

신경망을 이용한 회전축의 이상상태 진단에 관한 연구

유송민 · 박상신*

경희대학교 기계산업시스템 공학부

*영남대학교 기계공학부

A Study on the Neural Network Diagnostic System for Rotating Machinery Failure Diagnosis

Songmin Yoo and Sang-Shin Park*

College of Mechanical and Industrial System Engineering, Kyunghee Univ. Soowon, Korea

*School of Mechanical Eng. Yeungnam Univ. Gyungsan, Korea

Abstract – In this study, a neural network based diagnostic system of a rotating spindle system supported by ball bearings was introduced. In order to create actual failure situations, two exemplary abnormal status were made. Out of several possible data source locations, ten measurement spots were chosen. In order to discriminate multiple abnormal status, a neural network system was introduced using back propagation algorithm updating connecting weight between each nodes. In order to find the optimal structure of the neural network system reducing the information sources, magnitude of the weight of the network was referred. Hinton diagram was used to visually inspect the least sensitive weight connecting between input and hidden layers. Number of input node was reduced from 10 to 7 and prediction rate was increased to 100%.

Key words – rotating spindle, diagnostic system, neural network, Hinton diagram.

1. 서 론

볼 베어링을 이용한 회전축은 발전기 터빈, 고정밀 공작기계등에 많이 응용되고 있으며 회전기기에 근간을 이루고 있다. 이러한 회전축에 이상이 생긴 경우에 이상을 방지하고 계속 사용하게 되면 기계전체의 파손을 가져올 수 있으므로 이상상태를 진단하고 예측하기 위한 연구가 꾸준히 지속되어 왔으며 특히 전문가시스템을 이용하여 이러한 이상상태의 추론 법칙을 확립하고, 실제기계가 작동 중에 컴퓨터에 의한 이상유무의 판단 및 작동정지, 이상상태의 출력 등을 자동화시키는 연구가 최근에 이루어지고 있다[1-3].

이러한 진단시스템은 극한상황, 즉 깊은 지하에서 작동하는 핵프 또는 우주 공간에서 작동하는 회전축과 같은 상황하에 원거리에서 이상유무를 판단할 수 있는 시스템 개발의 기초가 될 수 있다. 또한 수력, 화력 발전소나 핵발전소 등과 같이 대형의 회전축의

이상이 생겼을 경우에 경제적 손실은 기하학적이라 볼 수 있기 때문에 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 될 수 있다.

진단시스템을 구축함에 있어 복합적인 정보를 비선형적인 관계에 국한됨이 없이 입출력관계로 지정할 수 있는 신경망(neural network) 기법을 응용하는 연구가 활발하게 진행되고 있다. 생물체의 정보전달체계를 모방한 신경망시스템은 정보의 인식, 분류 및 진단 등의 목적으로 활용되며 산업, 의료 및 국방분야 등에 실용적으로 적용되고 있다[4]. 그 중에 가장 널리 사용되고 있는 용도는 어떠한 대상체를 인식, 구분 및 판별하는 것으로서 사례로는 생산되는 물품

의 이상 및 정상 여부를 판별하는 것으로서 물체의 윤곽 형상에 의하여 양·불량여부를 판별하며 공정 중의 수집되는 신호를 근거로 공정의 비정상적인 작동여부를 진단하기도 한다[5].

