

신경회로망을 이용한 회전기계의 고장진단에 관한 연구

최 원 호·양 보 석*

효성중공업(주) · *부산수산대학교

(1992년 5월 10일 접수)

A Study on Defect Diagnosis of Rotating Machinery Using Neural Network

Won-Ho CHOI and Bo-Suk YANG*

Hyosung Industries Co., *National Fisheries University of Pusan

(Received May 10, 1992)

This paper describes an application of artificial neural network to diagnose the defects of rotating machinery. Induction motor was used to the object of defect diagnosis. For defect diagnosis, the frequency spectrum of vibration was utilized. Learning method of applied neural network was back propagation.

Neural network has following advantage ; Once it has been learned, inference time is very short and it can provide a reasonable conclusion regardless of insufficient input data. So, this defect diagnosis system can be used superiorly to rule based expert system as quality inspection of rotating machinery in the shop.

I. 서 론

산업플랜트에서 많이 사용되고 있는 회전기계의 경우, 성능향상을 위한 고속화와 원가절감을 위한 경량화의 추세에 따라 진동문제도 빈번히 발생하고 있다. 따라서 설비의 안정적인 운전을 위해 회전기계의 고장진단과 수명예측은 매우 중요하다. 회전기계에 전기 및 기계적 결함 또는 유체관련 문제가 발생하였을 경우, 이는 곧 바로 진동으로 나타남으로 진동신호를 통해 회전기계의 고장

을 분석·진단하는 것은 매우 유용하다. 그러나 이 고장진단은 주로 숙련된 전문가의 경험에 의존하여 해결하고 있지만, 진단자의 경험과 능력에 따라 진단결과가 크게 좌우되기 때문에 최근에 전문가의 경험지식을 이용한 룰에 기초한 전문가시스템(rule based expert system)에 관한 연구가 진행중이다. 그런데 기존의 전문가 시스템은 연결기구(man-machine interface)를 사용하여 step by step의 대화형식을 통해 결론에 도달함에 따라 이용자 역시 전문가 수준이어야 하며,

증가하는 데이터 처리문제, 그리고 예측하지 못한 상황에서의 해결방안도 문제가 된다. 그러나 인간 뇌의 처리기능과 구조를 수학적으로 아주 유사하게 모델링한 신경회로망(neural network)은 경험데이터를 학습(learning)함으로써 일반화(generalization)나 추론이 가능함에 따라 신경회로망을 이용할 경우, 종래의 전문가 시스템의 단점을 극복할 수 있다.

본 논문에서는 신경회로망을 이용한 회전기계의 고장진단 시스템 구축의 가능성을 검토한다. 고장진단 모델은 산업현장에서 회전기계로 가장 널리 사용되는 유도전동기를 사용하였다.

2. 신경회로망

2.1 유니트(unit)

Fig. 1은 인간의 신경세포인 뉴런을 나타내며, Fig. 2는 한개의 뉴런을 수학적 모델링한 것으로, 유니트라 한다. 이러한 유니트가 모여 그물망 모양으로 연결된(시냅스) 뉴로네트워크를 이룬다. 한 유니트에서의 출력은 실제 신경계통의 시냅스의 연결강도와 대응하는 결합계수(weight)와 곱해져 다른 유니트에 입력되고 더해져 NET값을 갖고 응답함수(F)에 의해 유니트의 출력(OUT)이 만들어 지며, 다시 또 유니트에 입력된다. 이 응

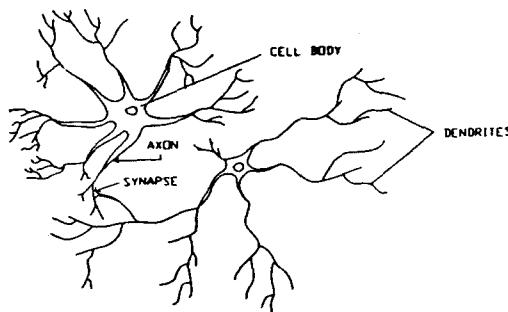


Fig. 1. Biological neuron.

