

# 회전기계의 결합진단을 위한 사례기반추론시스템

## Case-based Reasoning System for Defect Diagnosis of Rotating Machinery

양보석(부경대 기계공학부)

### 1. 서론

회전기계의 결합발생은 기계의 여러 상태변화에 의한 결과이며, 이 때 발생하는 증상(현상) 또한 다양하고 복잡하기 때문에 기계의 특성을 파악하고 원인을 추정하기 위해서는 매우 전문적인 지식과 오랜 경험이 필요하다. 실제 산업현장에서 사용되는 각종 회전기계들은 고성능화, 복잡화 및 전문가의 부족으로 인해, 결합 발생 시 원인과 발생현상의 관계를 명확히 표현하기에는 어려움이 있다. 이에 최근에는 진단에 관한 전문적인 지식을 구조적으로 표현할 수 있는 전문가 시스템(expert system)의 도입을 위한 연구가 활발히 이루어지고 있다. 전문가의 지식과 경험이라는 것은 발생한 많은 사례(case history)들로부터 얻어진 결과이기 때문에, 전문가의 추론과정을 모델링하여 만들어지는 회전기계의 진단시스템에는 확률적, 통계적인 접근 방법을 취하는 것이 적합하다. 그리고 현재 진단에 이용되는 각종 인공지능 알고리즘이나 분류화 알고리즘(classification algorithm)의 경우, 내부 학습방법으로 확률적이고 통계적인 방법을 주로 이용되고, 규칙기반, 모델기반, 사례기반 및 패턴인식 등에 의한 다양한 방법이 사용되고 있다<sup>(1,2)</sup>. 사례기반추론(Case-Based Reasoning, CBR) 시스템은 과거에 수행되었던 구체적인 사례를 통해서 새롭게 발생한 문제를 해결하는 방식으로, 여러 연구결과 및 상업적인 software의 개발 등의 성공적인 적용을 통해 급속히 발전하고 있다.

그리고 시스템에 대한 정보가 부족하거나 많을 때, 전형적인 샘플들을 사용하여 적응능력이 있는 신경회로망을 학습시켜 경험하지 않은 데이터도 처리할 수 있는 일반화 능력(generalization ability)을 가진 신경회로망(neural network)도 널리 사용되고 있다. 그 중에서 기계 상태의 정상 또는 이상(고장) 증상을 하나의 패턴으로 인식하여 정해진 클래스로 분류하는 방법 중에서 교사 없는 학습(unsupervised learning)방법을 사용하는 자기조직화지도(Self-Organizing Map, SOM)가 화상신호나 음성신호의 인식과 취득된 신호의 양자화(quantization)에 많이 사용되고 있다<sup>(3,4)</sup>.

본 강연에서는 사례기반추론시스템에서 사용된 기존의 진단사례를 통해서 전동기의 고장원인과 발생현상과의 관계를 검토하고, 사례베이스를 이용하여 실제 발생현상을 통한 고장원인을 추정하여 고장진단을 수행하는 SOM 기반의 알고리즘을 설명한다.

### 2. 사례기반추론(Case-Based Reasoning, CBR)

#### 2.1 CBR의 정의

Risebeck과 Schank는 사례기반추론(CBR)을 "과거의 어떤 문제를 해결하기 위해 사용했던 경험을 바탕으로 새로운 문제를 해결하는 방법" 이라고 정의하였다. 예로 의사가 환자를 진단하는데 필요한 지식을 정형화된 규칙만으로는 완전하게 표현하기는 어려우며, 과거의 경험을 기초로 진단하는 경우가 많이 있다. 즉, 새로운 환자를 진단할 때 과거 환자의 사례와 비교하는 경우가 많으며, 많은 경우 자신의 경험을 기초로 병의 원인을 설명하게 된다.

CBR이란 무엇인가? 앞서 언급한 내용을 정리하면, 새로운 문제에 직면했을 때, 이의 해결방법으로 예전의 비슷한 상황을 기억하고 그 상황에서 사용했던 정보와 지식을 재 사용함으로써 새로운 문제를 해결하는 것

이다. 이 방법은 최근에 금융분석, 보험금 평가, 의료진단, 소프트웨어 결정시스템, 예고 계획, 설계, 실제 감정평가 등의 여러 영역에 널리 보급되고 있다. CBR의 응용을 선도하는 상업용 도구들이 1990년대 초에 나타나, 현재 데이터베이스, graphical user interface tools 등 다른 소프트웨어 도구들과 결합하여 발전하고 있다.

## 2.2 CBR의 배경과 역사

과거 사례의 사용을 통한 추론은 인간이 문제 해결에서 강력하고 빈번히 적용하고 있는 방법이다. Schank는 경험의 유지와 기억구조의 발달에 기초한 학습(learning)과 재기억(remind)이론을 발전시켰고, Adneron은 사람들이 문제를 해결하기 위해 학습 시, 특히 초기 학습의 모델로서 과거사례를 이용한다는 것을 보여주었다. 그리고 Rouse는 과거사례의 사용은 숙련자들 중에서도 뛰어난 문제 해결방법이라는 것을 보여주었다.

인공지능분야에서 CBR의 시작은 Schank의 동적 메모리(dynamic memory)에 관한 연구<sup>(5)</sup>에서 시작되었고, CBR에 관한 다른 영역은 철학 및 심리학에서 유사적인 추론에 관한 연구<sup>(6)</sup>로부터 비롯되었다.

사례기반추론기(Case Base Reasoner)라 불리는 최초의 시스템은 예일대학 Schank의 연구그룹의 Koloder에 의해 명명된 CYRUS시스템<sup>(7,8)</sup>이다. CYRUS는 미국국무부장관의 출장 및 모임에서의 다양한 행동패턴을 사례로써 색인(indexing)한 것에 대해 메모리를 조직화한 질의-응답시스템이다. CYRUS는 Schank의 동적 메모리 모델과 문제해결 학습의 기억조직 패킷(memory organization packets) 이론에 근거하여 개발되었고, 이후의 많은 CBR시스템의 기본 개념으로 이용되었다. 다른 기초 모델은 Porter와 그의 텍사스 대학 연구그룹에 의해서 개발되었다. 그들은 처음으로 분류작업(classification task)을 위한 개념 학습의 기계 학습문제를 제시했다. 이것은 일반적인 영역의 지식과 특수한 사례 지식이 통합된 구조를 가진 PROTOS 시스템으로 발전되었다. 이외의 CBR시스템은 JUDGE, HYPO, CABARET과 같은 법률분야의 응용에 이용되었으며, CHEF는 사례기반 계획시스템(case-based planning system)으로 중국의 사천요리에 이용되었다. 동적 메모리는 과거의 요리경험사례를 그것이 충족해야할 목표(요리)와 그것이 피해야 할 실패에 의해 색인되어 상기(想起)에 이용되었다. 유럽의 CBR 연구는 미국보다 조금 늦게 시작되었으나, 전문가시스템의 발전과 지식획득(knowledge acquisition)의 연구에서 미국보다 앞선 연구 결과를 제시하고 있다. 현재, 연구자의 숫자 측면에서 독일이 가장 앞서 있고, 최근 일본 및 아시아의 여러 국가에서도 CBR에 관한 왕성한 연구활동이 이루어지고 있다.<sup>(9)</sup>

