

신경회로망을 이용한 공작기계 주축용 베어링의 고장검지

오 석 영,* 정 의 식,** 강 형 모,** 임 영 호***

Detection of Main Spindle Bearing Conditions in Machine Tool via Neural Network Methodology

Suk-Young Oh,* Eui-Sik Chung,** Hyung-Mo Kang,** Young-Ho Lim***

ABSTRACT

This paper presents a method of detecting localized defects on tapered roller bearing in main spindle of machine tool system. The statistical parameters in time-domain processing technique have been calculated to extract useful features from bearing vibration signals. These features are used by the input feature of an artificial neural network to detect and diagnose bearing defects. As a results, the detection of bearing defect conditions could be successfully performed by using an artificial neural network with statistical parameters of acceleration signals.

Key words : detection of bearing conditions, machine tool system, statistical parameters, time-domain processing techniques, acceleration signal, neural network

1. 서 언

공작기계의 시스템이 고속화, 복잡화 됨에 따라, 그 구성요소 개개의 고장이나 결함은 시스템 전체의 기능 정지를 초래하여 생산에 커다란 차질을 가져올 뿐만 아니라, 제품의 정밀도에 직접적인 영향을 미치게 된다. 이 경우, 시스템의 보전과 정밀도 유지라는 관점에서, 기계의 개개고장을 조기에 발견하고, 과혹한 조건에서도 엄밀한 정밀도가 요구되는 공작기계 주 베어링의 고장 및 결함검출에 대한 문제점 해결은 당면된 중요한 과제로 되고 있다.

베어링 고장검지에는, 진동해석, 온도변화, 혹은 소음변화를 이용하는 방법등이 있으며, 최근에는 AE에 의한 것도 연구되고 있으나, 그 민감도나, 취급 및 신호처리의 용이성등을 고려하여, 현재까지는 진동해석을 이용하는 방법이 가장 널리 이용되고 있다. 또한, 이들의 연구 동향을 살펴보면, McFadden⁽¹⁻³⁾ 등은 공진주파수의 피-크 부근의 가속도 신호만을 대역필터에 통과시키는 HFRT(high frequency resonance technique) 기법을 볼 베어링의 결함검출에 적용하였으며, Kovarskii⁽⁴⁾ 등은 충격 임펄스 진단법(impact-impulse diagnostics method)에 의한 볼 베어링의

* 숭실대학교 대학원 기계공학과
** 대전산업대학교 기계설계공학과
*** 숭실대학교 기계공학과

초기손상 검출방법을 제안하였다. 또한, Nishimoto와 Kamen⁽⁶⁾은 베어링 결함의 조기진단에 AE 법의 유용성을 검토하였고, Balderston⁽⁶⁾은 공진주파수 부근의 유효진폭 (r.m.s. amplitude) 및 HFRT 기법에 대한 유용성 검토와 함께, AE법을 이용한 결함검출 방법을 제안하였다. 또한 Smith는 포락검파 신호의 파고율 (crest factor) 해석기법을 이용한 검출방법을 제안하였으며, Dyer & Stewart⁽⁷⁾는 베어링 결함상태의 평가지표로서 첨도 (kurtosis)의 유용함을 입증하였다. 특히, 최근에는 Li와 Wu⁽⁸⁾가 패턴인식기법을, 그리고 Liu와 Mengel⁽⁹⁾이 인공신경회로망을 이용하여, 결함정보의 통합화를 위한 온-라인 베어링 감시기법을 제안하였다. 그러나, 이들 대부분의 연구는, 운전조건이 비교적 안정된 상태에서 정하중을 받고 있는 소형 회전보울베어링을 대상으로 하여, 베어링 결함의 유·무 상태만을 판정하기 위한 결함검출방법을 검토한 것이며, 운전조건이 비교적 과혹한 상태에서 결함의 크기를 명확히 분류하여 평가할 수 있는 베어링 진단 및 감시방법에 대해서는 아직 제안되어 있지 않은 실정이다.

