

## AE 신호 및 신경회로망을 이용한 공작기계 주축용 베어링 결함검출

정 의 식\*, 황 준\*\*

Detection of Main Spindle Bearing Defects in Machine Tool by  
Acoustic Emission Signal via Neural Network Methodology

Eui-Sik Chung\*, Joon Hwang\*\*

### Abstract

This paper presents a method of detecting localized defects on tapered roller bearing in main spindle of machine tool system. The feature vectors, i.e. statistical parameters, in time-domain analysis technique have been calculated to extract useful features from acoustic emission signals. These feature vectors are used as the input feature of an neural network to classify and detect bearing defects. As a results, the detection of bearing defect conditions could be sucessfully performed by using an neural network with statistical parameters of acoustic emission signals.

Keywords : acoustic emission signal (음향방출신호), neural network (신경회로망), bearing defect detection (베어링결함검출), tapered roller bearing (테이퍼로울러베어링), feature vectors (특징벡터), statistical parameters (통계매개변수), time-domain analysis techniques (시간영역 해석기법)

### 1. 서 론

공작기계가 고속화되고, 그 주변시스템이 거대화, 복잡화됨에 따라, 시스템 구성요소에 대한 개개의 고장이나 결함은 공작기계 시스템의 전반에 걸친 기능정지를 초래하여 생산에 커다란 차질을 가져올 뿐만아니라, 제품의 경

밀도에 직접적인 영향을 미치게 된다. 이 경우, 개개의 고장을 조기에 발견하고, 과혹한 조건에서도 엄밀한 정밀도가 요구되는 공작기계 주축용 베어링의 고장 및 결함검출에 대한 문제점 해결은 당면한 중요한 과제로 되고 있다.

베어링 고장진단에 관한 연구동향을 살펴보면, McFadden<sup>(1)</sup>, Darlow<sup>(2)</sup>, Drago<sup>(3)</sup>등은 공진주파수의

\* 대전산업대학교 기계설계 공학과

\*\* 충주산업대학교 기계설계학과

파-크 부근의 가속도 신호만을 대역필터에 통과시키는 HFRT(high frequency resonance technique) 기법을 볼베어링의 검출에 적용하였으며, Kovarskii<sup>(1)</sup> 등은 충격 임펄스진단법에 의한 볼베어링의 초기손상 검출방법을 제안하였다. 또한, Nishimoto<sup>(5)</sup> 등은 베어링 결함의 초기 진단에 있어서 AE신호사용의 유용성을 검토하였고, Balderston<sup>(6)</sup>은 공진 주파수 부근의 유효진폭 (r.m.s amplitude) 및 HFRT 기법에 대한 유용성 검토와 함께, AE신호를 이용한 결합검출방법을 제안하였다. 또한, Smith는 포락검파신호의 파고율(crest factor) 해석기법을 이용한 검출방법을 제안하였으며, Dyer<sup>(7)</sup> 등은 베어링 결합상태의 평가지표로서 첨도 (kurtosis)의 유용함을 입증하였다. 특히, 최근에는 Li 와 Wu<sup>(8)</sup> 가 패턴인식기법을, 그리고 Liu 와 Mengel<sup>(9)</sup> 이 인공신경회로망을 이용하여 결합정보의 통합화를 위한 온라인 베어링 감시기법을 제안하였다. 그러나, 이들 대부분의 연구에서는, 결합신호의 검출을 위하여 가속도 센서를 사용하고 있으며, 운전조건이 비교적 안정된 상태에서 정하중을 받고 있는 소형 회전 볼베어링을 대상으로 베어링 결함의 유무상태만을 판정하기 위한 결합 검출방법을 검토한 것으로, 운전 조건이 비교적 가혹한 상태에서 결합상태를 분류하여 평가할 수 있는 베어링 진단 및 결합 검출방법에 대한 연구는 거의 없는 실정이다. 또한, AE(acoustic emission)는 고체가 소성변형, 크랙(crack)의 발생과 성장, 변형 등과 같은 조직 혹은 구조변화를 일으켰을 때 고체내부에 축적된 변형에너지의 일부를 탄성파의 형태로서 방출하는 것으로, 이는 베어링이나 치차 등과 같은 기계부품의 이상 검출에 매우 유용하게 이용될 수 있을 것으로 생각된다.

본 연구에서는 기계가공시 공작물의 가공정밀도에 직접적인 영향을 미치는 공작기계 주축용 베어링의 결함을 검출하기 위하여, 선반의 주축대 모델을 이용하고, 주축용 베어링으로 널리 사용되고 있는 테이퍼 로울러 베어링 (#32017XJ)의 로울러부에 로크웰 경도시험기에 의한 점 결함(point defect)과 부식(etching defect)에 의한 박리현상(flaking)과 같은 인위적인 결함을 주었을 때, 베어링 회전속도와 결합상태에 따라 측정한 AE신호에 포함되어 있는 결함의 특징을 시간영역에서 통계파라메터로 추출하고, 추출된 특징벡터를 신경회로망(neural network)의 학습에 의한 패턴인식을 통해, 베어링 결합상태를 분류, 검지할 수 있는 방안을 제시하고자 한다.

