

# 회전기계의 이상진단을 위한 진동신호 분류시스템에 관한 연구

\*임동수\*, 안경룡\*\*, 양보석\*\*\*

## Classification System using Vibration Signal for Diagnosing Rotating Machinery

Dong-Soo Lim, Jin-Long An and Bo-Suk Yang

### Abstract

This paper describes a signal recognition method for diagnosing the rotating machinery using wavelet-aided Self-Organizing Feature Map(SOFM). The SOFM specialized from neural network is a new and effective algorithm for interpreting large and complex data sets. It converts high-dimensional data items into simple order relationships with low dimension. Additionally the Learning Vector Quantization(LVQ) is used for reducing the error from SOFM. Multi-resolution and wavelet transform are used to extract salient features from the primary vibration signals. Since it decomposes the raw timebase signal into two respective parts in the time space and frequency domain, it does not lose either information unlike Fourier transform. This paper is focused on the development of advanced signal classifier in order to automatize vibration signal pattern recognition. This method is verified by the experiment and several abnormal vibrations such as unbalance and rubbing are classified with high flexibility and reliability by the proposed methods.

### 1. 서론

회전기계에서 발생하는 이상이나 고장시의 진동 신호는 여러 상태변화의 결과이며, 그 관계가 매우 다양하고 복잡하기 때문에 원인을 추정하는 데에는 매우 전문적인 지식과 오랜 경험이 필요하다. 그러므로, 시스템의 고성능화, 복잡화 및 전문가의 부족으로 인하여 진단의 자동화를 도모하고자 할 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 패턴인식의 목적으로 사용되는 신경회로망(neural network)의 일종으로 교사없는 학습(unsupervised learning) 방법인 자기조직화지도(Self-Organizing Feature Map, SOFM) 기법, 분류화 결정영역의 특성을 향상시키기 위해 교사있는 학습인 학습벡터 양자화(Learning Vector Quantization, LVQ)를 적용하였다. 이는 기존 인공신경망에서 요구하는 많은 파라미터 설정 부분을 줄일 수 있으며, 분류상태를 시각적으로 확인할 수 있는 장점이 있다. 여기에 FFT의 시간영역에 대한 정보손실이 보완된 웨이브렛 변환기법과 통계적 특징추출기법을 연결된 회전기계의 이상진단 알고리듬을 제안하고, 실험장치로부터 추출된 결합신호에 이를 적용하여 그 유용성을 검증한다.

\* 부경대학교 대학원 기계공학과

\*\* 부경대학교 대학원 음향진동공학과

\*\*\* 부경대학교 기계공학부

## 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 교사없는 학습의 도구로 이용되어지는 자기조직화지도에 대한 아이디어는 1982년, 교사있는 학습벡터 양자화알고리듬은 1989년에 Kohonen에 의해 제안되었다.

### 2.1 SOFM 알고리듬<sup>6)</sup>

훈련집합을 입력데이터로 사용하여 학습한 후 각 패턴별로 분류하는 분류화 과정에 사용되며 순방향 2층 신경망으로 구성된다. 두뇌에서의 감각 경로를 구성하는 중요한 구성원인 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.

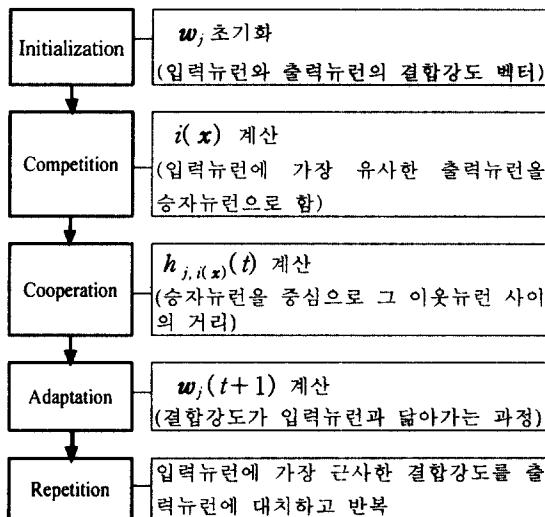


Fig. 1 Flow chart of SOFM

Fig. 1에서  $\mathbf{m}$ 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,  $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jm}]^T$ ,  $j = 1, 2, \dots, l$ 는  $j$  번째 출력벡터의 결합강도벡터를 나타낸다.  $i(\mathbf{x}) = \arg \min \|\mathbf{x} - \mathbf{w}_j\|$ ,  $j = 1, 2, \dots, l$ 는 승자뉴런의 인덱스를 말하고,  $h_{j,i(\mathbf{x})}(t)$ 은 가우스 분포함수인 위치근방이다(식(1)).  $\sigma$ 는 유효폭(effective width),  $d_{ji}$ 는 승자뉴런과 이웃뉴런 사이의 근접거리를 나타낸다. 결합강도를 갱신하는데는 아래 식(2)가 사용된다.