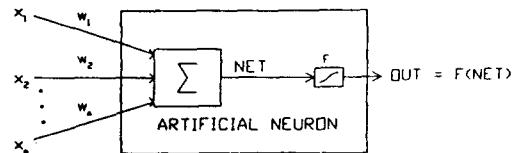


Fig. 2. Artifical neuron with activation.

답함수(activation function)는 NET 값에 의해 두 가지 상태값을 갖는 역차함수와 준선형의 포화형 응답특성을 갖는 시그모이드 함수가 있다.

2.2 네트워크 모델

네트워크는 유니트가 시냅스로 연결된 구조를 말하며, Fig. 3과 같이 상호결합형과 계층형네트워크가 있다. 본 연구에서는 유니트를 각층으로 그룹핑하여 같은 층내에는 결합이 없고 신호가 입력층에서 출력층으로만 전달되는 계층형네트워크를 사용하였다.

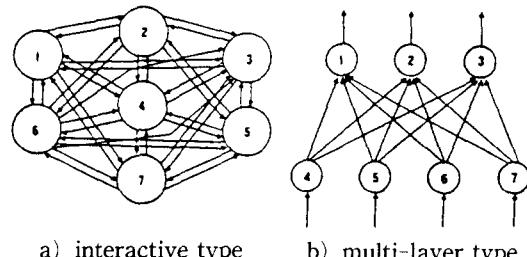


Fig. 3. Network model.

2.3 학습 알고리즘

신경회로망의 가장 큰 특징은 학습으로, 이는 어떤 입력에 원하는 출력을 얻을 수 있도록 결합계수를 최적화하는 것이다. 처음에 결합계수에 대한 지식이 없으면, 임의의 값을 설정하고 학습데이터를 입력하여 바라는 출력이 구해 지도록 결합계수를 최적화한다. 이때 출력을 교사신호와 비교 평가하여 유니트간의 결합계수를 조정하는 지도학습(supervised learning)과 외부 교사신호 없이

자기평가로 학습하는 자율학습(unsupervised learning)이 있다. 본 연구에 사용되는 학습 알고리즘은 교사신호와 출력신호의 제곱오차를 최소화하는 최대경사법을 이용하여 각층 사이의 결합계수를 조정하는 지도학습법을 채택하였다.

2.4 역전파 알고리즘(back propagation algorithm)

본 연구에 사용된 뉴로 네트워크는 Fig. 4와 같은 3층 구조이다. 그림에서 x_i^s 는 s 번째 입력패턴의 i 번째 값이고 h_{1l}^s , h_{2l}^s 는 각각 첫번째와 두번째 중간층의 s 번째 패턴에 대한 l 값으로 보통은 랜덤하게 초기화 된다.

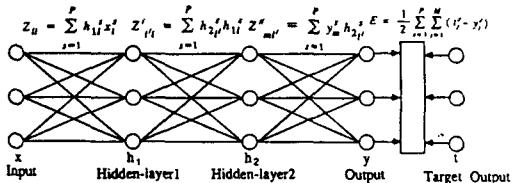


Fig. 4. Three-layer backpropagation.

y_m^s 는 s 번째 출력패턴의 m 번째 값이다. 또 Z_{li} 는 입력층의 i 번째와 첫번째 중간층의 l 번째 사이의 결합계수를 나타내고, Z'_{rl} 는 첫번째 중간층의 l 번째와 두번째 중간층의 l' 번째 사이의 결합계수를 나타낸다. 그리고 $Z''_{ml'}$ 는 두번째 중간층의 l' 번째와 출력층의 m 번째 사이의 결합계수이다.

각 층의 뉴런의 값은

$$\hat{h}_{1l}^s = \sum_{i=1}^N x_i^s Z_{li} \quad h_{1l}^s = f(\hat{h}_{1l}^s) \quad (1)$$

$$\hat{h}_{2l'}^s = \sum_{i=1}^L h_{1i}^s Z'_{rl} \quad h_{2l'}^s = f(\hat{h}_{2l'}^s) \quad (2)$$

$$\hat{y}_m^s = \sum_{l'=1}^L h_{2l'}^s Z''_{ml'} \quad y_m^s = f(\hat{y}_m^s) \quad (3)$$

와 같이 앞단의 값에 결합계수를 곱한 값의 합을 다시 비선형 응답함수에 의해 변경시킨 값이다.

$$f(x) = \frac{2}{1 + e^{-\xi x}} - 1 \quad (4)$$

f 는 비선형 함수로서, 여기서는 시그모이드함수를 사용했으며, ξ 는 시그모이드 함수의 기울기를 나타낸다.

