

본 연구는 96 교육부 기계공학분야 연구지원과제 (ME96-E-04)에 의하여 수행되었으며 이에 감사드립니다.

## 볼베어링으로 지지된 회전축의 이상상태 진단을 위한 진단전문가 시스템의 개발

유 승 민\*, 김 영 진\*\*, 박 상 신\*\*\*

### Development of Diagnostic Expert System for Rotating Machinery Failure Diagnosis

Song-min Yoo\*, Young-Jin Kim\*\*, Sang-shin Park\*\*\*

#### ABSTRACT

In this study, a neural network based expert system designed to diagnose operating status of a rotating spindle system supported by ball bearings was introduced. In order to facilitate practical failure situations, five exemplary abnormal status was fabricated. Out of several possible data source locations, seven most effective spots were chosen and proven to be the most successful in predicting single and multiple abnormalities. Increased signal strength was measured around where abnormality was embedded. Signal measurement locations producing high prediction rate were also classified. Even though multiple abnormalities were hard to be decoupled into their individual causes, proposed diagnostic system was somewhat effective in predicting such cases under certain combination of sensor locations. Among several abnormal operating conditions, highest prediction rate can be expected when signal is spoiled by the failure or damage in outer race. Proposed diagnostic system was again proven to be the most effective system in analyzing and ranking the importance of data sources.

**Key Words** : rotating spindle(회전축), ball bearing(볼 베어링), diagnostic system(진단시스템), neural network(신경망).

#### 1. 서 론

볼 베어링을 이용한 회전축은 모든 회전축의 근간을 이루고 있다. 이러한 회전축은 발전기 터빈, 고정밀 공작 기계등에 많이 응용되고 있다. 그런데 이러한 대규모의

회전축에 이상이 생긴경우에 이상을 방치하고 계속 사용하게 되면 기계전체의 파손을 가져올 수 있다. 이러한 기계전체의 파손이 일어나지 않도록 미리 이상을 진단할 수 있는 시스템을 구축하면 많은 비용을 절감할 수 있다. 따라서 이러한 볼 베어링으로 지지된 회전축의 이상을 진단

\* 경희대학교 공과대학 기계공학과(산학협력기술연구원)  
 \*\* 경희대학교 공과대학 산업공학과(산학협력기술연구원)  
 \*\*\* 영남대학교 기계공학부

할 수 있는 데이터베이스의 구축과 진단을 위한 추론 법칙의 확립은 필수적이라 할 수 있다<sup>(1)</sup>. 이러한 추론의 법칙을 확립하고, 실제기계가 작동 중에 컴퓨터에 의한 이상유무의 판단 및 작동정지, 이상상태의 출력 등을 자동화시킨 것을 진단 전문가 시스템이라 한다<sup>(2-5)</sup>. 따라서 본 연구에서는 볼 베어링으로 지지된 회전축의 이상을 베어링 내·외륜의 파손, 볼의 파손, 리테이너의 파손 등으로 나누어서, 각각의 경우에 나오는 회전계적, 열발생, 소음, 진동의 신호를 유추적으로 판단할 수 있는 신호를 측정하고, 정상상태에서의 신호들과 비교 분석을 통해 이상상태의 신호들을 추출하여 데이터 베이스를 구축하고자 한다. 한편, 이러한 데이터 베이스 구축과 병행하여, 동적인 센서에서 나오는 신호의 분포를 통계적으로 처리하는 프리프로세서의 개발과 불확실성이 내재된 정보에 기초하여 시스템에 대한 판단을 하는 방법을 개발하여 실제 회전축의 이상을 진단하는 전문가 시스템을 개발하고자 한다.

이러한 진단 전문가 시스템을 구축하게 되면, 깊은 지하에서 작동하는 펌프나, 우주 공간에서 작동하는 회전축과 같은 극한의 상황하에 원거리에서 이상유무를 판단할 수 있는 시스템 개발의 기초가 될 수 있다.

나아가 수력, 화력 발전소나 핵발전소 등과 같이 대형의 회전축의 이상이 생겼을 경우에 경제적 손실은 기하학적이라 볼 수 있으며, 이러한 이상이 생겼을 때, 이상 진단을 하여 보정을 제시할 수 있는 시스템 개발의 초석이 될 수 있다. 이것을 또 회전축에 국한되지 않고, 선반이나 밀링 등의 가공중의 공구의 이상 진단, 반도체 가공공정, 대형의 화학 공장의 이상진단 등의 여러 분야에 응용되어 시스템의 보호를 통한 경제적 손실을 막을 수 있는 기초가 된다고 생각된다.

