

〈논 문〉

## 자기조직화특징지도와 학습벡터양자화를 이용한 회전기계의 이상진동진단 알고리즘

Abnormal Vibration Diagnostics Algorithm of Rotating Machinery Using Self-Organizing Feature Map and Learning Vector Quantization

양 보 석\* · 서 상 윤\*\* · 임 동 수\*\* · 이 수 중\*

Bo-Suk Yang, Sang-Yoon Seo, Dong-Soo Lim and Soo-Jong Lee

(2000년 1월 31일 접수 ; 2000년 3월 24일 심사완료)

**Key Words** : Abnormal Vibration Diagnostics(이상진동진단), Self-Organizing Feature Map(자기조직화 특징지도), Learning Vector Quantization(학습벡터양자화), Rotating Machinery(회전기계)

### ABSTRACT

The necessity of diagnosis of the rotating machinery which is widely used in the industry is increasing. Many research has been conducted to manipulate field vibration signal data for diagnosing the fault of designated machinery. As the pattern recognition tool of that signal, neural network which use usually back-propagation algorithm was used in the diagnosis of rotating machinery. In this paper, self-organizing feature map(SOFM) which is unsupervised learning algorithm is used in the abnormal defect diagnosis of rotating machinery and then learning vector quantization(LVQ) which is supervised learning algorithm is used to improve the quality of the classifier decision regions.

### 1. 서 론

회전기계는 발전플랜트 등의 각종 산업현장에서 가장 광범위하게 사용되고 중요한 역할을 수행하기 때문에 이상이 발생했을 때, 즉각적인 고장원인의 추정과 이에 대한 대응책이 요구되어진다. 이러한 이상검출에는 진동신호가 많이 이용되고 있으며, 이는 진동신호가 기계에서 발생하는 이상증상들 가운데 그 동특성을 가장 잘 표현하고 있고, 이상의 조기 검출이 용이하기 때문이다. 그러나, 회전기계에서 발생하는 이상이나 고장시의 진동신호는 여러 상태변화의 결과이며, 그 관계가 실로 다양하고 복잡하기 때문 원

인을 추정하는 데에는 매우 전문적인 지식과 오랜 경험이 필요하다. 그러므로, 시스템의 고성능화, 복잡화 및 전문가의 부족으로 인하여 진단의 자동화를 도모하고자 할 때에는 진동원인과 발생하는 현상과의 관계를 잘 표현할 수 있는 기법이 요구되며 이에 대한 연구가 여러 방면으로 이루어져 왔다.<sup>(1~3)</sup> 이러한 목적 하에 최근에는 어떤 영역의 전문적인 지식을 구조적으로 표현할 수 있는 전문가 시스템(expert system)의 발전에 힘입어 진동 진단에 관한 전문가 시스템의 개발이 수행되고 있다. 전문가 시스템은 크게 추론엔진(inference engine)과 지식베이스(knowledge base)의 두 가지 구조로 이루어져 있으며, 이를 구축하기 위해 많은 기법들이 존재할 수 있다. 그러나 전문가의 지식과 경험이라는 것은 실제 문제에서 발생한 많은 사례들을 접하므로 얻어진 결과이기 때문에 전문가의 추론과정을 모델화하여 만들어지는 진단 시스템에는 확률적이며 통계적인

\* 정회원, 부경대학교 기계공학부

\*\* 부경대학교 대학원

접근방법을 취하는 것이 적합하다고 판단된다. 따라서, 본 논문에서는 규칙기반 형태의 추론엔진이 아닌 패턴인식의 목적으로 사용되며 인간 두뇌의 신경망 조직을 모델화한 신경망(neural network) 중에서도 교사없는 학습(unsupervised learning) 방법을 사용하는 자기조직화특징지도(Self-Organizing Feature Map, SOFM) 알고리즘에 의한 특징추출(feature extraction)과, 분류화 결정영역의 특성을 향상시키기 위해 패턴 분류화과정에 교사있는 학습인 학습벡터양자화(Learning Vector Quantization, LVQ)를 결합한 회전기계의 이상진단알고리즘을 제안하고, 실험장치로부터 추출된 결합신호에 이를 적용하여 그 유용성을 검증한다.