출력신호 y_m^s 와 교사신호 t_m^s 와의 오차는

$$E = \frac{1}{2} \sum_{s=1}^P \sum_{m=1}^M (t_m^s - y_m^s)^2 \quad (5)$$

로 정의되며, 최대경사법에 의해 최적화 되는 중간층에서의 값은 $(k+1)$ 번째 반복에서 다음과 같이 된다.

$$h_{1l}^s(k+1) = h_{1l}^s(k) - \eta_1 \frac{\partial E}{\partial h_{1l}^s} \quad (6)$$

$$h_{2l'}^s(k+1) = h_{2l'}^s(k) - \eta_2 \frac{\partial E}{\partial h_{2l'}^s} \quad (7)$$

여기서 η 는 학습율로 0에서 1까지의 값을 가지며 학습시키는 패턴의 수와 패턴의 길이에 영향을 받는다. 그리고 h_2 값의 변화가 h_1 값의 변화보다 더욱 크게 출력에 영향을 미치므로 보통 η_1 을 η_2 보다 크게 놓는다. 학습율을 너무 크게 주면 반복함에 따라 global minimum에 가지 못하고 oscillation을 하게 되고 너무 작게 두면 local minimum에 빠지기 쉬운데 이를 막기 위해 simulated annealing에서와 같이 학습율을 처음엔 크게 두었다가 점점 작게하는 방법을 쓰기도 한다.

식 (6)에서 오차의 미분항들은 다음과 같이 계산된다. 먼저 출력측에 가까운 두번째 중간층에 의한 오차의 미분은

$$\begin{aligned} \frac{\partial E}{\partial h_{2l'}^s} &= \sum_{s=1}^P \sum_{m=1}^M (t_m^s - y_m^s) f'(\hat{y}_m^s) \frac{\partial \hat{y}_m^s}{\partial h_{2l'}^s} \\ &= \sum_{s=1}^P \sum_{m=1}^M \delta_m^s [Z''_{ml'} f'(\hat{h}_{2l'}^s) \sum_{l=1}^L h_{1l}^s h_{1l}^p \\ &\quad + h_{2l'}^s t_m^s] \end{aligned} \quad (8)$$

으로 주어진다. 여기서 δ_m^s 는

$$\delta_m^s = (y_m^s - t_m^s) f'(\hat{y}_m^s)$$

이다. 첫번째 중간층에 의한 오차의 미분은

$$\begin{aligned}
 \frac{\partial E}{\partial h_{1l}^p} &= \sum_{s=1}^P \sum_{m=1}^M \delta_m^s \sum_{l'=1}^{L'} Z''_{ml'} f'(\hat{h}_{2l'}^s) \\
 &\quad [Z_{rl} f'(\hat{h}_{1l}^s) \sum_{i=1}^N x_i^s x_i^p + h_{1l}^s h_{2l'}^p] \\
 &= \sum_{s=1}^P \sum_{l'=1}^{L'} \delta_{l'}^s [Z_{rl} f'(\hat{h}_{1l}^s) \sum_{i=1}^N x_i^s x_i^p \\
 &\quad + h_{1l}^s h_{2l'}^p] \quad (9)
 \end{aligned}$$

여기서 $\delta_{l'}^s$ 는,

$$\delta_{l'}^s = \sum_{m=1}^M \delta_m^s Z''_{ml'} f'(\hat{h}_{2l'}^s)$$

여기서 δ 와 δ' 는 출력층에서의 오차가 입력 층으로 역전파되며, 식 (8)과 (9)에 의해 중간층의 값을 오차가 감소하는 방향으로 변화 시킴으로서 중간층을 최적화 시킨다.

