

자기조직화 특징지도를 이용한 회전기계의 이상진동진단

서상윤* · 임동수* · 양보석**

Abnormal Vibration Diagnosis of rotating Machinery Using Self-Organizing Feature Map

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

Key Words: Rubbing(접촉), Misalignment(정렬불량), Self-Organizing Feature Map(자기조직화특징지도), Learning Vector Quantization(학습벡터 양자화)

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 vibration 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 하기 때문에 이상이 발생했을 때, 즉각적인 고장원인의 추정과 그에 대한 대응책이 요구되어진다. 이러한 이상검출에는 진동신호가 많이 이용되고 있으며, 이는 진동신호가 기계의 증상들 가운데 그 동특성을 가장 잘 표현하고 있는 까닭에 이상의 조기 검출이 용이하기 때문이다. 그러나, 회전기계에서 발생하는 이상이나 고장시의 진동신호는 여러 상태변화의 결과이며, 그 관계가 실로 다양하고 복잡하기 때문에 원인을 추정하는 데에는 매우

전문적인 지식과 오랜 경험이 필요하다. 그러므로, 시스템의 고성능화와 복잡화 및 전문가의 부족으로 인해서 진단의 자동화를 기하고자 할 때에는 진동의 원인과 발생하는 현상과의 관계를 잘 표현할 수 있는 기법이 요구되며 이에 대한 연구가 여러 방면으로 이루어져 왔다.^(1~3) 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 결과이

* 부경대학교 대학원

** 부경대학교 기계자동차공학부

기 때문에 전문가의 추론 과정을 모델화하여 만들어지는 진단 시스템에는 확률적이며 통계적인 접근 방법을 취하는 것이 적합하다고 판단된다. 따라서, 본 연구에서는 전문가 시스템의 한 분야이고, rule-base 형태의 추론엔진이 아닌 패턴인식의 목적으로 사용되며 인간의 두뇌의 신경망 조직을 모델화한 신경회로망(neural network) 중에서도 교사없는 학습(unsupervised learning) 방법을 사용하는 자기조직화 특징지도(Self-Organizing Feature Map, SOFM) 알고리즘에 의한 특징추출(feature extraction)과, 분류화 결정영역의 특성을 향상시키기 위한 패턴 분류화 과정에 교사 있는 학습인 학습벡터 양자화(Learning Vector Quantization, LVQ) 알고리즘을 회전기계의 이상진단의 결합진단에 이를 적용하고, 그 유용성을 검증한다.

2. SOFM과 LVQ

인간의 두뇌는 계산, 연상, 추론, 기억 등 상당히 복잡한 일들을 수행하지만, 디지털 컴퓨터처럼 CPU, 기억장치와 같은 하드웨어적인 소자들이 존재하는 것이 아니라, 이러한 모든 작업들이 뉴런들의 결합체인 신경망의 작용에 의해서 이루어진다⁽⁴⁾. 신경망 중에서도 교사없는 학습의 도구로 이용되어지는 자기조직화 특징지도에 대한 아이디어는 1988년, 교사있는 학습벡터 양자화알고리즘은 1989년에 Kohonen에 의해 제안되었다.

2.1. SOFM 알고리즘^(5, 6)

훈련집합을 입력벡터로 사용하여 학습후 각 패턴별로 분류하는 단계에 사용되며 순방향 2층 신경망이다.

근간을 이루는 알고리즘은 두뇌에서의 감각 경로를 구성하는 중요한 구성원리 중의 하나는 감지된 외부의 자극에 대하여 뉴런의 배치가 정렬되어 있어서 감지된 외부자극의 어떤 물리적 특성을 반영한다는 것이다⁽⁷⁾. 예를 들어, 청각 경로의 각 단계에서 신경세포 및 신경 섬유들은 각각의 뉴런에 가장 큰 반응을 유도해내는 주파수에 따라 자동적으로 배치되어 각 뉴런에서의 응답이 최대가 되도록 한다. 청각경로의 이러한 구조는 청각피질(cortex)에 까지 확장된다. 물론 대부분의 하위 구조는 유전적으로 이미 결정되지만, 상위계층의 어떤 구조는 자기조직화 알고리즘에 의하여 학습기간 동안 형성된다. 이 원리를 응용한 SOFM알고리즘의

학습방법은 다음과 같다.