## 2.3 CBR의 원리

모든 CBR시스템의 중심 업무는 현재 발생하고 있는 문제상황을 인식하고, 새로운 문제와 비슷한 상황의 과거 사례를 찾아서, 현재 발생하고 있는 문제의 해결책으로 과거 사례의 해결방법을 제안하고, 제안된 해결책을 적용하여 평가하며, 평가된 해결책을 성공 혹은 실패의 사례로 다시 저장하여 사례베이스를 갱신하는 것이다. 최근 검색기반(retrieval-oriented)의 여러 기법들이 지능형 시스템을 개발하는데 점차 도입되고 있으며, 이는 과거 사례가 현재 문제의 해결에 결정적인 도움을 제공하는 진단 분야에 매우 적합한 것으로 알려져 있다. 특히 CBR과정에서 새로운 사례의 추가가 용이하므로 지식의 습득이 자연스럽게 이루어질 수 있으며, 다양한 사례가 확보될수록 보다 정확한 진단이 가능하게 된다.<sup>(10)</sup> CBR의 기본 아이디어는 흔히 사람들이 과거의 문제 해결을 재사용한다는 것이다. 이 같은 문제 해결과정의 재사용을 통해서 자동 학습이 가능해지므로 CBR은 전문가 시스템의 구축에서 가장 어려운 문제인 지식습득 문제를 자연스럽게 해결할 수 있다.

CBR시스템은 Fig. 1과 같이 4개의 과정에 의해서 그 추론 과정을 설명할 수 있다.

- 1) 검색(retrieve): 발생된 문제와 가장 유사한 이전의 사례검색
- 2) 재사용(reuse): 발생된 문제를 해결하기 위해 이전 사례로부터의 지식과 정보를 재사용
- 3) 수정(revise): 이전 사례로부터 제안된 해(solution)가 적용되었다면, 발생된 문제에 맞는 형태의 해로 수정
- 4) 저장(retain): 발생된 문제를 해결했다면 성공한 해로, 문제 해결에 실패하였다면 실패한 해로 저장

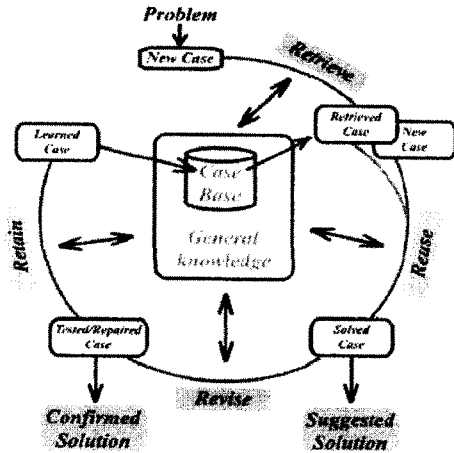


Fig. 1 Case-based reasoning cycle<sup>(9)</sup>

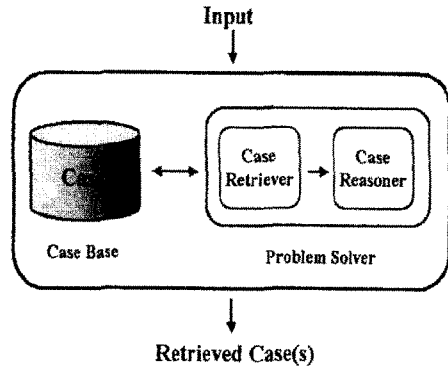


Fig. 2 Construction of CBR system<sup>(11)</sup>

### 2.3.1 CBR의 수행과정

CBR시스템의 주요 요소는 사례베이스(case base)와 문제해결자(problem solver)이다. 사례베이스는 이전에 해결된 문제의 특성들을 기술한 사례를 저장하며, 문제해결자는 사례검색기(case retriever)와 사례추론기(case reasoner)로 구성된다. 어떤 문제가 주어지면, 사례검색기는 사례베이스에서 가장 적절한 사례를 식별하여 사례추론기에 제공한다. 일반적으로 사례추론기는 검색된 사례를 조사하여 필요한 경우 적용(adaptation) 과정을 거쳐서 새로운 문제의 해결을 시도한다. 그러나 응용 분야의 특성이나 사례베이스의 내용에 따라 사례추론기가 필요치 않을 수도 있다. 즉, 거의 정확한 사례를 찾을 경우, 이를 사용자에게 제시하고 사용자가 필요한 약간의 수정을 가하도록 할 수 있다.

현재의 상황이 입력된 다음 사례베이스에 저장되어 있는 과거 사례들 가운데 유사한 사례를 검색하는 작업을 수행하는데, 이때 완전히 일치하는 사례를 찾는 것이 어려우므로 부분적인 일치를 허용하게 되는데, 이 부분적인 일치 즉, 유사성(similarity)을 어떻게 정의하느냐에 따라 시스템의 성능이 좌우될 수 있다. 검색된 사례가 현재의 상황과 완전히 일치하지 않는 경우, 이를 수정하여 현재 상황에 맞는 해결책을 제시하는 과정을 적용이라 한다. 시험(test) 단계는 적용 과정을 거쳐서 제안된 해결책을 현재 문제에 실제로 적용하는 단계이며, 성공이나 실패.

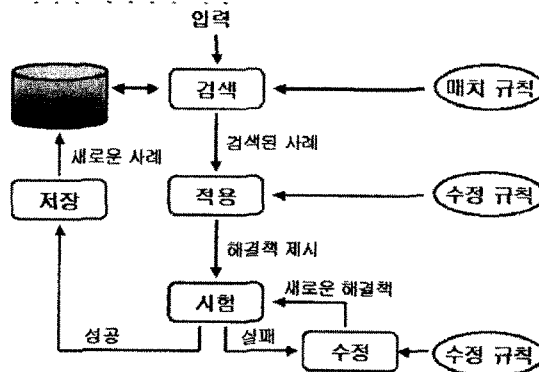


Fig. 3 Performance process of CBR system

### 2.3.2 CBR시스템의 개발 시 문제영역

CBR시스템을 개발하는 과정에서 다음과 같은 5가지의 문제영역이 존재한다.

