

## 선작 공작을 위한 지능형 실시간 공구 감시 시스템에 관한 연구

최기홍\*, 최기상\*\*

### A Study on Intelligent On-line Tool Condition Monitoring System for Turning Operations

Gi-Heung Choi\*, Gi-Sang Choi\*\*

#### ABSTRACT

In highly automated machining centers, intelligent sensor feedback systems are indispensable in order to monitor their operations, to ensure efficient metal removal, and to initiate remedial action in the event of accident.

In this study, an on-line tool wear detection system for turning operations is developed, and experimentally evaluated. The system employs multiple sensors and the signals from these sensors are processed using a multichannel autoregressive (AR) series model. The resulting output from the signal processing block is then fed to a previously trained artificial neural network (multilayered perceptron) to make a final decision on the state of the cutting tool.

To learn the necessary input/output mapping for tool wear detection, the weights and thresholds of the network are adjusted according to the back propagation (BP) method during off-line training.

The results of experimental evaluation show that the system works well over a wide range of cutting conditions, and the ability of the system to detect tool wear is improved due to the generalization, fault-tolerant and self-organizing properties of the neural network.

#### 1. 서 론

일반적인 기계 공작 시스템에서 오퍼레이터는 공작물을 다루는 일 뿐 아니라 공작 과정을 감시하고, 어떤 문제가 생기면 적절한 조치를 취하고, 생산품의 품질을 검사하고, 공정을 제어하는 일들을 하게 된다. 그러나 오늘날의 생산 현장은 보다 향상된 품질, 높은 생산성과 신뢰성을 달성하기 위하여 자동화, 무인화의 방향으로 움직이고 있다. 따라서 열악하고 예측하기 어려운 공장 환경하에서 오퍼레이터의 구체적인 지시 없이도

자동적으로 정해진 기계 공작을 행할 수 있는 지능형 공작 시스템(intelligent machining system)의 설치가 점차 중요하게 되었다. 이러한 지능형 공장 시스템의 직접적인 장점은 다음과 같이 요약될 수 있다.

- (1) 기계 공작 과정에 대한 정확한 정량적 정보를 제공한다.
- (2) 이를 정보는 작업의 예측성을 증가시키고 공작 기계의 더 나은 제어를 가능하게 한다.
- (3) 따라서, 결과적으로 기계 공작 과정에서 오퍼레이터의 필요성을 감소시킨다.

\* 쌔이텍 코리아

\*\* 서울시립대학교 제어계측공학과 (정희원)

또한 지능형 공작 시스템을 적용함으로써 기대되는 효과들은 구체적으로 다음과 같이 정리될 수 있다.

- (1) 생산성의 증대
- (2) 가공품 질의 향상
- (3) 불량 폐기 부품의 감소
- (4) 공작 중단 시간의 감소
- (5) 오퍼레이터에 대한 위험의 감소

일반적으로 절삭 가공에서 오퍼레이터의 중요한 역할 중의 하나는 절삭 시스템의 작동을 감시하고 문제가 생기기 전에 절삭 파라미터나 공구를 바꿔주는 것이다. 절삭 가공에서 절삭 공구는 절삭이 일어나는 모서리 부분이 마모되거나 파손되면 교환되어야 한다. 그러나 공구의 수명은 예측하기 힘들고 넓은 분포를 가지기 때문에 일반적인 공구 교환 정책을 수립하는 것이 불가능하다. 간단한 한 단계의 절삭 공정에서는 공구 수명의 넓은 분포가 큰 문제가 아닐 수도 있지만 복잡한 다단계의 생산 라인에서는 예측하지 못한 공구의 마모와 파손이 전체 공정의 예기치 못한 정지를 가져올 수 있다. 따라서 공작 과정 중 공구의 상태에 관한 센서 정보를 사용하는 실시간 감시 시스템은 전체 공정의 생산성의 향상을 위해 꼭 필요하다. 일반적으로 지능형 공작 시스템에서 센서 시스템의 성능은 결정적으로 중요한 요소이며 공작 과정에 관한 정확한 정보를 제공할 수 있을 만큼 감도가 좋고 열악하고 비예측적인 공장 환경 하에서도 문제없이 작동할 수 있는 센서 시스템의 개발은 꼭 필요하다. 구체적으로 Tlusty와 Andrews[1]는 무인 지능형 공작 시스템에서 다음과 같은 목적으로 센서가 필요하다고 지적하였다.

- (1) 공작물이 어떤 것인지 그리고 그 질, 놓여진 방향, 크기 등을 알아내기 위하여; 또 공작 기계나 공작물의 온도에 의한 변형, 공구의 마모에 따른 효과를 상쇄하기 위하여.
- (2) 공구를 알아내고 그 오프셋을 정하기 위해서; 공구를 감시하기 위하여; 칩 형성을 감시하기 위하여; 공구 마모를 체크하고 공구 파손을 감지함으로써 공구 교환을 하기 위해서.
- (3) 가이드웨이(guideways)와 피이드 드라이브(feed drive)의 스픬들 베어링들의 적절한 성능을 감시하기 위하여.
- (4) 제어 시스템과 그 부품들의 기능을 감시하기 위하여.

그동안 많은 공구의 감시의 방법들이 제안되고 평가

되었지만 절삭 공작의 복잡성 때문에 어떤 방법도 일반적으로 성공적이지는 못했다. 이들 방법들은 공구 마모 그 자체를 측정하고 마모에 의한 공구의 부피 손실을 측정하는 직접적인 방법과 공구 마모의 결과를 측정함으로써 공구 마모를 예측하는 간접적 방법으로 나누어진다. 직접적 방법으로는 광학적 방법 (광반사법 (light reflection method), 반사 패턴 방법 (reflection pattern method), 비디오 카메라에 의한 공구 마모의 감시등), 접촉 저항법(contact resistance method), 방사능 방법(radioactive method) 등을 들 수 있으며 간접적 방법으로는 절삭력 혹은 절삭 에너지의 측정(cutting force or power detection), 공구와 공작물의 간격 측정(measurement of the gap between tool and workpiece), 온도 측정(온도에 따른 기전력 방법(thermal emf method), 열전쌍에 의한 기전력의 측정(measurement of temperature by thermocouple), 적외선 방법(infra-red method), 전기 저항 방법(electrical resistance method), 진동 해석법(vibration analysis method), 음파 해석법(음파 진동법 (sonic vibration method), acoustic emission (AE) 방법) 등이 있다.[4, 5].

직접적 공구 마모 감시 방법들의 공통적인 문제점은 공장 환경 하에서 보통 대단히 작은 마모면의 실시간 측정이 아주 어렵다는 점이다. 반면에 대부분의 간접적 방법들은 측정이 공구의 마모뿐 아니라 공작물의 물성, 절삭 공구의 모양, 그리고 절삭 조건과 같은 공정 파라미터의 변화에 영향받는다. 이러한 파라미터의 변화가 있을 때 신뢰성은 직접적 방법보다 낮아지고 또한 많은 시간을 소요하는 현장에서의 보정 작업(calibration)이 필수적이다. 위에서 언급된 여러 방법들 중에서 AE 방법은 공구 마모 감시의 방법의 하나로 제안되었으며 효과적이며 입증된 바 있다[6, 7, 8, 9].

AE는 고체에서 갑작스런 응력장의 국부적 변화에 의해 발생되는 낮은 출력과 높은 주파수 성분을 가지는 응력파로 정의된다. 이 응력파는 물질을 통하여 전파되어 천이적인(transient) 표면의 진동을 일으킨다. 이 진동은 물질의 표면에 설치된 피에조엘렉트릭 센서(piezoelectric sensor)에 의해 감지되어 전기적인 신호로 바뀌게 되는데 이것이 AE 신호이다. AE는 기계적 실험에서 변형과 파괴의 미세한 메카니즘을 규명하는 도구로서 이용될 수 있으며 기계적 구조물의 결함을 감지해 내고 그 위치를 알아내기 위한 테스트 방법으로도

응용되고 있다. 절삭 가공에 관하여는 1977년에 Iwata 와 Moriwaki[6]가 처음으로 AE가 급속 절삭에서 점점 측 공구의 마모를 나타내는 좋은 척도가 될 수 있다고 보고하였으며 그 후 여러가지 생산 공정의 실시간 센서로서의 가능성은 Dornfeld와 동료들에 의해 광범위하게 연구되었다. 특히 그들은 AE 방법이 절삭 공정에서의 공구 상태 감시에 적합하다는 것을 구체적으로 입증하였다[8].

AE 방법의 가장 중요한 특징은 AE 신호가 절삭 공작의 미세한 메카니즘에 직접적으로 연관된다는 점이다. 실제로 절삭 공작의 주요한 3개의 메카니즘이 소성 변형, 마찰, 그리고 파괴는 모두 AE의 주요한 원천이다. 따라서 공구의 마모에 따른 절삭 공정의 미소역학적인(micromechanical) 변화는 AE에 잘 반영된다. 더욱이 AE 신호의 파워 스펙트럼은 약 1Mhz 이상까지 미치기 때문에 공작 기계의 진동이나 다른 환경 노이즈의 파워 스펙트럼 보다 훨씬 높은 주파수여서 이러한 노이즈에 의한 영향을 거의 받지 않는다.