Step 1. 초기화

N개의 입력으로부터 l 개의 출력 뉴런간의 연결강도를 0에서 1사이의 값으로 초기화한다.

Step 2. 경쟁과정(competitive process)

랜덤한 입력에 대해 출력뉴런 중에서 승자뉴런을 찾는 과정으로, 입력공간의 차원을 m이라고 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 j의 결합강도벡터를

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

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

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

에서 최소거리를 갖는 출력뉴런을 승자뉴런으로 선택한다.

Step 3. 협동과정(cooperative process)

승자뉴런을 중심으로 그 이웃뉴런(홍분된 뉴런)들과의 사이를 위상근방 $h_{j,i}$ 라 하고, 이는 다음 식으로 정의되는 가우스분포함수이다. 따라서, 이 사이의 거리를 개선하는 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, σ 는 유효넓이(effective width), $d_{j,i}$ 는 승자뉴런 i와 홍분된 뉴런 j사이의 근접거리(lateral distance)이다.

Step 4. 적용과정(adaptive process)

마지막 과정으로 결합강도가 입력벡터로 닮아 가는 형태를 취한다.

$$\begin{aligned} \mathbf{w}_i(t+1) = & \mathbf{w}_i(t) \\ & + \eta(t) h_{j, k(x)}(t)(\mathbf{x}(t) - \mathbf{w}_i(t)) \end{aligned} \quad (5)$$

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

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

2.2. LVQ 알고리즘^(6~9)

분류화의 제 2단계로써 자기조직화지도에서 학습 후 출력된 code book 벡터를 입력벡터로 하여 교사하는 학습을 통하여 분류화특성을 향상시키는 단계이다. 즉, 임의의 입력공간의 입력 \mathbf{x} 를 code book 벡터 \mathbf{w}_i 를 이용하여 미리 저장해 좋은 기준패턴과의 거리를 계산하여 가장 가까운 기준패턴의 클래스를 미지 패턴의 클래스로 결정하는 방법으로 최근방(k-nearest neighbour)규칙을 이용한다.

학습방법은 다음과 같다. LVQ로부터 생성된 여러 개의 code book 벡터가 \mathbf{x} 의 각 클래스에 할당되고, \mathbf{w}_i 가 속해있는 클래스에 \mathbf{x} 의 클래스가 소속되기 위해 인접 \mathbf{w}_i 를 구하면 다음 식과 같다.

$$\mathbf{w}_c = \arg \min \{ ||\mathbf{x} - \mathbf{w}_i|| \} \quad (6)$$

이때 구해진 \mathbf{w}_c 는 \mathbf{x} 에 가장 유사한 \mathbf{w}_i 이다.

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

만일 \mathbf{x} 와 \mathbf{w}_c 가 같은 클래스에 속한다고 하면

$$\mathbf{w}_c(t+1) = \mathbf{w}_c(t) + \alpha(t)[\mathbf{x}(t) - \mathbf{w}_c(t)] \quad (7)$$

만일 \mathbf{x} 와 \mathbf{m}_c 가 다른 클래스에 속한다고 하면

$$\mathbf{w}_c(t+1) = \mathbf{m}_c(t) - \alpha(t)[\mathbf{x}(t) - \mathbf{w}_c(t)] \quad (8)$$

한편, $i \neq c$ 일 때

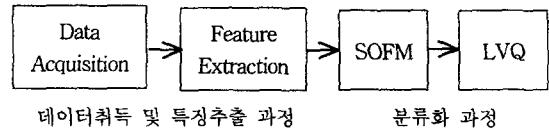


Fig. 1 Flow chart of classification system

$$\mathbf{w}_i(t+1) = \mathbf{w}_i(t) \quad (9)$$

여기서 $0 < \alpha(t) < 1$, α 는 상수이거나 시간에 비례하여 감소하며, 초기에 0.1보다 작은 값으로 하는 것이 좋은 결과를 유도한다.