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

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

$\eta(t)$  : 학습율 ( $t$ 가 증가함에 따라 감소,  $0 < \eta(t) < 1$ )

### 2.2 LVQ 알고리듬<sup>6)</sup>

분류화 과정의 제 2단계로써 학습벡터양자화는 자기조직화지도에서 학습 후 계산된 출력벡터를 입력벡터로 하는데 교사있는 학습을 통하여 결정 영역경계를 향상시켜 분류화특성을 높이는 단계이다. 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 때

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

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 있었다.

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 수는 있는 장점이 있다.

### 3. 웨이브렛 해석<sup>7(8)</sup>

웨이블렛변환은 분석대상이 되는 신호를 시간-스케일 단위의 선형조합으로 분해하는 것이다. 웨이블렛이란 평균값이 0인 제한된 기간의 파형을 말하며, 웨이블렛해석은 원 신호를 mother wavelet(또는 웨이블렛 기본함수(wavelet basic function)라 함)의 천이(translation)와 스케일(scale)값의 변화에 따라 여러 가지 신호성분으로 분해하는 것으로 시간에 따라 각각의 주파수성분의 변화추이를 알 수 있다.

#### 3.1 연속 웨이블렛변환

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

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

여기서

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

$a$ 는 스케일파라메터,  $b$ 는 천이파라메터,  $\Psi$ 는 mother wavelet을 나타낸다. 웨이블렛변환결과는 특정한 스케일과 천이에서의 신호  $f(t)$ 가 스케일되고 천이된 mother wavelet과의 상관성을 의미한다. 만약 신호  $f(t)$ 와 mother wavelet과 비슷하면 변환 결과는 큰 값을 가질 것이다. 웨이브렛 변환에 있어 중요한 개념인 천이는 앞섬과 자연을, 스케일은 확장과 압축을 의미한다. 고주파 신호성분에 대해서는 시간영역에서의 감도를 높이고 저주파 신호성분에 대해서는 주파수 영역의 감도를 높인다. 이로 인하여 다중해상도분석(multi-resolution analysis)이 가능하다.

#### 3.2 이산 웨이블렛변환

연속 웨이블렛변환에서는 모든 스케일에서 웨이블렛계수를 계산하므로 많은 시간을 요하고 많은

데이터를 생성한다. 이러한 결점을 보완하기 위해서 2의 누승이 되는 스케일에서 웨이블렛변환을 수행함으로써 정확성을 유지한 상태에서 계산시간을 훨씬 줄이게 되고, 보다 효율적인 변환을 수행할 수 있다. 이산 웨이블렛변환(Discrete Wavelet Transform, DWT)에 있어 스케일함수  $\phi(t)$ 와 웨이블렛 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 웨이블렛 계수를 의미한다.

입력신호는 이산웨이브렛변환회로를 거치면서 고대역통과필터를 거친 신호는 웨이브렛계수( $D_i$  또는  $level i$ )로, 저역통과필터를 통과한 신호는 다음 단계의 DWT회로로 이동하게 된다. 이러한 과정이 반복됨으로써 이산 웨이브렛변환이 수행된다.<sup>10)</sup>

### 4. 이상진동진단 알고리듬

이상에서 설명한 자기조직화 특징지도, 학습벡터 양자화 알고리듬 및 웨이브렛 변환을 이용하여 이상진동의 결함을 진단하는 과정을 설명한다. 본 논문에서 제시한 진단시스템은 Fig. 1에서 보이는 바와 같이 모두 4부분으로 되어 있다.

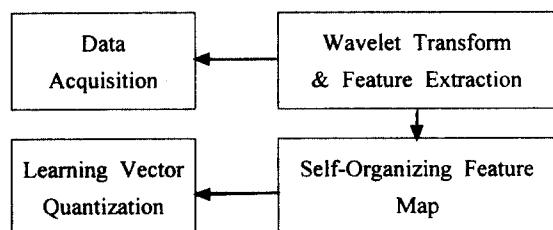


Fig. 1 Flow chart of diagnostic system

#### 4.1 신호취득<sup>11)</sup>

Rotor kit을 이용하여 정상, 불평형(unbalance), 접촉(rubbing) 및 정렬불량(misalignment)에 의한 진동 실험을 실시하였고, 좌단의 부시베어링 우측에 비접촉 변위센서를 이용하여 신호를 측정하였다. 접촉은 원판과 케이싱 사이에서 발생하도록 원판부착위치에 케이싱을 설치하였다. 정렬불량은 좌단 베어링 하우징 하단에 2.97mm의 seam을 삽입하여 발생시켰다. 실험에 사용된 원판의 잔류불평형량의

