

# 웨이브릿 변환과 인공신경망 기법을 이용한 소형 왕복동 압축기의 상태 분류

## Condition Classification for Small Reciprocating Compressors Using Wavelet Transform and Artificial Neural Network

임동수 · 양보석 · 김동조 · 안병하 · A. Tan

D. S. Lim, B. S. Yang, D. J. Kim, B. H. An and A. Tan

**Key Words :** Reciprocating Compressor(왕복동 압축기), Condition Classification(상태분류), Artificial Neural Network(인공신경망), Wavelet Transform(웨이브릿 변환)

**Abstract :** The monitoring and diagnostics of the rotating machinery have been received considerable attention for many years. The objectives are to classify the machinery condition and to find out the cause of abnormal condition. This paper describes a classification method of diagnosing the small reciprocating compressor for refrigerators using the artificial neural network and the wavelet transform. In order to extract salient features, the wavelet transform are used from primary noise signals. Since the wavelet transform decomposes raw time-waveform signals into two respective parts in the time space and frequency domain, more and better features can be obtained easier than time-waveform analysis. In the training phase for classification, self-organizing feature map(SOFM) and learning vector quantization(LVQ) are applied, and the accuracies of them are compared with each other. This paper is focused on the development of an advanced signal classifier to automatize the vibration signal pattern recognition. This method is verified by small reciprocating compressors, for refrigerator and normal and abnormal conditions are classified with high flexibility and reliability.

### 1. 서 론

회전기계에서 발생하는 이상이나 결함발생시의 진동신호는 여러 상태변화의 결과이며, 그 관계가 매우 다양하고 복잡하기 때문에 원인을 추정하는데에는 매우 전문적인 지식과 오랜 경험이 필요하다. 그러므로, 시스템의 고성능화, 복잡화 및 전문가의 부족으로 인하여 진단의 자동화를 추구할 때에는 진동 원인과 발생하는 현상과의 관계를 잘 표현할 수 있는 기법이 요구되며 이에 대한 연구가 여러 방면으로 이루어져 왔다<sup>1-3)</sup>. 전문가의 지식과 경험이라는 것은 실제 문제에서 발생한 많은

사례들을 접하므로 얻어진 결과이기 때문에, 전문가의 추론과정을 모델화하여 만들어지는 진단 시스템에는 확률적이며 통계적인 접근 방법을 취하는 것이 적합하다고 판단된다<sup>4)</sup>. 따라서, 본 논문에서는 규칙기반 형태의 추론방법이 아닌, 통상 음성이나 화상인식의 목적으로 사용되는 기법인 자기조직화특징지도(SOFM)와 학습벡터양자화(LVQ) 신경망을 적용하였다. 이는 기존 신경망에서 요구되는 많은 파라미터 설정 부분을 줄일 수 있으며, 분류상태를 시각적으로 확인할 수 있는 장점이 있다. 여기에 FFT의 시간영역에 대한 정보손실이 보완된 웨이브릿 변환기법과 통계적 특징추출기법을 결합한 냉장고용 소형 왕복동 압축기의 이상/정상 분류 알고리듬을 제안하고, 실험장치로부터 추출된 결함신호에 이를 적용하여 그 유용성을 검증한다. 분류율의 평가를 위하여 SOFM, SOFM과 LVQ 그리고 LVQ를 적용한 방법의 분류율을 각각 비교하였다.

---

접수일 : 2003년 5월 27일

임동수 : (주)나다S&V 기술연구소

양보석, 김동조(책임저자): 부경대학교 기계공학부

E-mail : ivvy@pknu.ac.kr Tel. 051-620-1410

안병하 : LG전자(주) 디지털 어플라이언스연구소

A. Tan : Queensland University of Technology

## 2. SOFM과 LVQ

인간의 두뇌는 계산, 연상, 추론 및 기억 등의 상당히 복잡한 일들을 수행하지만, 디지털 컴퓨터처럼 CPU, 기억장치와 같은 하드웨어적인 소자들이 존재하는 것이 아니라, 이러한 모든 작업들이 뉴런들의 결합체인 신경망의 작용에 의해서 이루어진다<sup>5)</sup>. 신경망 중에서도 교사 없는 학습의 도구로 이용되어지는 자기조직화지도에 대한 아이디어는 1982년, 교사 있는 학습벡터 양자화알고리듬은 1989년에 Kohonen에 의해 제안되었다.