3. 이상진동진단에의 적용

위와 같은 학습알고리즘을 가진 자기조직화 및 학습벡터양자화 알고리즘을 회전기계에서 발생할 수 있는 이상진동의 결합진단에 적용하였다. 본 연구에서는 학습을 위해 Kohonen의 연구그룹에서 개발한 SOM toolbox package와 LVQ package를 이용하였다.⁽⁸⁾

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

3.1. 신호취득

Bently Nevada사의 Rotorkit(Fig. 2)를 이용하여 정상, 불평형(unbalance), 접촉(rubbing) 및 정렬불량(misalignment)에 의한 진동실험을 실시하였고, 좌단의

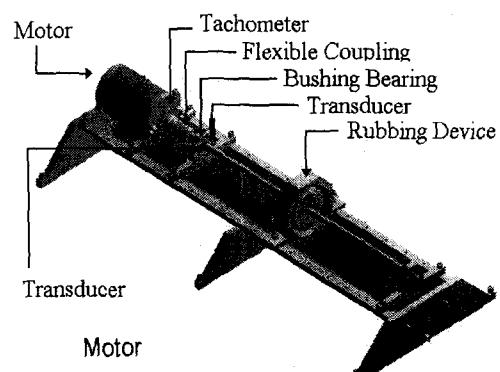


Fig. 2 Schematic diagram of experimental apparatus

부시베어링 우측에 비접촉 변위센서를 이용하여 신호를 측정하였다. 접촉은 원판과 케이싱 사이에서 발생하도록 원판에 불평형질량을 부착하였다. 정렬불량은 좌단 베어링에 와셔를 2.97mm 두께로 삽입하여 발생시켰다. 실험에 사용된 원판의 잔류불평형량의 크기를 고려하여 불평형 실험시의 정상과 이상 진폭의 구별시 허용크기는 편진폭 $15 \mu\text{m}$ 로 하였다. 각 증상신호마다 51개씩의 데이터를 취득하였으며, 각 신호의 최대주파수 취득범위는 200Hz, 샘플링데이터 개수는 4096개이다. Fig. 3은 정상상태, 불평형진동, 정렬불량진동 및 접촉진동에 대한 시간신호의 일 예를 나타낸다.

3.2. 특징추출

결합진단을 위한 자기조직화 알고리즘 상의 입력벡터의 속성은 평균(mean), 분산(standard deviation), 첨도(kurtosis) 및 웨도(skewness)의 4가지를 이용하였다.

발생결함은 불평형진동, 접촉진동, 정렬불량진동으로 하고, 클래스는 정상, 불평형, 접촉, 정렬불량의 총 4가지로 하였다.^(10, 11)

신경망의 입력으로 사용하기 위해 수직방향 진동변위 신호의 시간영역 데이터에서 시불변 특성을 추출한다. 시계열 데이터의 모멘트(moment)를 구하는 식은 다음과 같다.⁽¹²⁾

$$m_n = E\{|z(k)|^n\} = \frac{1}{N} \sum_{k=1}^N |z(k)|^n, \quad (n=1, 2, \dots, 4) \quad (10)$$

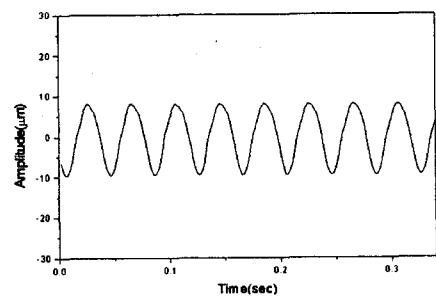
식(10)을 이용하여 다음과 같은 4개의 모멘트를 구할 수 있다.

$$\text{평균: } C_1 = m_1 \quad (11)$$

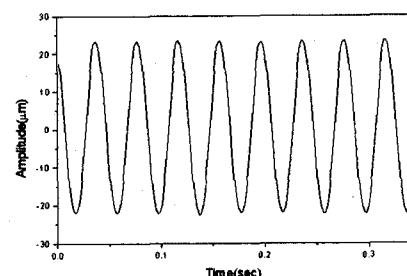
$$\text{표준편차: } C_2 = m_2 - m_1^2 \quad (12)$$

$$\text{첨도(skewness): } C_3 = m_3 - 3m_2m_1 + 2m_1^3 \quad (13)$$

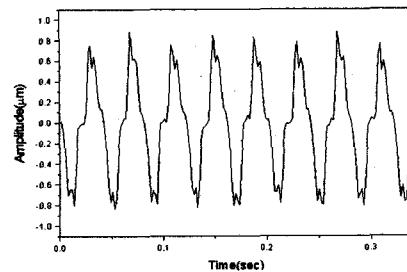
$$\text{웨도(kurtosis): } C_4 = m_4 - 4m_1m_3 + 6m_1^2m_2 - 3m_1^4 \quad (14)$$