## 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>(4)</sup>. 신경망 중에서도 교사없는 학습의 도구로 이용되어지는 자기조직화지도에 대한 아이디어는 1982년, 교사있는 학습벡터 양자화알고리즘은 1989년에 Kohonen에 의해 제안되었다.

### 2.1 SOFM 알고리즘<sup>(5, 6)</sup>

훈련집합을 입력벡터로 사용하여 학습후 각 패턴별로 분류하는 분류화 과정에 사용되며 순방향 2층 신경망으로 구성된다. 두뇌에서의 감각경로를 구성하는 중요한 구성원리 중의 하나는 감지된 외부의 자극에 대하여 뉴런의 배치가 정렬되어 있어서 감지된 외부자극의 어떤 물리적 특성을 반영한다는 것이다<sup>(7)</sup>. 예를 들어, 청각경로의 각 단계에서 신경세포 및 신경섬유들은 각각의 뉴런에 가장 큰 반응을 유도해내는 주파수에 따라 자동적으로 배치되어 각 뉴런에서의 응답이 최대가 되도록 한다. 청각경로의 이러한 구조는 청각피질(cortex)에까지 확장된다. 물론 대부분의 하위구조는 유전적으로 이미 결정되지만, 상위계층의 어떤 구조는 자기조직화알고리즘에 의하여 학습기간동안 형성된다. 이 원리를 응용한 SOFM알고리즘의 학습방법은 다음과 같다.

#### Step 1. 초기화

$N$ 개의 입력으로부터  $l$ 개의 출력 뉴런 사이의 결합강도를 0에서 1사이의 값으로 초기화한다.

#### Step 2. 경쟁과정(competitive process)

랜덤한 입력에 대해 출력뉴런 중에서 승자뉴런을 찾는

과정으로, 입력공간의 차원을  $m$ 이라고 할 때, 랜덤하게 선정된 입력벡터

$$\mathbf{x} = [x_1, x_2, \dots, x_m]^T \quad (1)$$

에 대해서 각 뉴런당 결합강도벡터를 다음과 같이 정의할 수 있다. 출력뉴런  $j$ 의 결합강도벡터를

$$\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jm}]^T, j = 1, 2, \dots, l \quad (2)$$

라 하였을 때, 입력벡터에 가장 유사한 결합강도를 가지는 뉴런을 찾는 다음 식

$$i(\mathbf{x}) = \arg \min \|\mathbf{x} - \mathbf{w}_j\|, j = 1, 2, \dots, l \quad (3)$$

에서 최소거리를 갖는 출력뉴런을 승자뉴런으로 선택한다.

#### Step 3. 협동과정(cooperative process)

승자뉴런을 중심으로 그 이웃뉴런(흥분된 뉴런)들과의 사이를 위상근방  $h_{j,i}$ 라 하면, 이는 다음 식으로 정의되는 가우스분포함수이다. 따라서, 이 사이의 거리를 갱신하는 단계이다.

$$h_{j,i(\mathbf{x})}(t) = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2}\right), t = 0, 1, 2, \dots \quad (4)$$

여기서,  $\sigma$ 는 유효폭(effective width),  $d_{j,i}$ 는 승자뉴런  $i$ 와 흥분된 뉴런  $j$ 사이의 근접거리이다.

#### Step 4. 적응과정(adaptive process)

마지막 과정으로 결합강도가 입력벡터로 닮아 가는 적응과정으로 다음 형태를 취한다.

$$\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + \eta(t)h_{j,i(\mathbf{x})}(t)(\mathbf{x}(t) - \mathbf{w}_j(t)) \quad (5)$$

여기서,  $\eta(t)$ 는 학습율로 시간  $t$ 에 따라 감소하며, 통상  $0 < \eta(t) < 1$ 이다.