생산 공정의 감시를 위한 지능형 센서 시스템의 개발은 일반적으로 다음과 같은 3단계를 포함한다.

(1) 센서 신호의 감시하고자 하는 공정 파라미터에 대한 감도(sensitivity) 테스트

(2) 감시하고자 하는 공정 파라미터의 정보가 많이 담긴 신호 파라미터를 골라 내기 위한 적절한 실시간 신호 처리 방법의 개발

(3) 현재의 센서 데이터 뿐 아니라 과거의 경험으로 부터 얻어진 데이터 베이스에 기초해서 결정을 내릴 수 있는 의사 결정 시스템 (decision making system)의 개발

본 연구에서는 다중 퍼셉트론 형태 신경회로망을 이용한 실시간 공구 마모 감시 시스템의 구조를 개발하고 그 시스템의 성능을 실험적으로 평가하는 것을 목적으로 한다. 이 시스템의 신호처리와 의사 결정 구조가 그림 1에 도시되어 있다. 이 시스템은 다중 센서 (AE, 절삭력, 전류 센서)를 사용하고 이를 센서로 부터의 신호는 다채널 AR 모델 (multichannel autoregressive series model)을 사용하여 처리 된다. 결과적으로 나오는 AR 계수 행렬 (AR coefficient matrix)은 특징 추출 (feature extraction)을 통해 공구 마모에 가장 민감한 특징 (feature)들이 선택되게 된다. 또한 이 특징들은 미리 훈련된 있는 신경회로망에 입력으로 전달되어 공구의 상태에 대한 최종적인 결론을 내리게 된

다. 공구 마모 감시에 필요한 입력/출력 맵핑(mapping) 관계를 학습하기 위하여 네트워크의 파라미터 (가중치와 임계치)는 역전달법 (back propagation, BP)[16]에 의하여 미리 학습되게 된다 (off-line training).

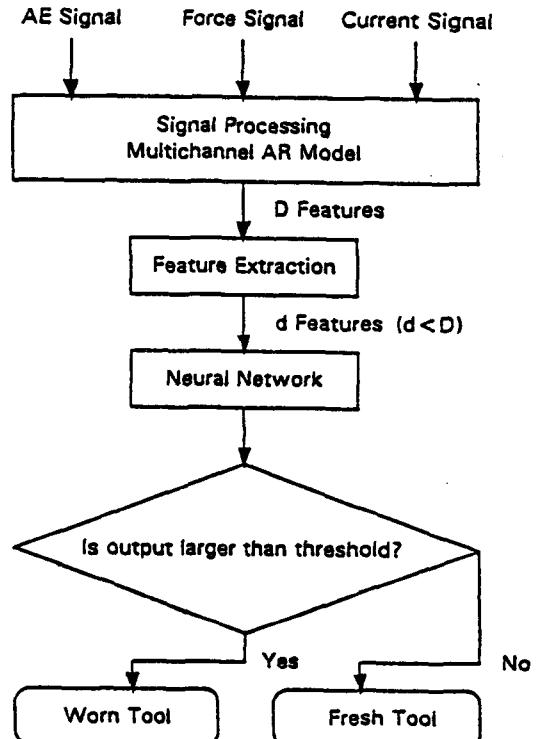


Fig. 1 신호처리 및 공구 마모 판단을 위한 구조

## 2. 신호처리

만약 어떤 공학적 시스템의 정확한 수학적 모델을 얻을 수 있다면 그 시스템은 수학적 모델을 사용해서 정량적으로 설명될 수 있을 것이다. 그러나 많은 경우에 있어서 시스템을 적절히 서술할 수 있는 정확한 수학적 모델을 구하는 것은 대단히 어렵다. 이러한 경우에 시스템의 특성은 실험으로 얻어진 데이터를 이용해서 확률적 모델 (stochastic model)을 적용함으로써 근사적으로 나타낼 수 있다.

센서로부터의 신호 그 자체는 신호의 무작위성 (stochastic nature) 때문에 해석하기 어려우므로 AE, 절삭력, 그리고 전류 센서로부터의 신호는 절삭 공구

상태에 관한 유용한 정보를 얻기 위하여 처리되어야 한다. 본 연구에서는 샘플된 데이터를 사용하는 다채널 AR 모델(multichannel autoregressive time series model) [10, 11, 12]이 사용되었다. m채널 p차 AR 모델,  $x(n)$ 은  $A(k)$ 가  $m \times m$  AR 계수 행렬이고,  $u(k)$ 가 제한적 정상 분포(wide-sense stationary)를 갖는  $m \times 1$  노이즈 벡터(noise vector)라고 할 때 다음과 같은 벡터 귀환식에 의해 정의된다.

$$x(n) = - \sum_{k=1}^p A(k) x(n-k) + u(n) \quad (1)$$

m채널 AR 모델은 m개 입력 신호 가운데 모든 채널의 조합간의 상관관계(crosscorrelation)를 고려한다는 점에서 m개의 독립된 AR 모델을 벡터로 나타낸 것과는 다르다.

Liang과 Dornfeld[8]는 AE 신호를 샘플해서 얻어진 AR 계수가 선삭에서 넓은 공작 조건에 대해서 공구 마모에 좋은 감도를 보였다고 보고하였다. 절삭력과 스판들 모터의 전류도 독립적으로 사용되서 공구 상태의 척도가 될 수 있다고 보고된 바 있다[1, 5]. 이들 센서 신호 (AE, 절삭력, 전류)의 특성이 절삭 공구 상태에 따라 변화한다면 이들 센서 신호로부터 계산된 다채널 AR 계수 행렬이 공구 마모의 척도가 될 수 있을 것이다. 따라서, 본 연구에서는 다채널 AR 계수 행렬이 절삭 공구의 상태를 나타내는 파라미터로 사용되었다.

또한 샘플된 센서 신호,  $x(n)$ 에 대해서 다음과 같이 정의되는 파워 스펙트럼 밀도(power spectral density)의 특정 부분도 공구 마모에 민감하다는 것이 알려져 있다[9].

$$S(f_i) = \sum_{k=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} x(n) x(n+k) \exp(-jkf_i) \quad (2)$$

따라서, 또 다른 신호 처리의 방법으로서 시간영역에서의 센서 신호를 FFT 방법을 사용하여 주파수 영역에서의 파워 스펙트럼 밀도로 변환하고, 그 결과는 통계적인 안정성을 얻기 위하여 주파수 영역을 10 밴드로 나누고 각각의 밴드 평균을 취한 값들을 절삭 공구의 상태를 나타내는 파라미터로 사용하여 그 성능이 다채널 AR 모델을 사용한 경우와 비교되었다.

### 3. 특징 추출(Feature Selection)

신경회로망에 큰 크기의 입력 신호 벡터를 사용한다고 해서 반드시 시스템의 성능이 향상되는 것이 아니며 오히려 많은 학습 샘플과 매우 큰 크기의 네트워크를 필요로 하기 때문에 비현실적일 수 있다. 따라서, 공구 마모의 민감하면서도 공작 조건이나 환경의 영향에 감도를 보이지 않는 성분만을 골라서 패턴 인식을 위한 신경회로망의 입력 벡터로 사용하여야 한다. 이를 위하여, D개의 센서 데이터들로부터 새로운 공구와 마모된 공구라는 두 개의 그룹(group) 사이의 최적의 분리도를 가져오는  $d(d < D)$  개의 특징(feature)들을 골라내기 위해 군내 분산 행렬,  $S_w$ 와 군간 분산 행렬,  $S_b$ 를 다음과 같이 계산한다[13].

$$S_w = \sum_{i=1}^2 P_i (1/n_i) \sum_{k=1}^{n_i} (x_{ik} - \bar{m}_i)(x_{ik} - \bar{m}_i)^T \quad (3)$$

$$S_b = \sum_{i=1}^2 P_i (\bar{m}_i - \bar{m})(\bar{m}_i - \bar{m})^T \quad (4)$$

단,

$x_{ik}$ 는 k번째 패턴 벡터,

$n_i$ 는 i번째 군에 속하는 패턴 벡터의 숫자,

$$\bar{m}_i = n_i / (\sum_{i=1}^2 n_i)$$

$$\bar{m} = (1/n_i) \sum_{k=1}^{n_i} x_{ik} \quad \text{는 } i\text{번째 군 패턴 벡터의 평균,}$$

$$\bar{m} = \sum_{i=1}^2 P_i \bar{m}_i \quad \text{는 모든 패턴 벡터의 평균이다.}$$

그리고 그룹 간의 분산을 최대화 하면서 각 그룹 내의 분산을 최소화하는, 즉 두 그룹을 가장 잘 분리시키는 특징(feature)들을 선정하기 위해 신호와 노이즈의 비를 나타내는 다음과 같은 계수가 사용될 수 있다.[9]

$$J = \text{trace}(S_b) / \text{trace}(S_w) \quad (5)$$

본 연구에서는 순차 전방 검색 알고리즘(sequential forward search algorithm)[13]이 공구 마모에 가장

민감한 특징들을 골라내기 위하여 사용되었다. 이 알고리즘에 따르면 먼저 1차원 공간에서 모든 D개의 특징(신호처리 과정으로 부터의 출력, 즉, AR 계수 행렬 혹은 파워 스펙트럼 밀도의 밴드 평균들)에 대해서 J가 계산되고, J를 최대화하는 하나의 특징(feature)이 골라진다. 그리고, 나머지 D-1개의 특징이 모두 미리 선정된 특징과 결합되어서 각각의 조합에 관해 2차원 공간에서 J가 계산된다. J를 최대화하는 조합으로부터 두번째의 특징(feature)이 선정되며 이러한 과정은 d개의 특징들이 선정될 때까지 계속된다.