## 2. 실험장치 및 신호처리방법

베어링 결합검출을 위해 구성한 실험장치를 Fig.1과 같이 구성하였으며, 실험에 사용된 장비들은 Table 1에 그 자세한 사양을 나타내었다. 실험에서, 선반의 주축대 모델은 (주) 남선정공 NSL400x750S를 사용하였으며, 인버터(SV015GS-2)를 이용하여 베어링의 회전속도를 변환하였다. 또한, 매 결합시험시마다 발생하는 주축의 회전 불균형을 최소화하기 위하여 간극센서(gap detector)와 다이얼 케이지를 이용하여 허용범위 0.001mm 이내로 동심도를 유지하고, 베어링의 결합특성이 AE신호에 잘 반영되도록 하기 위하여 예하중을 변경실험한 결과, 본 연구에서는 시험용 베어링(#32017XJ)에 7~9kg-m의 예하중을 잠금너트를 이용하여 베어링의 축방향으로 가하였다. 800rpm의 회전속도로 10분간 공회전 후 Table 2와 같은 실험조건에서 결합검출 실험을 행하였다. 한편, Photo.1에는 실험에 사용한 베어링의 결합상태를 나타낸다.

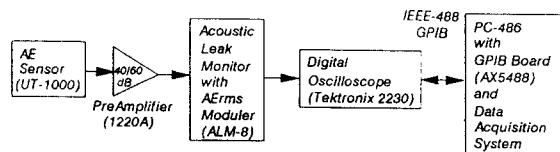


Fig.1 Schematic diagram of experimental set-up for bearing defect detection

Table 1 Specification of experimental instruments

Instruments	Model	Maker
Bearing	32017XJ	Namsun Precision Machinery
AE sensor	UT-1000 (60~1000kHz)	Physical Acoustic
Pre-amplifier	1220A	Physical Acoustic
Acoustic leak monitor	ALM-8	Physical Acoustic
Oscilloscope	Type 2230	Tektronix
GPIB board	AX5488	Samsung
Gap detector	VT120	Onosokki

파-크 부근의 가속도 신호만을 대역필터에 통과시키는 HFRT(high frequency resonance technique) 기법을 볼베어링의 검출에 적용하였으며, Kovarskii<sup>(1)</sup> 등은 충격 임펄스진단법에 의한 볼베어링의 초기손상 검출방법을 제안하였다. 또한, Nishimoto<sup>(5)</sup> 등은 베어링 결함의 초기 진단에 있어서 AE신호사용의 유용성을 검토하였고, Balderston<sup>(6)</sup>은 공진 주파수 부근의 유효진폭 (r.m.s amplitude) 및 HFRT 기법에 대한 유용성 검토와 함께, AE신호를 이용한 결합검출방법을 제안하였다. 또한, Smith는 포락검파신호의 파고율(crest factor) 해석기법을 이용한 검출방법을 제안하였으며, Dyer<sup>(7)</sup> 등은 베어링 결합상태의 평가지표로서 첨도 (kurtosis)의 유용함을 입증하였다. 특히, 최근에는 Li 와 Wu<sup>(8)</sup> 가 패턴인식기법을, 그리고 Liu 와 Mengel<sup>(9)</sup> 이 인공신경회로망을 이용하여 결합정보의 통합화를 위한 온라인 베어링 감시기법을 제안하였다. 그러나, 이들 대부분의 연구에서는, 결합신호의 검출을 위하여 가속도 센서를 사용하고 있으며, 운전조건이 비교적 안정된 상태에서 정하중을 받고 있는 소형 회전 볼베어링을 대상으로 베어링 결함의 유무상태만을 판정하기 위한 결합 검출방법을 검토한 것으로, 운전 조건이 비교적 가혹한 상태에서 결합상태를 분류하여 평가할 수 있는 베어링 진단 및 결합 검출방법에 대한 연구는 거의 없는 실정이다. 또한, AE(acoustic emission)는 고체가 소성변형, 크랙(crack)의 발생과 성장, 변형 등과 같은 조직 혹은 구조변화를 일으켰을 때 고체내부에 축적된 변형에너지의 일부를 탄성파의 형태로서 방출하는 것으로, 이는 베어링이나 치차 등과 같은 기계부품의 이상 검출에 매우 유용하게 이용될 수 있을 것으로 생각된다.