## 2. 신경망 모델링

신경망(artificial neural network)이란 여러가지 현상에 대한 적절한 판단을 유도하기 위한 것으로 비선형적인 사상(mapping)문제나 입출력간의 관계를 함수로 표현하기 어려운 문제에 대해서 좋은 도구로 인식되고 있어 많은 연구와 함께 실용분야에서 그의 활용영역을 넓히고 있는 분야이다. 신경망은 현상에 대한 분류 및 학습능력이 우수하고 외란에 대한 억제능력을 보유하고 있으며, 유연성을 보이고 있다. 단점으로는 복잡한 구조와 함께 비선형적 관계로 인한 분석에 어려움이 있으며 대부분에 경우에 구조를 설정하기에 용이하지 않으며 많은 양의 학

습데이터가 필요하며 학습 또한 쉽지 않다는 것이다. 신경망은 상호 연결된 병렬처리소자의 집합체로 생각할 수 있으며, 처리소자사이의 연결강도는 신경망이 부여하는 정보의 중요성을 나타낸다. 신경망을 이용한 자료의 활용 과정은 학습(learning)과 시험(test)이라는 두 가지 과정을 거치게 된다. 이러한 구조 및 자료의 처리과정은 인간두뇌의 사고능력을 모방하고 있으며 이것의 기원도 인간의 신경세포체계와 유사하다.

사용된 신경망모델링의 구조는 Fig. 1에서 보는 바와 같이 입력층(input layer), 은닉층(hidden layer)과 출력층(output layer)으로 구성되며 입력층은 실험장치에서 측정된 3방향의 가속도 값으로 이루어진 뉴런으로 이루어지고 은닉층은 1, 2개의 층으로 구성되며 출력층은 이상상태와 정상상태를 나타내는 뉴런으로 구성된다.




Fig. 1 Multilayer neural network structure

관찰된 실험자료는 유형에 따라 차이가 있지만 대부분 시스템에 상태에 따라 다양한 특징을 나타내는 것이다. 본 연구에서는 신경망에 적용시키기 위하여 신호의 분산정도를 나타내는 RMS(root mean square)를 사용하였다.

$$RMS = \sqrt{\frac{1}{n} \sum_i (x_i - \mu)^2} \quad (1)$$

이때  $x_i$ ,  $\mu$  와  $n$  은 각각 측정자료값, 평균과 계산자료수를 나타낸다.

## 3. 실험장치의 구성

볼베어링으로 지지된 회전축시스템을 구성하기 위하여 두 개의 하우징내에 설치된 볼베어링으로 지지된 축을 제

작하여 설치하였다. 볼베어링은 FAG사의 호칭번호 6008 깊은홈 볼 베어링을 사용하였다. 베어링의 설계원칙에 따라 시험베어링 B는 고정으로 하였고 시험베어링 A는 활동베어링으로 선정하여 설계하였다. 이는 베어링의 파손 시험을 할 때 고정축 베어링은 분해하지 않고 같은 베어링을 사용하므로써 상대적인 결과를 얻기 위함이었다. 동력원과 축을 플렉시블 커플링으로 연결하여 모터의 진동을 감소시키면서 정확한 동력전달이 이루어지도록 하였다. 모터 및 모터축을 고정시키기 위한 세 번째 하우징이 설치되었으며 동력원에서부터의 진동 및 모터축과 베어링축과의 수준차 등으로 인한 계반 영향을 최대한 감소시키도록 하였다. Fig. 2는 이러한 시스템 구성도를 나타내고 Fig. 3는 제작된 실험장치의 모습이다.

Fig. 4은 이 시스템에서의 센서의 부착이 가능한 각 측정지점을 표시하고 있다.