- 1) 영역전문가의 지식을 어떻게 표현할 것인가 하는 지식의 재표현(representation) 문제
- 2) 이렇게 재표현된 지식을 어떤 방법으로 검색할 것인가 하는 검색방법(retrieval method) 결정 문제
- 3) 결정된 검색방법을 통해 검색된 사례를 어떻게 재사용할 것인가의 재사용방법(reuse method) 결정 문제
- 4) 사례의 수정방법(revise method)의 결정 문제
- 5) 저장방법(retain method)의 결정 문제

## 2.4 CBR의 장점

CBR은 기존의 규칙기반추론(rule-base reasoning, RBR)에 비해 다음과 같은 장점을 가지고 있다.

1) 인간의 추론과 심리학적으로 유사: CBR은 인간의 기억구조로부터 발전하였기 때문에, 많은 규칙에 의해 추론하지 않고 과거의 사례로부터 추론하는 것은 인간의 추론 방법과 유사한 심리학적 모델이라 할 수 있다. 인간이 일상적인 문제를 해결하는 과정에서 CBR을 사용하는 예가 대부분이고 많은 연구에서 이것이 증명되었다.

2) RBR의 문제점을 해결: CBR은 RBR의 문제를 해결하기 위한 방법으로 발전하였기 때문에, RBR에 비해 다음과 같은 장점을 가진다.

- 지식획득(knowledge acquisition) : 사례는 추상적인 규칙보다 쉽게 기억될 수 있으므로, 전문가가 과거의 문제 및 해를 기억하여 새로운 해를 만드는 것이 수많은 규칙으로 문제를 해결하는 것보다 쉽다. 즉, 사례기반의 전문가 시스템을 만드는 것이 규칙기반의 시스템 구축보다 더 용이하다.

- 경험으로부터의 학습 : 사례기반시스템은 문제를 해결할 때, 문제 및 해를 사례로써 메모리에 기억하기 때문에, 쉽게 경험으로부터 학습할 수 있다. 즉, 과거의 문제와 동일한 문제를 해결하기 위해 추론과정을 다시 수행할 필요가 없다. 따라서 CBR시스템은 RBR시스템보다 계산비용의 절감효과가 뛰어나다.

- 적용성 : RBR시스템은 모든 지식이 규칙으로 기록되므로 문제가 규칙과 일치하지 않을 경우, 문제를 해결하기 어렵다. 그러나 CBR시스템은 유사한 특징을 갖는 과거의 문제를 메모리에서 검색하고, 그들이 새로운 문제를 해결할 수 있도록 검색된 사례의 해를 새로운 문제에 적용할 수 있다.

3) 자연적인 학습기능 : 과거의 해를 기억하고 그들을 적용함으로써 새로운 문제가 해결되었을 경우, 그 결과 사례베이스에 저장하므로, 추후 동일한 추론을 반복할 필요가 없다. 또한 CBR시스템은 새로운 문제가 입력되어 적용되고, 성공 혹은 실패의 사례로 저장됨으로써 과정의 반복을 통해 시스템의 성능이 향상된다. 또한 과거의 실패를 예측하고 회피할 수 있다.

## 3. 자기조직화지도 신경망(Self-Organizing Map Neural Network)

인공신경망은 신경세포들이 상호 연결된 네트워크로, 인간 뇌의 구조를 컴퓨터로 구현하여 인간과 유사한 기능을 가진 컴퓨터를 만들자는 개념에서 출발된 이론이다. 신경망은 "지능을 인공적으로 가진 기계(artificial intelligence machine)"보다는 "참 지능을 가진 기계(truly intelligence machine)"를 실현시켜줄 수 있는 가능성의 기술이라는 것으로 정의할 수 있다.<sup>(2)</sup> 그리하여 신경망을 이용하여 인간의 뇌가 하는 계산, 연산, 추론, 기억 등의 기능을 구현할 수 있게 만든 알고리즘을 구현하였는데, 그 중에서 자기 조직화(self-organizing) 신경망은 데이터 집합에 내재해 있는 고유의 구조를 발견하기 위하여 내부의 연결강도를 조정하는 것이다. 데이터의 원하는 출력을 알아야 하는 교사 있는 학습을 사용하는 신경망에 비해 자기조직화 신경망은 스스로

구조를 발견하는 능력 때문에 많이 사용되고 있다. 대표적인 자기조직화 신경망으로는 Carpenter와 Grossberg가 개발한 ART(adaptive resonance theory) 신경망과 Kohonen의 자기조직화지도(SOM) 신경망 등이 있다.

### 3.1 SOM 알고리즘

Kohonen이 제안한 SOM 신경망은 널리 사용되고 있는 인공신경망으로서, 신경세포들의 배치가 감지된 외부 자극의 물리적인 특징을 반영하는 방향으로 정돈된다는 이론에 근거를 두고 있으며, 영상처리, 패턴인식, 영상압축, 네트워크의 트래픽 제어, 정보보호에서의 침입방지 등의 여러 분야에 적용될 수 있다. 그 구조는 Fig. 4와 같이 입력층(input layer)과 출력층(output layer)만으로 구성되고, 입력층과 출력층은 결합강도를 나타내는 가중치(weight)  $w$ 로 연결된 순방향 단층 신경망(forward single layer network)이다. 근간을 이루는 알고리즘은 두뇌에서의 감각 경로를 구성하는 중요한 구성원리 중에 하나는 감지된 외부의 자극에 대하여 뉴런의 배치가 정렬되어 있어서 감지된 외부자극의 어떤 물리적 특성을 반영한다는 것이다. 뉴런이란 신경계의 기능적 최소단위를 말한다. 예를 들면, 입력층의 뉴런을 인간의 몸에 비유한다면 인간의 감각기관과 비슷하여 감각기관에 자극이 주어졌을 때, 이것을 어떤 유사한 자극에 대하여 군집을 이루며 인식하는 부분이 바로 뇌가 되며 출력층 지도가 된다. 여기서 결합강도라는 것은 입력뉴런과 출력뉴런 사이에 맺어진 반응에 대한 민감도이며, 뉴런간의 연결부위인 시냅스(synapse)를 표현한 것이다. 이는 시냅스의 신경 흥분 전달간격이 높으면 반응이 빠르게 나타나고 전달간격이 낮으면 반응이 잘 나타나지 않는다. 그리하여, 입력뉴런의 반응에 대해 가장 민감한 반응을 일으키는 출력뉴런이 존재하며, 따라서 가장 높은 결합강도를 가진 출력뉴런을 이 알고리즘에서는 승자뉴런(winning neuron)으로 선택하게 되는 것이다.