### 2.1 SOFM 알고리듬<sup>6)</sup>

훈련 집합을 입력데이터로 사용하여 학습한 후 각 패턴별로 분류하는 분류화 과정에 사용되며 순방향 2층 신경망으로 구성된다. 두뇌에서의 감각 경로를 구성하는 중요한 구성원리 중의 하나는 감지된 외부의 자극에 대하여 뉴런의 배치가 정렬되어 있어서 감지된 외부자극의 어떤 물리적 특성을 반영하는 것이다. 입력뉴런은 외부자극을 감지할 수 있는 신경세포이고, 출력뉴런은 뇌에서 응답을 하는 물리적 특성을 묘사한 것으로 가정할 수 있다. SOFM에서는 이러한 출력뉴런이 Fig. 1에서 보이는 바와 같은 자기조직화 알고리듬에 의해 형성되어 특징지도(feature map)로 표시된다. 특징지도의 형태가 수렴할 때까지 5단계 과정이 반복된다.

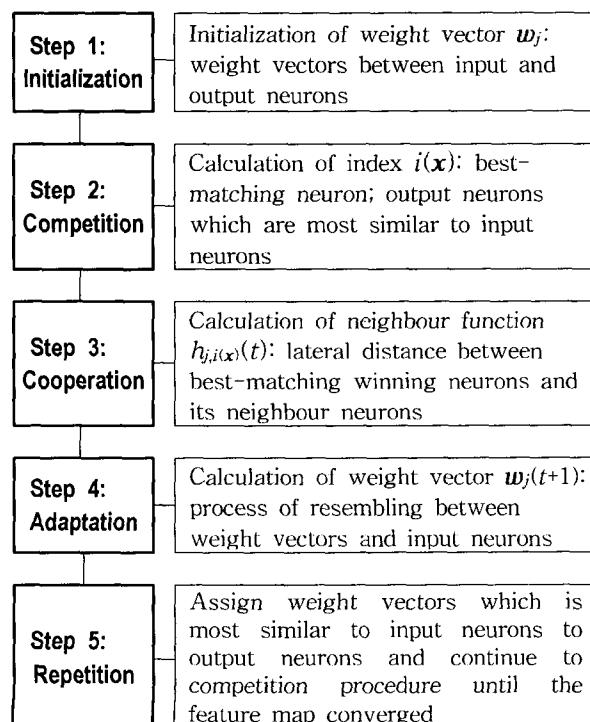


Fig. 1 Flow chart of SOFM algorithm

Fig. 1에서  $m$ 은 입력벡터(입력뉴런)의 차원,  $l$ 은 출력벡터(출력뉴런)의 차원,  $N$ 은 입력벡터의 수라고 가정한다.  $\mathbf{x} = [x_1, x_2, \dots, x_m]^T$ 는 입력벡터,  $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jm}]^T$ ,  $j = 1, 2, \dots, l$ 은  $j$  번째 출력벡터의 결합강도벡터를 나타낸다.

$i(\mathbf{x}) = \arg \min \| \mathbf{x} - \mathbf{w}_j \|$ ,  $j = 1, 2, \dots, l$ 은 승자뉴런의 인덱스이고,  $h_{j,i(x)}(t)$ 는 가우스 분포함수인 위치근방함수이다(식 (1)).  $\sigma$ 는 유효폭(effective width),  $d_{ji}$ 는 승자뉴런과 이웃뉴런 사이의 근접거리를 나타낸다. 결합강도를 생신하는 데는 식 (2)가 사용된다.

$$h_{j,i(x)}(t) = \exp\left(-\frac{d_{ji}^2}{2\sigma^2}\right), \quad t=0, 1, 2, \dots \quad (1)$$

$$\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + \eta(t) h_{j,i(x)}(t) (\mathbf{x}(t) - \mathbf{w}_j(t)) \quad (2)$$

여기서,  $\eta(t)$ 는 학습율로서,  $t$ 가 증가함에 따라 감소하며 통상  $0 < \eta(t) < 1$ 의 범위를 가진다.