Fig. 2 System layout




Fig. 3 Experimental Setup




Fig. 4 Measurement locations

본 실험에 사용된 동력원으로 후지사의 500 W 급 100 V 단상전동기를 사용하였으며 이러한 시스템의 운전조건으로서 베어링축의 회전수는 900, 1800, 3600 rpm으로 설정되었다. 설정된 각각의 운전조건에 대하여 Kistler사의  $\pm 500g$ 의 측정범위를 지니는 piezo형 3축 가속도 측정센서를 부착하였으며 운전상태의 변화에 따른 가속도의 변화를 신호변환기를 통하여 컴퓨터에 수록하였다. Fig. 2에 표시된 센서부착 가능지점 중에서 중복성을 피하고 변별력이 있는 특징신호를 추출하기 위하여 7개소(Fig. 4의 ②, ④, ⑤, ⑥, ⑩, ⑰, ⑲지점)를 선정하여 실험을 수행하였다. 회전축이 볼베어링으로 지지된 시스템의 상태를 정상적인 운전상태와 비교하기 위하여 일반적으로 운전 중에 얻어질 수 있는 시스템의 상태를 정상운전과 이상운전상태로 다음과 같이 분류하였다.

- ① 정상운전상태(A형)
- ② 리테이너의 파손(1개소:B형)
- ③ 리테이너의 파손(2개소:C형)
- ④ 볼의 파손(D형)
- ⑤ 베어링의 내륜의 파손(E형)
- ⑥ 베어링의 외륜의 파손(F형)

본 실험에서는 Fig. 4에서 ⑩지점 하우징에 설치된 볼베어링을 분해하여 필요한 부분을 절단하거나 손상시킨 후 재조립하여 회전축을 지지하도록 함으로써 요구되는 이상상태에 상당하는 운전조건을 인위적으로 조성하였다. 즉 리테이너의 1개소 파손은 실험으로 한부분을 절단하였으며 2개소 파손은 최초절단지점에서 180° 지점을 추가로 절단하였다. 볼의 파손환경을 조성하기 위하여  $\phi 1$  초경드릴의 날끝으로 볼의외부에 손상을 주었다. 또한 내륜과 외륜의 파손은  $\phi 2$  드릴로 볼의 안내면 홈에 손상을 주었다.

#### 4 실험자료분석

본 연구에서는 볼베어링으로 지지된 회전축의 이상상

태를 가장 효과적으로 진단할 수 있는 방법과 측정지점의 위치선정을 최적화시키기 위하여 측정된 3축방향 가속도 자료를 바탕으로 이상상태 및 측정지점수의 조합을 변화시켜서 상기시스템 및 제안한 신경망 시스템의 성능을 평가하고자 한다. 즉 센서를 설치하여 신호를 취득하는 지점의 수와 이를 바탕으로 정상운전상태와 구별하고자 하는 이상운전상태 수의 조합을 센서정보수집 지점이 1개소인 경우에 대하여 1가지에서 3가지까지로 비정상운전상태의 가짓수를 변화시켰으며 측정지점이 2개인 경우에는 측정지점수보다 많은 3가지의 비정상운전상태에 대하여 판별하도록 하여 총 4가지의 경우에 대하여 분석하였다.

본 연구에서는 정상운전상태에 대한 단일이상상태를 조성하여 연구를 수행하였으며 2개 이상의 이상상태의 경우는 단일운전조건에서 2개 또는 3개의 이상상태가 동시에 복합적으로 발생되는 경우가 아니고 각각 발생한 단일 이상상태를 2개 또는 3개 조합하여 정상과 구별하는지를 판별하고자 하였다.

4.1 신호처리분석

Fig. 5는 실험결과로 얻어진 신호로서 시스템을 1800rpm에서 회전시킬 때 센서를 Fig. 4의 ④지점에 설치하여 측정된 X축방향의 가속도성분을 6가지의 운전상태에 대하여 나타낸 것이다. 대부분의 이상상태에서 신호는 정상운전상태에 비하여 크게 변화하고 있다. 이러한 신호중 X축방향 가속도성분에 대하여 계산된 여러 RMS 값들의 평균이 Table 1에 나타나 있다. 가속도의 RMS 값이 신경망에 입력자료로 활용되기 때문에 이 RMS 값의 변화특성이 신경망시스템의 성능에 영향을 미칠 것이다. 가속도의 RMS수치의 경향을 X축방향에 대하여 센서의 설치지점, 회전속도, 이상유형의 변화에 따라 비교한다. 이러한 변화특성을 비교하기 위하여 센서의 측정지점위치에 대한 RMS값의 경향이 여러가지 회전속도에 대하여 표시되었다(Figs 6-7). Fig. 6에서와 같이 정상적









Fig. 5 Comparison of X-component acceleration signal measured at location ④ for various operating conditions running at 1800 rpm




Fig. 6 X component RMS acceleration for various rpm(type A)




Fig. 7 X component RMS acceleration for various rpm(type B)

