

펌프의 작동음 주파수 분석에 의한 진단

이신영*

(논문접수일 2003. 12. 11, 심사완료일 2004. 5. 27)

Diagnosis of a Pump by Frequency Analysis of Operation Sound

Sin-Young Lee*

Abstract

A fundamental study for developing a system of fault diagnosis of a pump is performed by using neural network. The acoustic signals were obtained and converted to frequency domain for normal products and artificially deformed products. The signals were obtained in various driving frequencies in order to obtain many types of data from a limited number of pumps. The acoustic data in frequency domain were managed to multiples of real driving frequency with the aim of easy comparison. The neural network model used in this study was 3-layer type composed of input, hidden, and output layer. The normalized amplitudes at the multiples of real driving frequency were chosen as units of input layer. Various sets of teach signals made from original data by eliminating some random cases were used in the training. The average errors were approximately proportional to the number of untaught data. The results showed neural network trained by acoustic signals can be used as a simple method for a detection of machine malfunction or fault diagnosis.

Key Words : Neural Network(신경회로망), Acoustic Diagnosis(음향 진단), Pump(펌프), Frequency Domain(주파수 영역)

1. 서 론

생산설비를 능률적으로 사용하기 위하여는 작업 능력을 최대한 유지하고 설비의 고장을 신속히 발견 또는 예지하여야 한다^(1,2). 기계 또는 설비의 고장을 진단하고 오작동을 예방하기 위한 많은 연구들이 수행되어 왔다^(3~8). 가속도와 같은 진동 신호들은 진단의 대상이 되는 기계의 유용한 정보를 포함하므로 기계의 진단에 자주 사용되었다^(5,8). 가

장 일반적인 기계의 진단 방법은 시각검사이다⁽⁹⁾. 이 방법은 비싸고 시간이 많이 걸리며 많은 경우 기계의 주요 부분을 검사하는 것이 곤란하여, 센서를 이용한 신호검출 방법이 일반적으로 사용된다. 신호처리 방법은 다양하며 경우에 따라 다른 효율을 나타내고 있다. Asakura 등⁽¹⁾과 Zang 등⁽²⁾은 신경회로망을 이용하여 고장을 진단하였다. Bae와 Lee⁽¹⁰⁾는 반응로의 해석에 신경망을 적용하였고, Staszewski⁽⁴⁾와 Lin 등⁽⁵⁾은 웨이블렛 변환을 이용하였다.

* 군산대학교 기계공학부 (sinylee@kunsan.ac.kr)
주소: 573-701 전북 군산시 미룡동 산68

구조 진단 문제는 통계적 패턴 인식법⁽¹¹⁾의 문현에 잘 나타나 있고, 이 진단은 작동 평가 단계, 데이터 획득 단계, 특징 추출 및 데이터 수축 단계 및 통계 모델 수립 단계의 4 단계로 이루어진다. 또한 Min 등⁽¹²⁾은 음향센서를 이용한 시스템 모니터링에 대하여 연구하였다.

신경회로망은 시스템 인식에 종종 사용되어 오고 있다. 신경회로망은 최급 경사 학습법에 의하여 역전파 학습됨으로써 비선형성을 포함한 계를 블랙 박스 형태로 물리 계를 모델링 한다^(13~15).

기계에서 발생하는 음향 신호 또한 진동 신호와 같이 작동 중인 기계의 동적 정보를 나타낸다. 본 논문에서는 신경회로망을 이용하여 기계에서 나오는 음향 신호를 통한 고장 진단의 기초 연구를 수행하고자 하였다. 정상 제품과 인위적으로 고장을 발생시킨 제품에 대하여 음향을 측정하고 주파수 영역으로 변환시켰다. 제한된 수의 펌프로부터 많은 데이터를 얻기 위하여 구동 주파수를 여러 단계로 변환시켰으며, 주파수 영역에서 소음의 피크치들을 구동 주파수의 배수 값에서 조사하였다. 본 연구에서 신경회로망은 입력 층, 은닉층, 출력층의 3층 회로망을 사용하였으며, 입력층은 음향 신호의 선택된 배수 주파수에서의 음압, 출력층은 정상 또는 고장의 형태 코드가 되도록 설정하였다. 여러 가지 경우에 대하여 신경회로망을 학습하였고, 평균 오차는 미학습 데이터의 수에 비례하였다. 음향 신호에 의하여 학습된 신경회로망은 기계의 고장을 검출하는 간단한 방법으로 사용될 수 있음을 나타내었다.