Step 5. 특징지도 내에 두드러진 변화가 관측되지 않을 때까지 Step 2부터 반복수행을 계속한다.

### 2.2 LVQ 알고리즘<sup>(6~9)</sup>

분류화과정의 제 2단계로써 자기조직화지도에서 학습 후 출력된 codebook벡터를 입력벡터로 하여 교사있는 학습을 통하여 분류화특성을 향상시키는 단계이다. 즉, 임의의 입력공간의 입력벡터  $\mathbf{x}$ 를 codebook벡터  $\mathbf{w}_j$ 를 이용하여 미리 저장해 놓은 기준패턴과의 거리를 계산하여 가장 가까운

기준패턴의 클래스를 미지패턴의 클래스로 결정하는 방법으로 최근방규칙(k-nearest neighbour rule)을 이용한다.

학습방법은 다음과 같다. 최근방규칙을 통해 생성된 codebook벡터가  $x$ 의 각 클래스에 할당되고,  $w_i$ 가 속해 있는 클래스에  $x$ 의 클래스가 소속되기 위해 근방  $w_i$ 를 구하면 다음 식과 같다.

$$w_c = \arg \min \{ \|x - w_i\| \} \quad (6)$$

이때 구해진  $w_c$ 는  $x$ 에 가장 유사한  $w_i$ 이다.

이를 바탕으로 하여 계속적으로 시간과 속도면에서 강력화된 LVQ학습법 중에서 LVQ1의 학습방법을 이하에 설명한다.

만일  $x$ 와  $w_c$ 가 같은 클래스에 속한다고 하면

$$w_c(t+1) = w_c(t) + \alpha(t)[x(t) - w_c(t)] \quad (7)$$

만일  $x$ 와  $w_c$ 가 다른 클래스에 속한다고 하면

$$w_c(t+1) = m_c(t) - \alpha(t)[x(t) - w_c(t)] \quad (8)$$

한편  $i \neq c$ 일 때


$$w_i(t+1) = w_i(t) \quad (9)$$

여기서  $0 < \alpha(t) < 1$ ,  $\alpha$ 는 상수이거나 시간에 비례하여 감소하며, 양호한 결과를 얻기 위해서는 초기에 0.1 이하의 값을 취한다.

### 3. 이상진동진단 알고리즘

이상에서 설명한 자기조직화특징지도 및 학습벡터양자화 알고리즘을 이용하여 구성된 결합진단 알고리즘을 실험장치로부터 취득된 정상 및 결합신호를 이용하여 이상진동의 결함을 진단하는 과정을 설명한다. 본 연구에서는 학습을 위해 Kohonen의 연구그룹에서 개발한 SOFM과 LVQ package를 이용하였다.<sup>(8)</sup>

Fig. 1은 본 논문에서 제시한 진단시스템의 흐름도로, 1단계는 신호취득과정, 2단계는 시계열 모멘트를 이용한 특징추출과정, 3단계는 SOFM, 4단계는 LVQ를 이용한 분류화과정을 간략하게 나타낸다.



데이터취득 및 특징추출 과정      분류화 과정

Fig. 1 Flow chart of diagnostics system

### 3.1 신호취득

Rotor kit(Fig. 2)을 이용하여 정상, 불평형(unbalance), 접촉(rubbing) 및 정렬불량(misalignment)에 의한 진동실험을 실시하였고, 좌단의 부시베어링 우측에 비접촉 변위 센서를 이용하여 신호를 측정하였다. 접촉은 원판과 케이싱 사이에서 발생하도록 Fig. 2와 같이 원판부착위치에 케이싱을 설치하였다. 정렬불량은 좌단 베어링 하우징 하단에 2.97 mm의 심을 삽입하여 발생시켰다. 실험에 사용된 원판의 잔류불평형량의 크기를 고려하여 불평형 실험시의 정상과 이상 진동의 구별시 허용크기는 편진폭 15  $\mu$ m로 하였다. 각 증상신호마다 51개씩의 데이터를 취득하였으며, 각 신호의 최대주파수 취득범위는 200 Hz, 샘플링데이터의 개수는 4096개이다. Fig. 3은 정상상태, 불평형진동, 정렬불량진동 및 접촉진동에 대해 취득된 시간신호의 일 예를 나타낸다.