이러한 신경망시스템을 정상적으로 작동시키기 위하여 신경망의 입력력 및 전달단자의 구성형태와 연산과정에 관여하는 연결가중치가 우선 결정되어야 하지만 분석에 사용되는 입력인자가 많을수록 시스템이 복잡해지고 계산량이 방대하여 결과분석을 위한 시간이 많이 소요된다. 따라서 이러한 시스템구축에 필수적인 최소한에 가중치를 활용하여 구조를 최소화시키는 것이 중요하다. 일반적으로 입력인자의 출력인자와의 관련성(saliency, relevancy), 중요도(importance) 또는 계산결과에 미치는 영향을 나타내는 민감도(sensitivity)는 가중치의 크기와 관련이 있는 것으로 나타나고 있다[6]. 신경망은 관련성, 중요도 및 민감도가 작은 요소의 역할을 최소화시키지만 이들의 역할을 배제하거나 구분하는 기능이 없으므로 이러한 요소가 포함되면 전체적인 시스템의 분석, 판단 및 예측능력이 저하된다[7]. 출력인자에 미치는 영향이 적은 요소를 제외한 최소한의 필수 인자만을 선별하여 구성한 신경망은 시스템의 크기가 저하되어 연산시간이 감소되며 이상상태와 정상 상태를 구분하는 판단능력이 저하되지 않고 오차도 증가하지 않는 것으로 나타났다. 또한 필요한 자료만 선별하여 사용하므로 추후에 자료수집비용을 절감할 수 있으며 최소한의 입력뉴런인자로 최대한의 정보를 추출할 수 있다[8]. 적용사례로서 롤러베어링을 장착한 회전기기 시스템에서 6개의 입력인자별로 가중치의 절대값 크기에 의한 민감도를 기준으로 2개의 인자를 제외한 4개의 입력인자를 선정한 결과 기기의 이상상태를 성공적으로 진단하였다 [9]. 가중치 제곱합으로 표시되는 민감도지수도 제시되어 적외선 목표물인식에 사용되었는데 입력인자가 9개이었고 분석결과 민감도가 낮은 인자를 3개까지 제거하여도 신경망의 인식성능이 저하되지 않았다[10].

본 연구에서는 볼 베어링으로 지지된 회전축의 이상을 베어링 내륜의 파손, 외륜의 파손으로 나누어 각각의 경우에 나오는 음향방출 신호를 측정하고, 정상상태에서의 신호들과 비교 분석을 통해 이상상태의 유형을 예측할 수 있는 시스템을 구축하고자 한다.

2. 신경망구성 및 민감도분석

신경망이란 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 외관에 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 학습데이터가 필요하며 학습 또한 쉽지 않다는 것이다. 신경망은 상호 연결된 병렬처리소자의 집합체로 생각할 수 있으며, 처리소자사이의 연결강도는 신경망이 부여하는 정보의 중요성을 나타낸다. 신경망을 이용한 자료의 활용과정은 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.

본 연구에서는 감독학습법 중 다층구조의 오차역전파(error backpropagation)방식의 시스템을 사용하며 이의 적용순서는 다음과 같다. 첫째, 목적에 맞는 데이터를 선택하여 데이터집단을 구성한다. 둘째, 부적

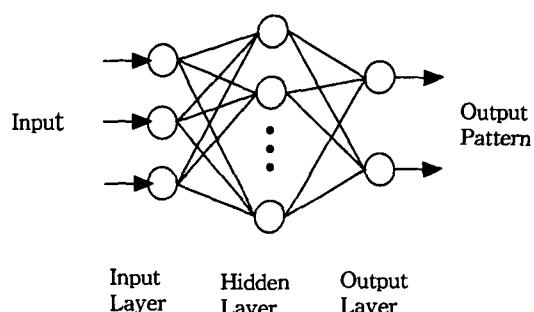


Fig. 1. Multilayer neural network.

합한 데이터를 제거하며 적정한 형태로 처리한다 (preprocessing). 셋째, 처리된 데이터집단을 학습용과 진단용으로 구분한다. 넷째, 제시된 입력자료의 수와 결정하고자 하는 판단결과의 수를 고려하여 신경망의 구조를 결정한다. 다섯째, 학습용 자료를 사용하여 제안된 신경망의 구조를 학습시킨다. 여섯째, 완성된 신경망을 사용하여 성능을 평가한다. 가중치 w_{ij} 를 결정하는 학습법은 오차의 자승합 E 및 가중치 η 에 대한 다음 식을 기초로 한다. 즉

$$\Delta w_{ij} = -\eta \frac{\delta E}{\delta w_{ij}} \quad (1)$$

총간을 연결하는 가중치의 중요도를 표시하는 기준으로 민감도지수(sensitivity coefficient)가 여러 가지의 형태로 정의되었다. 첫 번째 종류의 민감도지수는 일반적으로 가중치가 큰 경우에는 결과에 큰 영향을 미치며 이러한 가중치에 연결된 입력인자는 중요도가 큰 것으로 판단됨에 근거한 것이다[11].