인 운전상태에서는 베어링을 포함하고 있는 두 개의 하우징부분(Fig. 4의 ⑥와 ⑦)에서의 신호의 크기가 다른 부분보다 크게 나타나고 있으며 회전속도가 증가함에 따라 ⑥보다 ⑦의 크기가 약간 더 높게 나타난다. 그러나 B형 운전에서는 베어링부에 손상으로 인한 ⑥부분의 신호크기가 축의 회전속도가 증가할수록 증가하는 것이 주목된다(Fig. 7). 이러한 현상은 다른 이상조건(C형에서 F형까지)에서도 유사하게 나타나는 것으로 관찰된다(Table 1). 동일한 RMS값을 1800 rpm의 일정한 회전속도에서 이상상태 유형에 따라 비교한 Fig. 8과 9에서도 유사한 현상을 관찰할 수 있으며 이때 A형(정상운전)과 E형에서만 ①에서의 신호가 ⑥보다 약간 높게 나타나고 있다. 전

Table.1 Comparison of X component RMS acceleration for various rpm and sensor location acceleration(g)

rpm	Sensor location	Operation type					
		A	B	C	D	E	F
900	⑥	3.91	2.15	3.02	2.06	2.35	2.44
	⑦	2.92	1.92	2.53	1.94	2.31	1.94
	①	0.83	0.74	1.24	0.80	1.22	1.33
	②	1.01	0.73	0.96	0.78	0.96	1.33
	③	0.85	0.66	0.80	0.74	0.76	1.02
	④	0.83	0.75	2.04	0.72	0.82	1.02
	⑤	6.17	4.51	5.88	3.84	5.44	4.04
1800	⑥	3.80	5.66	6.06	4.32	6.48	6.83
	⑦	4.22	5.13	5.24	3.60	7.69	5.66
	①	2.26	1.53	2.06	1.77	2.25	3.22
	②	1.69	1.74	1.84	1.54	1.95	3.22
	③	1.32	1.36	1.42	1.65	1.75	3.35
	④	1.66	1.67	1.82	1.38	1.76	3.35
	⑤	9.52	16.68	15.72	13.99	18.97	15.61
3600	⑥	6.52	12.07	9.99	7.20	8.13	13.96
	⑦	8.17	8.85	9.98	7.50	6.81	11.67
	①	1.79	2.99	3.99	3.20	2.98	4.26
	②	1.86	3.18	2.96	3.04	2.57	4.26
	③	2.49	2.85	2.48	2.61	2.16	3.74
	④	2.72	3.34	2.82	3.03	2.23	3.74
	⑤	10.67	29.53	21.04	26.42	23.04	21.28




Fig. 8 X component RMS acceleration for type A through D(1800 rpm)

동기축과 직접 연결되고 커플러 이전에 하우징에 해당하는 ①점은 전동기의 직접적인 영향으로 상당히 높게 나타나고 있다.

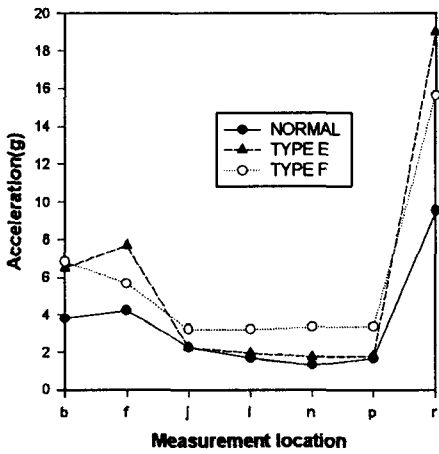


Fig. 9 X component RMS acceleration for type A, E and F(1800 rpm)

4.2 신경망시스템 분석

전술한 바와 같이 1개 또는 2개 일정한 수의 센서가 부착되어 해당되는 지점에서 얻어진 자료는 RMS 값으로 변환되어 신경망시스템에 활용된다. 복잡한 원인으로 발생하는 여러가지 이상운전상태를 구분하기 위하여 3개 까지의 이상을 진단하는 시스템이 도입되었다. 앞에서 언급한 바와 같이 사용된 신경망의 구조는 a-b-c 또는 a-b-b-c의 유형으로 입력층의 뉴런수는 각 측정점에서의 3 축방향의 가속도 값으로 결정되며 1개 측정점에서는 3개, 2개의 측정점에서는 6개의 뉴런이 사용되었다. 출력층의 구성은 1개의 이상과 정상상태를 구별하는 경우에는 2개, 2개의 이상상태에서는 3개(정상, 제 1 이상, 제 2 이상), 3개의 이상상태를 적용시킨 경우에는 4개(정상, 제 1 이상, 제 2 이상, 제 3 이상)가 사용되었다. 각 층의 node수의 조합의 한 예로 1개의 측정점과 1개의 이상의 경우에는 3 x 8 x 2 이다.