Fig. 4 Structure of the SOM network

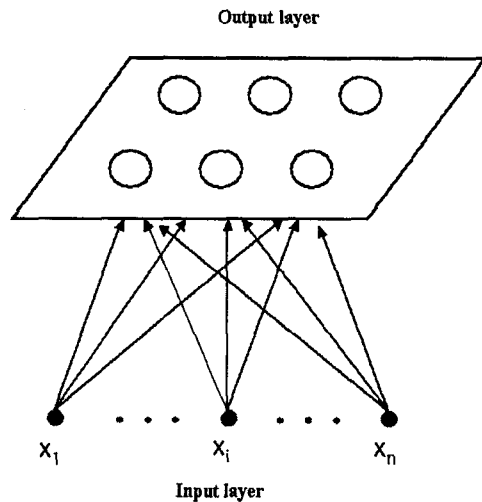



Fig. 5 2-dimensional mapping of the SOM network

상층의 출력층 뉴런을 배열하는 방법으로는 Fig. 4의 1차원 배열과 Fig. 5의 2차원 배열의 2가지 방법이 있으며, 출력 뉴런의 형태로는 이웃하는 뉴런들과의 연결형태가 Fig. 6과 같은 사각형의 형태를 가지는 사각형 배열과, 육각형의 배열을 갖는 육각형 배열이 존재한다.

### 3.2 SOM 신경망의 학습방법

#### Step 1. 초기화

먼저 가중치  $w_{ji}$ 와 학습률  $\eta$ , 인접영역함수  $h_{j,i}$ 를 초기화 한다. 입력층과 출력층의 뉴런 수가 정해지면



a) Tetragon type

b) Hexagon type

Fig. 6 Two different output neuron type of 2-dimensional map

가중치의 수가 결정되고, 가중치의 값은 0과 1사이의 값으로 초기화한다. 학습률  $\eta$ 는 초기에 1의 값을 취하고 학습의 진행에 따라 점차 값을 줄이며, 인접함수  $h_{j,i}$ 는 초기에 비교적 큰 값으로 초기화하여 전체 뉴런 영역을 포함 할 수 있도록 한다.

### Step 2. 경쟁과정

랜덤한 입력에 대해 출력뉴런 중에서 승자뉴런을 찾는 과정으로, 사실 SOM에서 출력뉴런도 벡터이며, 연결강도 가중치가 바로 각 출력뉴런의 벡터이다. 랜덤하게 선정된 입력벡터를

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

로 표시하면, 입력과 출력을 연결하는 가중치 벡터  $w_j$ 는

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

로 되고,  $m$ 은 입력벡터의 차원 수,  $n$ 은 출력뉴런의 수이다. 입력층의 뉴런 수는 입력벡터의 차원 수  $m$ 과 같고, 출력층의 뉴런 수는 분류의 요구에 따라 인위적으로 지정하며, 가중치  $w_{ji}$ 는  $n \times m$ 의 행렬로 된다.

승자뉴런을 찾는 과정은 입력벡터와 각 출력뉴런 벡터의 유클리드 거리를 구하여 거리가 제일 작은 출력벡터를 승자 뉴런으로 한다.

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

### Step 3. 협동과정(Cooperative process)

승자뉴런을 중심으로 그 이웃뉴런(흥분된 뉴런)들과의 관계를  $h_{j,i}$  즉, 형상학적 이웃(topological neighbor)이라 하고 식 (4)로 정의되는 Gauss분포함수의 형태를 띄며 Fig. 4와 같은 형태를 가진다. 이 그림은 근접거리(lateral distance)  $d$ 와 유효넓이(effective width)  $\sigma$ 의 관계를 보여주며, 근접거리는 Fig. 4에서와 같이 최초단계에서 모든 뉴런에 대해서 이웃관계가 성립되지만, 실질적으로 관계를 맺는 뉴런은 주어진 유효넓이  $\sigma$ 내에서만 이웃뉴런으로 관계를 갱신하게 되는 것을 나타낸다. 즉, 이웃과의 거리  $d_{j,i}$ 가 0이 되며  $h_{j,i}$ 가 1의 값을 가지면 이웃뉴런과 승자뉴런이 거의 유사한 결합강도를 가지게 되는 것이다. 그리고  $d_{j,i}$ 가 무한대로 되면  $h_{j,i}$ 는 0에까지 감소하게 되며 이웃관계가 성립되지 않으며, 한편 유효넓이  $\sigma$ 를 설정하여 학습과정에 참여하는 흥분뉴런의 범위를 제한해 주고 있다.

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

여기서,  $\sigma$ 는 유효넓이,  $d_{j,i}$ 는 승자뉴런  $i$ 와 흥분된 뉴런  $j$ 사이의 근접거리이다.




Fig. 7 Gaussian neighbor function<sup>(3)</sup>




Fig. 8 Area of topological neighbor according to time<sup>(4)</sup>

그리고, Fig. 8은 승자뉴런  $i$ 를 중심으로 그 이웃뉴런들과의 관계를 갱신하는 과정을 2차원 지도상에 나타낸 것이다.  $N_e(0)$ 는 최초 이웃뉴런의 관계가 생성되었을 때의 영역을 나타내고, 차츰 시간이 지남에 따라  $N_e(S_1)$ 과  $N_e(S_2)$ 의 영역 순으로 점점 좁혀지게 되는 것을 보여준다. 이와 같이 식 (4)를 이용하여 Fig. 8과 같은 과정을 거쳐 이웃관계를 형성하게 된다.<sup>(4)</sup>

#### Step 4. 적응과정(Adaptive process)

마지막 과정으로 결합강도가 입력벡터로 닳아 가는 형태를 취하는데, "같은 시간에 2개 뉴런이 활성이 크면, 그들 사이의 결합강도는 증가한다"는 Hebbian의 가설에 의해 결합강도의 변화는 단지 한 방향으로만 일어나기 때문에, 즉 뉴런의 출력이 클 때 뉴런의 입력들 중에서 하나가 크다면 입력과 뉴런 사이의 결합강도는 계속 커져서 마지막에는 결합강도가 포화상태에 이르게 된다. 따라서, 망각항(forgetting term)인  $g(y_j)$   $w_j$ 항을 고려함으로써 이 결점을 보완하게 된다. 여기서  $w_j$ 는 뉴런  $j$ 의 결합강도 벡터이고,  $g(y_j)$ 는 응답  $y_j$ 의 양의 값을 가지는 스칼라 함수이다. 함수  $g(y_j)$ 에 요구되는 조건은  $g(y_j)$ 의 Taylor 급수 전개 상수항은 0이어야 한다는 것이다. 이것은 다음과 같이 쓸 수 있다.