따라서 가중치의 일반함수형태로 표현되며 가장 간단한 경우에는 입력인자총과 연결되는 은닉층간에 연결되는 가중치의 부호와 크기를 표시한 힌턴도표 (Hinton diagram)[7]를 이용하여 가시화시키며 이때 가중치의 배열형태에 따라 크기로서 민감도를 판단한다. 힌턴도표법과 함께 가중치의 절대값이나 각각의 입력인자에 연결되는 가중치의 합을 최대치로 나누어 상대적인 크기, S 를 표시하는 방법이 이용되었으며 제외되는 입력인자를 설정하는 별도의 규칙이 설정되기도 하였다[12]. 즉

$$S = \frac{w_{ij}}{|w_{ij}|_{max}} \quad (2)$$

단 w_{ij} 는 입력과 은닉층을 연결하는 가중치이다.

실험자료분석을 위하여 측정된 자료를 신경망에 적용시키기 위한 전처리과정으로서 신호의 분산정도를 나타내는 RMS(root mean square)를 사용하였다.

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

이때 x_i , μ 와 n 은 각각 측정자료값, 평균과 계산자료수를 나타낸다.

3. 실험장치의 구성

볼베어링으로 지지된 회전축시스템을 구성하기 위

하여 두 개의 하우징내에 설치된 볼베어링으로 지지된 축을 제작하여 설치하였다. 볼베어링은 FAG사의 호칭번호 6008 깊은 홈 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 사용함으로써 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 제반 영향을 최대한 감소시키도록 하였다. Fig. 2는 이러한 시스템 구성도를 나타내고 Fig. 3은 제작된 실험장치의 모습이다. Fig. 4는 이 시스템에서의 센서의 부착이 가능한 각 측정지점을 표시하고 있다. 본 실험에 사용된 동력원으로 후지사의 500 W 급 100 V 단상

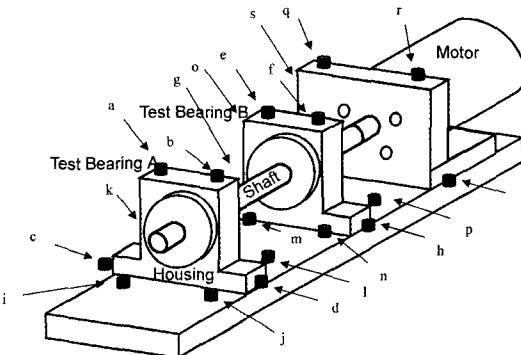


Fig. 2. System layout.

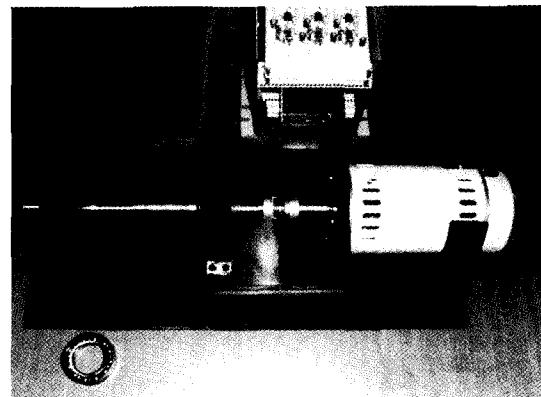


Fig. 3. Experimental Setup.

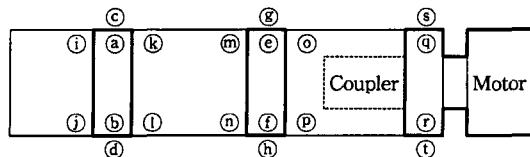


Fig. 4. Measurement locations.

전동기를 사용하였으며 이러한 시스템의 운전조건으로서 베어링축의 회전수는 900, 1800, 3600 rpm으로 설정되었으며 분석결과 가장 효율적으로 활용될 수 있는 1800 rpm에서의 자료를 사용하였다.