#### 4. 센서 융합(Sensor Fusion)과 판단 (Decision Making)을 위한 신경회로망

지능형 감시 시스템은 오퍼레이터 없이 비정상 상태를 감지해 내고, 교정 행동을 시작할 수 있어야 한다. 이를 달성하기 위하여 지능형 감시 시스템은 센서로 부터의 정보를 해석할 수 있고, 환경으로부터 학습할 수 있으며, 학습과정 동안 얻어진 지식에 반응하여 그 자신을 바꾸어 나갈 수 있으며, 적절한 제어 기능에 관하여 스스로 결정할 수 있어야 한다.

인공 신경회로망은 이러한 목적에 특히 유효하다. 즉, 인공 신경회로망의 이용은 인공 신경회로망을 이용한 시스템이 생체 시스템과 마찬가지로 많은 양의 센서 정보에서 중요한 특징을 자기조정(self-organization)에 의해 골라낼 수 있으며(feature extraction), 여러 센서로 부터의 정보를 집합적으로 처리할 수 있다는 점(sensor fusion), 또 적응성(adaptability)을 갖고 있다는 점에서 정당화할 수 있다. 현재의 컴퓨터 기술로 대단히 많은 뉴런(neuron)과 각 뉴런들을 연결하는 조밀한 시냅스(synapse)를 가지는 생체 신경계의 크기나 복잡성을 따라갈 수 있는 인공 신경회로망을 구현할 수 없으나 비교적 적은 정보량을 다루는 공학적 시스템의 모델링이나 공장자동화에 응용될 수 있는 간단한 패턴인식과 같은 특별한 목적에 사용됐을 때 특히 효과적일 수 있다.

실제로 응용하기 전에 신경회로망은 학습과정을 거쳐서 문제를 해결하는 기술을 익혀야 한다. 많은 경우에 있어서 학습의 목표는 입력과 출력 사이의 연관적인 맵핑(mapping) 관계를 점진적으로 형성해 나가는 것이다. 이러한 연관적인 맵핑(associative mapping) 관계의 형성을 위하여 신경회로망내의 내부 구조를 수정시켜

나가는 과정을 연관 학습(associative learning)이라 한다. 연관 학습에는 학습이 어떻게 일어나는지에 따라서 다른 두 가지의 종류가 있다. 감독 학습(supervised learning)에서는 시스템에 입력/출력 패턴을 제시함으로써 학습시스템에 연관 맵핑(mapping)이 형성된다. 주어진 입력에 대해서 시스템은 현재의 내부 모델에 따라서 출력 패턴을 계산한다. 그리고 계산된 출력은 외부에서 주어진 출력과 비교되어 내부 모델이 실제의 출력과 목표 출력의 차이를 줄이는 방향으로 조정된다. 본 연구에서는 이 방법이 사용된다. 또 다른 연관 학습방법은 무감독 학습(unsupervised learning)이다. 무감독 학습 시스템은 단지 입력 패턴만을 이용한다. 각각의 입력 패턴에 대해서 학습 시스템은 출력 패턴이 임의의 관점에서 최적화되도록 입력 패턴에 대해 반응한다. 성능의 척도는 외부 환경으로부터의 평가적인 피드백(evaluative feedback)에 의해 측정된다. 무감독 학습에서의 피드백 정보는 단지 평가적이고 감독 학습에서의 출력 패턴처럼 정보적이 아니기 때문에 무감독 학습은 일반적으로 대부분의 감독 학습에 비하여 훨씬 어렵다.

본 연구에서는 그림 2에서와 같은 3층 구조를 갖는 뉴런(neuron)의 네트워크가 사용되었다. 네트워크 내의 각각의 뉴런은 연결되어 있는 아랫층으로부터의 출력들에 가중치(weight)가 곱해진 값에 임계치(threshold)가 더

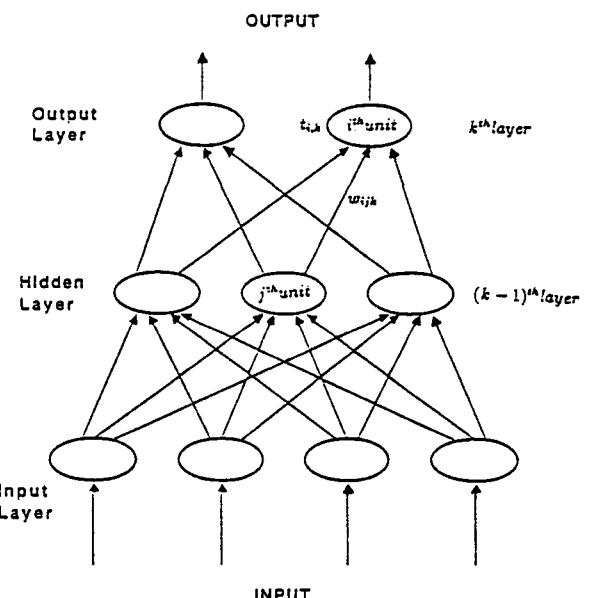


Fig. 2 3층 구조 feed forward 신경회로망

해전 값을 입력으로 취하고 이 입력의 비선형 함수인 출력을 다음과 같이 형성한다.

$$\text{net}_{i,k} = \sum_j w_{i,j,k} o_{j,k-1} + t_{i,k} \quad (6)$$

$$o_{i,k} = f(\text{net}_{i,k}) = 1 / (1 + \exp(-\text{net}_{i,k})) \quad (7)$$

단,

$w_{i,j,k}$  = (k-1) 번째 층 i번째 뉴런에서 k번째 층 j번째 뉴런으로의 가중치,  
 $t_{i,k}$  = k번째 층 i번째 뉴런의 임계치,  
 $\text{net}_{i,k}$  = k번째 층 i번째 뉴런으로의 입력,  
 $o_{i,k}$  = k번째 층 i번째 뉴런의 출력이다.

이 출력은 같은 층의 다른 뉴런으로 부터의 출력들과 함께 다음 층의 입력으로 작용하게 되며 이러한 과정은 반복된다. 네트워크의 기층은 입력층이고 최고층은 출력층이다. 단일층으로 구성된 퍼셉트론들도 패턴 인식에 사용될 수 있다. 그러나 단일층 퍼셉트론이 만족할 만한 패턴 인식을 행하기 위하여는 입력 특징이 특징 공간(feature space)에서 선형 분리가 가능하여야 한다. 2층 퍼셉트론에서는 출력이 두 층간의 가중치의 결합을 통하여 입력들로 부터 직접적으로 계산된다. 이러한 형태의 네트워크에서는 입력이 출력으로 직접 맵핑된다는 점 때문에 서로 비슷한 입력 패턴들은 서로 비슷한 출력을 생성하게 되며 서로 비슷한 입력이 아주 다른 출력을 생성하게 하는 것은 불가능하다. 이러한 단층 혹은 2층 퍼셉트론의 한계성은 3개 이상의 층을 가진 네트워크에 의해 극복될 수 있다. 하나 혹은 그 이상의 중간층을 갖는 다층 퍼셉트론은 임의의 복잡한 결정면 (decision surface)을 갖는 것을 가능하게 하며, 따라서 특성 공간에서 보다 복잡한 분리를 행하는 것을 가능하게 한다. 따라서, 본 연구에서는 3개의 층을 가진 네트워크가 사용되며 학습 방법으로는 역전달법(back propagation)이 사용되었다.

역전달법 [16]은 다층 퍼셉트론을 위한 학습 알고리즘으로서 네트워크가 입력/출력의 학습패턴 중 한 입력이 주어졌을 때 네트워크가 주어진 입력에 대한 출력을 생성할 수 있도록 파라미터를 바꾸어 준다. 일단 네트워크가 학습 샘플의 입력과 출력 사이의 맵핑 관계를 학습하면 전에 알려지지 않은 새로운 입력이 가해졌을 때 출력은 네트워크가 학습 샘플의 입력/출력 관계에 대한

지식에 기초해서 유추한 결론이 된다.