본 연구에서는 기계가공시 공작물의 가공정밀도에 직접적인 영향을 미치는 공작기계 주축용 베어링의 결함을 검출하기 위하여, 선반의 주축대 모델을 이용하고, 주축용 베어링으로 널리 사용되고 있는 테이퍼 로울러 베어링 (#32017XJ)의 로울러부에 로크웰 경도시험기에 의한 점 결함(point defect)과 부식(etching defect)에 의한 박리현상(flaking)과 같은 인위적인 결함을 주었을 때, 베어링 회전속도와 결합상태에 따라 측정한 AE신호에 포함되어 있는 결함의 특징을 시간영역에서 통계파라메터로 추출하고, 추출된 특징벡터를 신경회로망(neural network)의 학습에 의한 패턴인식을 통해, 베어링 결합상태를 분류, 검지할 수 있는 방안을 제시하고자 한다.

## 2. 실험장치 및 신호처리방법

베어링 결합검출을 위해 구성한 실험장치를 Fig.1과 같이 구성하였으며, 실험에 사용된 장비들은 Table 1에 그 자세한 사양을 나타내었다. 실험에서, 선반의 주축대 모델은 (주) 남선정공 NSL400x750S를 사용하였으며, 인버터(SV015GS-2)를 이용하여 베어링의 회전속도를 변환하였다. 또한, 매 결합시험시마다 발생하는 주축의 회전 불균형을 최소화하기 위하여 간극센서(gap detector)와 다이얼 케이지를 이용하여 허용범위 0.001mm 이내로 동심도를 유지하고, 베어링의 결합특성이 AE신호에 잘 반영되도록 하기 위하여 예하중을 변경실험한 결과, 본 연구에서는 시험용 베어링(#32017XJ)에 7~9kg-m의 예하중을 잠금너트를 이용하여 베어링의 축방향으로 가하였다. 800rpm의 회전속도로 10분간 공회전 후 Table 2와 같은 실험조건에서 결합검출 실험을 행하였다. 한편, Photo.1에는 실험에 사용한 베어링의 결합상태를 나타낸다.

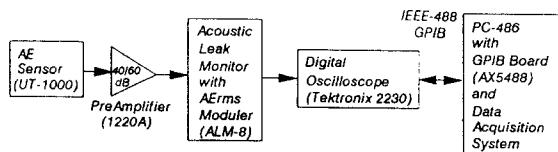


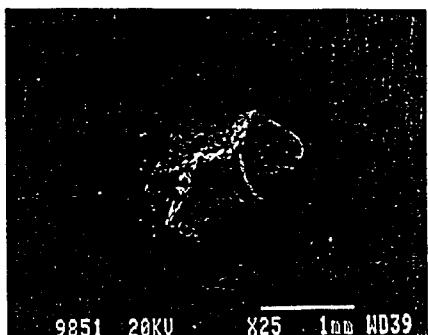
Fig.1 Schematic diagram of experimental set-up for bearing defect detection

Table 1 Specification of experimental instruments

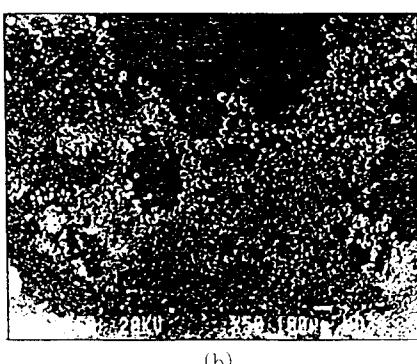
Instruments	Model	Maker
Bearing	32017XJ	Namsun Precision Machinery
AE sensor	UT-1000 (60~1000kHz)	Physical Acoustic
Pre-amplifier	1220A	Physical Acoustic
Acoustic leak monitor	ALM-8	Physical Acoustic
Oscilloscope	Type 2230	Tektronix
GPIB board	AX5488	Samsung
Gap detector	VT120	Onosokki

Table 2 Experimental conditions of bearing defect detection

damage types of tapered roller bearing	1) normal bearing 2) point defect 3) etching defect
main spindle speed	600, 900, 1200, 1500, 1800 rpm
preload	axial torque : 7, 8, 9 kg·m



(a)



(b)

Photo.1 Photographs of Point defect bearing(a), and Etching defect bearing(b)

또한, 시험용 베어링에서 가장 가까운 위치의 베어링 하우징에 축방향으로 고정설치한 AE센서에서 검출된 신호는 Fig.1에 나타낸 바와 같이, 증폭기와 음향방출기의 RMS(root mean square)모듈을 거쳐 디지털 오실로스코프로 보내어져 베어링의 각각의 결함상태에 따른 신호의 변화특성을 파악한 후, 디지털 오실로스코프의 샘플러

기능을 이용하여 0.5ms로 샘플링하여 GPIB 보드를 통해 컴퓨터로 전송함으로서, Fig.2와 같이 특징벡터 추출 및 신경회로망을 이용한 학습등에 필요한 데이터처리를 수행하였다.