$$g(y_j) = 0 \quad (y_j = 0 \text{ 일 때}) \quad (5)$$

위와 같은 가정에 의해 출력뉴런  $j$ 를 둘러싼 이웃뉴런의 격자(lattice)에서의 변화는 다음과 같이 표현할 수 있다.

$$\Delta w_j = \eta y_j x - g(y_j) w_j \quad (6)$$

여기서,  $\eta$ 는 학습률(learning rate)이고, 이는 결합강도의 변화 정도를 조절하는 것으로써, 신경망의 구조 및 응용 목적에 따라서 다르다. 이 알고리즘에서는 되도록 작은 값을 선택하면 좋은 수렴결과를 나타내지만, 시간지연이 많은 단점이 있다. CBR에서 학습률은 시간에 따라서 학습률이 곱해짐으로써 감소하게 된다. 보통

$\eta(t)$ 는  $0 < \eta(t) < 1$ 이다. 식 (6)에서 우변의 첫 항은 Hebbian항이고, 둘째 항은 망각항이다. 식 (5)의 조건을 만족시키기 위해서 선형인  $g(y_j)$ 를 고려하면

$$g(y_j) = \eta y_j \quad (7)$$

과 같이 표현할 수 있으며, 다음 식을 고려함으로써 식 (2.6)을 더 단순화시킬 수 있다.

$$y_j = h_{j,i(x)} \quad (8)$$

다음으로 식 (6)에 식 (7)과 (8)을 사용하여 다음 식을 얻을 수 있다.

$$\Delta w_j = \eta h_{j,i(x)} (x - w_j) \quad (9)$$

마지막으로, 이산시간지형(discrete-time formalism)을 도입하면, 시간  $t$ 의 뉴런  $j$ 의 결합강도벡터  $w_j(t)$ 와 시간  $t+1$ 에서 갱신된 결합강도벡터는 다음 식에 의해 정의된다.

$$w_j(t+1) = w_j(t) + \eta(t) h_{j,i(x)}(t) (x(t) - w_j(t)) \quad (10)$$

### Step 5. 반복

지도 내에 두드러진 변화가 관측되지 않을 때까지 Step 2부터 반복수행을 계속한다. 이 과정을 전반적으로 살펴보면, 초기에 입출력 unit 사이의 결합강도를 작은 임의의 값으로 설정한 후 입력패턴을 제시한다. 입력과 모든 unit 사이의 거리를 계산하여, 만일 결합강도벡터가 정규화되어 모든 입력 unit에서 각 출력 unit로의 결합강도를 제공하여 합산한 값이 동일한 일정한 길이를 가지면 입력벡터와 결합강도의 내적(dot product)을 구하여 최소 유클리드 거리를 갖는 unit를 찾을 수 있다. Step 2에서 필요한 선택은 최대값을 갖는 unit를 찾는 문제이다. 최대값을 갖는 뉴런이 선택되면, 그 뉴런과 주위 이웃 뉴런으로의 결합강도를 조정하여 현재의 입력에 이 unit들이 보다 잘 반응하도록 한다. 또 다른 입력에 대하여 이러한 과정이 반복된다. Step 4의 학습률이 0으로 감소하면, 결합강도는 궁극적으로 수렴하여 고정된다.<sup>(3,4)</sup> 이와 같은 학습을 통하여 지도(map)라는 출력층 뉴런을 생성하게 되면, 이 지도에 우리가 원하는 분류화가 정보가 담겨져 있다.

## 4. 결합 사례베이스

### 4.1 사례베이스

전동기의 사례베이스는 진동진단 전문가가 현장에서 다양하게 발생하는 현상을 관찰하여 진동의 원인을 발견하고, 이에 따른 대책수립을 수행하였던 많은 양의 사례에 대한 기술보고서를 정리한 기계건강진단사례집에 수록된 전동기 사례를 이용하였다. 사례베이스의 기본양식은 Fig. 9와 같이 사례의 제목과 구성기계 및 주 진동현상을 열거하고, 진동문제를 대상기계의 세부사항, 문제가 발생했을 당시의 물리적 현상을 서술한 발생현상 항목, 전문가가 발생현상을 바탕으로 추정했던 원인을 서술하는 원인추정 항목, 추정된 원인을 기초로 진동해석 및 자료를 분석하여 문제의 원인을 확정하는 해석 및 자료분석 항목, 확정된 원인을 제거하기 위해 실시되었던 대책을 서술하는 실시한 대책 항목, 사례를 통해서 얻을 수 있는 교훈항목과 인공문헌으로 구성된다. 실제 고장진단을 수행하기 위해서는 각 사례마다 서술되고 있는 진동 발생현상과 원인을 정리하는 작업이 필요하다.

사례베이스의 구축은 국내 사정상 진동 트러블을 해결했던 기술자료의 공유가 잘 이루어지지 않기 때문에, 주로 외국의 해결사례를 번역하여 정리하였다. 따라서 각 사례에서 실시된 대책은 국내 상황에 적합하지 않



을 수도 있다. 표준 사례는 전동기에서 발생되었던 실제 진동트러블을 해결한 기술자료를 바탕으로 작성되었다. 현재의 사례를 SOM 신경망에 이용하기 위해서는 사례를 분석하는 작업이 필요하다.

## 4.2 사례베이스 분석

현재의 사례베이스는 기계건강진단사례집<sup>(12)</sup>에 있는 전동기 사례 중에서 원인추정이 정확하지 않은 사례와 앞장에서 언급한 결함에 포함되지 않은 사례를 제외한 31개와 진단관련 업체의 기술보고서 그리고 각종 해외저널에 실린 사례를 포함해서 총 47개의 사례로 구성되어 있다.