(1) 1개 측정점과 1개의 이상상태

앞에서 언급한 바와 같이 5가지의 이상상태에 대한 경우 정상운전상태와 구별할 수 있는지의 여부를 Fig. 4에서 표시한 지점 중 특징적으로 자료가 추출되며 유사한 지점을 배제한 ㉔, ㉕, ㉖, ㉗, ㉘, ㉙, ㉚의 7개소 각각에 대하여 비교하였다. 신경망은 3축방향 가속도 3개의 자료에 대한 입력소자(input node)로 입력되어 출력에서 정상 및 이상상태로 구분되어 학습되었으며 학습완료후 학습에 참여되지 않은 자료를 사용하여 신경망시스템의

예측률을 검증한 결과 측정개소의 종류(7)와 이상상태의 종류(5)의 가능한 조합인 35가지의 경우에 대하여 예측한 결과를 얻었으며 각 측정점과 이상상태의 종류를 기준으로 계산한 평균예측률이 Table 2에 나타나 있다. 전반적으로 예측률이 높게 나타났으나 측정위치기준으로 전동기에 근접한 ㉔부분이 약간 저조하였고(Table 2(b)) 900rpm에서는 다른 운전속도에 비하여 평균예측률이 낮게 나타났(Table 2(c)). 한 개의 측정점을 기준으로 검증한 경우에는 1개소에서 측정된 다른 환경에서의 이상상태의 경우를 조합하여 2개 및 3개의 이상상태의 경우에 적용하였다.

Table 2 Prediction rate(%) for single measurement location and single abnormality

(a) Rate at 1800rpm

rpm	Measurement location						
	Average	㉔	㉕	㉖	㉗	㉘	㉙
Average	97.9	100.0	99.5	100.0	100.0	99.5	86.3
B	99.6	100.0	100.0	100.0	100.0	97.5	100.0
C	99.8	100.0	98.8	100.0	100.0	100.0	100.0
D	99.8	100.0	98.8	100.0	100.0	100.0	100.0
E	90.2	100.0	100.0	100.0	100.0	100.0	31.3
F	100.0	100.0	100.0	100.0	100.0	100.0	100.0

(b) Average for various measurement location

rpm	Measurement location						
	㉔	㉕	㉖	㉗	㉘	㉙	㉚
900	79.3	93.3	88.3	76.0	80.7	80.0	84.0
1800	100.0	99.5	100.0	100.0	99.5	100.0	86.3
3600	95.7	99.0	100.0	99.7	98.0	99.7	89.0

(c) Average for abnormality type

rpm	Abnormality type				
	B	C	D	E	F
900	87.9	75.0	90.2	74.8	87.6
1800	99.6	99.8	99.8	90.2	100.0
3600	99.8	99.3	97.1	97.4	92.9

(2) 1개 측정점과 2개의 이상상태

동일한 지점 7개소에서 1지점을 선정하여 추출한 자료를 토대로 2가지의 이상상태를 모두 인지할 수 있는지의 여부를 시험하였다. 1800 rpm의 경우에 대한 결과는 Table 3(a)와 같다. 이상상태로는 C형과 F형의 조합이 88.7%, B형과 F형의 조합이 88.1%로 가장 높고 측정

지점으로는 ㉔과 ㉕가 각각 95.2% 및 92.1%로 높게 관찰되었다. Table 3(b)와 (c)에서 보는 것과 같이 전반적으로 900rpm의 회전속도에서는 평균예측률이 높지 않았으며 측정점을 기준으로 분석한 결과 ㉕, ㉔과 ㉖에서 1800rpm이상일 때 80% 이상의 높은 예측률 평균값을 기록하고 있다(Table 3(b)). 두 개의 이상상태를 조합한 결과 F형과 결합된 모든 이상상태가 회전속도 1800과 3600rpm인 경우에 80% 이상의 높은 평균예측률을 기록하고 있다(Table 3(c)). 즉 베어링의 외륜이 파손된 경우(F형)에는 또 다른 1개의 이상이 발생하더라도 각각을 잘 구분하여 예측할 수 있는 것으로 나타나고 있다.