역전달법에 의하면 네트워크는  $T_i$ 가 목표치,  $O_{i,N}$ 이 입력층에 제시된 입력 벡터에 대한 네트워크의 출력일 때 다음과 같은 출력층의 제곱 오차의 합이 최소화되도록 학습된다.

$$E = \sum_i (T_i - O_{i,N})^2 \quad (8)$$

최대 감소방법에 기초한 반복법 (iterative procedure based on the steepest descent method)이 E를 최소화하기 위해 사용된다. 즉, 가중치,  $w_{i,j,k}$ 와 임계치,  $t_{i,k}$ 는  $\eta_w$ 와  $\eta_t$ 가 각각 가중치와 임계치의 학습율 (learning rate) 일 때 다음과 같이 갱신된다.

$$\begin{aligned} w_{i,j,k}(n+1) &= w_{i,j,k}(n) - \eta_w \\ (\partial E / \partial w_{i,j,k}) &= w_{i,j,k}(n) \\ &- \eta_w \delta_{i,k} o_{j,k} \end{aligned} \quad (9)$$

$$\begin{aligned} t_{i,k}(n+1) &= t_{i,k}(n) - \eta_t (\partial E / \partial t_{i,k}) \\ &= t_{i,k}(n) - \eta_t \delta_{i,k} \end{aligned} \quad (10)$$

단, 출력층에서

$$\delta_{i,N} = (T_i - O_{i,N}) O_{i,N} (1 - O_{i,N}) \quad (11)$$

중간층에서

$$\begin{aligned} \delta_{i,k} &= O_{i,k} (1 - O_{i,k}) \sum_j w_{i,j,k} \delta_{j,k+1} \\ j \end{aligned} \quad (12)$$

이다. 학습 과정에서 학습 샘플의 입력 패턴은 입력층에 제시되고 네트워크를 통하여 전달되어서 출력이 생성된다. 그리고 출력층에 대한  $\delta_{i,N}$ 이 식 (11)에 따라 계산되고 중간층에 대한  $\delta_{i,k}$ 는 식 (12)에 따라 순환적 (recursively)으로 역전달에 의해 계산된다. 최종적으로 가중치와 임계치는 식 (9)와 (10)에 따라 조정된다.

## 5. 실험 장치

실시간 공구 마모 감시를 위한 시스템은 Tree 1000 선반, PC (i386 based SAIC Delta Neurocomputer Workstation), 컴퓨터와 선반의 인터페이스를 위한 전자 하드웨어 그리고 AE 센서와 force 센서 그리고 전류 센서로 구성되었다. 실험에서 사용된 장치가 그림 3에 도시되어 있다. 원래 Tree 1000 선반은 제어패널을 통하여 프로그램되는 내장 컴퓨터에 의해 구동되나 좀 더 효과적인 제어를 위하여 전자 하드웨어를 통해

PC내의 소프트웨어에 의해 자동으로 구동될 수 있도록 개조되었다. PC에는 델타 부동 소수점 연산 보드(Delta Floating Point Processor board)가 장착되었는데 이 보드는 신호 처리나 인공 신경회로망의 모사(simulation)를 위한 병렬처리 환경(parallel processing environment)를 제공하도록 특별히 설계된 것이다.

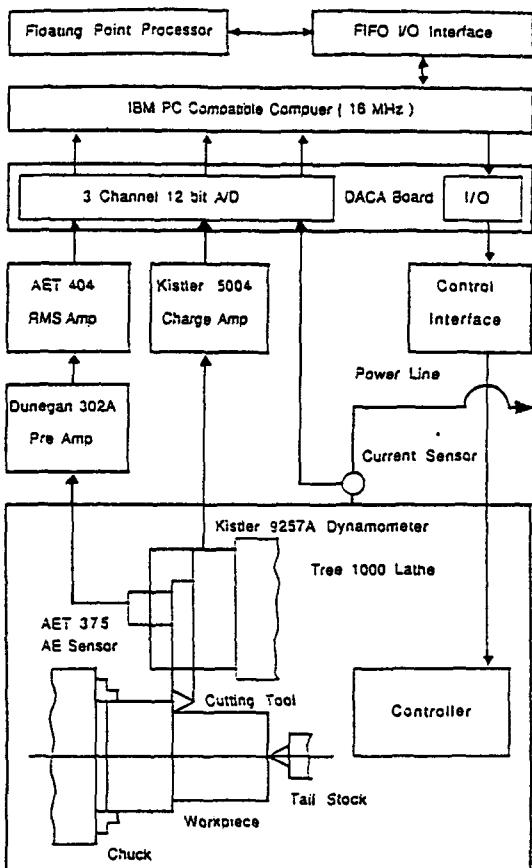


Fig. 3 실시간 공구 마모 감시를 위한 시스템

절삭 공작중 AE와 절삭력은 각각 절삭 공구에 부착된 AET 375 AE 센서와 공구대에 부착된 Kistler 9257A 공구동력계(dynamometer)에 의하여 측정되었으며 전류 신호는 스피드 모터 전원선 주위에 설치된 Omron 자기형 전류센서에 의해 측정되었다. 그리고 이 신호들은 12-bit A/D 컨버터(IBM DACA board)를 통하여 1KHz로 PC로 샘플링되었다. 신호들은 델타 보드로 FIFO I/O 인터페이스를 통하여 보내져서 처리되고 패턴 인식의 결과는 PC로 다시 보내진다.

2개의 독립된 프로그램이 하나는 PC에 대해서 또 하나는 델타 보드에 대해서 작성되었다. PC 프로그램은 선반을 제어하고, DACA 보드를 통하여 센서 데이터를 수집하며, 델타 보드의 작동을 제어하고, 델타 보드와의 통신을 위한 부분으로 구성되었으며, 델타 보드 프로그램은 많은 부동소수점 연산을 필요로 하는 신호 처리, 패턴 인식과 PC와의 통신을 위한 부분을 포함한다. 이 두 컴퓨터(PC와 델타 보드)를 동시에 제어하는데 있어서의 한가지 문제점은 동기화(synchronization)였다. 즉, PC가 샘플한 데이터를 신호처리와 패턴인식을 위하여 델타 보드로 보내려 할 때 델타 보드가 이전의 데이터를 이용한 계산이 아직 완료되지 않은 상태라면 문제가 발생한다. 이와 같은 문제를 해결하기 위하여 hand shaking 방법을 사용하였다. 즉, 델타 보드에서 계산중에 PC에서 샘플링이 끝난 경우 PC는 "data-ready" 신호를 델타 보드에 보내고 계산이 끝나기를 기다렸다 데이터를 보내게 된다. 반대로, 델타 보드에서 계산이 끝났을 때까지도 PC에서 샘플링이 완료되지 않으면 델타 보드는 PC에 "ready-to-get-data" 신호를 보내고 PC는 샘플링이 끝나자마자 데이터를 델타 보드에 전송하게 된다. 공구 마모 감시 한 사이클의 주기는 샘플링 주기와 샘플링되는 데이터의 숫자에 영향을 받는다. 본 실험에서 측정된 결과는 1KHz의 샘플링 주기로 한 사이클당 512개의 샘플을 취했을 경우 최대 1.6초 정도이었다. 이는 공구의 마모가 이에 비해 훨씬 긴 시간에 걸쳐 이루어지는 점진적인 과정이라는 사실을 고려할 때(통상 수분에서 수 시간 정도) 실시간 적용에도 무리가 없는 짧은 시간이라 할 수 있다.

## 6. 실험 결과에 대한 토론

공구 마모 감시 시스템을 평가하기 위하여 2회의 금속 절삭 실험이 선반에서 행하여졌다. 첫번째 실험은 공구 마모 감시 시스템을 학습시키기 위한 데이터를 수집하기 위한 것이었고 두번째는 이 시스템의 실시간 운영과 평가를 위한 것이었다. 실험에서는 4인치 지름의 AISI 4340 재질의 강봉이 Kennametal사의 TPGF-322 K68 인서트(insert) 형태의 공구를 사용하여 절삭되었다. 마모된 공구로 사용된 인서트는 새 인서트를 실험에 사용하기 전에 미리 사용하여 공구의 측면(flank face)이 마모되도록 하였으며 현미경을 사용하여 측정한 결과 마모면의 크기는 대략 1.0mm였다. 실험에 사용

된 절삭 조건은 절삭 깊이가 0.005-0.08인치(0.127-2.032mm), 이송 속도가 0.01-0.07 in/rev(0.254-1.778 mm/rev), 절삭 속도가 250-350 ft/min(76.2-106.7 m/min) 이었다.

그림 4-6은 절삭 공구가 새 것일 때와 마모된 것일 때의 전형적인 RMS(root mean square) AE, 절삭력 그리고 전류 신호를 각각 보여 준다. 처리가 되지 않은 RMS AE나 절삭력 신호도 공구 마모에 우수한 감도를 보임을 알 수 있다. 공구가 마모되었을 때 RMS AE 신호의 평균 강도가 증가하고 또 높은 주파수 성분이 상대적으로 증가하는 것을 볼 수 있었다. 이는 참고문헌 [18]에 보고된 결과와도 일치한다. 절삭력 신호는 평균치는 크게 변하지 않지만 높은 주파수 성분이 증가함을 볼 수 있었다. 반면에 스팬들 모터의 전류 신호는 절삭 공구의 상태에 크게 영향받지 않음을 알 수 있다. 전류 신호는 교류 전원의 60Hz 성분이 강하게 나타나고 공구가 마모됨에 따른 약간의 평균치의 증가를 제외하고는 그 신호 형태의 변화가 적음을 알 수 있다.