### 2.2 LVQ 알고리듬<sup>6)</sup>

학습벡터양자화는 입력벡터(또는 코드북 벡터)를 교사 있는 학습을 통하여 결정영역경계를 항상 시켜 분류화 특성을 높이는 단계이다. 계산 속도와 기억공간의 절감을 위해 각 클래스에서 일부의 입력벡터만을 선택해서 사용할 수 있다. LVQ에서의 출력벡터는  $\mathbf{m}_i$ 로 한다.

$\mathbf{m}_i$ 가  $\mathbf{x}$ 와 가장 유사한 벡터라면, 최근방규칙( $k$ -nearest neighbour rule)에 의해 식(3)과 같이  $\mathbf{m}_c$ 가 결정된다.

$$\mathbf{m}_c = \arg \min \{ \| \mathbf{x} - \mathbf{m}_i \| \} \quad (3)$$

만일  $\mathbf{x}$ 와  $\mathbf{m}_c$ 가 같은 클래스에 속하는 경우( $S=1$ )와 그렇지 않은 경우( $S=-1$ )는

$$\mathbf{m}_c(t+1) = \mathbf{m}_c(t) + S\alpha(t)[\mathbf{x}(t) - \mathbf{m}_c(t)] \quad (4)$$

이고, 한편  $i \neq c$  일 때는 다음과 같다.

$$\mathbf{m}_i(t+1) = \mathbf{m}_i(t) \quad (5)$$

여기서  $0 < \alpha(t) < 1$ ,  $\alpha$ 는 상수이거나 시간에 비례하여 감소하며, 양호한 결과를 얻기 위해서는 초기에 0.1 이하의 값을 취해야 함을 수치실험에서 알 수 있다.

기존의 인공신경망이 각 층(layer)의 수 등을 경험적으로 결정해야 하는 것에 비해, SOFM 및 LVQ는 학습율 및 출력뉴런의 수를 결정하기만 하면 자기조직적으로 데이터가 학습되며, 학습결과를 시각적인 특징지도(feature map)로 확인할 수 있는 장점이 있다.

### 3. 웨이브릿 해석<sup>7,8)</sup>

웨이브릿 변환은 분석대상이 되는 신호를 시간-스케일 단위의 선형조합으로 분해하는 것이다. 웨이브릿이란 평균값이 0인 제한된 기간의 과정을 말하며, 웨이브릿 해석은 원 신호를 mother 웨이브릿(또는 웨이브릿 기본함수라 함)의 천이(translational)와 스케일(scale)값의 변화에 따라 여러 가지 신호성분으로 분해하는 것으로 시간에 따라 각각의 주파수 성분의 변화추이를 알 수 있다.

#### 3.1 연속 웨이브릿 변환

연속 웨이브릿 변환(Continuous Wavelet Transform, CWT)은 분석 대상 신호  $f(t)$  와 천이되고 스케일된 mother 웨이브릿  $\Psi_{a,b}$ 의 곱의 전 시간구간에 대해 적분한 것이다. 수학적인 표현으로는 시간함수  $f(t)$ 의 연속 웨이브릿 변환은 다음과 같이 정의된다<sup>9)</sup>.

$$CWT(a, b) = \int_{-\infty}^{\infty} f(t) \Psi_{a,b} dt \quad (6)$$

$$\Psi_{a,b} = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (7)$$

여기서  $a$ 는 스케일 파라미터,  $b$ 는 천이 파라미터,  $\Psi$ 는 mother 웨이브릿을 나타낸다. 웨이브릿 변환결과는 특정한 스케일과 천이에서의 신호  $f(t)$ 가 스케일되고 천이된 mother 웨이브릿과의 상관성을 의미한다. 만약 신호  $f(t)$ 와 mother 웨이브릿이 비슷하면 변환결과는 큰 값을 가질 것이다. 웨이브릿 변환에 있어 중요한 개념인 천이는 앞섬과 지연을, 스케일은 확장과 압축을 의미한다. 고주파 신호성분에 대해서는 시간영역에서의 감도를 높이고 저주파 신호성분에 대해서는 주파수 영역의 감도를 높인다. 이로 인해 다중 해상도 분석(multi-resolution analysis)이 가능하다.