(3) 1개 측정점과 3개의 이상상태

마찬가지로 1개 지점의 자료에 대하여 3가지의 이상상태를 동시에 판정할 수 있는 지의 여부를 점검하였으며 1800 rpm의 경우에 대한 결과는 Table 4(a)와 같다. 3개의 이상상태를 모두 판정하는 것은 1개의 지점을 선정할 때는 예측률이 80% 미만으로 나타나고 있으며 두드러지는 측정지점은 ㉕ 및 ㉖으로 각각 88.3%와 84.3%를 기록하고 있다. 측정지점을 기준으로 분석한 결과인 Table 4(b)에 의하면 측정지점 ㉕, ㉖와 ㉖에 대하여 1800과 3600rpm의 경우 70%를 상회하여 비교적 예측률의 평균값이 우수하게 나타나고 있다. 판별하고자 하는 이상상태의 수가 증가할수록 예측률이 저조하게 되는 것으로 지금까지의 분석결과를 통하여 알 수 있는데 이러한 이상상태가 1개의 측정지점에 대하여 3개를 구분하고자 하는 경우에는 2개의 경우와 유사하게 F형과 또 다른 2가지의 이상이 조합될 경우 C+E+F가 1800rpm에서

태를 동시에 판정할 수 있는 지의 여부를 점검하였으며 1800 rpm의 경우에 대한 결과는 Table 4(a)와 같다. 3개의 이상상태를 모두 판정하는 것은 1개의 지점을 선정할 때는 예측률이 80% 미만으로 나타나고 있으며 두드러지는 측정지점은 ㉕ 및 ㉖으로 각각 88.3%와 84.3%를 기록하고 있다. 측정지점을 기준으로 분석한 결과인 Table 4(b)에 의하면 측정지점 ㉕, ㉖와 ㉖에 대하여 1800과 3600rpm의 경우 70%를 상회하여 비교적 예측률의 평균값이 우수하게 나타나고 있다. 판별하고자 하는 이상상태의 수가 증가할수록 예측률이 저조하게 되는 것으로 지금까지의 분석결과를 통하여 알 수 있는데 이러한 이상상태가 1개의 측정지점에 대하여 3개를 구분하고자 하는 경우에는 2개의 경우와 유사하게 F형과 또 다른 2가지의 이상이 조합될 경우 C+E+F가 1800rpm에서

Table 3 Prediction rate(%) for the combination of one measurement location and two abnormal status

(a) Rate at 1800rpm

Combination of abnormal status	Measurement location							
	Average	㉔	㉕	㉖	㉗	㉘	㉙	㉚
Average	78.8	81.4	92.1	78.6	66.7	95.2	81.5	56.2
B+C	76.7	100.0	82.2	86.7	58.9	91.1	62.2	55.6
B+D	74.4	90.0	93.3	76.7	33.3	97.8	73.3	56.7
B+E	71.9	66.7	96.7	70.0	60.0	94.4	87.8	27.8
B+F	88.1	84.4	93.3	100.0	70.0	100.0	95.6	73.3
C+D	74.3	86.7	90.0	76.7	64.4	85.6	65.6	51.1
C+E	74.4	66.7	87.8	60.0	74.4	90.0	75.6	66.7
C+F	88.7	100.0	92.2	86.7	86.7	98.9	78.9	77.8
D+E	72.4	58.9	96.7	62.2	60.0	94.4	90.0	44.4
D+F	86.8	93.3	93.3	100.0	63.3	100.0	87.8	70.0
E+F	80.8	67.8	95.6	67.8	96.7	100.0	98.9	38.9

(b) Average for various measurement location

rpm	Measurement location							
	㉔	㉕	㉖	㉗	㉘	㉙	㉚	㉛
900	64.2	79.4	77.1	63.5	73.2	62.4	75.8	
1800	81.4	92.1	78.6	66.7	95.2	81.5	56.2	
3600	77.6	85.2	89.5	93.3	86.4	91.5	82.3	

(c) Average for abnormality type

rpm	Abnormal operation type										
	B+C	B+D	B+E	B+F	C+D	C+E	C+F	D+E	D+F	E+F	
900	66.5	70.7	64.2	77.1	79.6	53.9	69.3	67.7	83.3	75.5	
1800	76.7	74.4	71.9	88.1	74.3	74.4	88.7	72.4	86.8	80.8	
3600	88.1	76.6	80.6	92.2	83.9	85.1	94.6	81.1	89.9	93.5	