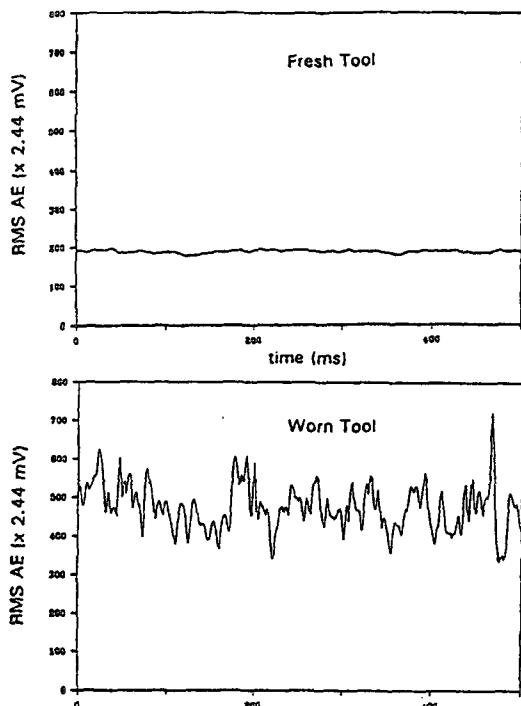


Fig. 4 새로운 공구와 마모된 공구를 사용했을 때의 RMS AE 신호. 절삭조건: 절삭속도, 350 fpm; 절삭깊이, 0.04 in.; 이송속도, 0.007 ipr.

AR 계수의 공구 상태에 대한 감도를 보기 위해 3센서로 부터의 단채널 AR 계수를 2그룹(새로운 공구와 마모된 공구)에 대해서 특징 공간(feature space)에서 도시하고 2그룹 사이의 분리도를 검사하였다(그림 7). 2그룹이 특성 공간에서 비교적 잘 분리되어서 정량적으로 AR 계수를 해석함으로써 공구 상태를 판정할 수 있음을 알 수 있다. 그러나 경계영역에서는 2그룹간의

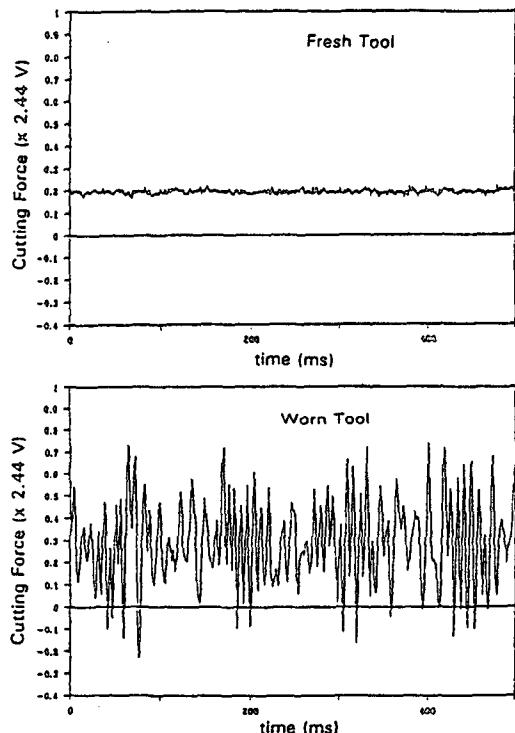
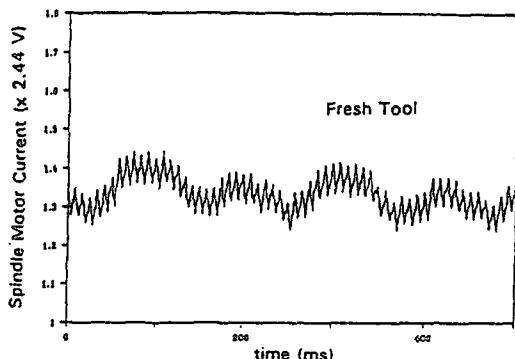


Fig. 5 새로운 공구와 마모된 공구를 사용했을 때의 절삭력 신호. 절삭조건: 절삭속도, 350 fpm; 절삭깊이, 0.04 in.; 이송속도, 0.007 ipr.



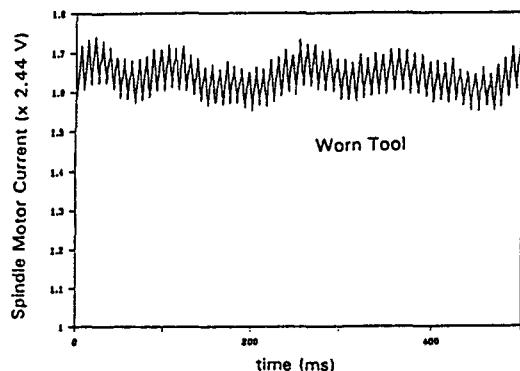


Fig. 6 새로운 공구와 마모된 공구를 사용했을 때의 스픈들 모터 전류. 절삭조건: 절삭속도, 350 fpm; 절삭깊이, 0.04 in.; 이송속도, 0.007 ipr.

겹침이 있기 때문에 경계선 근처의 영역에서는 두 군을 구분하기 어렵다. 특히 전류 신호의 경우에는 두 군이 많이 섞여 있다. 그러므로 한 개의 센서를 사용하고 선형 패턴 인식기를 사용해서는 만족할 만한 공구 상태 감시의 성능을 기대하기 어렵다. 따라서 다중 센서를 사용하고 그 센서 신호로 부터 다채널 AR 계수 행렬을 구해 이를 정보를 종합할 수 있고 비선형 패턴 인식기의 역할을 할 수 있는 3층 구조 퍼셉트론형 신경회로망의 입력으로 사용되었다. 표 1은 각각 새로운 공구를 사용했을 때와 마모된 공구를 사용했을 때 센서 신호로부터 계산된 AR 계수 행렬을 표로 정리한 것이다. 각 센서 신호의 자기상관(autocorrelation)에 관련되는 대각선 방향의 성분( $a_{11}$ ,  $a_{22}$ ) 뿐 아니라 상호상관(crosscorrelation)에 관련되는 대각선 방향외의 성분도 새 공구와 마모된 공구 사이에 큰 차이를 보임을 알 수 있다. 앞에서 언급한 바와 같은 방법으로  $J$ 를 계산했을 때 2그룹사이에 최적의 분리도를 가져오는 것은 ( $a_{11}(2)$ ,  $a_{22}(1)$ ,  $a_{21}(3)$ ,  $a_{11}(1)$ ,  $a_{11}(3)$ ,  $a_{21}(1)$ ) 세트이었으므로 모든 실험에서 이 특징의 세트(feature set)가 신경회로망에 입력벡터로 사용되었다.

뒤에 구체적인 결과로 설명될 수 있듯이 신경회로망을 이용해서 여러 센서로부터의 정보를 종합함으로써 공구 마모 감시 성능이 향상되었다. 실제로 시스템이 하나의 절삭 조건하에서 학습되고 시스템이 학습된 절삭 깊이, 이송 속도, 절삭 속도의 50~200%의 절삭 조건하에서 평가되었을 때 정인식률(correct recognition rate)은 95% 이상이었으며 같은 절삭 조건이 학습과 평가에 사용되었을 때는 훨씬 좋은 결과를 보였다. 이러

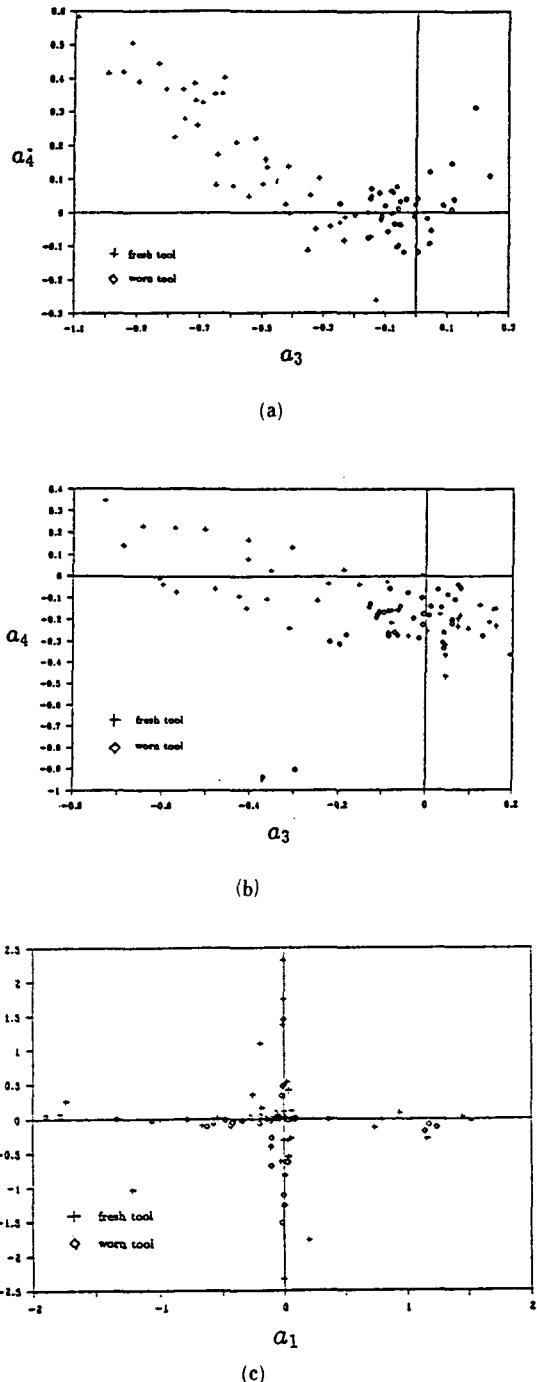


Fig. 7 RMS AE 신호 (a), 절삭력 신호 (b), 그리고 전류 신호 (c)에 의한 AR 계수의 2그룹(새 공구와 마모된 공구)에 대한 분리도. 절삭조건: 절삭속도, 250~350 fpm; 절삭깊이, 0.005~0.08 in.; 이송속도, 0.004~0.01 ipr;