#### 3.2 이산 웨이브릿 변환

연속 웨이브릿 변환에서는 모든 스케일에서 웨이브릿 계수를 계산하므로 많은 시간을 요하고 많은 데이터를 생성한다. 이러한 결점을 보완하기 위해서 2의 누승이 되는 스케일에서 웨이브릿 변환을 수행함으로써 정확성을 유지한 상태에서 계산 시간을 훨씬 줄이고, 보다 효율적인 변환을 수행할 수 있다. 이산 웨이브릿 변환(Discrete Wavelet Transform, DWT)에 있어 스케일함수  $\phi(t)$ 와 웨이브릿 함수  $\Psi(t)$ 는 다음과 같이 정의된다<sup>9)</sup>.

$$\phi(t) = \sum_k c_k \phi(2t-k) \quad (8)$$

$$\Psi(t) = \sum_k (-1)^k c_k \phi(2t+k-N+1) \quad (9)$$

여기서  $N$ 은 2의 누승인 데이터의 개수,  $c_k$ 는 웨이브릿 계수를 의미한다.

입력신호는 이산 웨이브릿 변환회로를 거치면서 고대역통과필터를 거친 신호는 웨이브릿 계수( $D_i$  또는 level  $i$ )로, 저역통과필터를 통과한 신호는 다음 단계의 DWT 회로로 이동한다. 이러한 과정이 반복됨으로써 이산 웨이브릿 변환이 수행된다<sup>10)</sup>.

### 4. 상태분류 알고리듬

이상에서 설명한 자기조직화 특징지도, 학습벡터 양자화 알고리듬 및 웨이브릿 변환을 이용하여 왕복동압축기의 상태를 분류하는 과정을 설명한다. 본 논문에서 제시한 분류 진단시스템은 Fig. 2에서 보이는 바와 같이 구성되어 있다.

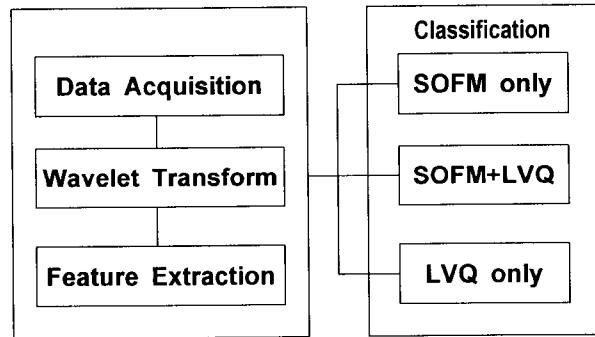


Fig. 2 Flow chart of classification system

#### 4.1 신호 취득

데이터 취득(data acquisition)을 위해 냉장고용 왕복동 압축기의 자동생산라인에서 현장 기술자의 청각을 이용하여 판정된 정상품 5대, 불량품 5대의 반제품 왕복동형 압축기를 대상으로 Fig. 3과 같이 압축기 상단에 마이크로폰을 설치하여 소음을 측정하고 데이터 레코더에 저장하였다. 압축기는 실험장치 기초 위에 볼트로 고정되었다. 110V의 정격 전압으로 구동하고, 한 번의 데이터 취득을 위해 5초 간 운전되었다. 신호처리를 위한 최대 주파수 취득범위는 10kHz, 샘플링 데이터 개수는 4,096개로 하였다. 신호분석 결과, 불량 압축기 중 1대는 정상 상태와 완전히 일치하였으므로 인공신경망의 훈련과정에서는 정상 데이터로 사용하였다.