2. 실험 장치 및 방법

실험 대상으로는 단순하고 가격이 낮은 LG PU-250M 펌프를 사용하였고, 분석장비로는 Data Physics사의 DP-104 FFT 분석기, 음향 센서로는 GRAS사의 probe microphone을 사용하였다. 또한, 참조용으로 펌프의 가속도를 측정하였다. 인위적 고장의 종류로는 Table 1과 같이 (1) 정상인 것, (2) 냉각 핀을 구부려서 축을 변형시킨 것, (3) 인위적으

Table 1 Selected types of artificial defects

Pump Id.	Defect
A, B	Normal
C, D	Deformed shaft with bended fins
E, F	Grounded blade
G, H	Damaged bearing

로 블레이드를 마모시킨 것, (4) 베어링을 손상시킨 것의 3 종류를 사용하였다. 8대의 펌프를 사용하고 구동 주파수는 54에서 64Hz까지 변화시켰다.

Fig. 1~5는 각각 정상 펌프 A와 B, 냉각 핀을 굽힘으로써 축에 변형을 준 펌프 C, 블레이드를 인위적으로 불균일하게 갈아낸 펌프 E, 베어링이 손상된 펌프 G의 음향 신호를 주파수 영역으로 변환한 것이다.

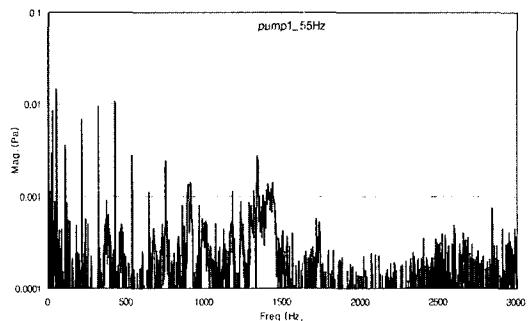


Fig. 1 Normal pump A driving at 55Hz

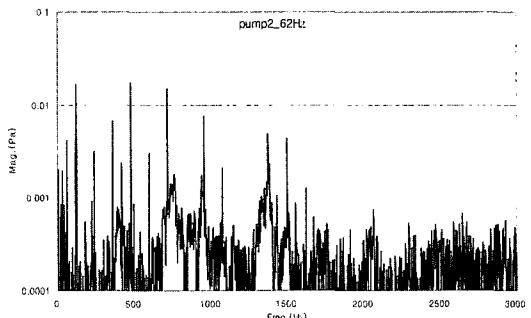


Fig. 2 Normal pump B driving at 62Hz

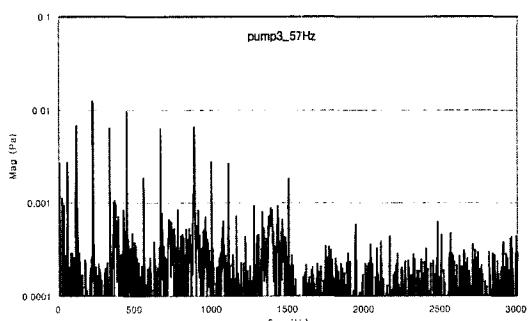


Fig. 3 Pump C driving at 57Hz

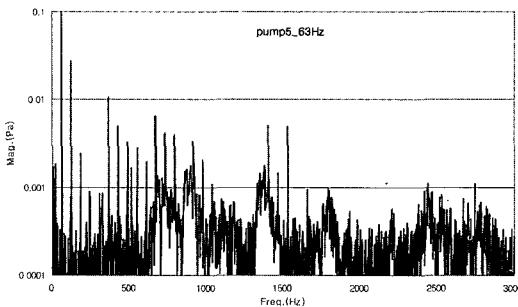


Fig. 4 Pump E driving at 63Hz

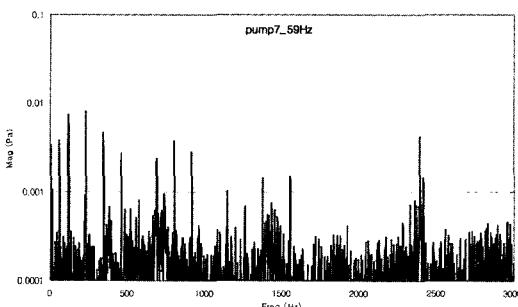


Fig. 5 Pump G driving at 59Hz

3. 신경회로망

신경회로망의 기본 구조를 이루는 것은 다수의 입력을 받아 1개의 출력을 내보내는 뉴론(neuron)이고, 신경회로망은 입력층, 은닉층 및 출력층으로 구성되며, 각 층은 다수의 뉴론 유닛으로 이루어진다. 학습 중 각 층 사이의 흐름은 한 방향으로만 향하게 된다⁽¹⁴⁾.

신경회로망의 기본 구조를 구성하는 각 뉴론의 내부상태 U_i^n 과 출력 O_i^n 은 결합계수 $W_{j,i}^{n-1,n}$ 과 역치(threshold) θ_i^n 를 사용하여 표현된다.