설정된 각각의 운전조건에 대하여 음향방출(AE : Acoustic Emission) 측정센서를 부착하였으며 운전상태의 변화에 따른 신호의 변화를 증폭기를 통하여 컴퓨터에 수록하였다. Fig. 2에 표시된 센서부착 가능지점 중에서 중복성을 피하고 변별력이 있는 특징 신호를 추출하기 위하여 10개소(Fig. 4의 ⑥, ⑦, ⑧, ⑨, ⑩, ⑪, ⑫, ⑬, ⑭, ⑮지점)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)
 - ⑤ 베어링의 내륜의 파손(B형)
 - ⑥ 베어링의 외륜의 파손(C형)

본 실험에서는 Fig. 4에서 ⑮지점 하우징에 설치된 볼베어링을 분해하여 필요한 부분을 손상시킨 후 재조립하여 회전축을 지지하도록 함으로써 요구되는 이상상태에 상당하는 운전조건을 인위적으로 조성하였다. 내륜과 외륜을 정량적인 크기로 파손시키기 곤란하여 Φ 2 드릴로 볼의 안내면을 일정시간(3분) 가공하여 흡에 손상을 주었다.

4. 실험자료분석

본 연구에서는 볼베어링으로 지지된 회전축의 이상 상태를 가장 효과적으로 진단할 수 있도록 신경망 기법을 도입하여 적용시킨다. 신경망의 구조를 가장 효율적으로 설계하기 위하여 Fig. 4에 나타난 바와 같이 측정 가능한 지점 20개소에서 대칭부를 제외한 10개소에 대한 음향방출신호를 측정하여 자료를 확보하-

였으며 이를 바탕으로 이상상태를 가장 효과적으로 진단할 수 있는 주요 측정지점을 결정하고자 한다.

인위적으로 조성된 2개의 이상상태에 대하여 각각의 이상운전상황 발생시 독립적으로 정상운전상태와 구분할 수 있는지를 판별하며 복합적인 이상운전상태를 가정하여 2개의 이상을 구별할 수 있는지의 여부를 확인한다.

4-1. 신호처리분석

Fig. 5는 실험결과로 얻어진 신호로서 시스템을

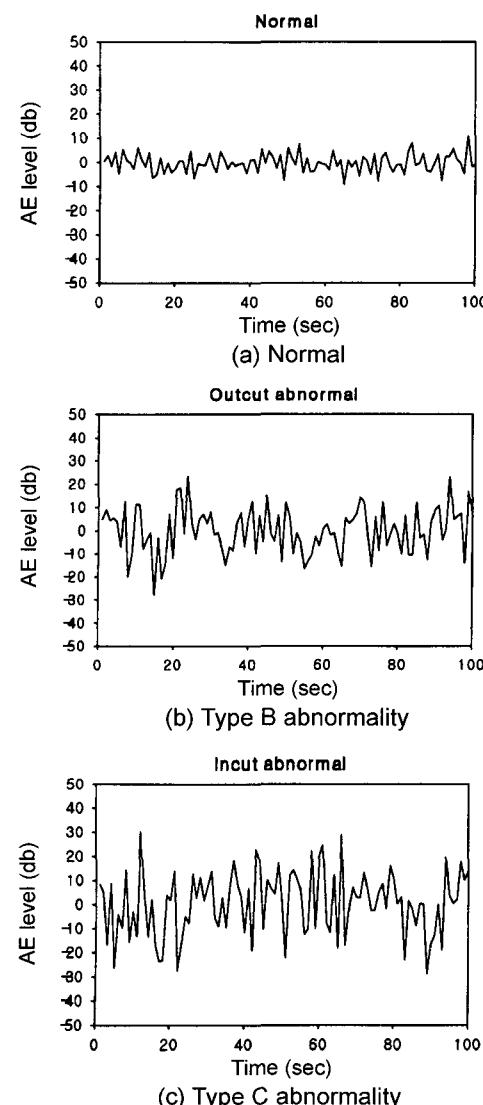


Fig. 5. Comparison of AE level measured at location (b) for various operating conditions.