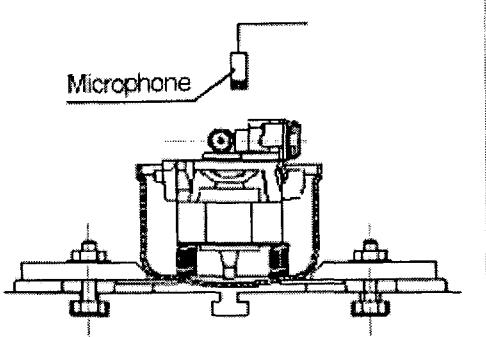
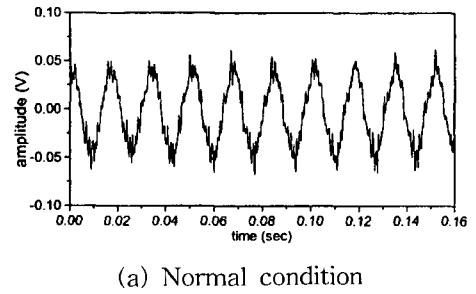
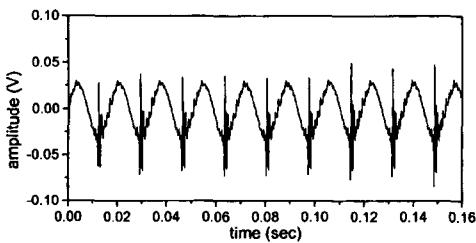


Fig. 3 Experiment set of reciprocating compressor

Fig. 4는 정상 및 불량상태의 경우 측정된 소음 신호파형의 예를 나타낸다. 운전주파수의 파형에 고주파 음 성분이 포함되어 있고, 불량상태에서는 충격음이 포함되어 있는 것을 알 수 있다.



(a) Normal condition



(b) Abnormal condition

Fig. 4 Time-waveform of normal and abnormal conditions

#### 4.2 웨이브릿 변환 및 특징추출

대상기계의 각 상태를 평가하기 위해 각 압축기 당 10개씩의 시계열 신호를 Daubechies D10 웨이브릿을 이용하여 변환을 수행하였다. 웨이브릿 계수의 level 1은 5kHz~10kHz, level 2는 2.5kHz~5kHz, level 3은 1.25kHz~2.5kHz, level 4는 625Hz~1.25kHz에 해당된다. 웨이브릿 변환신호에 대한 각각 10개의 level마다 평균(mean), 표준편차(standard deviation), 왜도(skewness) 및 첨도(kurtosis)의 4가지를 구하여 모두 16개의 속성을 구하였다<sup>11,12)</sup>. Level 4까지의 데이터를 사용한 이

유는 신호를 비교해 본 결과, 저주파수 영역보다 고주파수 영역에서 정상 및 불량 상태의 구분이 용이함을 알 수 있었기 때문이다.

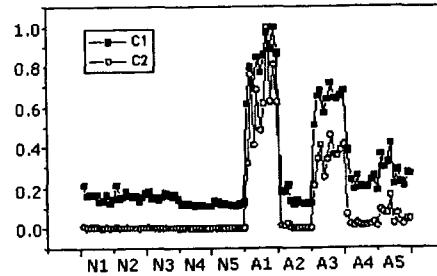
즉 왕복동 압축기의 경우, 고주파 영역의 진동 및 소음신호는 습동(friction)이나 마멸(wear)을 나타내는 징후가 된다.  $N$ 개의 시계열 데이터( $z$ )에 대한 모멘트를 구하는 식은 다음과 같다.

$$m_n = E(|z(k)|^n) = \frac{1}{N} \sum_{k=1}^N |z(k)|^n, \quad (n=1 \sim 4) \quad (10)$$

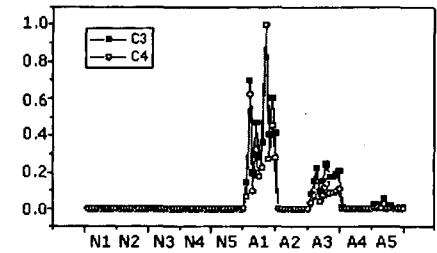
평균 :  $C_1 = m_1$ , 표준편차 :  $C_2 = m_2 - m_1^2$ ,