SOM 신경망을 이용한 결함진단을 위해서는 현재의 사례베이스 분석을 통해 각 사례에 해결방안을 마련하기 위해 수행했던 해석 및 자료분석과 결함발생 당시에 보고된 발생현상을 토대로 하여 사례베이스에 포함된 모든 진동현상들을 추출하고 그것들을 원인별로 분류하는 작업이 이루어져야 한다. 이는 각 사례가 가진 특징들을 분석하는 일로서, 각 사례를 원인별로 분류하는 것은 사례에서 수행되었던 해결방안을 통해서 쉽게 알 수 있지만, 실제 진동현상이 아닌 보고서 형식의 사례를 통해서 각 사례가 가진 발생현상을 찾아낸다는

::: 전동기&발전기 :::		목록보기   그림보기   내용출력
사례 M-23	전동기의 자기적 중심불일치에 의한 진동	전동기, 압축기 전자진동
대상기계	원심압축기 구동용 전동기(Westinghouse제, 700HP, 3600rpm)	
발생현상	원심압축기 구동용 전동기가 높은 축방향진동을 경험했다. 전동기를 분해검사(overhaul)하여 재설치된 후, 축방향진동이 정상보다 더 높게 되었다. 또한 전동기에서 덜거덕 거리는 소음이 발생되었고, 이 소음은 연속적이었다.	
해석 및 자료분석	축방향의 진동신호(그림 1)는 1x와 3x의 진동주파수를 나타내었다. 주파수의 확대(zooming)에서 몇 개의 작은 측대파(sidebands)를 보였지만, 중요하지는 않았다.	
원인추정	전동기를 정지하고, 정렬(alignment)을 조사한 후, 필요에 따라 재정렬을 실시하도록 권장하였다.	
실시한 대책	커플링이 파손되었을 때, 그리스(grease)가 발견되지 않았다(즉, 커플링은 건조한 상태에서 운전하였다). 전동기는 자기적인 중심(magnetic center)을 발견하기 위해서 분리운전하였다. 전동기가 압축기와 체결될 때, 전동기는 자기적인 중심이 어긋나는 것이 발견하였다.  전동기가 자기적인 중심에서 벗어나 운전되었기 때문에, 진동이 정상적인 축진동 보다 높게 발생하였다. 이것은 전동기가 올바른 자기적 중심으로 되돌아가도록 시도하기 때문이다. 커플링내에 그리스가 없는 것이 기어이의 마끄러짐을 방해하였다. 이것은 토크 자물쇠(torque lock)을 제거하고 2x와 3x 진동주파수를 아끼시켰다. 재정렬과 윤활을 실시하여 전동기를 보수한 후 진동 신호는 정상적인 진동레벨을 보였다.	
인용문헌	K.R. Guy, Case Histories : Power Industry, Vibration Institute, 1993	

Fig. 9 An example of standard case

것은 쉬운 일이 아니다. 이것은 진동과 진단에 대한 많은 지식과 경험을 필요로 한다.

사례분석을 통해서 얻은 원인별 분류는 전기적 결함인 회전자 손상, 고정자 이상, 공극편심과 기계적 결함인 정렬불량, 불평형, 헐거움이다. 각 사례에 포함된 발생현상들은 원인별로 약간의 차이가 있지만, 유사한 구성을 보이고 있다. 이것은 각 사례가 SOM 신경망에서 원인에 따라 다른 속성을 보이며, 실제 분류에 있어서도 다른 발생현상의 구성에 따라 다른 원인을 추정할 수 있게 한다.

Fig. 10은 표준사례(standard case)를 SOM 신경망에 적용하기 위해서 재 표현한 사례베이스를 나타낸다.




Fig. 10 Case-base for electric motor

원인	기계적	헐거움, 정렬불량, 불평형,
	전기적	회전자 손상, 고전자 이상, 공기불량
발생현상		전동기 베어링 부 진동
		베어링 수직, 수평, 축방향 진동
		회전축 진동
		전동기 기초(바닥)에서 진동
		전동기 케이싱 진동
		부하에 따라 진동 증가
		유량에 따라 진동 증가
		전원 차단 시 즉시 진동소멸
		토크변동(맥동) 발생
		접촉(rubbing) 발생
		공진 발생, 울림(beat) 발생
		운전주파수 성분
		운전주차수 분수 및 배수조파성분
		울림주파수 성분
		전원주파수, 2배성분주위의 측대역파
		전원주파수 2배 성분
		주기적 소음, 단순 이상음
		과전류, 옴할유 변색
		베어링 손상, 교체
		회전자 손상

Fig. 11 Causes and symptoms of electric motor defects

## 5. SOM신경망에 의한 분류화 과정

실제 진동 데이터의 분석은 진단에 대한 많은 지식과 경험을 가지고 수행을 하지만, 전동기의 결함에 있어서는 전기적인 결함에서 주로 발생하는 전원주파수의 2배 성분과 기계적인 결함에서 발생하는 운전속도 성분이 주된 주파수 성분이며, 이 두 개의 성분들이 각각의 결함에 대해서 나타나기도 하기에 정확한 원인 판단이 어렵게 된다. 따라서 정확한 신호 분석이외에도 외부에서 발생하는 여러 현상들과 외부환경에 따라 발생할 수 있는 여러 현상들을 고려해야 할 것이다. 앞장에서 정리한 사례베이스의 각각의 사례들은 신호분석 이외에도 결함 발생 당시의 여러 현상들도 중요한 요소(factor)로 정리하였다. 따라서 전동기의 사례베이스를 통한 SOM 신경망에 의한 분류화는 전동기에서 전기 또는 기계적이 결함이 발생했을 경우 진동 데이터의 분석을 통한 원인규명이 어렵거나, 규명된 원인에 대한 조치활동을 결정하는 지원 도구으로써 이용할 수 있다. 본 예에서는 전동기 결함에서 발생현상 26개를 가지고 전동기의 결함원인을 추정하고자 한다.

### 5.1 전동기 결함 분류과정

우선 사례 분석을 통해서 사례를 구분하고, SOM 신경망에 대입하여 신경망을 훈련하여야 한다. 즉, 훈련 과정(training process)이 먼저 필요하다. 훈련이 완료되면, 신경망 사이의 가중치(weight)가 구하여 지고 각 원인에 대한 상태의 패턴이 기억된다. 다음으로 미 학습된 사례를 입력했을 때, SOM 신경망은 입력된 사례와 이미 기억된 원인사이의 유사성(similarity)을 비교하여 제일 유사한 원인으로 사례를 분류한다. 이를 분류 과정이라 한다. SOM 신경망의 출력 뉴런(output neuron)의 수는 적당하여야 하며, 뉴런 수가 너무 많으면 같은 유형의 원인도 여러 원인으로 나누어지고 분류율이 낮아지게 되며, 역으로 너무 적으면 각 원인을 모두 표현할 수 없으므로 역시 분류율이 낮아지게 된다.