Fig. 2 Schematic diagram of experimental apparatus

### 3.2 특징추출

결합진단을 위한 자기조직화 알고리즘 상의 입력벡터의 속성은 평균(mean), 표준편차(standard deviation), 첨도(kurtosis) 및 왜도(skewness)의 4가지를 이용하였다. 발생결함은 불평형진동, 접촉진동, 정렬불량진동으로 하고, 클래스는 정상, 불평형, 접촉, 정렬불량의 총 4가지로 하였다.

신경망의 입력으로 사용하기 위해 수직방향 진동변위신호의 시간영역 데이터에서 시불변 특징을 추출한다.  $N$ 개의 시계열 데이터에 대한 모멘트(moment)를 구하는 식은 다음과 같다.<sup>(10, 11)</sup>

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


식 (10)을 이용하여 다음과 같은 4개의 속성을 구할 수 있다.

평균 :  $C_1 = m_1$  (11)


표준편차 :  $C_2 = m_2 - m_1^2$  (12)

침도 :  $C_3 = m_3 - 3m_2m_1 + 2m_1^3$  (13)


왜도 :  $C_4 = m_4 - 4m_1m_3 + 6m_1^2m_2 - 3m_1^4$  (14)




(a) Normal condition



(b) Unbalance



(c) Misalignment



(d) Rubbing

Fig. 3 Time signal of each condition

3.3 분류화 과정

각 증상마다 51개의 신호에 대해 위의 4가지 속성을 구하고, 이 중 40개를 훈련용 입력벡터로, 나머지 11개를 테스트용으로 사용하여 자기조직화 특징지도를 구성한다. 한편 출력 뉴런의 개수는 훈련용 데이터가 적기 때문에 데이터의 개수에 비례하여 다음과 같이 설정하였다.

- 훈련집합의 개수 : 160개 (클래스당 40개)
- 테스트집합의 개수 : 44개 (클래스당 11개)
- 입력벡터 속성의 개수 : 4개
- 입력뉴런의 개수 : 160개
- 출력뉴런의 개수 : 160개

출력뉴런의 개수는 데이터 크기를 그대로 반영하였다. 더욱 크게 하면 SOFM의 codebook벡터 상에 필요없는 정보(클래스간의 상관관계가 높은 데이터)까지 포함하게 되는 경우가 발생하여 에러율이 높아지게 되고, 너무 작을 경우에는 작은 수의 codebook벡터만으로 표현하게 되므로 테스트집합을 특징지도상에서 제대로 인지할 수 없는 경우가 발생한다. 특히 클래스 상호간에 유사도가 높을 때는 데이터의 수만큼 특징지도를 구성하면 좋은 결과를 얻을 수 있다.

Fig. 4는 훈련집합을 이용하여 자기조직화 특징지도를 형성하는 과정으로 4개의 속성 중 평균과 표준편차의 2개의 속성만을 고려하여 초기 학습이 시작될 때와 최종 학습말기의 상태를 2차원으로 표현하였다. 그림에서 군집을 형성한 점(+)들은 데이터 집합을 나타낸다. Fig. 4(a)에서 기호 'O'가 삼각형으로 형성된 것은 특징지도의 출력뉴런을 나타내며, 이것은 학습 초기에 입력벡터 전체의 공간에 뉴런들이 분포해 있는 것을 나타낸다. Fig. 4(b)는 학습말기의 특징지도형상으로 각 데이터 즉, 각 패턴마다 뉴런들이 일정하게 수렴해가며, 유사한 데이터들 사이에 뉴런이 이

웃관계를 형성하는 것을 보여준다. 각 데이터의 군집은 점 선을 이용하여 영역을 표현하였으며, 각각 정상, 불평형, 정렬불량, 접촉을 나타내고 있다. 그리고, Fig. 5에 테스트집합을 이용하여 자기조직화지도도를 형성한 결과를 나타낸다.