$$U_i^n = \sum_{j=1}^k W_{j,i}^{n-1,n} O_j^{n-1} + \theta_i^n \quad (1)$$

$$O_i^n = f(U_i^n) \quad (2)$$

본 논문에서는 출력함수 $f(x)$ 로서 변형된 시그모이드(sigmoid)함수를 사용하였다.

$$f(x) = \frac{2}{1 + \exp(-x/a)} - 1 \quad (3)$$

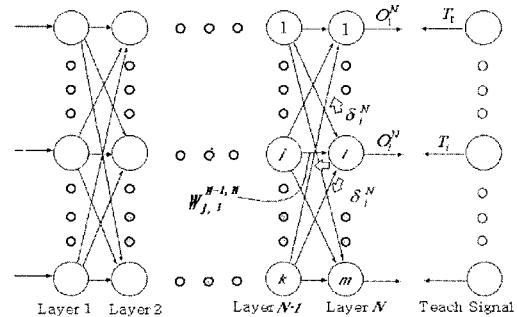


Fig. 6 Neural network

여기에서 a 는 함수의 기울기를 나타내는 상수이다. 또한 신경회로망은 뉴론 모델을 Fig. 6에 표시한 바와 같은 계층형 네트워크로 사용한다. 가중치와 역치의 학습에는 오차역전파법을 사용하였다⁽¹⁾. Fig. 6에 표시한 N 층 신경회로망을 고려하면, 제 N 층 i 번쨰 뉴론의 내부상태 및 출력은 다음 식과 같다.

$$U_i^N = \sum_{j=1}^k W_{j,i}^{N-1,N} O_j^{N-1} + \theta_i^N \quad (4)$$

$$O_i^N = f(U_i^N) \quad (5)$$

최종 N 층에서의 오차제곱을 평가함수 J 라고 하고 다음과 같이 정한다.

$$J = \sum_{i=1}^m (T_i - O_i^N)^2 / 2 \quad (6)$$

여기에서 T_i 는 교사신호라고 부르는 것으로 입력신호에 대하여 기대되는 출력이다. 최급강하법에 의하면 일반적으로 제 n , $n-1$ 층 간에 있어서 결합계수 및 역치의 수정은 다음 식과 같다.

$$W_{j,i}^{n-1,n}(t+1) = W_{j,i}^{n-1,n}(t) + \Delta W_{j,i}^{n-1,n} \quad (7)$$

$$\theta_i^n(t+1) = \theta_i^n(t) + \Delta \theta_i^n \quad (8)$$

여기에서,

$$\Delta W_{j,i}^{n-1,n} = -\epsilon \frac{\partial J}{\partial W_{j,i}^{n-1,n}}, \quad \Delta \theta_i^n = -\epsilon \frac{\partial J}{\partial \theta_i^n} \quad (9)$$

ϵ 은 양의 상수이다.

본 연구에서는 입력 벡터로 1X, 2X 및 8X와 같이 구동

주파수의 배수에서의 음암을 입력하였고, 본 연구에서 입력시 선택된 배수는 각 경우의 5대 피크를 조사하여 1, 2, 4, 5, 6, 7, 8, 10, 11, 12, 13, 14, 16, 18, 20, 23, 25이었다.