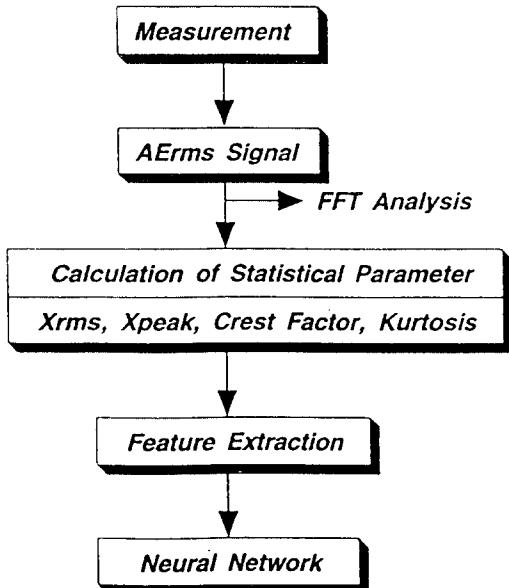


Fig.2 Schematic diagram of signal processing flow

이상의 실험장치 및 신호처리방법을 이용하여, 베어링의 결함상태에 따라 검출된 AErms 신호의 대표적인 일례를 Fig.3에 나타내었다. 그림에서 알 수 있는 바와같이, 정상 베어링의 경우, AErms의 진폭크기는 결합베어링에 비하여 작은값을 나타내며, 결합 베어링의 경우에는, 정상 베어링에 비하여 진폭이 크게 증가하며, 점결합에 비하여 부식결합에서 AErms 신호의 에너지 레벨이 더욱 크게 증대하고 있다. 이는 점결합의 경우 결합부위의 크기가 부식결합에 비하여 매우 작은 국부적결합으로 존재하고 있기 때문으로 생각된다(Photo.1). 또한, 결합베어링에 의해 발생되는 주기적인 충격력은 시간에 따라 변화하고 있으며, 신호의 퍼-크 진폭과 주파수 성분이 변동이 심하기 때문에 포락검파처리기법<sup>(1,10)</sup>을 이용한 시간 영역에서의 해석기법이 신호처리 시간의 단축 차원에서도 베어링 결함상태를 온-라인으로 검출하는데 더욱 유용할 것으로 생각된다.

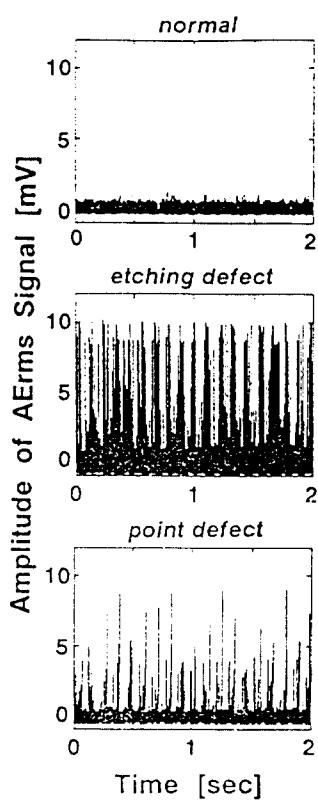


Fig.3 AErms signal measured from a normal and roller damaged bearing)

### 3. 특징추출 (Feature Extraction) 및 특징벡터의 거동

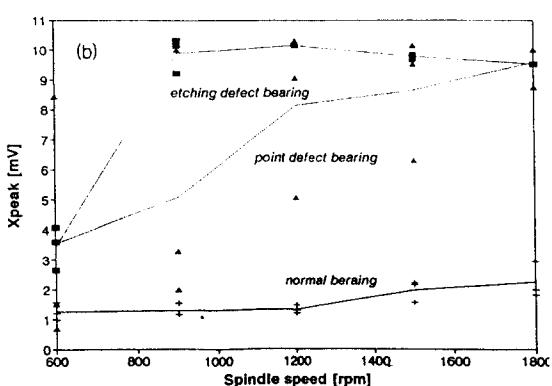
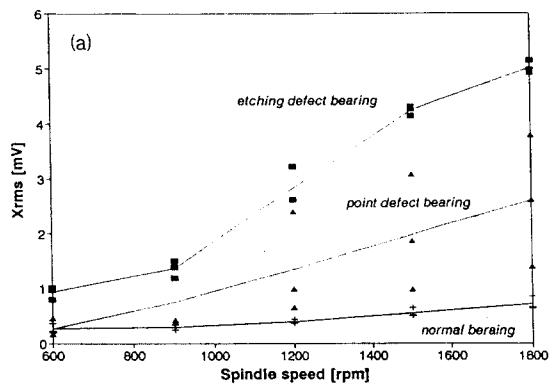
본 연구에서는, 온-라인 결합검출을 실현한다는 목표하에, 베어링 결함의 특징을 대표하는 특징벡터를 광대역(wide-band) 측정치를 이용하는 시간영역에서 추출하였다. 즉, 측정한 AErms 신호에 대한 통계파라메터. 예를들면 유차원 매개변수인 실효값( $X_{rms}$ ), 퍼크값( $X_{peak}$ )과 무차원 매개변수인 과고율(crest factor: C/F), 첨도(kurtosis: Ku)를 아래에 정의된 수식으로부터 산출하여, 이를 특징벡터를 신경회로망의 입력요소로 사용하였다. 즉