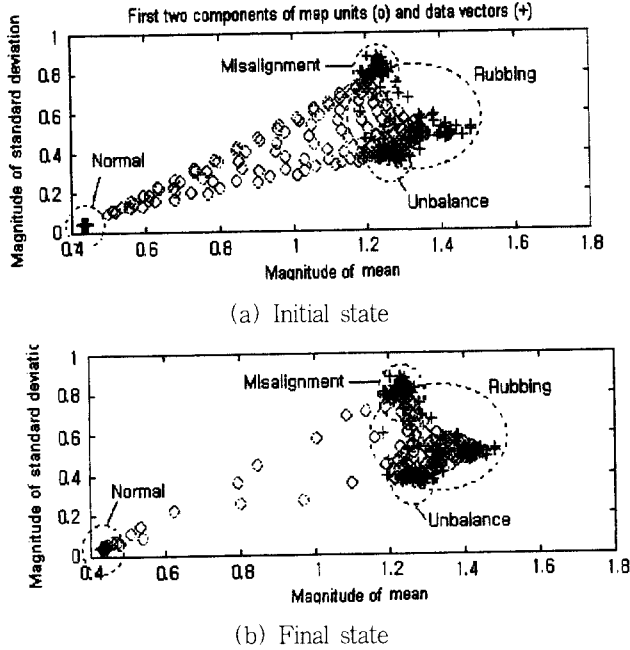


Fig. 4 Feature map using first two components of training data

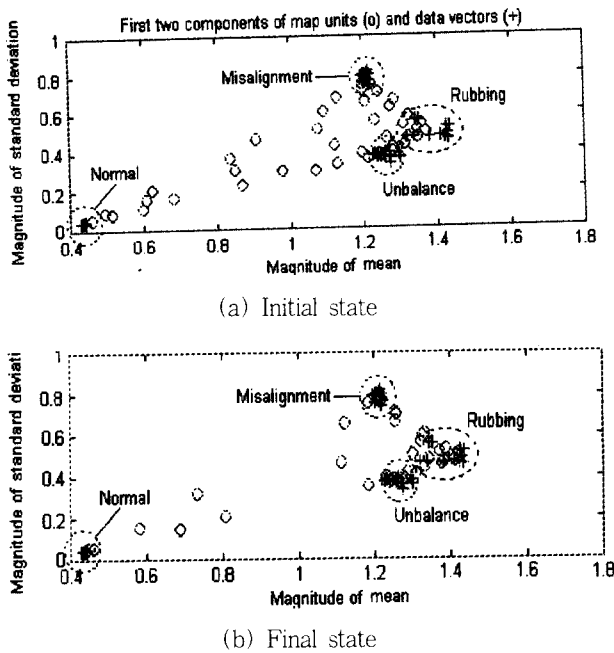


Fig. 5 Feature map using first two components of test data

테스트용 데이터의 개수가 적기 때문에 각 데이터 군집의 크기가 작으며, 훈련집합으로 만든 과정과 동일한 형태로 데이터의 군집이 잘 이루어지고 있음을 알 수 있다. 자기조직화지도가 형성된 상태를 비교하기 위해 훈련집합과 테스트집합에 각각 4개의 속성 모두를 이용하여 자기조직화특징지도를 구성하면, Fig. 6 및 7과 같이 된다. Fig. 6은 훈련집합을, Fig. 7은 테스트집합을 사용하여 학습 완료 후에 출력뉴런의 구성을 나타내는 특징지도로서, 특징지도 내에 표시된 수치는 '0'은 접촉이 발생하지 않는 1500 rpm에서의 불평형진동, '1'은 불평형질량이 부착되지 않은 상태