본 연구에서는, 기계가공시 공작물의 가공정밀도에 직접적인 영향을 미치는 공작기계 주축용 베어링의 결함발생을 검출하기 위하여, 인공신경회로망 (artificial neural network)을 이용한, 베어링 고장검지 시스템의 개발을 연구목적으로 하고 있다. 구체적으로는, 선반의 주축대 모델을 이용하여, 공작기계 주축용 베어링으로 널리 사용되고 있는 테이퍼 롤-러 베어링 (#32017)의 롤-러부에 박리현상 (flaking)과 같은 인위적인 점결함을 주었을 때, 주축 회전속도와 결함의 크기에 따라서 측정된 신호에 포함되어 있는 결함특징을 시간영역의 통계모멘트계수로 추출하고, 추출된 계수를 신경회로망에 의해 패턴인식하여, 베어링 결함상태를 검지할 수 있는 방법을 개발하고자 한다. 본 연구에서, 측정신호는 가속도 신호를 이용하였고, 베어링의 결함발생 정도를 명확하게 구별하고 인식하는데 대한 신경회로망의 유용성 여부를 검토하였다.

2. 실험방법 및 신호처리

본 연구에 사용한 선반 주축대 모델과 실험장치의 개략도를 Fig. 1에 나타내었다. 실험에 사용한 선반 주축대 모델은, 베어링 하우징내에 모터와 직결된 주축대를, 지지용 베어링 #32014와 시험용 베어링 #32017 테

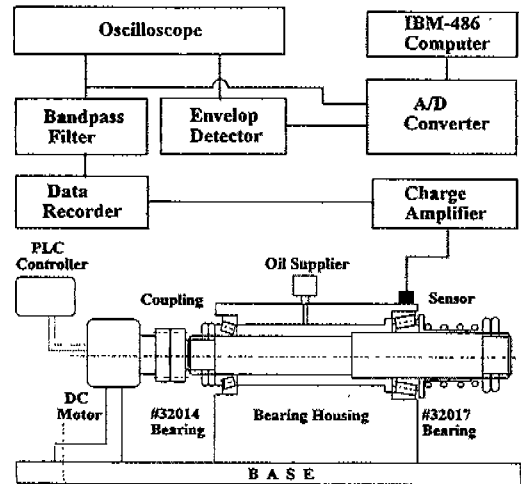


Fig. 1 Schematic diagram of bearing test rig

Table 1 Experimental conditions of bearing defect detection

Damage levels of roller	1) Undamaged 2) Light Damage 3) Medium Damage 4) Heavy Damage
Main spindle speed (r.p.m)	800, 900, 1000, 1100
Preload (kgf)	Axial load : 30

이퍼 롤-러 베어링이 지지하도록 하였으며, 이들 두 베어링간의 거리는 180 mm (NSL 400x750S)로 하였다. 그리고, Table 1과 같은 실험조건으로, PLC board에 연결된 모터의 회전속도를 변화시키면서, 롤-러부의 결함크기 (Photo. 1)에 따른 베어링 결함검출 실험을 행하였다.

또한, 시험용 베어링으로 부터 가장 가까운 위치의 베어링 하우징에 고정 설치한 가속도센서 (B&K type 4369)에서 검출된 신호는, 증폭기 (B&K type 2635)를 거쳐 데이터 레코더 (TEAC XR310)에 일단 수록한 후, 이를 재생하여, 주파수 분석 (NEC 7T26S)을 행하거나, 혹은, 오실로스코프 (Tektronix 2230), 대역통과 필터, 포락검파 회로를 통과시킨 후, A/D 변환하여 컴퓨터 (PC486)에 저장시켜, 신호분석을 행하였다. Fig. 2는 신호처리의 흐름도를 나타낸다.



(a) Light damage (b) Medium damage (c) Heavy damage
Photo. 1 Photographs of tapered roller bearing defects