$$C/F = \frac{X_{peak}}{x} \quad (1)$$

$$Ku = \frac{1}{(N-1)} \sum_{i=1}^N (x_i - \bar{x})^4 \quad (2)$$

위의 식(1), (2)에서 평균값  $\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$ 이며, 편차  $s^2 = \frac{1}{(N-1)} \sum_{i=1}^N (x_i - \bar{x})^2$ 로 각각 정의된다.

한편, Fig.4 (a),(b),(c),(d)는 AErms 신호로 부터 추출된 각 특징벡터가 베어링의 결함 형태와 주축의 회전 속도에 어떠한 영향을 미치는 가를 살펴보기 위하여, Table 2에 나타낸 비교적 광범위한 운전조건에서 결합 검출실험을 행하였을 때 얻어진 특징벡터의 거동을 조사한 결과이다.



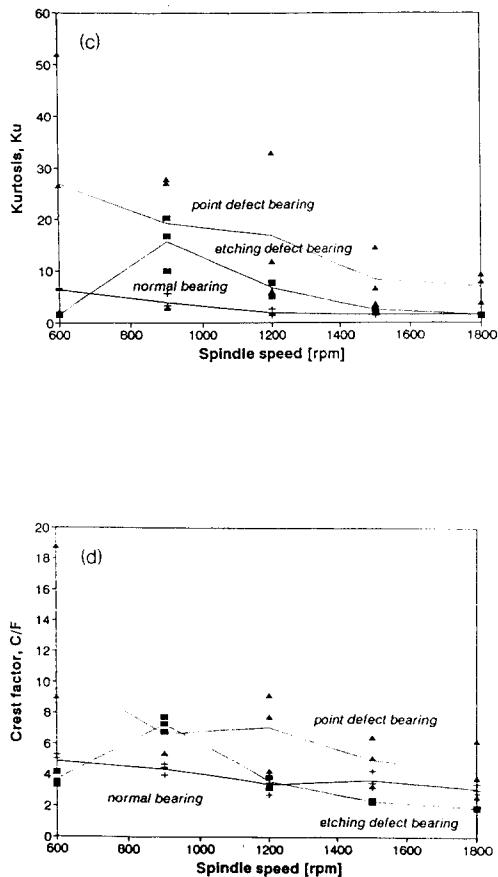


Fig.4 Behavior of the feature vectors ((a) Xrms, (b) Xpeak, (c) Kurtosis, (d) Crest Factor) with bearing defect types

이들 그림에서 볼 수 있는 바와같이, 유차원 매개변수 Xrms, Xpeak는 주축의 회전속도가 증가함에 따라 비교적 민감하게 증대하고 있으며, 반대로 무차원 매개변수 C/F, Ku는 감소하는 경향을 보여주고 있어, 이를 특징 벡터의 크기는 공작기계 주축의 회전속도에 직접적인 영향을 받고 있음을 알 수 있다. 또한, 결합형태에 대하여는, 전 특징벡터에 걸쳐 연결함(▲표)의 경우, 베어링 예하중에 따른 데이터 흘러짐의 폭이 부식결함(■표)에 비하여 비교적 크게 나타나고 있으며, 이와같은 원인은 접결 합이 베어링 예하중의 영향을 비교적 민감하게 받고 있기 때문으로 생각된다.

또한, C/F, Ku의 거동은 Xrms, Xpeak에 비하여 정상베어링과 데이터의 중첩 벤도가 많은 것으로 나타나고 있으며, 본 실험의 결과에 따르면, 베어링 결합형태를 고려하지 않고 정상상태와 결합상태만을 식별하여 인식하는 경우, 일부 제한적 가치를 갖으나, 유차원 매개변수 Xrms, Xpeak의 사용도 어느정도 가능할 수 있을 것으로 생각된다.

그리나, 이상의 특징벡터만을 이용하여 베어링 결합상태를 검출하는 경우, 앞에서 언급한 바와 같이, AERms 신호에서 추출된 특징벡터는 베어링의 회전속도와 예하중 등, 주변 운전조건의 변화에 대하여 민감하며, 특히 베어링의 결합상태, 예를들면, 정상상태와 부식결함, 혹은 접결합 상태를 명확히 구별하여 인식하는 것은 불가능한 것으로 판단된다. 따라서, 다음절에서는 이를 특징벡터를 입력요소로 하는 신경회로망을 이용하여 베어링의 결합상태를 식별하여 인식할 수 있는 검출방법을 검토하였다.

