測定", 日本精密機械, 30(8), pp.53-57.
2. Guisti, F., Santoch, M., 1979, "Development of a Fiber Optic Sensor for in process measurement of tool wear", Proc. of 20th M.T.D.R. conf., pp. 351-360.
3. 上原邦雄, 竹下英夫, 菊池昌安, "電氣抵抗による切削狀態の監視", 昭和 63年度 精密學會 秋季大會 學術講演 論文集, pp.27-28.
4. 山根 八洲男 外 1人, 1984, "正面フライス 切削 時の工具損傷に及ぼす 霧井氣 影響", 日本精密機械, 50卷 8號, pp44-48.
5. Groover, M.P 外2人, 1977, "A Study of Relationship Between Remote Thermocouple. Temperature and Tool Wear in Machining", Int. J. Prod. Res., Vol. 25, No. 2, pp.129-141.
6. 松島克守, 佐田登志夫, 村田雅典, "主軸電動機の 電流波形 パターンによる工具の缺損 検出", 昭和 53年度 精密學會 秋季大會 論文集, pp.5-6.
7. 蘇井義他, 李勇, "主軸電流値による切削狀態の監視について", 昭和 63年度 精密學會 秋季大會學術講演 論文集, pp.27-28.
8. S.Takata, 1987, "Tool Breakage Monitoring by Means of Fluctuations in Speed", Annals of CIRP, Vol.36, pp.49-52.
9. S.Takada, 1988, "Tool Breakage Detection by the Measurement Spindle Rotational Speed Fluctuation", Proc. of the winter annual meeting of the ASME, PED Vol.129-135.
10. K. Iwata, etc., 1977, "An Application of Acoustic Emission to In-process Sensing of Tool Wear", Annals of CIRP, Vol.26/1, pp.21-26.
11. Higuchi, M., Yano, A., 1983, " 研削音による加工狀態の診斷", 日本精密機械, 49卷, pp.1071-1076.
12. Koren, Y., Ko, T.R., Danai, K., and Ulsoy, A. G., 1989, "Methods for Tool Wear Estimation from Force Measurements Under Varying Cutting Conditions", Proc. of the winter annual meeting of the ASME, Control Issues in Manuf. Processes, pp.45-53.
13. Elbestawi, M. A., Papazafiriou, T. A., and Du, R. X., 1991, "In-Process Monitoring of Tool Wear in Milling Using Cutting Force Signature", Int. J. Machine. Tools Manufact., Vol. 33, No. 1, pp.55-73.
14. S.Rangwala, D. Dornfeld, 1990, " Sensor Integration Using Neural Networks for Intelligent Tool Condition Monitoring", ASME, J. of Eng. for Ind., Vol. 112, pp. 219-228.
15. Rangwala, S. S., and Dornfeld, D. A., 1987, "Integration of Sensors via Neural Networks for Detection of Tool Wear States", Proc. of the winter annual meeting of the ASME, pp.109-120.
16. Rangwala, S. S., and Dornfeld, D. A., 1989, "Learning and Optimization of Machining Operations Using Computing Abilities of Neural Networks", IEEE Trans. on Systems, Man, and Cybernetics, Vol. 19, No. 2, pp.299-314.
17. Yoh-Han Pao, 1989, " Adaptive Pattern Recognition and Neural Networks", Addison-Wesley, Pub. Company, Inc., N.Y.
18. D. Chester, 1990, "Why two hidden layers are better than one", Int. Joint. Conf. Neural Networks, Washington, IEEE, pp.265-268.
19. Trent, E. M, 1967, Proceeding of a conference on machineability, London Iron and steel Institute.
20. 김정석 외2, 1994, "신경회로망을 이용한 채터진동의 인프로세스 감시", 1994년 한국정밀공학회 추계학술대회 논문집, pp.70-75.

21. 박동삼, 1993, "다층퍼셉트론을 이용한 절삭칩 형상
과 채터검출에 관한 연구", 1993년 한국정밀공학회 추
계학술대회 논문집, pp.293-297.