3. 유도전동기의 결함 진동 주파수

전동기의 주요결함으로 회전자의 기계적 또는 자속의 불평형에 의해 회전주파수 성분의 진동이 발생하며, 회전자와 고정자의 편심으로 인한 공극변화와 고정자 권선결함으로 인한 전원 주파수의 2배수 성분의 진동이 발생하게 된다. 그리고 도체가 들어가는 슬롯은 고정자와 회전자 슬롯의 통과비의 함수로써 자계회로의 자기저항을 초래하여 불평형의 자기흡인력이 발생하여 진동을 일으킨다. 또 유도전동기에서 많이 사용되는 구름베어링의 경우 베어링의 외륜, 내륜 또는 볼의 손상이 발생할 경우 회전시 손상 부위의 접촉으로 충격진동이 발생하게 된다. 이들 진동 주파수의 계산식은 다음과 같다.

1) 회전자의 불평형 주파수

$$F_1 = N_s(1-S)$$

2) 공극 및 전류변동 주파수

$$F_2 = 2f$$

3) 슬롯 주파수

$$F_3 = f \{R_s(1-S)/2P\}$$

4) 구름베어링의 외륜 결함 주파수

$$F_4 = (n/2)f_r(1 - (BD/PD) \cos\beta)$$

5) 구름베어링의 내륜 결함 주파수

$$F_5 = (n/2)f_r(1 + (BD/PD) \cos\beta)$$

6) 구름베어링의 볼 결함 주파수

$$F_6 = (PD/BD)f_r[(1 - (BD/PD)^2 \cos\beta)]$$

단, N_s : 동기 회전수 (Hz)

S : 슬립율 $\{(N_s - f_r)/f_r\}$

f_r : 회전자의 회전주파수 (Hz)

R_s : 회전자 슬롯수

P : 전동기 극수

BD : 베어링 볼직경

PD : 베어링 띠치직경

β : 볼의 접촉각

n : 볼의 수

예로 볼베어링 (#6305)이 장착된 5HP, 4극 전동기의 경우, 위의 결함 진동 주파수는 Table 1과 같다.

Table 1. Defect vibration frequency

F_1	29.67Hz
F_2	120.00Hz
F_3	237.60Hz
F_4	74.00Hz
F_5	158.20Hz
F_6	79.10Hz

단 N_s : 30Hz (1800RPM)

S : 0.001

f_r : 29.67Hz

f : 60Hz

R_s : 32개

P : 4

BD : 14.5mm

PD : 43.5mm

β : 0°

n : 8개

Fig. 5의 a)와 b)는 각각 회전자의 불평형, 볼베어링의 결함으로 인해 발생된 진동의 주파수 분석 데이터의 예이다. 계산으로 구한 결함 주파수는 회전부의 슬립, 그리고 FFT

의 resolution 등으로 정확히 일치하지 않으므로 다음과 같은 피크 주파수의 판정대역을 설정한다.

$$F_p - \Delta f < F < F_p + \Delta f$$

단 F_p : 측정된 피크 진동주파수

F : 결합진동주파수

Δf : 피크주파수의 판정대역 설정
을 위한 주파수

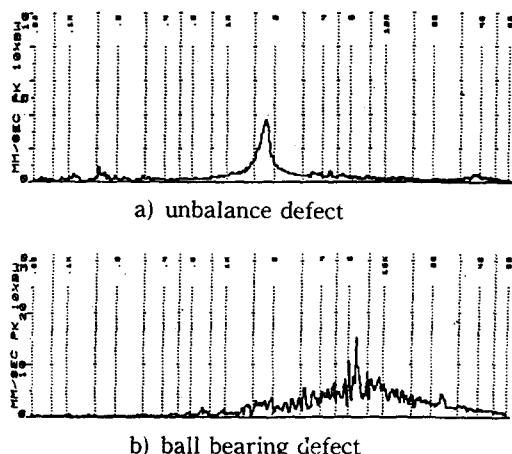


Fig. 5. Frequency spectrum of vibration with defect.