Fig. 6 Unified feature map of all component after training with the training data




Fig. 7 Unified feature map of all component after training with the test data

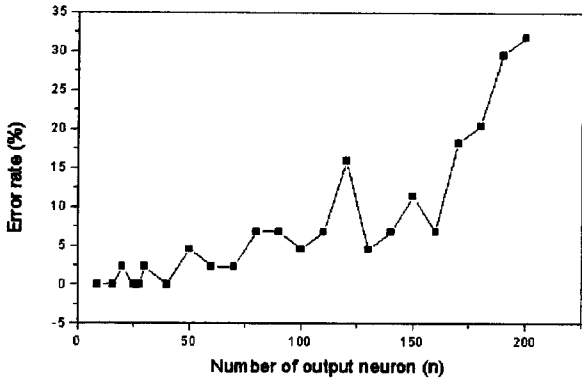


Fig. 8 Error rate according to the number of output neuron

에서 1500 rpm의 정상진동, '2'는 정렬불량상태, '3'은 접촉이 발생한 직후인 회전속도 1510 rpm에서의 접촉진동의 클래스를 각각 나타낸다. 훈련집합이나 테스트집합을 사용하여 특징지도를 만들었을 때 동일한 형태를 보여주며, 테스트집합이 훈련집합을 평가하기 위한 데이터로 적합하다는 것을 알 수 있다. 그리고, 각 클래스들 사이의 경계가 존재하는 것은 클래스들 사이의 이웃정도가 약하다는 것을 나타내며, 우측의 막대그래프는 좌측의 특징지도에서 뉴런 사이의 거리 관계를 색깔로써 보여주고 있다. 예를 들면, 클래스 내에서 뉴런들 사이의 관계는 우측막대그래프에서 보듯이 수치가 0에 가까울수록 클래스사이의 유사도가 크고, 수치가 크게 될수록 유사도가 낮다는 것을 의미한다. 클래스 '0'과 '3' 및 '2'와 '3'사이의 관계는 서로 유사하며, 정상진동인 '1'과 나머지 클래스와의 관계는 약하다는 것을 나타낸다. 이때 테스트집합을 이용하여, 훈련집합을 사용하여 만든 특징지도에 분포된 160개인 뉴런의 codebook벡터가 가진 클래스와 테스트집합이 가진 클래스를 비교하여 측정했을 때, 에러율은 11.36%이다. 그리고, 출력뉴런의 개수에 따른 에러율을 Fig. 8에 나타낸다. 이는 출력뉴런의 개수를 작게 하면 에러율이 줄어드는 결과를 보여주지만, 정확하게 이 값을 찾기 위해서는 경험적이고 시행착오의 과정을 거쳐야 한다. 본 연구에서 사용된 프로그램 내부에는 데이터의 개수가 일정 크기를 넘으면 자동적으로 가장 최적인 뉴런의 개수를 정해주는 알고리즘이 존재하지만, 본 연구에서는 데이터의 개수가 상대적으로 작기 때문에 훈련집합의 개수와 동일하게 출력뉴런의 개수를 정하였다.

다음은 자기조직화특징지도로부터의 분류화과정에서 발생하는 에러율을 줄이기 위해 SOFM의 학습결과로부터 얻어진 출력뉴런들의 결합강도인 클래스를 대표하는 codebook벡터 즉, 지도상의 출력뉴런수와 동일한 160개를 가지고 LVQ알고리즘에 입력벡터로 사용하여 학습하는 단계이다<sup>(12)</sup>. SOFM에서는 각 출력뉴런마다 reference벡터(결

합강도)가 만들어지며 그 뉴런마다 클래스를 갖고 있지만, 인접한 뉴런끼리는 클래스를 동일 시 함으로 그 클래스의 값이 존재하지 않는 것도 있다. 그리고, 뉴런의 개수를 크게 함으로 인해 학습이 완전하게 이루어지지 않고 오분류되는 경우가 발생하는 데, 이 오분류 정도에 따라서 SOFM의 에러율이 결정된다. 그러나, 특정 codebook벡터의 수를 가질 때, 오히려 정확도가 증가하는 경우가 발생할 수 있다. 이는 확률적인 요소인 위상근방함수  $h_{j,i}$ 의 값이 전체적인 경향과 다르게 계산될 수도 있기 때문으로 생각된다.