크기를 고려하여 불평형 실험시의 정상과 이상 진동의 구별시 하용크기는 편진폭  $15 \mu\text{m}$ 로 하였다. 각 증상신호마다 50개씩의 데이터를 취득하였으며, 각 신호의 최대주파수 취득범위는 200Hz, 샘플링 데이터의 개수는 4096개이다. 운전속도는 1500rpm으로 하였고, 러빙현상의 경우는 접촉불량이 발생한 직후인 1510rpm에서 측정하였다.

## 4.2 웨이브렛 변환 및 특징추출

대상기계의 각 상태를 평가하기 위해 각 진동현상마다 40개씩의 시계열 신호를 Daubechies D10 웨이브렛을 이용하여 변환을 수행하였다. Fig. 2와 Fig. 3은 각각 불평형 진동과 러빙 현상에 대한 웨이브렛 계수 중 진폭이 큰 level 1~5를 나타낸 것이다. level 1은 100~200Hz, level 2는 50~100Hz, level 3은 25Hz~50Hz, level 4는 12.5~25Hz, level 5는 6.25~12.5Hz의 주파수 대역에 해당된다. Fig. 3을 보면, 러빙현상에서 발생하는 2X, 2.5X성분인 level 2가 상대적으로 Fig. 2보다 큼을 알 수 있고, level 3은 2X 성분이 포함되어, 진폭이 크다. 0.5X성분이 포함되어 있는 level 4 및 level 5도 불평형의 경우보다 현저한 차이가 있음을 알 수 있다.

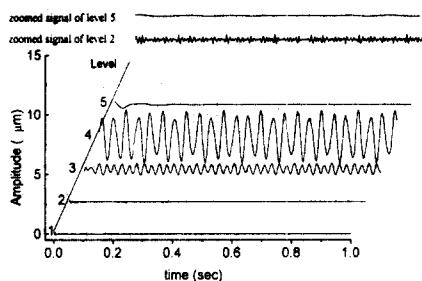


Fig. 2. Wavelet transform of unbalance

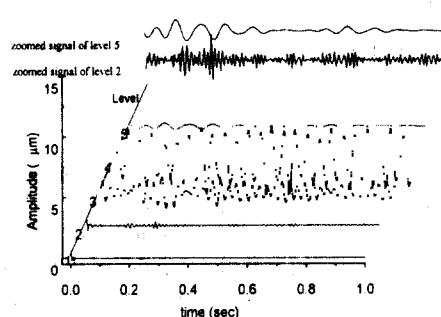


Fig. 3. Wavelet transform of rubbing

웨이브렛 변환 신호에 대한 각각 10개의 level마다 평균(mean), 표준편차(standard deviation), 첨도(kurtosis) 및 왜도(skewness)의 4가지를 구하여 모두 40개의 속성을 구한다. N개의 시계열 데이터( $z$ )에 대한 모멘트 계수(moment coefficient)를 구하는 식은 다음과 같다.<sup>11)</sup>

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

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

첨도 :  $C_3 = m_3 - 3m_2m_1 + 2m_1^3$ ,

왜도 :  $C_4 = m_4 - 4m_1m_3 + 6m_1^2m_2 - 3m_1^4$

$x_i^i$ 를 속성  $i$  ( $i=1 \sim 40$ )를 가지고 클래스  $j$  ( $j=1 \sim 4$ )에 속하는 훈련집합의 데이터라고 가정한다.  $x$ 의 평균을  $A$ 라 하면, 임의의 속성  $i$ 에 대한  $x_i^i$ 의 평균  $A_i^i$ 가 구해진다. 이는 속성  $i$ 를 가지고 클래스  $j$ 를 갖는 데이터의 대표값이다.  $A_i^i$ 의 분산을 구하여 이를  $V^i$ 라 한다. 따라서  $V^i$ 의 값이 클수록 각 클래스를 구분할 수 있는 정도가 큰 것으로 가정한다. 본 연구에서는 40개의 속성 중에서  $V^i$  값이 큰 10개를 취하였다. 얻어진 속성들이 Table 1에서 보이는 데 웨이브렛 변환에서 확인한 바와 같이 진폭의 구분이 뚜렷한 level 1~5에 집중되어 있음을 알 수 있다.