4. 학습

측정한 데이터에서 입력패턴을 결합주파수 $F_1 \sim F_6$ 별로 크기를 기록하고, 이와 대응하는 목표 출력 패턴은 $+1, -1$ 의 두개의 값으로 배열한다. $+1$ 은 결함이 있음을 표시하고 -1 은 결함이 없음을 표시한다. 출력패턴에서

Table 2. Input pattern

F_1	F_2	F_3	F_4	F_5	F_6
4.0	1.0	0.1	0.4	0.3	0.4

Table 3. Output pattern

F_1	F_2	F_3	F_4	F_5	F_6	N
1	-1	-1	-1	-1	-1	-1

N 은 전동기가 결함이 없고 정상 상태일 경우 1의 값을 갖는다.

Table 4은 학습에 사용된 입력패턴 중의 일부이며, 본 연구에서는 50개의 결합패턴을 입력하여 학습을 수행하였다. 학습시 사용된 입력 파라메터값은 Table 5와 같으며, 허용 오차 0.01까지 수행하였다. Fig. 6은 학습을 수행함에 따른 오차감소를 보여주고 있다. Fig. 7는 2.4항에서 설명한 학습 알고리즘의 흐름도이다.

Table 4. Input pattern data

No.	F_1	F_2	F_3	F_4	F_5	F_6
1	0.80	0.30	0.20	0.10	0.12	0.30
2	0.20	0.90	0.30	0.20	0.22	0.21
3	0.10	0.30	1.40	0.26	0.30	0.10
4	0.10	0.12	0.21	0.54	0.31	0.10
5	0.15	0.21	0.25	0.11	0.49	0.15
6	0.31	0.11	0.21	0.15	0.29	0.94
7	0.18	0.12	0.18	0.16	0.13	0.15

Table 5. Learning parameter

hidden layer No.	2
hidden layer neuron No.	20, 20
sigmoid function gain	2.0, 2.0
threshold	0.1
momentum factor	0, 0, 0
tolerance error	0.01
learning factor	0.1, 0.1, 0.1
initial weight No.	-0.5, 0.5
input neuron No.	6
output neuron No.	7

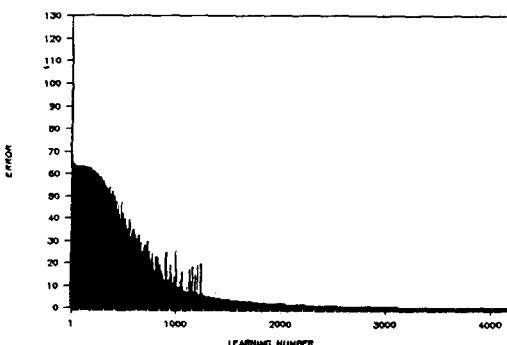


Fig. 6. Error drop curve by learning.

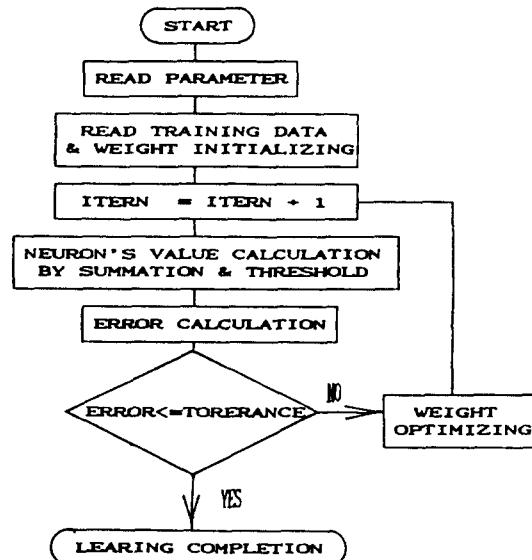


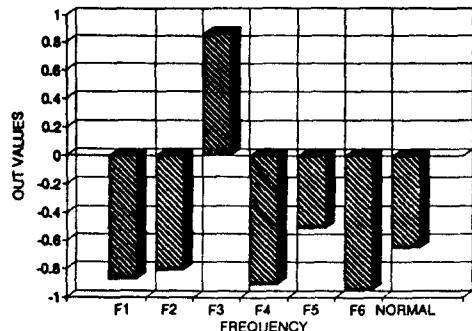
Fig. 7. Flow chart of backpropagation.