먼저 총 47개의 사례에 대해 사례분석을 통해서 분류한 6가지 원인별로 사례를 구분하고, 이 중 42개는 훈

련용 입력벡터로 사용하고 나머지 5개는 테스트용 입력벡터로 사용하여 자기조직화지도를 구성하였다. 상태 분류를 위한 입력 뉴런은 전동기의 일반적인 진단방법과 사례분석을 통해서 얻은 발생현상으로 현재의 시스템의 경우는 26개로 일정한 값을 가진다. 하지만 많은 사례의 수집과 현재 사례베이스의 해석에 따라 다양한 입력 뉴런의 형태로 바꿀 수 있지만, 현재의 시스템에서는 전동기 결함에서 발생할 수 있는 모든 현상들로 나타내었다. 출력뉴런의 수는 데이터의 개수만큼 출력 뉴런을 만드는 것이 가장 좋으며, 본 연구에서는 출력 뉴런의 수를 데이터의 수보다 크게 하였다. Table 1은 각 학습과 테스트를 위한 상태를 정리한 것이다.

Table 1 Training condition of SOM

Item	No. of data
Training set	42
Test set	5
Attribute of input vector	6
Input neuron	26
Output neuron	200

Table 2 Symbol of defect cause

회전자 이상	O
고정자 이상	S
불평형	B
정렬불량	M
헐거움	L
공극 편심	A

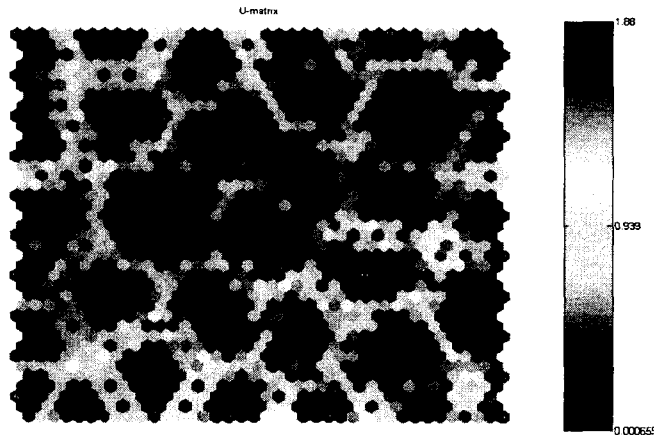


Fig. 12 Unified feature map of all component after training

각 원인별 사례분포는 회전자 이상 21개, 고정자 이상 4개, 기계적 헐거움 8개, 정렬불량 7개, 불평형 4개, 공극 편심 3개이다. Fig. 12는 최종적으로 학습된 자기조직화지도를 나타낸다. 여기서 Table 2는 출력 뉴런의 상태를 기호로 표시한 것이다. Fig. 12에서 보면 6개의 속성으로 학습한 결과이지만, 동일한 원인을 가진 사례들도 독립적으로 분포되어있음을 알 수 있다. 실제 진동 데이터를 가지고 회전체 결함을 진단한 결과를 보면, 동일한 속성을 가진 사례에 대해서는 서로 인접하여 군집을 이루는 것을 알 수 있다.<sup>(17)</sup> 실제 진동 데이터를 가지고 특징을 추출하여 얻은 수치들은 동일 속성에 대해서 유사한 값을 나타내기 때문인데, 사례베이스를 통한 결과는 각 사례 속에 실제 진동 데이터 이외에도 길로 나타난 가시적인 현상과 같은 진동 데이터가 아닌 요소들이 포함되어 있기 때문이다. 이것은 사례가 가지는 특징 중에 유일성을 나타내는 것이다. 각 사례사이의 경계가 존재하는 것은 사례 사이의 이웃정도가 약하다는 것을 나타내며, 우측의 막대그래프는 좌측의 지도에서 뉴런간의 거리 관계 정도를 색깔로서 보여주고 있다.

## 5.2 테스트 결과

1) 입·출력 뉴런의 크기의 영향: 출력뉴런의 수를 변화해가면서 분류율의 변화를 조사하였다. 여기서는 데이터의 수가 적은 관계로 인해, 총 데이터에서 임의로 5개를 선택하여 총 5회의 테스트를 통해서 평균치를 구하였다. Fig. 6.2를 보면 알 수 있듯이 뉴런수가 너무 적거나 많을 때는 분류율이 낮고 약 300개에서 분류율이 높게 나타남을 알 수 있다. 실제 진동 데이터를 가지고 분류를 할 경우<sup>(13,17)</sup>에는 데이터의 추출한 특징들이 입력 벡터가 된다. 따라서 데이터의 특징이 많으면 더 나은 결과를 보인다. 하지만 본 연구에서는 입력 뉴런의 수는 26개의 발생현상으로 고정된다. 만약 입력 뉴런과 분류율과의 관계를 알기 위해서는 현재의 사례베이스를 현재와는 다르게 재구성을 해야한다. 출력 뉴런의 수는 현재의 시스템만이 가지는 속성으로, 이것이 다른 경우에도 만족하는 것은 아니다. 적은 사례를 가지고 분류를 하기 위해서는 학습 시에 입력 데이터의 수보다는 많은 출력 뉴런을 형성하여 인접 근방에 많은 뉴런을 생성하는 것이 좋은 결과를 보이기 때문이다. 하지만 입력 데이터에 비해 너무 많은 출력 뉴런이 생성되면 학습을 하는 시간도 많이 소요되고 분류율도 향상되지 않기 때문에 적당한 출력 뉴런의 선택이 중요하다.




Fig. 13 Effect of neuron number for output layer




Fig. 14 Effect of number for output layer

2) 사례의 수의 영향: 이번은 훈련 데이터의 수에 따라서 분류율이 어떻게 변화하는지는 알아보기 위한 테스트이다. 먼저 기계건강진단 사례집에 나와있는 31개의 사례를 가지고 먼저 테스트를 실시하고, 사례집 외에 추가로 진단관련 업체의 기술보고서 그리고 각종 해외저널에 실린 사례를 합한 후에 테스트를 실시하였다. 테스트 방법은 앞과 동일하게 총 데이터에서 테스트를 위한 데이터 5개를 제외한 나머지로 훈련을 실시하고 5개의 데이터로 테스트를 실시했다. Fig. 6.3은 분류 결과를 나타내며, 전체적인 경향을 보면 사례수가 많을 경우에 분류 성공율이 높은 것을 알 수 있다. 47개의 사례를 통한 분류율을 보면 전체 분류율은 약 65% 정도이다. 이것은 다른 참고문헌에서 보는 분류율과 비교해 볼 때 낮은 수치이다. 그 이유는 첫째, 사례수의 부족이다. 47개의 사례를 보면 회전자 손상의 경우 21개의 사례로 가장 많은 비율을 차지하고 있다. 테스트에서도 다른 원인보다는 훨씬 낮은 결과를 보여주었다. 하지만 상대적으로 사례의 수가 적은 원인들은 출력 뉴런의 수가 많아지더라도 분류율의 차이가 나지 않았다. 그리고 고정자 이상과 공극 편심의 경우에는 상호 반대로 분류되어 분류율을 떨어뜨리는데, 그 이유는 두 가지 모두 전기적인 결함으로서 실제 진동 데이터를 분석을 통해서도 판별이 어려울 정도로 유사한 경향을 보이고 있기 때문이다.