왜도 :  $C_3 = m_3 - 3m_2 m_1 + 2m_1^3$ ,

첨도 :  $C_4 = m_4 - 4m_1 m_3 + 6m_1^2 m_2 - 3m_1^4$



(a) Mean and standard deviation



(b) Kurtosis and skewness

Fig. 5 Moment coefficients of time waveform

Fig. 5는 웨이브릿 변환을 하지 않은 시계열 신호에 대해 평균, 표준편차, 첨도 및 왜도 값을 구한 것이다. 가로축은 각 시료의 명칭이고, 세로축은 최대값으로 정규화한 모멘트 값이다. 시료의 명칭 중 N은 정상(normal), A는 불량(Abnormal)을 의미한다. Fig. 6은 웨이블릿 계수 중 level 1에서 level 4까지의 모멘트를 나타낸 것이다. 불량 시료 2번(A2)은 모든 level에서 정상 신호와 일치함을 보인다. 불량 시료 4번(A4)은 시계열 신호만을 고려한 경우(Fig. 5)에서는 정상과 구별이 불가능하지만, 웨이브릿 변환을 수행한 경우는 level 2, level 3 그리고 level 4의 고주파 영역에서 각 모멘

트가 확연히 구별됨을 알 수 있다. 따라서, 웨이브릿 계수를 이용하면 원래의 시계열 신호에서 특징을 추출하는 것보다 진동상태가 잘 구분되는 다수의 특징을 구할 수 있게 된다.

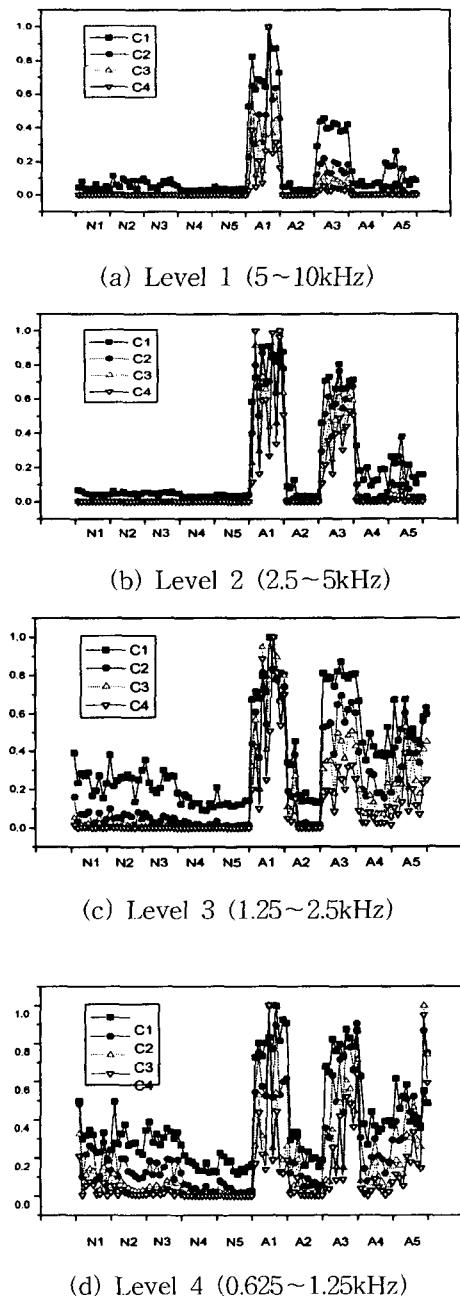


Fig. 6 Moment coefficients of wavelet coefficient

#### 4.3 분류화 과정

정상상태의 데이터를 60개, 불량상태의 데이터를 40개로 하여, 100개의 신호 데이터를 사용하였다. 이 중 인공신경망 훈련을 위해서 각 시료 당 7개씩 70개를 훈련집합, 각 시료 당 3개씩 30개를 인

공신경망의 분류율 평가를 위해 사용되었다. 그 다음 웨이브릿 변환 및 통계적 추출기법을 이용하여 16개의 속성을 구하였다. 또한 분류율 비교를 위해 시계열 신호만을 이용하여 4개의 속성을 구하였다.