Table 4 Prediction rate(%) for the combination of one measurement location and three abnormal status

(a) Rate at 1800rpm

Combination of abnormal status	Measurement location							
	Average	㉔	㉕	㉖	㉗	㉘	㉙	㉚
Average	70.1	78.3	88.3	70.8	50.8	84.3	67.2	51.3
B+C+D	61.8	91.7	75.0	69.2	25.0	80.0	45.8	45.8
B+C+E	69.2	75.0	81.7	70.0	62.5	87.5	70.8	36.7
B+C+F	70.7	95.0	87.5	88.3	50.0	50.0	50.0	74.2
B+D+E	66.4	63.3	96.7	65.8	50.8	76.7	74.2	37.5
B+D+F	76.2	92.5	91.7	87.5	50.0	94.2	50.0	67.5
B+E+F	72.6	67.5	92.5	71.7	50.0	90.8	89.2	46.7
C+D+E	65.1	67.5	81.7	64.2	46.7	84.2	79.2	32.5
C+D+F	72.1	85.8	93.3	70.8	50.0	90.0	50.0	65.0
C+E+F	68.5	76.7	90.0	50.0	50.0	92.5	71.7	48.3
D+E+F	78.6	68.3	93.3	70.0	72.5	96.7	90.8	58.3

(b) Average for various measurement location

rpm	Measurement location							
	㉔	㉕	㉖	㉗	㉘	㉙	㉚	㉛
900	56.3	70.8	68.3	48.5	67.2	47.7	63.7	
1800	78.3	88.3	70.8	50.8	84.3	67.2	51.3	
3600	61.6	73.3	80.3	85.0	76.5	84.0	62.6	

(c) Average for abnormality type

rpm	Abnormal operation type										
	B+C+D	B+C+E	B+C+F	B+D+E	B+D+F	B+E+C+D	C+D+E	C+D+F	C+E+D+E	D+E	
900	53.2	57.9	69.1	53.4	65.0	63.1	49.6	69.0	54.3	68.8	
1800	61.8	69.2	70.7	66.4	76.2	72.6	65.1	72.1	68.5	78.6	
3600	66.7	72.6	85.7	61.1	71.3	83.0	71.1	74.4	83.6	78.2	

Table 5 Prediction rate(%) for the combination of two measurement spots and three abnormal status

(a) B+E+F (900rpm)

	(b)	(f)	(j)	(n)	(r)
(b)					
(f)	50.0				
(j)	92.5	91.9			
(n)	48.8	88.8	91.9		
(r)	86.3	66.9	84.4	88.8	

(b) C+E+F (900rpm)

	(b)	(f)	(j)	(n)	(r)
(b)					
(f)	85.6				
(j)	86.3	93.8			
(n)	81.9	89.4	85.0		
(r)	81.9	50.0	50.0	50.0	

(c) B+E+F (1800rpm)

	(b)	(f)	(j)	(n)	(r)
(b)					
(f)	79.4				
(j)	74.4	96.9			
(n)	70.6	99.4	100.0		
(r)	78.8	76.3	83.1	78.8	

(d) C+E+F (1800rpm)

	(b)	(f)	(j)	(n)	(r)
(b)					
(f)	88.8				
(j)	41.3	97.5			
(n)	75.0	97.5	96.9		
(r)	68.8	76.3	55.6	80.0	

(e) B+E+F (3600rpm)

	(b)	(f)	(j)	(n)	(r)
(b)					
(f)	50.0				
(j)	50.0	96.9			
(n)	50.0	98.8	94.4		
(r)	90.6	67.5	64.4	53.1	

(f) C+E+F (3600rpm)

	(b)	(f)	(j)	(n)	(r)
(b)					
(f)	50.0				
(j)	50.0	96.3			
(n)	85.6	96.3	98.1		
(r)	71.9	63.1	53.1	51.3	

68.5%를 나타내는 경우를 제외하고는 회전속도 1800과 3600rpm의 고속의 경우 모두 70% 이상의 평균예측률을 기록하고 있다(Table 4(c)).