사례의 수가 많다는 것은 26개의 입력 벡터로 생성할 수 있는 연결강도 또한 많아진다는 것을 의미한다. 진동기의 각 원인들은 진동데이터 스펙트럼 분석 외에도 여러 요소들이 포함되어있다. SOM은 확률 및 통계적인 접근 방법을 택하고 있고, 특히 사례베이스를 통한 SOM분류는 많은 사례를 수집하여 각 원인에 대한 경우의 수를 많이 보유함으로써 더 나은 결과를 기대할 수 있을 것이다.

## 6. 결론

본 연구에서는 전동의 결합진단을 목적으로 이전부터 사용되어온 오차역전파법과는 다른 순방향 2층 신경망이며 교사 없는 학습을 하는 SOM 신경망과 과거의 어떤 문제를 해결하기 위해 사용했던 경험을 바탕으로 새로운 문제를 해결하는 방법인 사례기반추론시스템을 이용하여 결합진단에 적용 가능성을 검토하였다.

일반적인 진동 데이터가 아닌 사례기반추론시스템의 사례베이스를 가지고 SOM 신경망에 이용하기 위해서 자연어로 만들어진 표준형식의 사례를 재 표현하였고, 각 사례가 가지는 전동기의 기계적인 결합과 전기적인 결합을 분석하여 사례베이스를 6가지의 고장원인과 26개의 발생현상으로 분류하였다. 테스트를 통해서 사례의 수와 출력 뉴런이 분류율에 미치는 영향에 대해 조사하여, 사례의 수가 많을수록 더 나은 결과를 보인다는 것을 파악하였다. 기계건강진단 사례집과 국내·외의 기술보고서 그리고 각종 해외저널에 게재된 사례를 이용하여 시스템을 검증하였다. 하지만 SOM 신경망과 사례기반추론을 이용한 결합진단시스템은 많은 확률적이며 통계적인 접근방법을 취하는 것이기 때문에 많은 정보가 필요로 한다. 앞으로 시스템을 통해서 여러 가지 사례에 대해서 평가가 있어야 하고 보다 나은 진단 결과를 얻기 위해서 많은 양의 사례 수집을 통한 사례베이스 구축작업이 지속적으로 이루어져야 할 것이다. 현재와 같이 사례분석을 통해서 얻은 현상들을 병렬적인 방법으로 나열하는 대신에 다른 여러 방법에 의한 분류성능도 검토하여야 할 것이다.

## 참고문헌

- (1) R. P. Lippmann, An Introduction to Computing with Neural Nets, IEEE ASSP Mag., pp. 4-22, April 1987.
- (2) 조영입, 최신 인공지능, 학문사, 1999.
- (3) S. Haykin, Neural Network, 2nd edition Prentice Hall, 1999.
- (4) 이성환, 패턴인식의 원리, 홍릉과학출판사, 1994.
- (5) R. Schank, Dynamic Memory; a Theory of Reminding and Learning of Computer & People, Cambridge Univ. Press, 1982.
- (6) E. Tulving and W. Donaldson, Organization of Memory, Academic Press, 1972, pp.381-403.
- (7) J. Kolodner, Maintaining Organization on a Dynamic Long-Term Memory, Cognitive Science, Vol. 7, pp.243-280, 1983.
- (8) J. Kolodner, Reconstructive Memory, a Computer Model, Cognitive Science, Vol. 7, pp. 281-328, 1983.
- (9) A. Aarnodt & E. Plaza, Case-Based Reasoning: Foundational Issue Methodological Vibrations and System Approaches, IOS Press Vol. 7, NO. 1, pp.39-59.
- (10) Barletta, R., Case-based reasoning and information retrieval: Opportunities for technology sharing, IEEE Expert, Vol. 8. No. 6, pp.2-3, 1993.
- (11) 김은경, 신장질환진단을 위한 규칙기반추론과 사례기반추론의 통합, 정보과학논문지 24권 10호, pp. 1093-1100, 1997.
- (12) 양보석, 기계건강진단 사례집, 효성출판사, 1998.
- (13) 서상윤, 임동수, 양보석, 자기조직화지도를 이용한 회전기계의 이상진동진단, 한국소음진동공학회 추계학술대회, p.411-416, 1999.
- (14) T. Kohonen, et al., SOM\_PAK, The Self-Organizing Map Program Package, Helsinki Univ. Technol., Lab. Computer and Information Sci., Espoo, Finland, 1995; "cochlea.ht.fi" (130.233.168.48).
- (15) 이창목, 양보석, 회전기계의 이상진동진단을 위한 사례기반추론시스템의 개발, 한국소음진동학회 추계학술대회, 2000.
- (16) J. S. Mitchell, Introduction to Machinery Analysis and Monitoring, Pennwell Books, pp. 470, 1993
- (17) 안경룡, 인공지능망을 이용한 회전기계의 고장진단, 박사학위논문, 부경대학교, 2002
- (18) 양보석, 진동법에 의한 설비진단의 실제, 일오출판사, 1993
- (19) 이창목, 회전기계의 이상진동진단을 위한 사례기반 추론 시스템의 개발, 석사학위논문, 부경대학교, 2000.
- (20) 오용민, 패트리 넷를 이용한 CBR시스템의 사례검색, 석사학위논문, 부경대학교, 2001.
- (21) 최성필, 신경회로망을 이용한 불배어링의 결합진단에 관한 연구, 석사학위논문, 부경대학교, 1994.
- (22) 조영천, 임동수, 양보석, Fuzzy ID3를 이용한 회전기계의 진동진단, 한국소음진동공학회 추계학술대회, p.118-122, 1999.
- (23) 김용수, 사례기반추론과 자기조직화지도를 이용한 회전기계의 이상진동진단, 석사학위논문, 부경대학교, 2003.