먼저 SOFM과 LVQ를 결합한 경우를 고려하기 위해 LVQ의 파라미터를 결정하였다. Table 1은 LVQ의 코드북 벡터의 수에 따른 분류율을 나타낸 것이다. LVQ에서 학습율이 낮을수록 좋은 분류율을 나타내므로 식(4)의 학습율을 0.001로 하였다.<sup>6)</sup> 시계열 신호를 사용한 경우와 웨이브릿 변환을 사용한 경우 모두 코드북 벡터의 수가 훈련집합의 수에 근접할수록 분류율이 높아졌다. 또한 웨이브릿 변환을 사용한 경우가 시계열 신호만을 사용한 경우보다 높은 분류율을 가짐을 알 수 있다. 따라서, 코드북 벡터의 수는 훈련집합의 수인 70을 기준으로 하였다. SOFM과 LVQ를 연계해서 사용하는 경우는 SOFM에서 생성된 출력벡터를 LVQ의 입력벡터로 사용하였다.

Table 1 Classification accuracy according to number of codebook vectors for LVQ

| No. of codebook vector | 10   | 20   | 30   | 40   | 50   | 60   | 70  |
|------------------------|------|------|------|------|------|------|-----|
| Time-waveform          | 80   | 80   | 80   | 80   | 86.7 | 86.7 | 90  |
| Wavelet                | 93.3 | 93.3 | 93.3 | 96.7 | 96.7 | 100  | 100 |

Table 2 Classification accuracy of SOFM and SOFM with LVQ

| No. of output vectors | SOFM          |         | SOFM with LVQ |         |
|-----------------------|---------------|---------|---------------|---------|
|                       | Time-waveform | Wavelet | Time-waveform | Wavelet |
| 10                    | 90.0%         | 93.3%   | 86.7%         | 90.0%   |
| 20                    | 90.0%         | 93.3%   | 86.7%         | 90.0%   |
| 30                    | 83.3%         | 93.3%   | 83.3%         | 96.7%   |
| 40                    | 90.0%         | 90.0%   | 86.7%         | 100%    |
| 50                    | 86.7%         | 90.0%   | 80.0%         | 100%    |
| 60                    | 86.7%         | 90.0%   | 86.7%         | 100%    |
| 70                    | 90.0%         | 90.0%   | 86.7%         | 100%    |

Table 2는 시계열 데이터와 웨이브릿 계수를 이용한 경우의 출력벡터의 수에 따른 SOFM, SOFM +LVQ의 분류율을 나타낸 것이다. SOFM의 경우에도 학습율(식(2))을 0.001의 낮은 값으로

정하였다<sup>6)</sup>.

시계열 신호를 사용한 경우에는 LVQ만을 사용한 경우가 가장 높은 분류율을 나타내었고, 웨이브릿 계수를 사용한 경우에는 SOFM+LVQ 그리고 LVQ를 적용하면 더욱 높은 분류율을 나타내는 경향을 보인다. 시계열 신호를 사용한 경우, 출력벡터의 수에 따른 SOFM의 분류율 경향은 일정하지 않은데, 이는 특징의 수가 적으로 특징지도의 구성이 출력벡터의 수에 영향을 많이 받는 것으로 추정된다. 웨이브릿 계수를 이용하는 경우는 출력벡터의 수가 충분히 크면(Table 2의 40 이상), LVQ를 적용할 때(SOFM+LVQ와 LVQ)에 가장 높은 분류율을 나타낸다.

시계열 신호를 사용할 때는 SOFM과 LVQ를 같이 사용하면 분류율이 높아지지 않는데, 이는 시계열 신호의 특징만으로는 각 클래스 간의 특징을 명확히 구분할 수 없기 때문에, SOFM에서 생긴 오류가 LVQ에서 유지되거나 확대되기 때문이다. 또한, SOFM은 LVQ에 비해서 낮은 분류율을 가지는데, 이것은 SOFM이 유사한 벡터끼리는 클래스를 동일시하므로 그 클래스의 값이 소멸되기 때문에 발생한다.

따라서, 훈련데이터의 종류에서는 웨이브릿 계수를 사용하는 경우, 훈련방법으로는 LVQ를 사용하는 경우에서 가장 높은 성능을 얻을 수 있음을 알 수 있다.