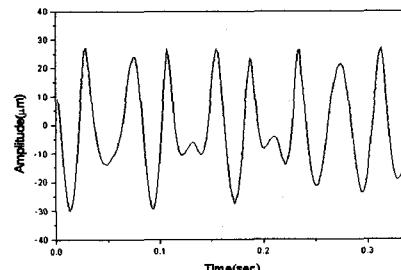
(a) Normal condition



(b) Unbalance



(c) Misalignment



(d) Rubbing

Fig. 3 Time Signal

3.3. 분류화 과정

각 종상마다 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 작기 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 code book 상에 필요없는 정보(클래스간의 상관관계가 높은 데이터)까지 포함하게 되는 경우가 발생하여 에러율이 높아지게 되고, 너무 작을 경우에는 작은 수의 code book만으로 표현하게 되므로 테스트집합을 특징지도상에서 인지를 제대로 할 수 없는 경우가 발생한다. 특히 클래스 상호간에 유사도가 높을 때는 데이터의 수만큼 특징지도를 구성해주면 좋은 결과를 얻을 수 있다. Fig. 4는 최초 학습이 시작될 때 특징지도의 형성과정을 보여준다. 군집을 형성한 점(+)들의 집합은 데이터를 나타내는데 1, 2

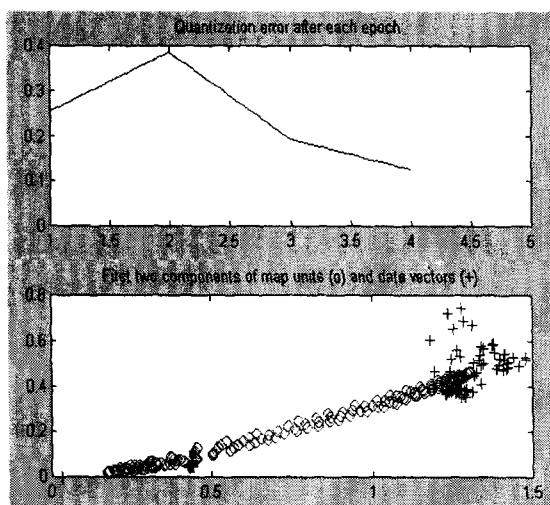


Fig. 4 Feature map of first two component in initial state

번째 속성으로써 2차원으로 표현하였으며, x축은 1번째 속성, y축은 2번째 속성으로 구성된다. 그리고, '0'로 구성되어 일렬로 형성된 것은 특징지도의 출력뉴런을 나타내며, 이것은 초기에 입력벡터 전체의 공간에 뉴런들이 분포해 있는 것을 나타낸다.

Fig. 5는 학습말기의 형상을 보여주는데 각 데이터 즉, 각 패턴마다 뉴런들이 수렴해가며, 유사한 데이터들 사이에 뉴런의 이웃관계를 형성하는 것을 보여준다.

위와 같은 특성을 가지고 모든 입력을 이용하여 자기조직화 지도를 구성하면, Fig. 6과 같이 된다.

Fig. 6은 학습완료 후에 출력뉴런의構성을 나타내는 특징지도이며, 특징지도 내에 표시된 수치는 '0'은 접촉이 발생하지 않은 1500rpm의 불평형진동, '1'은 불평형 질량을 부착하지 않은 상태에서 1500rpm의 정상진동, '2'는 좌측단 배어링 하우징 밑면에 두께 2.719mm의 와셔를 삽입한 정렬불량상태, '3'은 접촉이 발생한 직후인 회전속도 1510rpm에서의 접촉진동의 클래스 각각을 나타낸다. 그리고 각 클래스 사이의 경계가 존재하는 것은 클래스 사이의 이웃정도가 약하다는 것을 나타내며, 우측의 막대그래프는 좌측의 특징지도에서 뉴런간의 거리 관계 정도를 색깔로써 보여주고 있다. 예를 들면, 클래스 내에서 뉴런들 사이의 관계는 우측막대그래프에서 보듯이 보듯이 가장 짙고 동일한 색으로써 0의 값을 가지는데, 이것은 서로가 아주 유사하다는 것을 나타낸다. 그리고, '0'과 '3', '1'과 '2'의 관계는 서로 유사하며, '2'와 '3', '1'과 '3'의 관계는 약하다는 것을 나타낸다. 이때 테스트집합을 이용하여 160개의 특징지도상에 분포된 뉴런의 code book 벡터