#### 4. 신경회로망에 의한 베어링 결합검출<sup>(10)</sup>

Fig.5는 본 연구에서 사용한 신경회로망 구조도를 나타낸 것이다. 입력층 신경세포수가 n개일 때, 신경회로망의 입력벡터는  $x = (x_0, x_1, \dots, x_{N-1})$ 이 되고, 신경세포는 연결강도  $w_{i,j,k}$ 를 가지고 연결되어 있으며, 다음단계의 신경세포 입력은 전단계 신경세포의 출력치에 연결강도  $w_{i,j,k}$ 를 곱하고, 신경세포의 임계치  $t_{i,k}$ 를 더하여 식 (3)과 같이 구하게 된다.

$$y_{i,k} = \sum_{j=0}^{N-1} x_j w_{i,j,k} - t_{i,k} \quad (3)$$

여기서,  $w_{i,j,k}$ 는 (k-1)번째층의 i 번째 신경세포에서 k번째층 j번째 신경세포의 연결강도를,  $t_{i,k}$ 는 k 번째 층의 i 번째 신경세포의 임계치를,  $y_{i,k}$ 는 k 번째층의 j 번째 신경세포로의 입력을 의미한다.

본 연구에서는 신경회로망의 입력층 노드수는 5개로 결합상태를 대표하는 특징벡터, 즉 Xrms, Xpeak, C/F, Ku와 주축회전속도를 입력패턴요소로 채택하였으며, 출력층의 노드수는 1개이며 3가지의 결합패턴을 출력요소로 하되, 정상베어링을 "0.1", 부식결함을 "0.5", 접결함을 "0.9"로 하여, 이를 목표출력(target outputs)으로 하는 베어링 결합정보를 얻을 수 있도록 하였다. 또한, 은닉층의 숫자와 노드수의 결정에 있어서 아직까지 정확

한 방법은 제시되고 있지 않으므로 시행착오를 통하여 결정하고 있다. 본 연구에서는 학습 시간과 신호처리 시간의 단축을 위해 은닉층을 1층으로 정하고, 은닉층의 노드 수를 변화시키면서 학습시킨 결과 은닉층의 노드수가 10 개일 때 오차 범위가 가장 감소하였다. 따라서 통계파라메타를 이용한 신경회로망 구조는 5-10-1의 구조이고, 신경회로망의 활성함수로 쓰이는 시그모이드(sigmoid)는 식(4)와 같이 표시되며, S자형태로 인해 작은 입력에는 큰 기울기가 적용되고, 큰 입력에는 작은 기울기가 적용되므로써 신경세포가 큰 입력과 작은 입력에 대하여 모두 적당하게 반응할 수 있게 해 준다.

$$O_{i,k} = f(y_{i,k}) = \frac{\alpha}{1 + e^{-(\beta * y_{i,k})}} \quad (4)$$

여기서,  $O_{i,k}$ 는 k번째층 i 번째 신경세포의 출력을 의미하며,  $y_{i,k}$ 는 동일 신경세포로의 입력을 의미한다. 또한,  $\alpha$ 는 최대출력을 결정짓는 파라메터로 신경세포의 최대출력을 제한하며,  $\beta$ 는 시그모이드 함수의 기울기로 신경세포 출력값이 최대 및 최소범위를 넘지 못하게 제한하며, 본 연구에서는 각각 1로 설정하였다. 식(4)에 의해 계산된 출력은 동일층의 다른 신경세포의 출력들과 함께 다른 층의 입력으로 전달되며 이러한 과정은 역전파 알고리즘(back-propagation algorithm)을 이용하여 결합함께를 인식, 분류할 수 있도록 가중치를 구하였다. 또한, 보다 효과적으로 신경회로망의 수렴속도를 높이고 오차진동을 줄이기 위하여 학습률(learning rate)와 모멘텀(momentum rate)을 변경시키면서 초기 학습을 시켰으며, 본 연구에서는 학습률을 0.9, 모멘텀을 0.7로 설정하였다.

Table 2에 나타낸 바와같이 각 예압별로 주축회전수를 변화시킨 15개의 실험조건에서 3 가지 형태의 베어링 결합상태별로 실험한 45쌍의 시험데이터로 부터 특징벡터를 추출하여 신경회로망을 학습시켜 가중치를 저장하였다.