(4) 2개 측정점과 3개의 이상상태

가장 복합적인 경우에 대한 진단을 위하여 2개소의 측정지점에 대한 3가지의 이상상태를 판단하는 시스템을 구성하였다. 센서가 설치되는 측정지점은 앞에서의 7개소에서 ①과 ②를 제외한 5개소에 대하여 분석하였다. 가

능한 이상상태조건의 종류로 볼이 파손되는 경우는 제외하고 내외륜의 이상(E형, F형)에 대하여 리테이너가 1군데(B형) 또는 2군데(C형)가 파손되는 경우를 각각 고려하여 시험하였다. 1800 rpm의 경우 B형, E형 및 F형이 조합된 경우와 C형, E형 및 F형이 조합된 경우 모두 ①와 ②, ③와 ④ 그리고 ①와 ⑤에 대하여 96.9%, 99.4% 및 100%와 97.5%, 97.5% 및 96.9%로 가장 우수하게 나타나고 있다. 다른 모든 회전수를 고려한 결과 측정지점의 조합이 ③와 ①, ③와 ⑤ ①와 ⑤인 경우가 최저 88% 이상의 예측률을 보이고 있어 우수한 것으로 나타나고 있다.

전반적으로 이상상태의 가짓수가 증가할 수록 예측률이 저하되었으며 ③와 ④에 센서를 설치하여 자료를 취득한 것을 활용하는 경우에 높은 예측률을 기대할 수 있었으며 ①에서 얻어진 자료는 신호세기에 비하여 예측률을 크게 높이지는 못하는 경향으로 분석되었다(Fig. 10-12).




Fig. 10 Prediction rate for one sensor and various abnormality (900 rpm)

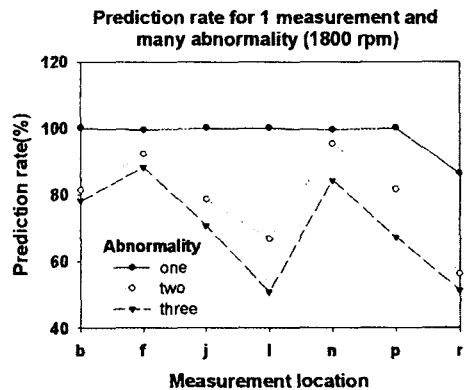


Fig. 11 Prediction rate for one sensor and various abnormality (1800 rpm)






Fig. 12 Prediction rate for one sensor and various abnormality (3600 rpm)

### 5. 결 론

본 연구에서는 볼베어링으로 지지된 회전축에 대하여 여러 가지의 이상상태에 대한 진단 및 검증기술을 확보하기 위한 연구를 수행하여 적은 수의 이상상태에 대하여는 상당한 정도로 진단이 가능하였고 이상상태가 증가할수록 이를 효율적으로 파악하기 위한 최적의 시스템을 구축하기 위한 자료를 도출하였으며 이를 요약하면 다음과 같다.

- 볼베어링으로 지지된 회전축시험시스템을 구축하였다.
- 시스템 상태 검증을 위한 신경망시스템을 구축하였으며 이를 효과적으로 활용하기 위한 전처리기를 개발하였다.
- 측정지점과 이상상태를 다양하게 조합하여 가장 민감하고 효과적인 센서의 위치를 결정하기 위한 과정을 시험하였다.
- 진단 및 검증을 위한 가장 최적의 시스템인자를 선정하

기 위한 기반연수를 수행하였다.

본 연구에서는 이상운전상태를 각각 독립된 환경에서 조합하여 적용시켰으므로 실제적으로 2개 이상의 비정상적인 운전상태가 동시에 발생한 경우에 대하여 적용이 가능한지 여부에 대한 비교연구가 이루어져야 할 것이다.

### 참 고 문 헌

1. 김완두, "축경사가 볼 베어링의 피로수명에 끼치는 영향에 관한 연구," 서울대학교 박사학위 논문, 1993.
2. Tae Jo Ko and Dong Woo Cho, "On the Monitoring of Single Crystal Diamond Tool Wear in Ultra-Precision Machining by Fuzzy Pattern Recognition Technique," '91 대한기계학회 추계학술대회 논문집 (I), 1991, pp. 218-222.
3. 유송민, 김영진, "가공공정의 이상상태 진단을 위한 진단전문가 시스템의 개발," 한국정밀공학회 논문, 1997.
4. Kim, Y., "A Framework for an On-Line Diagnostic Expert System for Intelligent Manufacturing," Expert Systems with Applications, An International Journal, 1995.
5. Young-jin Kim, "A Framework for On-Line Diagnostic Expert System with Intelligent Sensor Validation," KSME Journal, vol 9, No.1, Mar. 1997.