Table 1. Comparison of AE level measured at 10 locations for various operating conditions

Status \ Location	(b)	(d)	(f)	(h)	(j)	(l)	(n)	(p)	(r)	(t)
Normal(A)	4.22	4.16	3.89	3.79	0.84	1.65	0.97	1.17	1.82	0.78
Incut(B)	13.88	8.92	4.10	4.87	6.05	3.55	5.56	4.23	5.05	5.05
Outcut(C)	10.72	9.82	5.56	7.75	12.33	12.33	2.97	2.97	5.59	5.59

1800 rpm에서 회전시킬 때 센서를 Fig. 4의 ⑤지점에 설치하여 측정된 AE 신호를 3가지의 운전상태에 대하여 나타낸 것이다. 대부분의 이상상태에서 신호는 정상운전상태에 비하여 크게 변화하고 있다. AE의 RMS 값이 신경망에 입력자료로 활용되기 때문에 이 RMS 값의 변화특성이 신경망시스템의 성능에 영향을 미칠 것이다. 이러한 AE 신호에 대하여 계산된 여러 RMS 값들의 평균이 Table 1에 나타나 있다. AE 수치의 경향을 센서의 설치지점, 이상유형의 변화에 따라 비교한다. 이러한 변화특성을 비교하기 위하여 센서의 측정지점위치에 대한 RMS 값의 경향이 표시되었다(Fig. 6).

Fig. 6에서와 같이 정상적인 운전상태에서는 베어링을 포함하고 있는 두 개의 하우징부분(Fig. 4의 ⑤와 ⑥)에서의 신호의 크기가 다른 부분보다 크게 나타나고 있다. 내륜에 이상이 있는 경우에는 손상폐어링이 장착된 하우징부인 ⑤, ⑥, ⑦부의 RMS값의 증가가 주목할 만하며 전동기와 커플러로 연결된 하우징부에 신호도 약간 증가하는 것으로 나타나고 있다. 외륜을 손상시킨 경우에는 이러한 경향이 좀 더 두드러지게 나타나고 있으며 전동기와 연결된 하우징에서는 내륜의 경우와 유사한 수준에 증가를 보이고 있다.

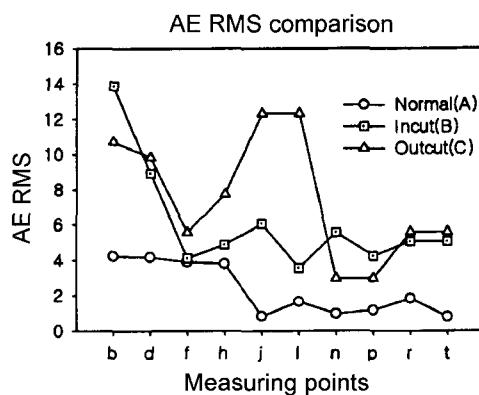


Fig. 6. AE RMS comparsion.

4-2. 신경망시스템 분석

전술한 바와 같이 10개 지점에서 얻어진 AE 신호는 RMS 값으로 변환되어 신경망시스템에 활용된다. 복합적인 원인으로 발생하는 여러가지 이상운전상태를 구분하기 위하여 2개까지의 이상을 진단하는 시스템이 도입되었다. 사용된 신경망의 구조는 2개의 은닉층을 가진 a-b-b-c의 유형으로 입력층의 뉴런수는 측정지점의 수와 동일한 10개이다. 출력층의 구성은 1개의 이상과 정상상태를 구별하는 경우에는 2개, 2개의 이상상태에서는 3개(정상, 제 1 이상, 제 2 이상)로 구성하였다. 각 층의 node수의 조합의 한 예로 10개의 측정점과 2개의 이상의 경우에는 $10 \times 8 \times 8 \times 3$ 이다.