Table 1. 새로운 공구 (a)를 사용했을 때와 마모된 공구 (b)를 사용했을 때 센서 신호로부터 계산된 AR 계수 행렬. 절삭조건: 절삭속도, 250-350 fpm; 절삭깊이, 0.02-0.06in.; 이송속도, 0.004-0.01 ipr; 센서 조합, RMS AE+force; 신호처리 방법, 7th order 2 ch. AR; 샘플의 수, 512.

	$a_{11}(x)$		$a_{12}(x)$		$a_{21}(x)$		$a_{22}(x)$	
	mean	std. dev.						
A <sub>11</sub> , (1)	-0.928340	0.261238	-0.022094	0.049240	0.316135	0.232237	-0.366868	0.094736
A <sub>11</sub> , (2)	0.090204	0.233537	0.114028	0.036749	-0.047512	0.375932	0.068259	0.075488
A <sub>11</sub> , (3)	-0.012559	0.040433	-0.043969	0.026511	-0.440779	0.364739	-0.036403	0.044885
A <sub>11</sub> , (4)	0.003572	0.037760	-0.103384	0.045574	-0.412492	0.357541	-0.159190	0.052351
A <sub>11</sub> , (5)	0.024134	0.038682	0.009801	0.074435	0.163601	0.262322	0.011854	0.020982
A <sub>11</sub> , (6)	0.029460	0.029769	-0.032995	0.013667	0.064580	0.173366	-0.050422	0.020921
A <sub>11</sub> , (7)	-0.026428	0.023950	-0.032995	0.013667	0.064580	0.173366	-0.050442	0.020921

	$a_{11}(x)$		$a_{12}(x)$		$a_{21}(x)$		$a_{22}(x)$	
	mean	std. dev.						
A <sub>21</sub> , (1)	-1.546516	0.300210	0.121548	0.087703	-0.683381	0.415407	-1.109775	0.249590
A <sub>21</sub> , (2)	1.012368	0.218994	-0.130371	0.122933	0.251499	0.541007	0.725152	0.190638
A <sub>21</sub> , (3)	-0.315251	0.121748	0.027993	0.073696	0.935547	0.413403	-0.117039	0.123711
A <sub>21</sub> , (4)	0.051784	0.085442	-0.069901	0.058823	-0.945381	0.351181	-0.132764	0.065021
A <sub>21</sub> , (5)	-0.029258	0.040872	0.025929	0.013745	0.706437	0.331800	0.092737	0.051009
A <sub>21</sub> , (6)	0.033704	0.046916	-0.034317	0.035688	-0.579266	0.393904	-0.060372	0.043081
A <sub>21</sub> , (7)	-0.033376	0.024225	-0.023933	0.024176	0.182669	0.138497	0.001391	0.028311

한 결과는 신경회로망을 사용한 센서 융합(sensor fusion)의 장점을 보여 준다.

신경회로망에서 반복 학습이 계속됨에 따른 출력 오차 수렴의 예가 그림 8에 나타나 있다. 학습에서는 새로운 공구에 의한 네트워크의 출력값으로 0.1, 마모된 공구에 의한 네트워크의 출력값으로 0.9, 그리고 의사 결정(decision making)을 위한 네트워크 출력의 임계값(threshold value)을 0.5로 각각 설정하여 실제 운전에서 네트워크의 출력값이 0.5이하이면 새 공구로, 그리고 0.5이상이면 마모된 공구로 판정하도록 하였다. 이는 뉴런의 입출력 관계를 모사하는 지그모이드 함수가 "0", 또는 "1"의 출력값을 포화(saturation)로 인하여 갖을 수 없기 때문이다. 그림 8에서 학습이 시작될 때는 네트워크로 부터의 출력이 목표치와 많은 차이를 보인다. 그러나 네트워크의 반복 학습이 진행되면서 학습 샘플의 입력/출력 관계를 모사(simulation)하게 됨에 따라 출력은 목표치에 천천히 부드럽게 수렴하는 것을 볼 수 있다. 그림 9는 실시간 운전 이전의 학습과정에

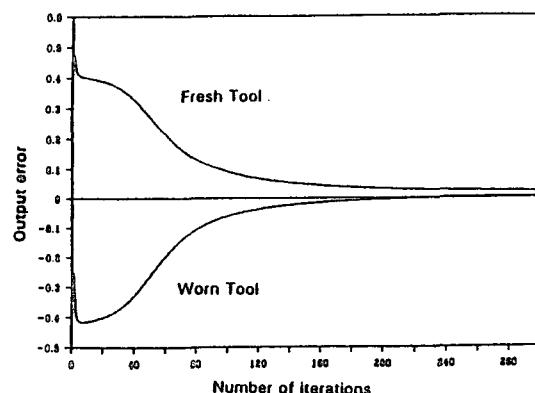


Fig. 8 학습과정에서 3층 퍼셉트론의 출력 오차의 수렴  
서 네트워크의 가중치와 임계치가 어떻게 수렴하는지를  
보여 준다. 학습이 시작되기 전에 모든 가중치와 임계  
치는 균일하게 분포된 난수로 초기화되고 역전달법에  
의해서 조정된다. 학습과정에서 가중치와 임계치의 초기  
치는 수렴 여부와 수렴 속도에 큰 영향을 미친다. 가중  
치와 임계치의 초기값으로 사용될 난수의 범위는 입력

신호에 의해 신경회로망의 지그모이드 함수가 포화상태에 이르지 않도록 신중히 선택되어야 한다. 그럼 10과 11은 가중치와 임계치의 초기값을 위한 난수의 범위가 어떻게 출력 오차의 수렴에 영향을 미치는지를 보여 준다. 네트워크로의 입력이나 출력의 크기가 모두 1범위 내에 있으므로 가중치와 임계치의 초기값 범위를 1로 설정했을 때 문제를 일으키지 않고 우수한 성능을 보였다. 그림 12는 학습률(learning rate),  $\eta$ 의 출력 오차 수렴에 대한 영향을 보여준다. 빠른 수렴을 위해서는 큰 학습률이 사용되어야 하지만 너무 큰 숫자는  $\eta = 2.0$  경우에서 보는 것처럼 큰 오프셋(off set)을 가져올 수 있다.

표 2에서는 네트워크로의 입력의 숫자에 따른 효과가 나타나 있다. 실험에서 입력 특징의 크기가 2에서 6일 때 정인식률에 큰 변화가 없었으나 그 이상으로 증가시키면 오히려 나쁜 결과를 가져왔다. 표 3은 공구 마모 감시 시스템의 성능이 은닉층의 노드 숫자에 따라 어떻게 변하는지를 보여 준다. 은닉층 노드 숫자 변화에 따른 정인식률의 큰 변화는 없었으나 은닉층 노드의 숫자가 6개 이상이면 오히려 성능의 열화를 가져왔다.