Table 1 Chosen property index

Index	1	2	3	4	5	6	7	8	9	10
Wavelet level ( $D_i$ )	$D_4$	$D_4$	$D_4$	$D_3$	$D_2$	$D_1$	$D_3$	$D_4$	$D_5$	$D_2$
Moment Coefficient ( $C_i$ )	$C_1$	$C_2$	$C_4$	$C_1$	$C_1$	$C_1$	$C_2$	$C_3$	$C_1$	$C_2$

따라서, 원래의 시계열 신호에서 특징을 추출하는 것 보다 진동상태가 잘 구분되는 양질의 특징을 구할 수 있게 된다.

## 4.3 분류화 과정

각 증상마다 데이터의 수를 40개로 하여, 160개의 신호 데이터를 훈련집합으로 사용하고 테스트집합은 각각 10개씩 사용하여 40개로 한다. 그 다음 4.2절에서 설명한 웨이브렛 변환 및 통계적 추출기법을 이용하여 10개의 속성을 구하였다. 입력뉴런의 수는 훈련집합의 수인 160개로 된다.

먼저 SOFM을 통해서 입력뉴런은 각 클래스의

특징에 맞도록 출력벡터로 재구성된다.(Fig. 4) 이 때 테스트집합을 이용하여 출력벡터가 가진 클래스와 테스트집합이 가진 클래스를 비교하여 분류의 정확도를 측정하게 된다. 이 테스트집합을 실제 진단시 입력되는 미지의 데이터로 가정하게 되는 것이다. Fig. 4는 SOFM에서 생성된 특징지도이다. 여기에서 '0'은 불평형진동, '1'은 정상진동, '2'는 정렬불량진동, '3'은 러빙진동을 나타낸다. 각 클래스들 사이에 경계가 존재하는 것은 클래스들 사이가 뚜렷히 구분된다는 것을 나타내며, 우측의 막대 그래프는 특징지도에서 주위 클래스 사이의 유클리디언 거리를 나타내는 것인데, 그 값이 1에 가까울수록 구분이 뚜렷함을 보여준다.

다음은 SOFM로부터 분류화시 얻어진 에러율을 줄이기 위해 SOFM의 학습결과로부터 얻어진 출력벡터를 LVQ의 입력벡터로 하여 새로운 출력벡터를 구하게 된다.<sup>[2]</sup> 이 출력벡터에 테스트집합을 비교하여 최종 정확도를 구한다. 이 때의 출력벡터의 수는 분류율에 영향을 미치지 않음을 각 경우에 따라 비교한 결과 알 수 있었으므로 본 논문에서는 입력뉴런의 수와 동일한 160개로 하였다.

출력벡터의 수가 많고 에러율도 낮다면, 미지의 새로운 데이터가 분류를 위해 입력되었을 때, 올바르게 분류될 가능성을 높여주게 되므로 전전한 데이터라고 할 수 있다. 따라서 에러율이 낮은 최대 출력벡터의 수를 결정해야 한다. Fig. 5에서는 웨이브렛변환과 시계열신호 만을 가지고 모멘트계수를 구한 경우와 SOFM, SOFM 및 LVQ를 사용한 방법을 서로 조합한 4가지 경우를 나타내고 있다. 그래프에서 웨이브렛 변환을 사용하고 SOFM 및 LVQ를 사용한 경우에 에러율이 가장 낮음을 알 수 있다. 시계열 신호 만을 사용한 경우에 SOFM 및 LVQ를 사용하면 에러율이 오히려 증가하는데, 이는 시계열신호 만으로 그 특징을 명확히 구분할 수 없기 때문에, SOFM에서 생긴 에러율이 LVQ에서 더 크게 확대되는 것으로 생각된다. 따라서 웨이브렛변환 및 SOFM과 LVQ를 연동한 경우에 출력벡터의 수를 입력벡터의 수에 가깝게 하면 가장 낮은 에러율을 얻을 수 있다. 본 연구에 의하면 입력벡터 수의 약 90% 근방에서 양호한 결과를 얻을 수 있음을 알 수 있었다.

## 5. 결론

본 연구에서는 회전기계에서 취득된 각 상태의 진동신호를 웨이브렛 변환하고 통계적 방법에 의해 특징을 추출한다. 이 특징을 순방향 2층 신경망으로 교사없는 학습을 수행하는 자기조직화특징지도(SOFM)에 입력벡터로 사용하여 제 1단계의 분류

화를 실행한다. 그런 다음 이때 발생하는 오차를 감소시켜 분류화율을 증가시키기 위해 SOFM의 출력뉴런에 생성된 결합강도, 즉 출력뉴런의 각 클래스마다의 출력벡터를 학습벡터양자화(LVQ) 알고리듬의 입력벡터로 다시 사용하여 2단계로 분류화를 수행하는 기법을 제안하였다.