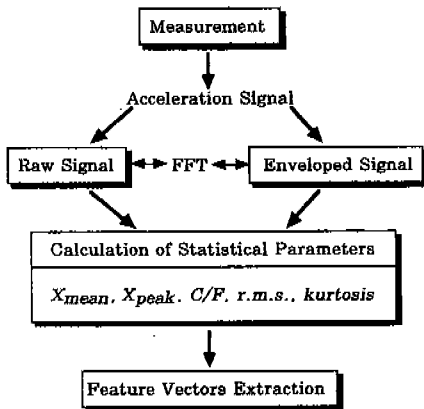


Fig. 2 Signal processing flow diagram

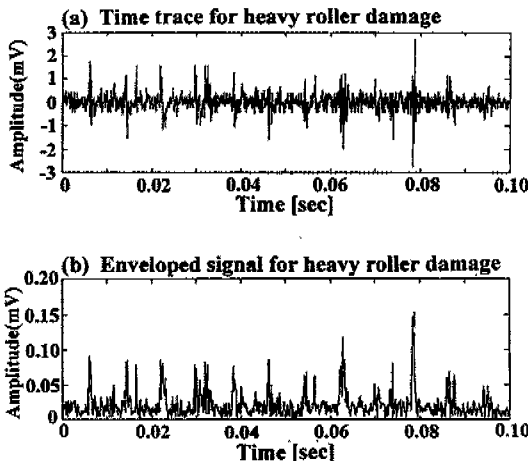


Fig. 3 Bearing signal measured from a roller damaged bearing

한편, Fig. 3(a),(b)는, 이상의 실험방법 및 신호처리 방법을 이용하여, 롤러부의 결함이 비교적 큰 베어링에서 측정된 진동 가속도의 주신호 (Fig. 3(a))와 포락검파신호 (Fig. 3(b))를 검출한 결과(10,000 sam-

ples/sec.)의 일례를 나타낸 것이다. 여기서, 포락검파신호는 주신호의 부(-)측 성분을 반전시킨 절대값으로서 다음의 식으로 부터 얻었다.

$$X_{envelop} = \frac{1}{N} \sqrt{\sum_{j=1}^N X_j^2}$$

그림에서, 베어링 신호의 특성은 시간에 따라 변화하고 있으며, 신호의 피크 진폭과 주파수성분의 변동이 심한 것을 알 수 있다. 이는 손상된 베어링에 의해 발생하는 주기적인 충격력이 시간에 종속적으로 변화하고 있음을 의미하며, 이 때문에 베어링 결함검출을 위한 신호처리에서는 시간영역의 해석기법(time-domain analysis techniques)이 널리 이용되고 있는 것으로 생각된다.

3. 특징추출(Feature Extraction) 및 인공신경회로망(Artificial Neural Network)

3.1 특징벡터(Feature Vectors)의 거동⁽¹¹⁾

신경회로망의 입력패턴요소로 사용될 각 특징벡터, 즉 각 통계모멘트계수가 베어링의 결함크기와 주축 회전속도에 어떠한 영향을 미치는 가를 살펴보기 위하여, 이들의 거동을 주신호와 포락검파신호에 대하여 각각 조사하였다.

Fig. 4(a),(b),(c)는 주신호에 대한 $X_{peak}, r.m.s., kurtosis$ 의 거동을 조사한 결과로서, $X_{peak}, r.m.s.$ 는 주축 회전속도가 증가함에 따라 대체로 증가하고 있으며, 베어링의 결함정도를 비교적 명확하게 반영하고 있다. 또한, Fig. 5(a),(b),(c)는 포락검파신호에 대한 $X_{peak}, r.m.s., C/F$ 를 조사한 결과로서, 여기서도 주축 회전속도에 따른 $X_{peak}, r.m.s.$ 의 거동은, 주신호와 마찬가지로의 경향을 나타내고 있다. 그러나, 주신호의 $kurtosis$ (Fig. 4(c))와 포락검파신호의 C/F (Fig. 5(c))은 정상 베어링과 손상된 베어링간의 신호의 크기에는 현격한 차이를 보이고 있으나, 주축 회전속도와 결함크기에 대해서는 민감하지 못한 결과로 나타나고 있다.

즉, 현 상태로서도, 주신호와 포락검파신호의 $kurtosis$ 와 C/F 를 제외한, X_{peak} 및 $r.m.s.$ 에 적절한 임계값(threshold)을 설정하고, 이들 두 통계모멘트계수를 시간영역에서 측정하는 것에 의해, 베어링의 결함상태를 실시간으로 검출할 수 있을 것으로 판단되며, 이 경우 베어링의 결함크기에 따라 얻어지는 가속

도 신호의 X_{peak} 은, $r.m.s$ 에 비하여 그 증가의 폭이 커서, 베어링 결함검출에 더욱 유용하게 이용될 수 있을 것으로 생각된다.