변형의 유무 및 변형의 종류에 따라 출력 코드를 부여하였고 정상인 경우(1, 0, 0), 냉각 펀을 굽힌 경우는(1, 0, 0), 블레이드를 연삭한 경우는(0, 1, 0), 베어링에 손상을 준 경우는(0, 0, 1)으로 하였다. 입력층과 출력층의 유닛 수는 각각 17과 3이었고, 은닉층의 유닛 수는 3부터 56까지 단계적으로 변화시켰다. 난수 발생에 의하여 각 신경회로망을 구성하고 역전파법을 사용하여 학습하였다. 원래의 데이터 88(8대×주파수 11종)에서 임의의 데이터를 제외하여 56 내지 84 데이터로부터 학습한 결과를 검토하였다. 제외된 데이터 역시 난수 발생으로 어느 데이터를 제외할 것인지를 결정하였다. 미학습 데이터의 수 및 은닉층 유닛의 수를 변화시키면서 오차역전파법에 의한 학습을 수행하고 그 결과를 검토하였다.

4. 결과 및 검토

여러 가지 상황에 대하여 기계 오류를 인지함에 있어서의 오차를 계산하였다. 각각의 상황에 난수 발생법에 의하여 임의의 학습 데이터를 제외하였다. 따라서 각각의 경우(case)에 학습 데이터 및 미학습 데이터의 종류를 다르게 하였다. 신경회로망의 출력은 연속적이고, 기대치가 0인 경우에는 0.3 이하, 기대치가 1인 경우에는 0.7 이상을 학습한 경우로 하고 그 외의 경우는 학습 실패한 것으로 정하여, 학습에 실패한 이벤트의 비율을 오차로 고려하였다. Figs. 7~10은 미학습 데이터의 수에 따른 오차를 나타낸다. Fig. 7과 Fig. 8, Fig. 9는 각각 3, 5, 8번째의 오차를 나타낸다. 12가지 전체의 총 평균 오차를 Fig. 10에 나타내었고, 미학습 데이터가 32% 이내일 때 평균오차가 10% 이내이었고, 전체적으로 미학습 데이터의 수에 따라서 증가하는 것을 볼 수 있다.

Fig. 11~14는 미학습 데이터의 수가 변할 때 은닉층의 유닛 수에 대한 오차의 경향을 나타낸다. Fig. 11~13에서 은닉층 유닛의 수는 각각 4, 32와 44이었다. 전체적인 평균 오차는 Fig. 14와 같고, 전반적으로 오차의 크기가 작았다. 전체적인 평균오차는 은닉층의 수가 44인 경우 가장 작았고 은닉층의 수가 3인 경우 가장 커졌으며, 은닉층 유닛의 수에 따른 일정한 경향은 나타내지 않았다. 이 결과들로부터 음향신호에 의해 학습된 신경회로망이 기계의 오작동 또는 오류를 검출하는 데 사용될 수 있음을 알 수 있었다.