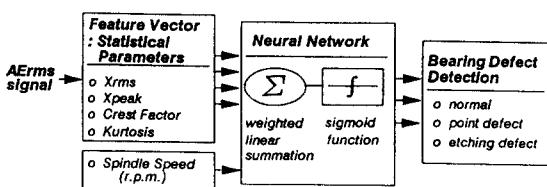
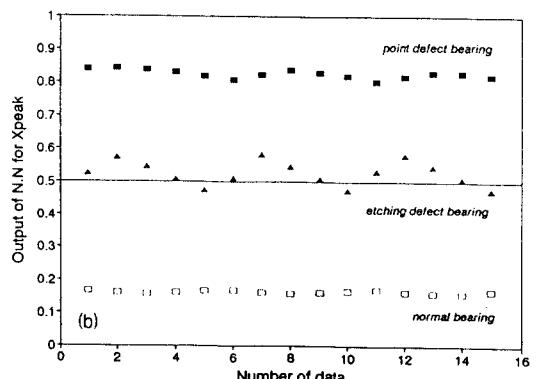
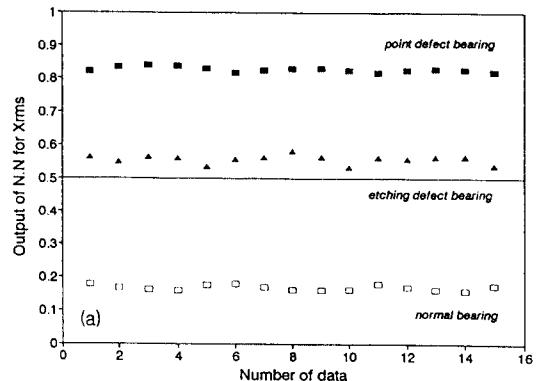


Fig.5 Schematic diagram of bearing defect detection system with neural network

며, 신경회로망의 검출타당성을 검토코자 각 통계파라메타별 신경회로망의 출력결과를 Fig.6 (a), (b), (c), (d)에 나타내었다. 이를 그림에서 볼 수 있는 바와 같이, 각 특징벡터들은 결합패턴에 따른 출력총의 목표 출력값(0.1, 0.5, 0.9)을 중심으로 베어링 결합상태에 대응하는 “인식정보의 군”을 형성하고 있으며, 각 특징벡터마다 다소의 차이는 있으나, 신경회로망의 출력은 정상베어링과 부식결합 및 점결합 상태를 비교적 명확히 구별하여 인식하고 하고 있음을 알 수 있다. 즉, 신경회로망의 출력결과를 목표 출력값의 편차에 대응하는 허용오차 ( $\delta$ )를 취하여, 출력값이 “0.1”과 “ $0.1 \pm \delta$ ”의 범위내에 있는 것을 정상베어링, “0.5”와 “ $0.5 \pm \delta$ ”를 부식결합, “0.9”와 “ $0.9 \pm \delta$ ” 사이를 점결합으로 하였을 때, 유차원 매개 변수 Xrms 와 Xpeak 는 모두 허용오차  $\delta = \pm 0.1$  의 범위내에서 거의 완벽하게 인식하고 있으며, 무차원 매개변수 C/F 와 Ku 는 유차원 매개변수에 비하여 다소 민감도가 떨어지는 것으로 나타나고 있다. 또한 이들 각 특징



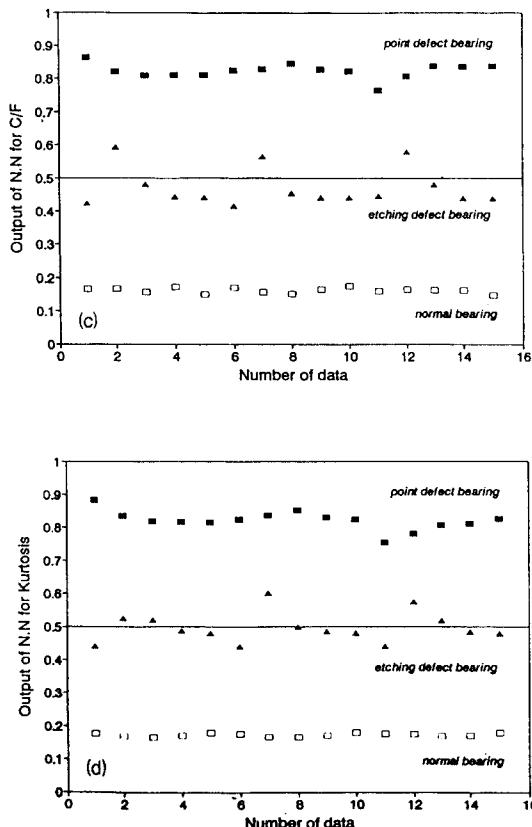


Fig.6 Outputs of an neural network for feature vectors : ((a) Xrms, (b) Xpeak, (c) Crest Factor, (d) Kurtosis)

벡터에 대한 출력결과를 정성적으로 비교해 보면, Xrms, Xpeak, C/F 혹은 Ku의 순으로 인식결과가 좋음을 알 수 있다.