(1) 1개 이상상태

내륜 또는 외륜의 손상으로 인한 이상신호를 RMS로 처리하여 신경망에 적용하였으며 각각의 경우 적용된 신경망의 구조는 $10 \times 8 \times 8 \times 2$ 이다. 학습된 가중치를 토대로 시험자료에 적용시킨 결과 각각 100%의 인식률을 보였다. Figs. 7-8은 이때 사용된 가중치의 상대적인 크기를 도식한 힌턴도표이며 내륜 이상의 경우에는 3, 4번째(Fig. 4에서 ⑤, ⑥) 외륜이상의 경우에는 3, 9, 10(Fig. 4에서 ⑤, ⑨, ⑩)번째의 가중치가 상대적으로 작은 것을 알 수 있다.

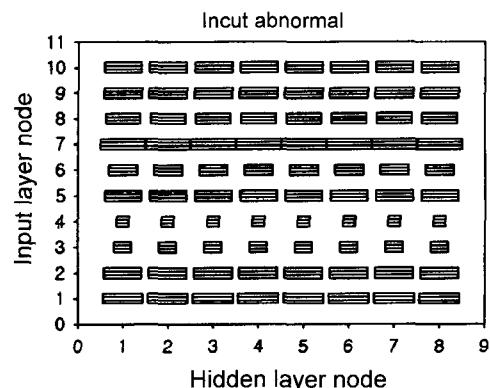


Fig. 7. Hinton diagram for type B abnormality.

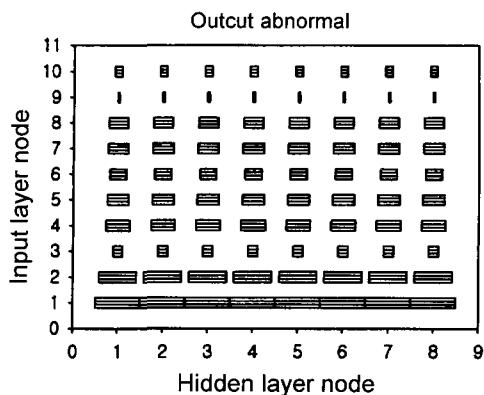


Fig. 8. Hinton diagram for type C abnormality.

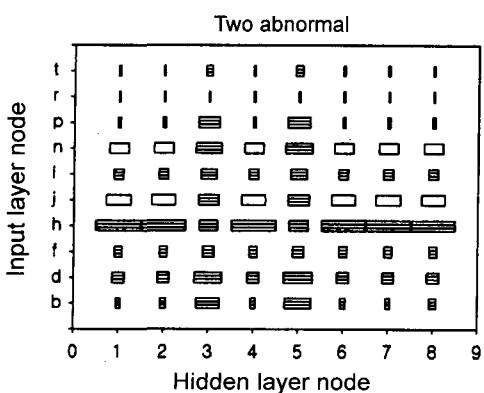


Fig. 9. Hinton diagram for two abnormal case.

(2) 2개의 이상상태

측정지점 10개소에서의 자료를 토대로 2개의 이상상태를 예측할 수 있도록 하기 위하여 신경망을 구성하여 적용시킨 결과 60개의 시험자료에 대한 예측률이 68.3%로 나타났으며 이 경우에 힌턴도표를 통한 가중치의 상대적인 중요도를 Fig. 9에서 알 수 있다. 10개의 측정점을 모두 사용한 경우에 예측률이 저조하고 신경망의 구조가 복잡하므로 1개의 측정점에서의 자료를 제거하여 입력인자 9개의 새로운 구조의 신경망을 적용시켰다.

제외되는 측정지점과 적용된 구조에 따른 예측률이 Table 2에 나타나있다. 은닉층의 수를 최초에 설정된 8개에서 7, 6개로 변화시킨 3가지 신경망구조를 대상으로 적용시킨 결과 5번째의 인자(측정점 ①)를 제외시킨 경우에 예측률이 모두 크게 증가하였다. 그러나 은닉층의 수가 최소화된 9x6x6x3의 구조를 제외하고는 예측률이 100%에 이르지 않아 아직