먼저 SOFM에서 얻어진 학습결과(codebook벡터)를 LVQ의 입력벡터로 사용하며 SOFM에서 사용된 테스트집합 44개를 가지고 분류화율을 판단한다. LVQ에서는 최근 접이웃 알고리즘을 통해 LVQ 알고리즘 내에서 사용하는 codebook벡터의 수를 결정하게 되며, 이는 Fig. 9와 같이 분류화율에 많은 영향을 미치게 된다. 한편, 학습율(learning rate)에 따라서 분류화율도 변화하게 되는데, LVQ의 분류화 시 3가지 클래스사이의 혼잡도가 높기 때문에 아주 작은 학습율을 사용함으로써 좋은 분류화율을

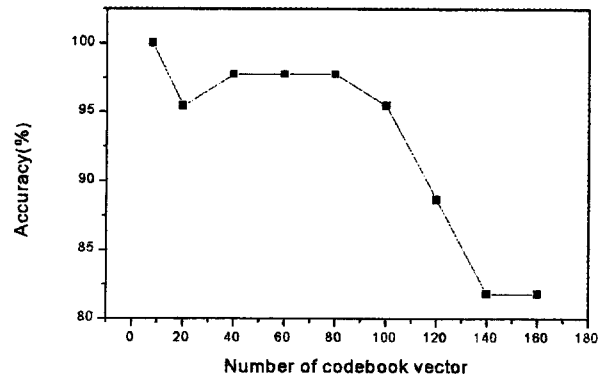


Fig. 9 Accuracy according to the number of codebook vector

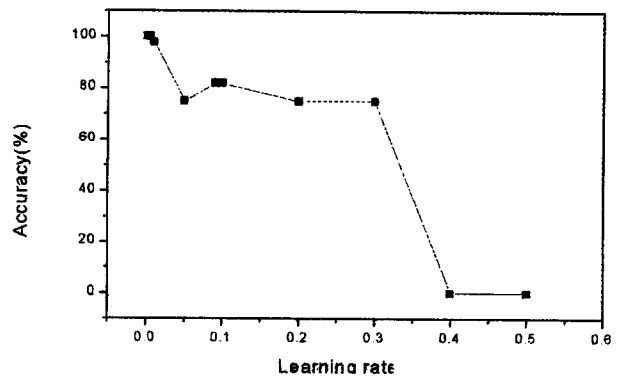


Fig. 10 Accuracy according to learning rate(  $\alpha$  )

Table 1 Classification results

Experimental condition	Classification accuracy
Normal condition	100%
Misalignment	100%
Unbalance	100%
Rubbing	100%

얻을 수 있다. 학습율의 크기에 따른 분류화율을 Fig. 10에 나타내었다. 따라서, 클래스당 2개씩의 codebook벡터를 사용하고 0.001의 학습율을 사용하였을 때, Table 1과 같이 아주 양호한 분류화율을 얻을 수 있음을 알 수 있다.

이상의 결과와 같이 SOFM과 LVQ를 기반으로 하는 진단알고리즘을 이용하여 분류화를 수행한 결과, 본 진단시스템이 결합진단을 위한 양호한 클래스의 분류화율을 얻을 수 있으며 좋은 진단결과를 제공하여주는 것을 알 수 있다.