Fig.7에는 학습이 끝난 신경회로망을 이용하여 예하중 8kg·m, 600~1800 rpm의 5가지 운전속도의 조건에서 각각의 3가지 베어링 결함상태별로 운전했을 때, 신경회로망에 의한 결합검출 결과를 나타내었다. 그림에서 볼 수 있는 바와같이, 본 연구에서 구성한 신경회로망 출력은 목표 출력값(정상베어링 : 0.1, 부식결합 베어링 : 0.5, 점결합 : 0.9)에 따라 베어링 결합상태를 명확히 분류하여 인식하고 있으며, Fig.4에서 언급한 바와 같이, 순수 통계 파라메타만을 이용하여 결합상태를 검출할 경우, 베어링 운전속도의 영향을 많이 받아 효과적인 결합검출이 어

려웠지만, 신경회로망을 이용할 경우 보다 명확한 결합검출이 가능함을 보여주고 있다. 또한, 베어링의 부식결합의 검출에 있어서 통계파라메타 각각을 특징벡터로 사용하여 학습시켜 검출한 결과보다 다수의 특징벡터를 융합하여 결합상태를 검출한 결과가

인식감도 및 정확성 면에서 보다 우수함을 보여주고 있으며, 이는 적절한 센서정보 및 특징 벡터의 융합효과에 대한 유용성을 입증해 주는 좋은 결과라고 사료된다.

## 5. 결 론

공작기계 주축용 테이퍼 로울러 베어링의 로울러부에 발생된 결합상태를 AE 신호로서 검출하고, 신경회로망을 이용하여 결합형태를 분류 평가함과 동시에 이를 검출하기 위한 방법을 검토했던 결과, 다음과 같은 결론을 얻었다.

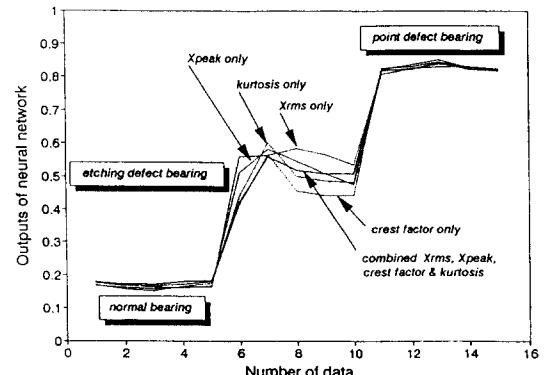


Fig.7 Outputs of an neural network performance with normal and defects bearings >

1. 베어링 결합형태를 고려하지 않고 결합상태의 유무만을 식별하여 인식하는 경우, 제한적 운전조건에서, AE rms 신호의 유차원 매개변수 Xrms, Xpeak의 사용이 가능하다.
2. 신경회로망은 베어링 결합형태, 즉 정상베어링과 점결합 및 부식결합 상태를 명확히 분류하여 인식하고 있으며, AE rms 신호에서 추출한 특징벡터 중 Xrms, Xpeak, C/F, Ku의 순으로 인식결과가 좋게 나타났다.
3. 센서정보의 통합은 결합상태에 대한 인식감도를 향상시키거나, 또는 검출정밀도를 개선시킬 수 있는 기대효과가 있다.

## 참 고 문 헌

1. McFadden, P.D., and Smith, J.D., "Vibration Monitoring of Rolling Element Bearing by the High Frequency Resonance Technique - A Review", *Tribology*, Vol.17, No.1, pp.3-10, 1984.
2. Darlow, M.S., and Badgley, R.H., "Applications for Early Detection of Rolling Element Bearing Failures Using the High Frequency Resonance Technique", *ASME Paper No. 75-DET- 46*, 1975.
3. Drago, R.J., and Board, D.B., "High Frequency Vibration Monitoring Techniques for Gear/Bearing System Failure Detection", *AGMA Paper No.109*, Oct., 1975.
4. Kovarskii, E.M., Malygin, V.M., and Gorbunov, A.G., "Impact-impulse Diagnostics Method for Initial Damage to Rolling Contact Bearings", *Elektrotehnika*, Vol.52(1), pp. 57-59, 1981.
5. Nishimoto, S., and Kamenno, R., "Estimate of the Fatigue Condition on Rolling Bearing by AE", *Progress in Acoustic Emission*, Japan Soc. for NDI, pp.446-453, 1988.
6. Balderston, H.L., "The Detection of Incipient Failure in Bearing", *Materials Evaluation*, 1969.
7. Dyer, D., and Stewart, R.M., "Detection of Rolling Element Bearing Damage by Statistical Vibration Analysis", *Trans. of the ASME, J. of Mechanical Design*, Vol.100, pp.229-235, 1978.
8. Li, C.J., and Wu, S.M., "On-Line Detection of Localized Defects in Bearing by Pattern Recognition Analysis", *Trans. of the ASME, J. of Engineering for Industry*, Vol.111, pp.331-336, 1989.
9. Liu, T.I., and Mengel, J.M., "Detection of Ball Bearing Conditions by an A.I. Approach", *Sensor, Controls, and Quality Issues in Manufacturing*, ASME, 1991.
10. 정의식, 외3명, "신경회로망을 이용한 공작기계 주축용 베어링의 고장검지", *한국정밀공학회*, 제12권, 제5호, pp.33-39, 1995.