Table 2. Prediction rate for various structure with single element removed

Prediction To remove	Network structure		
	9x8x8x3	9x7x7x3	9x6x6x3
⑤	66.7	51.7	70.0
⑥	66.7	69.3	65.0
⑦	68.3	69.3	68.3
⑧	35.0	35.0	35.0
⑨	98.3	81.7	100.0
⑩	66.7	61.7	65.0
⑪	70.0	68.3	58.3
⑫	65.0	68.3	60.0
⑬	68.0	68.3	53.3
⑭	48.3	46.7	70.0

Table 3. Prediction rate for various structure with two elements removed

Prediction To remove	Network structure		
	8x8x8x3	8x7x7x3	8x6x6x3
⑤	75.0	70.0	66.7
⑥	100.0	100.0	86.7
⑦	98.3	96.7	100.0
⑧	73.3	61.7	71.7
⑨	-	-	-
⑩	100.0	100.0	95.0
⑪	78.3	100.0	100.0
⑫	61.7	100.0	100.0
⑬	86.7	80.0	83.3
⑭	90.0	96.7	100.0

예측률이 충분히 높지 않은 것으로 나타났다. 제외된 ⑤점의 가중치크기는 Fig. 9 힌턴도표에 나타난 바와 같이 그다지 크지 않은 것으로 나타나고 있다.

다음단계에서는 제외된 ⑨번쨰의 인자이외에 제거될 수 있는 인자를 확인하기 위하여 추가적으로 한 개를 더 제거하여 총 8개의 입력신호에 대한 신경망에 적용결과 예측률을 판단한다. Table 3은 ⑨이외에 추가적으로 한 측정개소를 더 제외시켰을 때의 예측률로서 표시된 3가지 신경망구조에 대하여 ⑨을 제

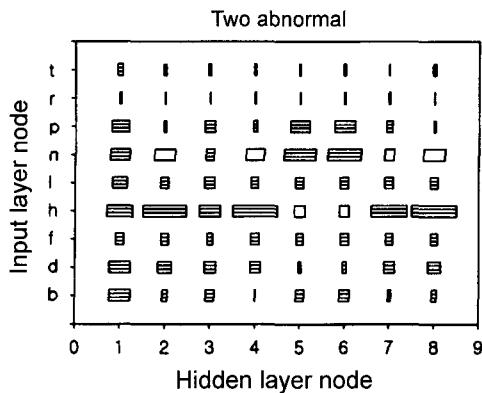


Fig. 10. Hinton diagram for two abnormal case(① removed).

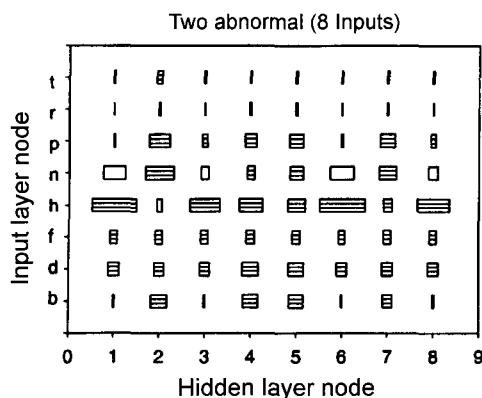


Fig. 11. Hinton diagram for two abnormal case(① , ② removed).

거시키는 경우에 대한 예측률이 가장 크게 개선되는 것으로 나타나고 있다. Fig. 10은 입력층과 은닉층의 수가 각각 8인 경우에 대한 힌턴도표를 나타내고 있다.

추가적으로 신경망의 구조를 축소하기 위하여 ① 와 ①이외에 제거되는 인자에 대한 예측률을 확인하였다. Table 4는 추가적으로 제거되는 3번째 인자와 신경망구조에 대한 예측률을 나타낸 것으로서 ⑥, ⑦, ⑧, ⑨를 제거하는 경우에는 예측률이 100%에 근접하여 우수한 반면 ⑩ 또는 ⑪를 제외시킬 경우에 예측률이 낮게 나타나 상대적으로 중요한 인자로 인식될 수 있다.