또한, 베어링의 결함크기를 고려하지 않은 경우, $kurtosis$ 와 C/F 도 비교적 광범위한 주축 회전속도 영역에서의 베어링 결함검출에 이용될 수 있으며, 이때 정상베어링과 손상된 베어링 간의 증가폭은 $kurtosis$ 가 약 3배, C/F 는 약 1.5배 정도로 나타나고 있어, 이 경우 C/F 보다는 $kurtosis$ 가 더욱 유용하게 활용될 수 있을 것으로 생각된다.

그러나 이상의 통계모멘트계수만을 이용하여 베어링 결함상태를 검출하는 방법은, 베어링의 회전속도와 부하 등, 주변의 상황변화에 대하여 민감하며, 베어링 결함검출에 있어 매우 제한적인 가치를 갖는 것으로 지적되고 있다.⁽⁷⁾ 따라서, 다음 절에서는, 이들 통계모멘트계수를 특징입력으로 하는, 신경회로망을 이용하여 베어링 결함




Fig. 4 Behavior of the statistical parameters with bearing damaged levels in raw signal




Fig. 5 Behavior of the statistical parameters with bearing damaged levels in enveloped signal. Legend is the same as Fig. 4

상태를 인식할 수 있는 검출방법을 검토하였다.

3.2. 역전달 방식의 신경회로망(Back-Propagation Neural Network)

인공신경회로망을 동적시스템의 고장진단에 적용하는 방법이, Ono⁽¹⁰⁾에 의해 제시되었다.

Fig. 6은 본 연구에서 사용한 신경회로망의 구조를 나타낸다. 신경회로망은 3층 구조로 되어 있으며, 입력층에는 결함특징을 나타내는 통계모멘트계수, 즉 Fig.




Fig. 6 Back-propagation neural network with one hidden layer

2의 신호처리 방법에 의해 얻어진 각 특징벡터(X_{peak} , $r.m.s.$, $kurtosis$, C/F)와 주축 회전속도($r.p.m$) 및 결합크기(*bearing damage levels*)를 입력패턴요소로 사용하였다. 또한, 은닉층은 1층으로, 10개의 노드를 갖으며, 출력층은 3가지 크기의 결합패턴을 출력요소로 하되, 정상베어링(*Undamage*)을 "-1", 중간 결합상태(*Light & Medium Damage*)를 "0", 큰 결합상태(*Heavy Damage*)를 "1"로 하여, 이들을 목표출력(target outputs)으로 하는 3 가지의 인식정보를 얻을 수 있도록 하였다. 한편, 신경회로망의 학습은, Fig. 4와 Fig. 5에서 얻은 각 결합상태에 대응하는 20개의 표본 데이터를 사용하여, 역전달방식(back-propagation method)에 의해 실행되며, sigmoid 함수를 활성화 함수로 사용하였다.

4. 신경회로망에 의한 베어링 결합검출

학습이 완료된 신경회로망에, Fig. 4, Fig. 5와 같은 16개의 실험조건에서 추출한 각 특징벡터와, 주축 회전속도 및 3가지 크기의 베어링 결합상태를 특징입력으로 하여, 얻어진 출력결과를 주신호와 포락검파신호에 대하여 Fig. 7과 Fig. 8에 각각 나타내었다.

이들 그림에서 볼 수 있는 바와같이, 각 특징벡터들은 결합패턴에 따른 출력층의 목표 출력값(-1, 0, 1)을 중심으로 베어링 결합크기에 대응하는 "인식정보의 군"이 형성되고 있다. 즉, 각 특징벡터에 따라 다소의 차이는 있으나, 신경회로망의 출력값은 정상 베어링과 중간 결합 및 큰 결합의 상태를 비교적 명확히 반영하고 있음을 알 수 있다. 또한, 이때 *kurtosis*와 C/F 는, Fig. 4(c)와 Fig. 5(c)에도 나타난 바와같이, 이들 자체