#### 4. 결 론

본 연구에서는 모멘트법을 이용하여 진동신호의 특징을 추출하고 순방향 2층 신경망으로 교사없는 학습을 수행하는 자기조직화특징지도(SOFM)에 입력벡터로 사용하여 제 1단계의 분류화를 실행하고, 이때 발생하는 오차를 감소시켜 분류화율을 증가시키도록 하기 위해 SOFM의 출력뉴런에 생성된 결합강도, 즉 출력뉴런의 각 클래스마다의 codebook벡터를 학습벡터양자화(LVQ)알고리즘의 입력벡터로 다시 사용하여 2단계로 분류화를 수행하는 회전기계의 진단알고리즘을 제안하였다.

SOFM 알고리즘은 데이터의 크기에 따라 출력뉴런의 수가 결정되며 이에 따라 특징지도의 크기를 결정하는 알고리즘이 내부적으로 존재한다. 그러나 통상 진단에 사용될 수 있는 데이터 수는 그리 많지 않으므로 뉴런의 수 및 특징지도의 크기는 이 데이터의 수에 비례하여 생성하였고, 이로 인해 SOFM의 학습결과 발생하는 높은 에러율을 LVQ를 보조수단으로써 사용하여 더욱 좋은 분류화율을 얻도록 하였다.

그리고, LVQ에서 에러율은 학습율이나 학습횟수(학습시간)보다는 LVQ 알고리즘 내에서 사용자가 결정하는 codebook벡터의 크기에 더 많은 영향을 받으며, 그 수는 각 클래스를 가장 잘 나타내어 줄 수 있는 대표적인 수를 선택함으로써 좋은 분류화율을 얻을 수가 있다. Codebook 벡터의 크기와 학습율 값에 따른 정확도의 변화관계의 정량적인 평가는 향후의 연구과제로서 수행될 예정이다.

#### 후 기

본 논문은 과학기술부가 지원하는 특정연구개발 사업 중 중점국가연구개발사업(기계설비요소기술개발)으로 지원되어 수행하였습니다.

#### 참 고 문 헌

- (1) 최성필, 1994, 신경회로망을 이용한 볼베어링의 결합진단에 관한 연구, 부경대학교, 석사논문.
- (2) Yang, B. S., Park C. H., and Kim, H. J., 2000, An Efficient Method of Vibration Diagnostics for Rotating Machinery using a Decision Tree, International Journal of Rotating Machinery, Vol. 6, No. 1, pp. 19~27.
- (3) Yang, B. S. Jo Y. C., and Lim, D. S., 2000, Defect Diagnostics of Rolling Element Bearing Using Fuzzy Dichotomy Technique, JSME International Journal(to be printed).
- (4) 오창석, 1996, 뉴로컴퓨터, 지성출판사.
- (5) Kohonen, T., Oja, O. E. Simula, Visa, and J. Kangas, 1996, Engineering Application of the Self-Organizing Map, Proceeding of the IEEE, Vol. 84, No. 10, pp. 1358~1384.
- (6) Haykin, S., 1999, Neural Network, 2nd Edition, Prentice Hall.
- (7) Kandel E. R., and Schwartz, J. H., 1985, Principles of Neural Science, Elsevier, New York.
- (8) Kohonen, T., 1995, SOM\_PAK, The Self Organizing Map Program Package, Helsinki Univ. Technol., Lab. Computer and Information Sci., Espoo, Finland, : cochlea.ht.fi (130.233.168.48).
- (9) 이성환, 1994, 패턴인식의 원리, 홍릉과학출판사.
- (10) McCormick, A. C. and Nandi, A. K., 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.
- (11) 김창구, 박광호, 기석호, 기창두, 1998, 복소시계열 모멘트의 신경회로망 적용에 의한 회전기계의 상태진단, 한국소음진동공학회 추계학술대회논문집, pp. 527~531.
- (12) Christodoulou, C. I. and Pattichis, C. S., 1999, Unsupervised Pattern Recognition for the Classification of EMG Signals, IEEE Trans. on Biomedical Eng., Vol. 46, No. 2, pp. 169~178.