Fig. 8의 a), b), c)는 50개의 결함패턴으로 오차 0.01까지 학습을 완료한 후, 어떤 입력패턴이 들어 왔을 때 진단한 결과이다. $F_1 \sim F_6$ 는 3절에서 정의한 주파수이며 normal은 진단결과 정상임을 표시한다. 그림 위의 pattern의 값은 테스트를 위한 입력패턴이다. 목표 출력값이 +1, -1은 아니나 근접하는 값으로 결합판정에는 무리가 없다. Fig. 8의 a)는 F_3 즉, 슬롯의 결함을 진단한 결과이며, b)는 정상임을 나타내고 c)의 경우 불평형과 베어링의 외륜에 결함이 있음을 진단하고 있다. 결과에서 알 수 있듯이 만족스로운 진단결과를 나타내며 대화 절차없이 한번의 입력으로 결론에 도달할 수 있음을 보여주고 있다.

5. 결 론

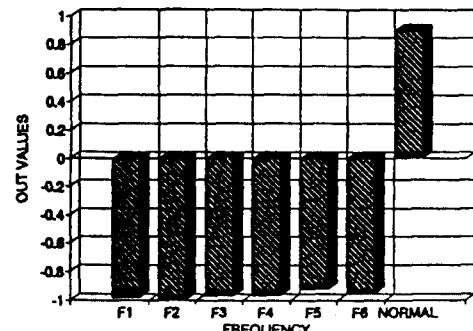
본 논문에서는 신경회로망에 의한 회전기 고장진단 시스템의 구축 가능성을 검토하였다. 신경회로망에 의한 고장진단 시스템의 경우, 고장에 대한 실시간 응답이 가능하며

PATTERN: 0.4 0.4 0.47 0.34 0.41 0.38



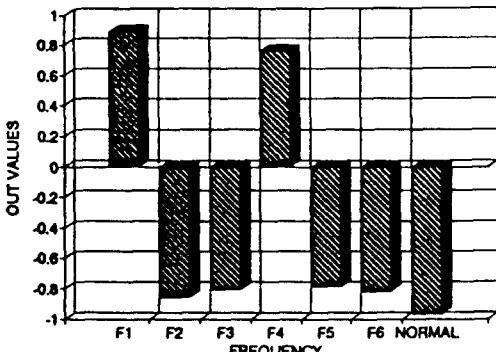
a) slot defect

PATTERN: .22 .28 .31 .21 .34 .19



b) normal

PATTERN: .79 .18 .31 .87 .24 .19



c) defect of unbalance and bearing outer race

Fig. 8. Results of defect diagnosis.

불안정한 데이터나 noise가 입력되어도 이를 처리할 수 있는 장점이 있다. 따라서 향후 전문가시스템 구축에 매우 유용할 것으로 생각되며, 본 시스템으로 대량 생산되는 전동기와 같은 회전기계제품의 품질 검사용으로도 유용할 것으로 판단된다.

참 고 문 헌

- 1) Philip D. Wasserman (1989) : Neural Computing Theory and Practice. Vannostrand reinhold.
- 2) James A. Freeman and David M. Skapura (1991) : Neural Networks Algorithms, Applications and Programming Techniques. Addison-Wesley.
- 3) 中野聲, 飯沼一元, 桐谷滋(1989) : ニューロコンピュータ. 技術評論社.
- 4) 甘利後一(1978) : 神經回路網の數理. システムサイエンスシリーズ, 産業圖書.
- 5) James L. McClelland and David E. Rumelhart (1988) : Explorations in Parallel Distributed Processing. A Bradford Book, The MIT Press Cambridge, Massachusetts London, England.
- 6) James L. McClelland and David E. Rumelhart, and the RDP research group (1986) : Parallel Distributed Processing.
- 7) 최원호(1991) : 산업용 유도전동기의 진동특성. 효성중공업 연구개발 보고서 7(1).
- 8) 민성식(1991) : 다층구조 양방향 연상기억 모델. 한국과학기술원, 석사학위 논문.
- 9) 한국과학기술원(1990) : 신경회로망 컴퓨터 이론, 응용 및 구현. 산학협동공개강좌.