Fig. 7 Outputs of the neural network in raw signal

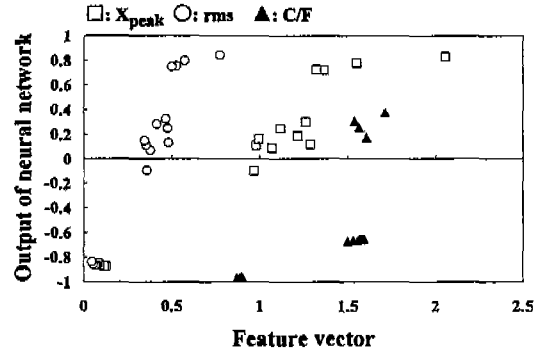


Fig. 8 Outputs of the neural network in enveloped signal

의 값만으로는 베어링 결합크기를 식별할 수 없었으나, 신경회로망의 출력결과에서는, 결합크기에 따른 특징벡터의 중복에도 불구하고, 베어링의 결합상태를 비교적 명확히 반영하고 있으며, 특히 *kurtosis*의 경우, 베어링의 각 결합크기에 대응하는 목표 출력값에 매우 근접하는 출력결과가 얻어지고 있음을 알 수 있다. (Fig. 7) 그리고, 이와같은 출력결과를, 신경회로망이 손상된 베어링의 결합크기를 진단하는데 매우 유용하게 이용될 수 있음을 잘 입증해 주고 있다.

한편, 이들 신경회로망의 출력결과를, 목표 출력값의 편차에 대응하는 허용오차 (tolerance: δ)을 취하여, 이에 대한 인식 성공률을 Fig. 9와 Fig. 10에 나타내었다. 이때, 출력값이 "1"과 " $1-\delta$ "의 범위내에 있는 것들은 큰 결합상태, "0"과 " $0\pm\delta/2$ " 사이를 중간 결합상태, 그리고 "-1"과 " $(-1)-\delta$ " 사이를 정상베어링 상태로 하




Fig. 9 Success rate as function of tolerance and each feature vectors used for the detection of bearing defect in raw signal

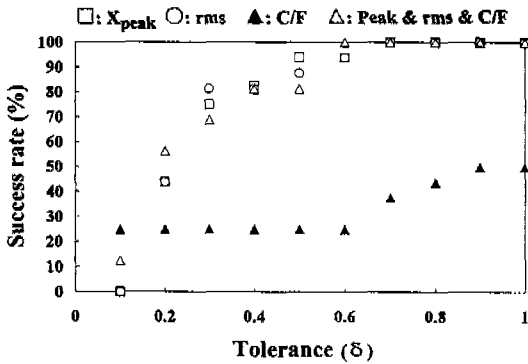


Fig. 10 Success rate as function of tolerance and each feature vectors used for the detection of bearing defect in enveloped signal

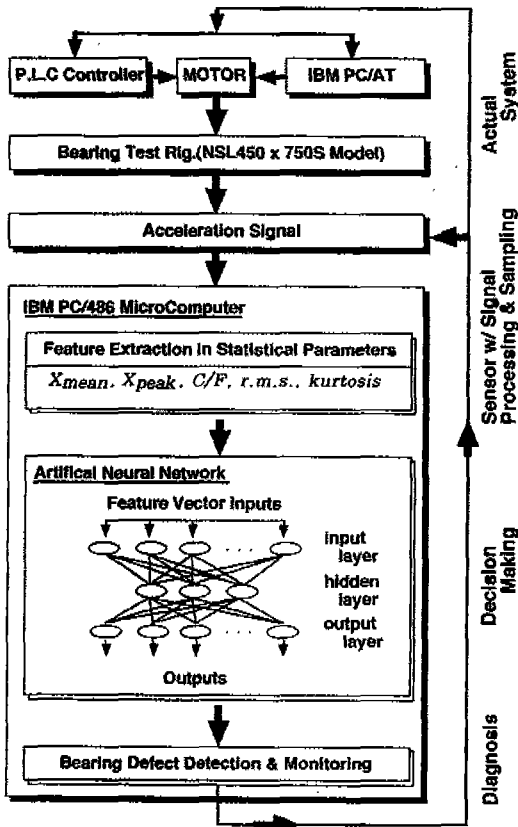


Fig. 11 Configuration of the proposed bearing defects monitoring system

여 성공률을 각각 구하였다.