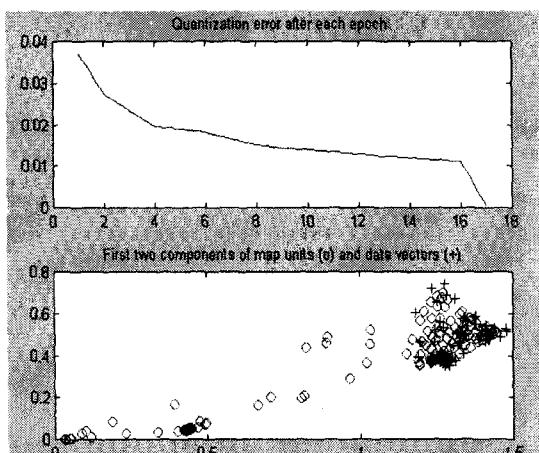


Fig. 5 Feature map of first two component in final state

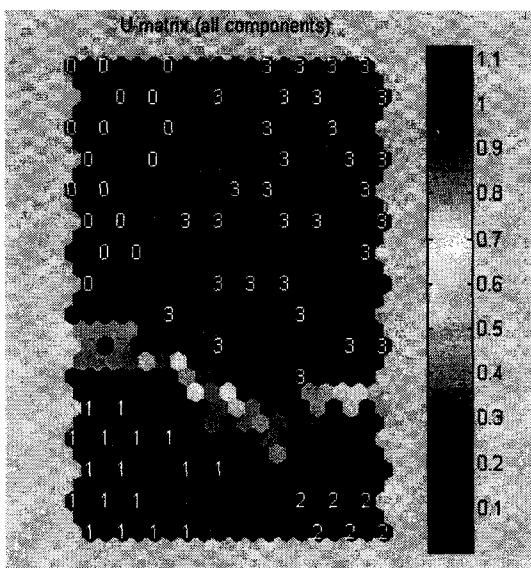


Fig. 6 Unified feature map of all component after training

의 클래스와 테스트집합이 가진 클래스를 비교하여 측정했을 때 에러율은 15.91%이다.

다음은 SOFM의 학습결과로부터 얻어진 뉴런들의 code book 벡터 즉, 지도상의 뉴런수와 동일한 160개를 가지고 LVQ에 입력벡터로 사용하여 학습하는 단계이다⁽¹³⁾. 각 뉴런 당 reference 벡터가 만들어지지만, 유사한 것끼리는 동일 시 함으로 그 클래스의 값이 존재하지 않는 것도 있다. 한편, 이 code book의 생성정도에 따라서 SOFM의 에러율이 결정된다.

먼저 SOFM에서 나온 학습결과(code book)를 훈련집합으로 사용하고 SOFM에서 사용된 테스트집합 44개를 가지고 에러율을 판단하였다. 이 때, 전체 code book을 LVQ상의 code book으로 다 사용하였을 때는 90.91%의 정확도를 가지는 반면에, 각 패턴당 2개씩의 code book을 사용하였을 때는 97.73%의 정확도를 얻을 수 있었는데(Table 1), 이것은 전체 160개 code book 벡터를 다 사용하게 되면 각 클래스들간에 유사하게 형성된 패턴까지 포함하게 되므로 에러율이 높아지며 각 패턴을 대표할 수 있는 code book 벡터(현 데 이터에서는 각 패턴당 2개씩)를 사용함으로써 에러율을 낮출 수가 있었다. 한편, 학습방법으로는 LVQ1을 사용하였으며, 학습횟수는 10000회, 학습률은 0.05%를 사용했다.