초기 시계열 신호만으로 특징추출을 실행할 경우, 추출할 수 있는 특징의 수가 제한되므로 시계열신호가 각 상태마다 유사한 경우, 신호의 분류가 용이하지 않게 된다. 웨이브렛 변환 및 분산에 의한 통계적 처리를 실행할 경우, 각 상태를 구분할 수 있는 양질의 속성들을 얻을 수 있으므로 분류의 효율을 증가시킬 수 있다.

SOFM 알고리듬에서는, 출력벡터의 수가 분류율에 영향을 미치는데 LVQ 알고리듬을 연계함으로써 SOFM의 학습결과 발생하는 높은 에러율을 낮출 수 있었다. 또한 출력뉴런의 수와 에러율을 조사함으로써, SOFM과 LVQ를 연계하고 출력뉴런의 수를 입력뉴런의 수에 가깝게 하면 가장 높은 분류율을 얻을 수 있음을 알 수 있었다.

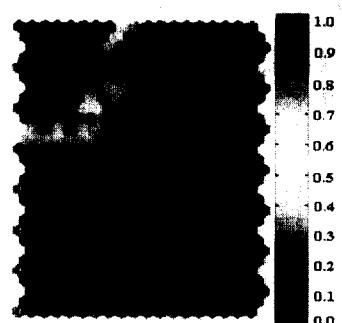


Fig. 4 Feature map from training data

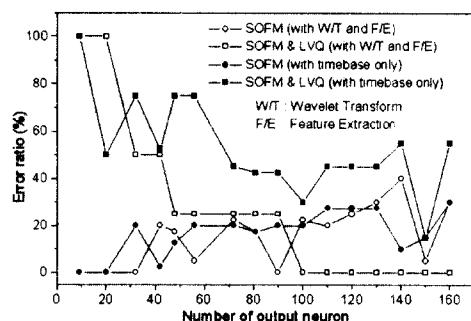


Fig. 5 Error ratio as the number of output neuron increasing

## 사사

본 논문은 한국과학기술부가 지원하는 특정연구 개발사업 중 중점국가연구개발사업(기계설비요소기술개발)으로 지원되어 수행하였습니다.

## 참고문헌

- 1) J. Altmann, J. Mathew, Automated DWPA Feature Extraction of Fault Information from Low Speed Rolling Element Bearing, Proceedings of A-PVC '99, Singapore, Vol. 2, pp. 637~641, 1999
- 2) C. I. Christodoulou, Combining Neural Classifiers in EMG Diagnosis, Proceeding of EUFIT'98, September 7~10, 1998, pp. 1837~1841, 1998
- 3) A. C. McCormick, Real-Time Classification of Rotating Shaft Loading Conditions Using Artificial Neural Networks, IEEE Trans. on Neural Networks, Vol. 8, No. 3, pp. 748~757, 1997
- 4) J. M. Wu, J. Y. Lee, Y. C. Tu, C. Y. Liou, Diagnoses for Machine Vibration Based on Self-Organizing Neural Network, Proceeding of IECON'91, pp. 1506~1510, 1991
- 5) T. Kohonen, Engineering Application of the Self-Organizing Map, Proceeding of the IEEE, Vol. 84, No. 10, pp. 1358~1384, 1996
- 6) S. Haykin, Neural Network, 2nd Edition, Prentice Hall, 1992
- 7) C. K. Chui, An Introduction to Wavelets, Academic Press, 1992
- 8) B. S. Yang, J. W. Kim, B. W. Kim, D. J. Kim, Seismic Response Analysis of Steam Turbine-Generator Rotor System Using Wavelet Analysis, Proceeding of APVC'99, December 12~13, Singapore, Vol. 1, pp. 509-512, 1999
- 9) I. Daubechies, Ten Lectures on Wavelets, SIAM, Pennsylvania, USA, 1992
- 10) C. I. Christodoulou, Unsupervised Pattern Recognition for the Classification of EMG Signals, IEEE Trans. on Biomedical Eng., Vol. 46, No. 2, pp. 169~178, 1999
- 11) 김창구, 박광호, 기석호, 기창두, 복소시계열 모멘트의 신경회로망 적용에 의한 회전기계의 상태진단, 한국소음진동공학회 추계학술대회논문집, pp. 527-531, 1998
- 12) 양보석, 서상윤, 임동수, 이수종, 자기조직화지도와 학습벡터양자화를 이용한 회전기계의 이상진동진단 알고리듬, 한국소음진동공학회지, Vol. 10, No. 2 (계제 예정)