5. 결 론

볼베어링으로 지지되는 회전축에 대하여 내륜 또

Table 4. Prediction rate for various structure with three elements removed

Prediction To remove	Network structure		
	8x8x8x3	8x7x7x3	8x6x6x3
⑩	78.3	78.3	98.3
⑪	95.0	100.0	75.0
⑫	98.3	98.3	98.3
⑬	70.0	71.7	96.7
⑭	-	-	-
⑮	-	-	-
⑯	100.0	100.0	100.0
⑰	100.0	100.0	100.0
⑱	93.3	100.0	100.0
⑲	85.0	100.0	100.0

는 외륜의 손상에 따른 이상상태에 대한 진단기술을 확보하기 위한 연구를 수행하였으며 단일이상에 대하여는 100% 진단이 가능하였다. 복합적인 이상상태에 대하여 이를 효율적으로 파악하기 위한 최적의 시스템을 구축하도록 신경망의 구조를 축소하는 체계를 시도하였으며 이를 요약하면 다음과 같다.

(1) 볼베어링으로 지지된 회전축시험시스템을 구축하였으며 음향방출 신호를 여러 개소에 대하여 추출하였다.

(2) 시스템 상태 검증을 위한 신경망시스템을 구축하였으며 이에 자료를 효과적으로 활용하기 위하여 RMS 전처리기를 적용하였다.

(3) 시스템에 소요되는 측정지점을 최소화하기 위하여 중요도가 낮은 인자부터 제외시켰으며 이러한 과정의 타당성을 신경망의 층간을 연결하는 가중치의 상대적인 크기를 표시하는 힌턴도표를 통하여 검증하였다. 분석결과 중요도가 낮아 제외되었을 경우 시스템의 성능을 향상시키는 인자의 가중치크기는 다른 중요한 인자에 비하여 크지 않는 것으로 나타났다.

(4) 손상된 부위지점부근(Fig. 4의 ⑩⑪)에서 측정되는 자료의 중요도가 대체적으로 크게 나타났으나 일부의 경우에는 고정축(Fig. 4의 ⑫)에서의 자료도 중요한 것으로 확인되었다.

독립된 환경에서 조합하여 적용된 이상상태보다 실제로 2개 이상의 비정상적인 운전상태가 동시에 발생한 경우에 대하여 적용이 가능한지 여부에 대한

좀 더 많은 비교연구가 이루어져야 하겠다.

참고문헌

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. R.J. Schalkoff, *Pattern Recognition: Statistical, Structural and Neural Approaches*. John Wiley & Sons, Inc. 1988.
5. Rangwala S. and Dornfeld D. Sensor integration using neural network for intelligent tool conditioning monitoring, *Trans of ASME, J of Eng for Ind* 1990;112:219-228.
6. Hirose Y., Yamashita K. and Hijiya S. Back-propagation algorithm which varies the number of hidden units. *Neural Networks* 1991;4:61-66.
7. A.P Engelbrecht, I Cloete and J.M. Zurada, “Determining the Significance of Input Parameters Using Sensitivity Analysis,” International Workshop on Artificial Neural Networks, 382-288, 1995.
8. R. Naiminohasses, D.M. Barnett, D.A. Green and P.R. Smith, “Sensor Optimization using Neural Network Sensitivity Measures,” *Measurement Science and Technology*, Vol. 6, No. 9, 1291-1300, 1995.
9. Y. Shao, K. Nezu, K. Chen and X. Pu, “Feature Extraction of Machinery Diagnosis Using Neural Network,” 1995 International Conference on Neural Networks, 459-464, 1995.
10. J.M. Steppe and K.W. Bauer, Jr., “Feature Saliency Measures,” *Computers Math. Applic.* Vol. 33, No. 8, 109-126, 1997.
11. N.C. Hammadi and H. Ito, “A Learning Algorithm for Fault Tolerance Feedforward Neural Networks,” *IEICE Trans. INF & SYST.*, Vol E80-D, No. 1, 21-27, 1997.
12. F. Despagne and D. Massart, “Variable Selection for Neural Networks in Multivariate Calibration,” *Chemometrics and Intelligent Laboratory Systems*, Vol 40, No. 2, 145-163, 1998.