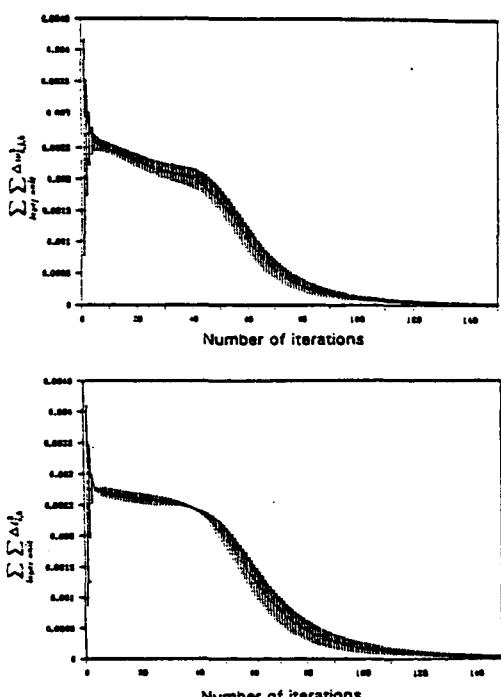


Fig. 9 학습과정에서 3층 퍼셉트론 파라메터(가중치, 가중치)의 수렴

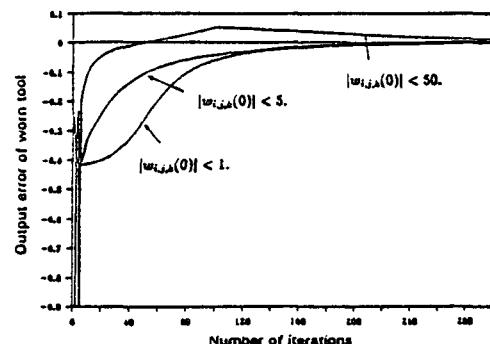


Fig. 10 학습에서 가중치 초기값 3층 퍼셉트론의 출력 오차 수렴에 대한 영향

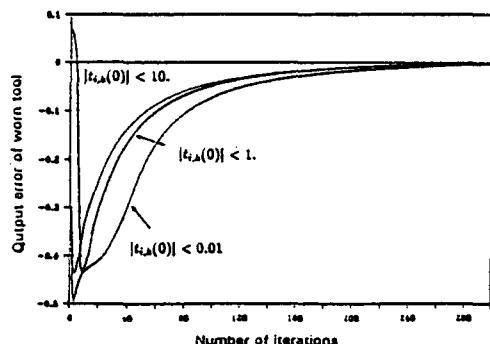


Fig. 11 학습에서 임계치의 초기값의 3층 퍼셉트론의 출력 오차 수렴에 대한 영향

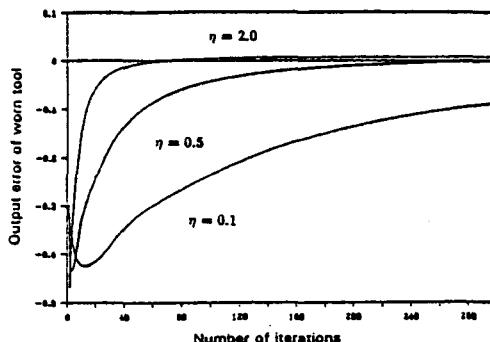


Fig. 12 학습에서 학습률의 3층 퍼셉트론의 출력 오차 수렴에 대한 영향

이러한 결과들로 부터 큰 크기의 입력과 많은 숫자의 은닉층 노드를 갖는 큰 크기의 네트워크는 이 연구에서와 같이 비교적 간단한 입력/출력의 맵핑(mapping) 관계를 모사(simulation)하는 데에는 적절하지 않다는 것을 알 수 있다. 감시 시스템의 성능이 네트워크의 크기에 따라 크게 변화하지 않는다면 작은 크기의 네트워크가 효율성이라는 측면에서 바람직하다. 실제로 6-4-

1 네트워크(6개의 입력 노드, 4개의 중간 노드, 1개의 출력 노드를 갖는 3층 네트워크)로도 적절한 성능을 얻을 수 있었고 그 이상으로 네트워크를 크게 해도 큰 성능의 향상을 가져올 수 없었다. 따라서 6-4-1 네트워크가 본 연구에서 사용되었다.

Table 2. 감시 시스템의 성능에 대한 네트워크로의 입력 숫자의 영향. 학습에서의 절삭조건: 절삭속도, 350 fpm; 절삭깊이, 0.04in.; 이송속도, 0.007 ipr. 실제 평가에서의 절삭조건: 절삭속도, 250-350 fpm; 절삭깊이, 0.02-0.066 in.; 이송속도, 0.004-0.01 ipr; 센서 조합, RMS AE+force; 신호처리 방법, 7th order 2 ch. AR; 샘플의 수, 512.

Input Feature Dimension	2	4	6	8	10
정인식 횟수/총시행 횟수	371/400	379/400	387/400	329/400	291/400

Table 3. 감시 시스템의 성능에 대한 중간층 노드 숫자의 영향. 학습에서의 절삭조건: 절삭속도, 350 fpm; 절삭깊이, 0.04in.; 이송속도, 0.007 ipr. 실제 평가에서의 절삭조건: 절삭속도, 250-350 fpm; 절삭깊이, 0.02-0.066 in.; 이송속도, 0.004-0.01 ipr; 센서 조합, RMS AE+force; 신호처리 방법, 7th order 2 ch. AR; 샘플의 수, 512.

Number of Hidden Units	2	4	6	8	10
정인식 횟수/총시행 횟수	376/400	387/400	386/400	380/400	363/400

감시 시스템이 효과적으로 사용될 수 있는 절삭조건의 범위를 결정하기 위해서 여러 절삭 조건하에서 시스템의 성능을 테스트한 결과가 표 4-6에 나타나 있다. 일반적으로 심한 절삭 조건하에서 더 우수한 성능을 보임을 알 수 있다. 또, 학습과 실제 운전에서 같은 절삭조건이 사용된다면 깊은 범위의 절삭 조건에 걸쳐 우수한 성능을 보였으나, 네트워크가 하나의 절삭 조건하에서 학습되고 여러 다른 절삭 조건하에서 운전되었을 때 정인식률은 운전에서 사용된 절삭 조건의 범위가 증가함에 따라 약간 낮아졌다. 그러나 표 7에서 보는 것처럼 실제 운전중 있을 수 있는 여러 절삭 조건하에서 얻어진 샘플들로 네트워크를 학습시킴으로써 변하는 절삭조건 하에서의 절삭에 대해서도 우수한 성능을 얻을 수 있다.

표 8은 3센서중에 2개 센서의 각종 조합이 입력으로 사용되고 2채널 AR 모델이 신호처리방법으로 사용됐을 때 감시 시스템의 성능을 보여 준다. 그림 4-6의 시간 영역 신호에서 예측할 수 있는 것처럼 AE-절삭력 조합이 가장 우수한 성능을 나타냈다. 3개 다른 신호처리방

Table 4. 같은 절삭 조건하에서 학습과 평가가 이루어졌을 때 여러 절삭 깊이에 대한 감시 시스템의 성능. 학습과 평가에서의 절삭조건: 절삭속도, 350 fpm; 절삭깊이, 0.005-0.08in.; 이송속도, 0.007 ipr; 센서 조합, RMS AE+force; 신호처리 방법, 7th order 2 ch. AR; 샘플의 수, 512.

Depth of Cut (in)	0.005	0.01	0.02	0.04	0.06	0.08
정인식 횟수/총시행 횟수	184/200	193/200	200/200	197/200	200/200	200/200

Table 5. 같은 절삭 조건하에서 학습과 평가가 이루어졌을 때 여러 절삭 깊이에 대한 감시 시스템의 성능. 학습과 평가에서의 절삭조건: 절삭속도, 350 fpm; 절삭깊이, 0.04in.; 이송속도, 0.004-0.01 ipr; 센서 조합, RMS AE+force; 신호처리 방법, 7th order 2 ch. AR; 샘플의 수, 512.

Feed Rate (in/rev)	0.001	0.004	0.007
정인식 횟수/총시행 횟수	196/200	200/200	200/200

Table 6. 같은 절삭 조건하에서 학습과 평가가 이루어졌을 때 여러 절삭 깊이에 대한 감시 시스템의 성능. 학습과 평가에서의 절삭조건: 절삭속도, 250-350 fpm; 절삭깊이, 0.04in.; 이송속도, 0.007 ipr; 센서 조합, RMS AE+force; 신호처리 방법, 7th order 2 ch. AR; 샘플의 수, 512.

Cutting Speed (ft/min)	250	350
정인식 횟수/총시행 횟수	200/200	200/200

Table 7. 학습에서의 절삭 조건의 숫자에 따른 감시 시스템의 성능의 변화. 학습과 평가에서의 절삭조건: 절삭속도, 250-350 fpm; 절삭깊이, 0.02-0.04in.; 이송속도, 0.004-0.01 ipr.; 실제 평가에서의 절삭조건: 절삭속도, 250-350 fpm; 절삭깊이, 0.02-0.06 in.; 이송속도, 0.004-0.01 ipr; 센서 조합, RMS AE+force; 신호처리 방법, 7th order 2 ch. AR; 샘플의 수, 512.

Number of Cutting Conditions for Training	1	3	5
정인식 횟수/총시행 횟수	191/200	198/200	200/200

Table 8. 여러 센서 조합하에서의 감지 시스템의 성능. 학습에서의 절삭조건: 절삭속도, 250-350 fpm; 절삭깊이, 0.02-0.04in.; 이송속도, 0.004-0.01 ipr.; 실제 평가에서의 절삭조건: 절삭속도, 250-350 fpm; 절삭깊이, 0.02-0.06 in.; 이송속도, 0.004-0.01 ipr; 신호처리 방법, 7th order 2 ch. AR; 샘플의 수, 512.