이들 그림에 나타낸 바와같이, 베어링 결함상태를 인

식하는데 있어, 포락검파신호의 C/F 를 제외한 나머지 특징벡터 X_{peak} , $r.m.s.$, $kurtosis$ 에서, 최대허용오차를 $\delta_{max} = 0.5$ 로 하였을 때, 80~100 %의 성공률을 얻었으며, $kurtosis$ (100%), X_{peak} (88~94%), $r.m.s.$ (81~88%), C/F (25%)의 순으로, Fig. 7과 Fig. 8에서도 예상되는 바와같이, $kurtosis$ 가 가장 높은 성공률을 나타내었다. (Fig. 9) 또한, Fig. 9와 Fig. 10에는 이들 특징벡터를 통합한 경우(예를들면, 주신호의 X_{peak} , $r.m.s.$, $kurtosis$, 포락검파신호의 X_{peak} , $r.m.s.$, C/F)에 대한 인식결과의 성공률도 함께 나타내었다. 이 경우, 각 특징벡터의 통합효과에 관하여는, 현 상태로 단언할 수는 없으나, Fig. 10에서 볼 수 있는 바와같이, C/F 자체 (▲ 표)만으로는 낮은 성공률을 나타내는 데 반하여, 통합한 경우 (△ 표)에는 전 허용오차 δ 의 범위에 걸쳐서 성공률이 향상되고 있음을 알 수 있어서, 향후 검출정보의 통합에 대한 효과도 어느정도 기대해 볼 수 있을 것으로 생각된다.

이상의 결과로부터, 신경회로망은 베어링 결함크기를 명확히 분류하고 평가하는데 유용하게 이용될 수 있으며, 이때 신경회로망의 특징입력으로는, 여러 통계모멘트계수들 가운데, $kurtosis$ 가 베어링의 고장진단에 가장 유용한 정보를 제공해 줄 수 있을 것으로 판단된다. 한편, Fig. 11에는 본 연구를 통하여 제안하고자 하는 베어링 고장검지 시스템의 구성 개요도를 나타내었다.

5. 결 론

공작기계 주축용 베어링의 롤-러부에 발생된 결함상태를, 인공신경회로망을 이용하여 검지하는 방법을 검토한 결과, 다음과 같은 결론을 얻었다.

(1) 베어링 결함발생에 대응하는 가속도 신호에 대한 시간영역의 통계모멘트계수를 구하고, 신경회로망을 이용하여 베어링 결함상태를 인식하는 방법을 제안하였다.

(2) 통계모멘트계수 X_{peak} , $r.m.s.$, $kurtosis$, C/F 는 베어링 결함상태를 명확히 반영하고 있으나, 신경회로망의 특징입력으로 $kurtosis$ 를 사용하는 것이 베어링 고장검지에 가장 유용한 검출효과를 얻을 수 있을 것으로 생각된다.

(3) 인공신경회로망은 베어링의 결함크기를 구별하여 인식하는데 유용하게 이용될 수 있으며, 본 연구에서 제안한 시스템에 의하면, 베어링의 결함상태를 적어도 3단계로 명확하게 구별하여 인식할 수 있다.

후 기

본 연구의 일부는 1994년도 산·학·연 공동기술개발 대전지역권소사업 사업비의 지원으로 수행되었기에 관계자 여러분에게 감사드립니다.

참고문헌

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. Kovaskii, E. M., Malygin, V. M., and Gorbunov, A. G., "Impact-impulse Diagnostics Method for Initial Damage to Rolling Contact Bearings", Elektrotehnika, 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 Mech. Design, Vol.100, pp.229-235, 1978.
8. Li, C. J., and Wu, S. M., "On-Line Detection of Localized Defects in Bearings 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. 小野俊彦, "動的システムの故障診断における最近の研究", 機械の研究, 第45巻, 第2號, pp.245-252, 1993.
11. 오석영, 정의식, 임영호, "공작기계 주축용 베어링 결함검출", 한국정밀공학회 '94년도 추계 학술대회논문집, pp.351-356, 1994.