앞서와 같이 code book의 수에 따른 정확도는

Table 1 Accuracy According to the Number of Code Book

	No. of Code Book			
	160	120	80	8
Accuracy (%)	90.91	95.45	93.18	97.73

Table 2 Classification Results

Experimental Condition	Classification Accuracy
Normal Condition	100%
Misalignment	100%
Unbalance	100%
Rubbing	90.91%
Average Accuracy	97.73%

Table 1과 같으며, 가장 좋은 분류화율을 보여주는 code book에 대한 분류결과를 Table 2에 나타낸다.

SOFM에 의한 학습 및 분류화를 수행한 후, LVQ로 분류화를 한 후 테스트집합을 사용하여 학습한 결과는 전체 97.73%의 인식도를 보였다. 한편, 접촉에 대한 분류화율이 낮은 것은 특징지도상에서도 나타나듯이 '0'과 '3'의 클래스가 유사하게 평가된 것으로 사료된다.

이상의 결과와 같이 SOFM과 LVQ를 사용하여 분류화를 수행한 결과로써 현 진단시스템을 사용하는 것이 결합진단에 유용하며 좋은 진단결과를 보여준다는 것을 알 수 있다.

4. 결 론

본 연구에서는 회전기계의 이상진동진단을 목적으로 기존의 오차역전파법과는 달리 교사없는 학습을 할 수 있는 분류화도구를 적용하였으며 좋은 분류화 능력을 보여주는 것을 확인하였다. 이는 SOFM과 LVQ를 순차적으로 사용하므로써 분류화의 정확도를 높일 수가 있고, 특징지도의 크기 설정은 데이터가 많지 않은 관계로 그 수에 비례하여 생성하였다. 따라서 SOFM의 학습결과 높은 에러율을 나타내었으나, 이에 LVQ를 이용하므로써 더욱 좋은 분류화율을 얻을 수 있었다. 특징지도의 크기가 작기 때문에 지도형성에는 20~30초 정도의 시간이 소요되어, 빠른 수렴을 나타내

었다. 그리고, LVQ 이용시에 code book의 수는 대표되는 code book 벡터가 그 클래스를 잘 나타내어 주기 때문에 적은 수로도 좋은 분류화율을 나타내며, 전체 분류화시스템을 통하여 좋은 진단결과를 보여줌을 알 수 있다.

사 사

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

참고 문헌

- (1) 최성필, 1994, 신경회로망을 이용한 볼베어링의 결합진단에 관한 연구, 부경대학교, 석사논문.
- (2) 박철현, 1997, 결정목에 의한 회전기계의 진동진단에 관한 연구, 부경대학교, 석사논문.
- (3) 조영천, 임동수, 양보석, 1999, Fuzzy ID3를 이용한 회전기계의 진동진단, 한국소음진동공학회, 춘계학술대회, pp. 118~122.
- (4) 오창석, 1996, 뉴로컴퓨터, 지성출판사, 1996.
- (5) T. Kohonen et al., Oct. 1996, Engineering Application of the Self-Organizing Map, Proceeding of the IEEE, Vol. 84, No. 10, pp.1358~1384.
- (6) S. Haykin, 1999, Neural Network, 2nd edition, Prentice Hall.
- (7) E.R. Kandel and J.H. Schwartz, 1985, Principles of Neural Science, Elsevier, New York.
- (8) T. Kohonen, et al. 1995, SOM_PAK, The Self-Organizing Map Program Package, Helsinki Univ. Technol., Lab. Computer and Information Sci., Espoo, Finland, ; "cochlea.hf.fi" (130.233.168.48).
- (9) 이성환, 1994, 패턴인식의 원리, 홍릉과학출판사.
- (10) 김상운, 1997, 패턴인식입문, 홍릉과학출판사.
- (11) A. C. McCormick et al., May. 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.
- (12) 김창구, 박광호, 기석호, 기창두, 1998, 복소시계열 모멘트의 신경회로망 적용에 의한 회전기계의 상태진단, 한국소음진동공학회 추계학술대회논문집, pp. 527~531.
- (13) C. I. Christodoulou et al. Feb, 1999, Unsupervised Pattern Recognition for the Classification of EMG Signals, IEEE Trans. on Biomedical Eng., Vol. 46, No. 2, pp. 169~178.