## 5. 결 론

본 연구에서는 소형 왕복동 압축기에서 취득된 각 상태의 진동신호를 웨이브릿 변환하고 통계적 방법에 의해 특징을 추출하였다. 초기 시계열 신호만으로 특징추출을 실행할 경우, 추출할 수 있는 특징의 수가 제한되므로 시계열신호가 각 상태마다 유사한 경우, 신호의 분류가 용이하지 않게 된다. 웨이브릿 변환 및 통계적 특징 추출을 적용한 경우, 각 상태를 구분할 수 있는 양질의 속성들을 얻을 수 있으므로 분류의 효율을 증가시킬 수 있었다.

인공신경망 훈련방법의 성능비교를 위해 SOFM, SOFM과 LVQ를 결합하여 사용한 경우와 LVQ만을 사용한 경우의 분류율을 비교하였다. SOFM에 LVQ를 적용하면 SOFM 자체가 가지는 분류 오류를 저감시킬 수는 있으나, 완전히 감소시키지는 못하였다. 소형 왕복동 압축기의 정상/불량 분류를 위한 소음 진호의 패턴을 인식하는데 LVQ를 사용

하는 것이 가장 높은 효율을 가짐을 알 수 있었다.

차후에는 다량의 그리고 양질의 훈련데이터와 테스트 데이터를 사용하여 분류기법의 유용성을 검증하고 많은 특징들 중 각 클래스간의 성질을 잘 구분해주는 특징을 자동으로 추출해내는 알고리듬을 연구할 예정이다.

## 사 사

이 논문은 2001년도 부경대학교 연구년교수지원에 의하여 연구되었음.

## 참고 문현

1. J. Altmann and J. Mathew, 1999, "Automated DWPA Feature Extraction of Fault Information from Low Speed Rolling Element Bearing", Proc. of A-PVC'99, Singapore, Vol. 2, pp. 637~641.
2. C. I. Christodoulou, 1998, "Combining Neural Classifiers in EMG Diagnosis", Proceeding of EUFIT'98, pp. 1837~1841.
3. A. C. McCormick et al., 1997, "Real-time Classification of Rotating Shaft Loading Conditions Using Artificial Neural Networks", IEEE Trans. on Neural Networks, Vol. 8, No. 3, pp. 748~757.
4. J. M. Wu, J. Y. Lee, Y. C. Tu and C. Y. Liou, 1991, "Diagnoses for Machine Vibration Based on Self-Organizing Neural Network", Proceeding of IECON'91, pp. 1506~1510.
5. T. Kohonen et al., 1996, "Engineering Application of the Self-Organizing Map", Proc. IEEE, Vol. 84, No. 10, pp. 1358~1384.
6. S. Haykin, 1999, "Neural Network", 2nd Edition, Prentice Hall.
7. C. K. Chui, 1992, "An Introduction to Wavelets", Academic Press.
8. B. S. Yang, J. W. Kim, B. W. Kim and D. J. Kim, 1999, "Seismic Response Analysis of Steam Turbine-Generator Rotor System Using Wavelet Analysis", Proceeding of A-PVC'99, Singapore, Vol. 1, pp. 509~512.
9. I. Daubechies, 1992, "Ten Lectures on Wavelets", SIAM, Pennsylvania, USA.

10. C. I. Christodoulou, 1999, "Unsupervised Pattern Recognition for the Classification of EMG Signals", IEEE Trans. on Biomedical Eng., Vol. 46, No. 2, pp. 169~178.
11. B. S. Yang, D. S. Lim and J. L. An, 2000, "Defect Diagnostics of Rotating Machinery Using SOFM and LVQ", Proc. of Int. Congress of Sound and Vibration, July 4~7, Germany, CD-Rom edition.
12. B. S. Yang, D. S. Lim, J. L. An and D. J. Kim, 2000, "Vibration Diagnostic System of Rotating Machinery using Self-Organizing Feature Map and Wavelet Transform", Proc. of ACSIM, Nanjing China, Vol. 1, pp. 444~449.