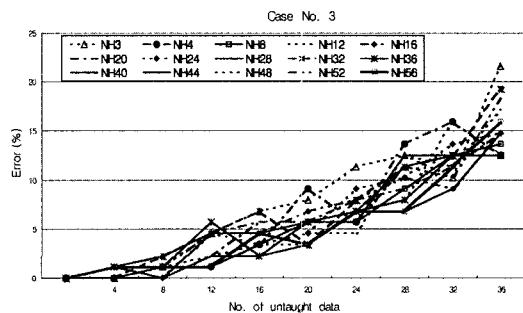


Fig. 7 Errors in the 3rd case

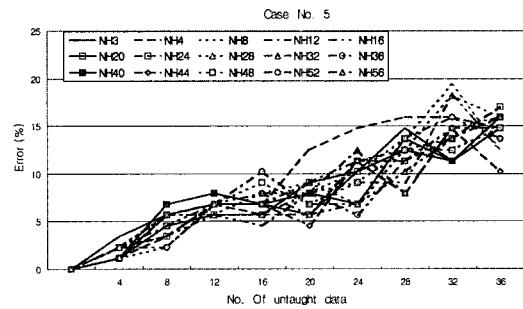


Fig. 8 Errors in the 5th case

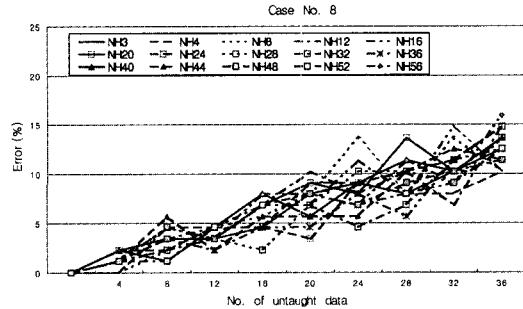


Fig. 9 Errors in the 8th case

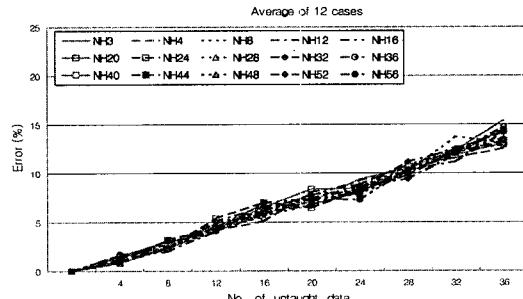


Fig. 10 The resultant average errors

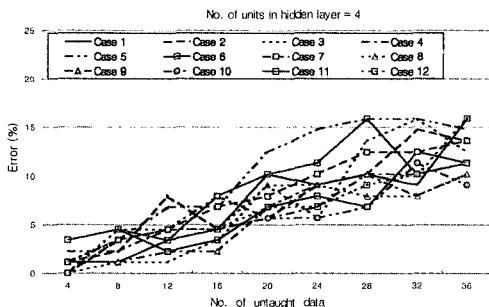


Fig. 11 Errors of 4 units in hidden layer

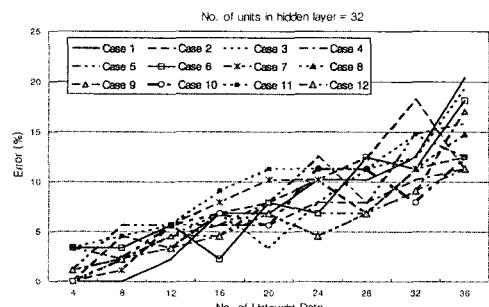


Fig. 12 Errors of 32 units in hidden layer

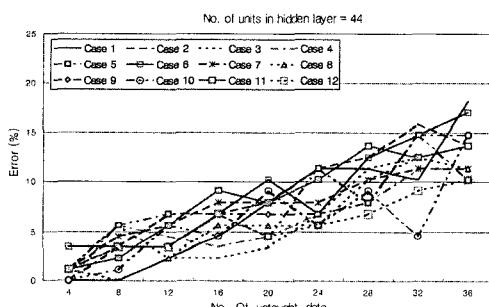


Fig. 13 Errors of 44 units in hidden layer

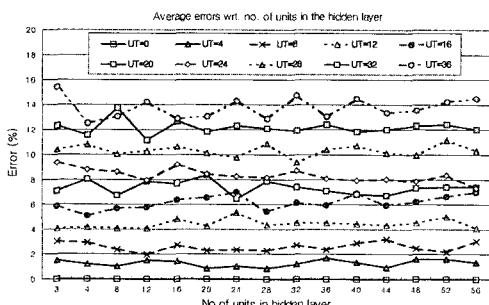


Fig. 14 Errors vs. no. of hidden layer units

5. 결론

펌프를 여러 가지 구동 주파수로 작동시키면서 발생하는 음향 신호를 획득하였다. 주파수 영역으로 변환된 음향 데이터는 작업의 용이성을 위하여 실제 구동주파수의 배수에서의 음압 크기가 입력벡터로 사용되었다. 신경회로망 모델은 입력층, 출력층 및 1개의 은닉층으로 구성하였다. 출력층은 펌프 이상 상황에 따라 0 또는 1의 값을 요소로 갖는 벡터로 구성하였다. 원래의 음향 데이터에서 몇 개의 데이터를 난수발생의 방법으로 제외하여 신경회로망의 학습 데이터를 구성하였다. 미학습 데이터의 수를 변화시켜 가며 학습을 진행한 결과 미학습 데이터가 32% 이내일 때 평균 오차가 10% 이내이었고, 전체적으로 미학습 데이터의 수에 따라서 증가하는 것을 볼 수 있다. 은닉층 유닛의 수를 변화시킨 결과 평균적인 오차는 은닉층의 수가 44인 경우 가장 작았고 은닉층의 수가 3인 경우 가장 커졌으며, 전반적으로 오차의 크기가 작았고 은닉층 유닛의 수에 따른 일정한 경향은 나타내지 않았다. 이 결과들로부터 음향신호에 의해 학습된 신경회로망이 기계의 오작동 또는 오류를 검출하는데 사용될 수 있음을 알 수 있었다.

참고 문헌

- (1) Asakura, T., Kobayashi, T., Xu, B., and Hayashi, S., 2000, "Fault Diagnosis System for Machines Using Neural Networks," *JSME International Journal, Series C*, Vol. 43, pp. 364 ~ 371.
- (2) Staroswiecki, M., 2000, "Quantitative and Qualitative Models for Fault Detection and Isolation," *Mechanical Systems and Signal Processing*, Vol. 14, pp. 301 ~ 325.
- (3) Danai, K., and Chin, H., 1991, "Fault Diagnosis with Process Uncertainty," *Journal of Dynamic Systems, Measurement and Control*, Vol. 113, pp. 339 ~ 343.
- (4) Staszewski, W., 1998, "Wavelet Based Compression and Feature Selection for Vibration Analysis," *Journal of Sound and Vibration*, Vol. 211, pp. 735 ~ 760.