Sensor Combination	RMS AE + Force	Force + Current	RMS AE + Current
정인식 횟수/총시행 횟수	392/400	294/400	249/400

법(7차 2채널 AR 모델, 3차 3채널 AR 모델, 밴드 평균 파워 스펙트럼 밀도)을 사용한 데 따른 성능의 변화가 표 9에 나타나 있다. 밴드 평균 파워 스펙트럼 밀도 방법의 성능은 다채널 AR 모델보다 낮음을 알 수 있다. 이는 각 주파수 벤드별로 평균된 파워 스펙트럼 밀도가 네트워크에서 포화(saturation)가 일어나지 않는 동작의 범위를 쉽게 벗어나기 때문에 학습과정중 국지적인 평형점(local equilibrium)으로 수렴하는 경향 때문이다. 따라서, 이 경우 절삭 공작의 정확한 임/출력 관계를 모사할 수 없게 된다. 반면에 다채널 AR 시리즈 모델을 사용했을 때 넓은 절삭조건에 걸쳐서 95% 이상의 우수한 정인식률을 보였다. 표 10은 샘플 숫자의 감시 성능에 대한 영향을 보인다. 성능이 샘플의 숫자의 증가에 따라 현저하게 좋아지지 않음을 알 수 있다. 따라서 512 혹은 256 샘플이 1024 혹은 더 많은 샘플보다 효율성의 측면에서 실제 응용에 더 적합하다.

마지막으로, 표 11은 한 감시 사이클당 소요되는 시간을 각각의 신호처리 방법에 대하여 나타내고 있다. AR 모델의 차수와 채널의 수가 증가함에 따라 소요시간도 따라서 증가하는데 본 연구에서 행해진 실험에서는 최대 1.6초가 소요되었는데 이는 앞에서도 언급한 바와 같이 공구의 마모 감시를 위해서는 충분히 짧은 시간으로 실시간 응용에 있어서 별 문제가 되지 않는다. 그러나 DACA 보드보다 빠른 속도의 A/D 컨버터를 사용함으로써, 또 AR 계수행렬을 구하는데 블럭처리방법(blockwise processing method) 대신 적응처리방법(adaptive processing method)을 사용함으로써 한 감시 사이클당 소요시간을 단축할 수 있을 것이며, 또한 요즘 많은 연구가 진행되고 있는 하드웨어로 구현된 신경회로망(neural network chip)을 사용한다면 소프트웨어로 모사(simulation) 하는 것에 비해서 학습과 패턴인식에 소요되는 시간을 대폭 줄일 수 있을 것이다.

## 7. 결 론

이 연구에서는 선삭가공을 위한 실시간 공구 마모 감시 시스템의 구조를 개발하고 그 성능을 평가하였다. 본 연구로 부터 다음과 같은 결론들을 도출할 수 있다.

- (1) 다채널 AR 모델과 인공 신경회로망(다중 퍼셉트론)을 사용해서 공구의 상태에 따라 출력이 변화하는 다중 센서 신호의 특징을 학습시킴으로써 공구 마모

Table 9. 신호처리 방법에 따른 감지 시스템의 성능. 학습에서의 절삭조건: 절삭속도, 350 fpm; 절삭깊이, 0.04in.; 이송속도, 0.007 ipr. 실제 평가에서의 절삭조건: 절삭속도, 250-350 fpm; 절삭깊이, 0.02-0.06 in.; 이송속도, 0.004-0.01 ipr; 센서 조합, RMS AE+force; 샘플의 수, 512.

Signal Processing Method	7th Order 2 Ch. AR	3rd Order 3 Ch. AR	FFT
정인식 횟수/총시행 횟수	392/400	294/400	249/400

Table 10. 샘플 숫자의 감지 시스템의 성능에 대한 영향. 학습과 평가에서의 절삭조건: 절삭속도, 350 fpm; 절삭깊이, 0.04in.; 이송속도, 0.007 ipr. 실제 평가에서의 절삭조건: 절삭속도, 250-350 fpm; 절삭깊이, 0.02-0.06 in.; 이송속도, 0.004-0.01 ipr; 센서 조합, RMS AE+force; 신호처리 방법, 7th order 2 ch. AR; 샘플의 수, 512.

Number of Samples	256	512	1024
정인식 횟수/총시행 횟수	752/800	759/800	760/800

Table 11. 한 감시 사이클당 소요시간. 샘플의 수=512.

Signal Processing Method	One Detection Cycle
7th order 2 Ch AR	1.60 sec
5th order 2 Ch AR	1.27 sec
3th order 2 Ch AR	0.98 sec
3th order 3 Ch AR	1.45 sec
Power Spectrum	1.15 sec

의 효과적인 감시가 가능함이 입증되었다. 미세한 마모를 감지하는데 있어서 감시 시스템의 신뢰도는 훨씬 낮을 것으로 예전되지만 새로운 공구와 비교적 큰 1mm의 측면 마모(flank wear)를 가진 공구로부터의 신호를 분리하는데 제안된 공구 마모 감시 시스템은 90% 이상의 신뢰도를 보였다.

- (2) 제안된 공구 마모 감시 시스템은 신경회로망의 일반화(generalization) 특성 때문에 절삭조건의 변화에 대한 감도가 낮아서 단 하나의 절삭조건 하에서 학습되었어도 넓은 절삭조건 하에서 운전하는 것이 가능하였다. 이러한 특성은 간접적 공구 마모 감시 방법들을 실용화하는데 가장 큰 장애점인 실제 현장에서의 보정 시간을 크게 단축하는 것을 가능하게 한다.
- (3) 신경회로망의 여러가지 파라미터들을 공구 마모 감시 시스템을 최적의 성능과 효율 하에서 작동시키기 위해서 잘 설정되어야 한다. 선삭에서는 비교적 작

은 크기의 신경회로망이 공구 마모 감시의 목적으로 사용될 수 있는 것으로 판명되었다.

- (4) 이러한 실시간 공구 마모 감시 시스템을 공장 환경에 실제로 적용하기 위하여는 보다 다양한 절삭 공구(재질 및 형상)와 공작물 그리고 좀 더 광범위한 조건하에서의 평가가 선행되어야 할 것이다.

### 참고문헌

1. Tlusty, J., and Andrews, G., "A Critical Review of Sensors for Unmanned Machining", *Annals of the CIRP*, Vol. 32, 1983, pp. 563~572.
2. Wright, P., and Bourne, D., "Manufacturing Intelligence", Addison-Wesley, 1988.
3. Eversheim, W., Koenig, W., Weck, M., and Pfeifer, F., "Tagungsband des AWK, 1984", Aachener Werkzeugmaschinen Kolloquium.
4. Shiraishi, M., "Notes on In-Process Measurement, Monitoring and Control Techniques", 1987.
5. Shiraishi, M., "Scope of In-Process Measurement, Monitoring and Control Techniques in Machining Process-Part 1: In-Process Techniques for Tools", *Precision Engineering*, Vol. 10, No. 4, Oct, 1988, pp. 178~189.
6. Iwata, K., and Moriwaki, T., "An Application of Acoustic Emission to In-Process Sensing of Tool Wear", *Annals of CIRP*, 26, 1, 1977, pp. 21~26.
7. Inasaki, I., Aida, S., and Fukuoka, S., "Monitoring System for Cutting Tool Failure Using an Acoustic Emission Sensor", *JSME International Journal*, Vol. 30, No. 261, 1987.
8. Liang, S., and Dornfeld, D., "Detection of Cutting Tool Wear using Adaptive Time-Series Modeling of Acoustic Emission Signals", *Sensors for Manufacturing*, M.K. Tse and D.A. Dornfeld Eds., ASME, New York, 1987, pp. 27~38.
9. Rangwala S. S., "Machining Process Characterization and Intelligent Tool Condition Monitoring using Acoustic Emission Signal Analysis", Ph.D Thesis, Dept. of Mech. Engg., University of California, Berkeley, CA, Nov. 1988.
10. Strand, O., "Multichannel Complex Maximum Entropy (Autoregressive) Spectral Analysis", *IEEE Trans. Autom. Control*, Vol. AC-22, Aug. 1977, pp. 634~640.
11. Jones, R., "Identification and Autoregressive Specturm Estimation", *IEEE Trans. Autom. Control*, Vol. AC-19, Dec. 1974, pp. 894~897.
12. Robinson, E., "Multichannel Time Series Analysis", 2nd. Ed., Goose Pond Press, Houston, TX., 1983.
13. Whitney, A., "A Direct Method of Non-parametric Measurement Selection", *IEEE Transactions on Computers*, Vol. 20, 1971, pp. 1100~1103.
14. Chryssolouris, G., and Domroese, M., "Sensor Integration for Tool Wear Estimation in Machining", *Sensors and Controls for Manufacturing*, E. Kannatey-Asibu Jr., Y. Koren, and J.L. Stein Eds., ASME, New York, 1988, pp. 115~123.
15. Will, C.R., "Review of the DARPA Neural Network Study", *Neural Network Review*, Vol. 2, No. 3, 1988, pp. 74~102.
16. Rumelhart, D., and McClelland, J., "Parallel Distributed Processing, Volume 1", MIT Press, Cambridge, MA, 1986.
17. Choi, Gi S., "Monitoring and Control of Machining Processes Using neural Network", Ph.D Thesis, Department of Mechanical Engineering, University of California, Berkeley, May, 1990.
18. E.Emel, and E.Kannatey-Asibu Jr., "Acoustic Emission Monitoring of the Cutting Process Negating the Influence of Varying Conditions", *Trans. ASME, J. Eng. Ind.*, Vol. 103, No. 3, 1990, pp. 330~340.