- (5) Lin, J., and Qu, L., 2000, "Feature Extraction Based on Morlet Wavelet and Its Application for Mechanical Fault Diagnosis," *Journal of Sound and Vibration*, Vol. 234, pp. 135 ~ 148.
- (6) Zang, C., and Imregun, M., 2001, "Structural Damage

- Detection Using Artificial Neural Networks and Measured FRF Data Reduced via Principal Component Projection," *Journal of Sound and Vibration*, Vol. 242, pp. 813~827.
- (7) Chen, Z., and Mechefske, C., 2002, "Diagnosis of Machinery Fault Status using Transient Vibration Signal Parameters," *Journal of Vibration and Control*, Vol. 8, pp. 321~335.
- (8) Jung, W. S., 2000, *Fault Diagnosis of a Pump Using Analysis of Vibration Signal(in Korean)*, Graduate School of Kunsan National University, Korea.
- (9) Zimmerman, D. C., Smith, S. W., Kim, H. M., and Bartkowicz, 1996, "An Experimental Study of Structural Health Monitoring Using Incomplete Measurements," *ASME Journal of Vibration and Acoustics*, Vol. 118, pp. 543~550.
- (10) Bae, Y. H. and Lee, S. K., 1998, "Multiple Fault Diagnosis Method by Modular Artificial Neural Network," *Journal of KSPE*, Vol. 15, No. 2, pp. 35~44.
- (11) Duffey, T. A., Doebling, S. W., Farrar, C. R., Baker, W. E., and Rhee, W. H., 2001, "Vibration-Based Damage Identification in Structures Exhibiting Axial and Torsional Response," *ASME Journal of Vibration and Acoustics*, Vol. 123, pp. 84~91.
- (12) Min, H. S., Lee, S. H., and Ahn, S. E., 2002, "Monitoring of Laser Fusion Cutting Using Acoustic Emission," *Trans. of KSMTE*, Vol. 11, No. 3, pp. 39~44.
- (13) Stech, D. J., 1994, "Towards Real-time Continuous System Identification Using Modified Hopfield Neural Networks," *Proceedings of 12th IMAC.(International Modal Analysis Conference)*, pp. 1135~1140.
- (14) Kirkegaard, P. H. and Rytter, A., 1994, "Use of Neural Networks for Damage Assessment in a Steel Mast," *Proceedings of 12th IMAC.*, pp. 1128~1134.
- (15) Kim, D. H., 2003, "A Study on Friction Coefficient Prediction of Hydraulic Driving Members by Neural Network," *Trans. of KSMTE*, Vol. 12, No. 5, pp. 53~58.