

11-1
11-2
11-3
11-4

공학석사 학위논문

사례기반추론과 인공신경망을 이용한 회전기계의 이상진동진단



2003年 2月

부경대학교 대학원

기계설계학과

김 용 수

김 용 수의 공학석사 학위논문으로 인준함

2002年 12月

주	심	공학박사	김	동	조
위	원	공학박사	백	운	경
위	원	공학박사	양	보	석



목 차

Abstract	3
제 1장 서론	4
제 2장 인공신경망 알고리즘	6
2.1 자기조직화지도 신경망	6
2.2 ART 신경망 알고리즘	12
2.3 ART-Kohonen 알고리즘	13
제 3장 사례기반추론(CBR)	17
3.1 사례기반추론의 정의	17
3.2 사례기반추론의 배경과 역사	17
3.3 사례기반추론의 원리	18
3.4 사례기반추론의 장점	21
제 4장 전동기의 결합진동	23
4.1 전동기 결합	23
4.1.1 전동기의 기계적인 결합	23
4.1.2 전동기의 전기적인 결합	27
4.2 전동기 사례베이스	34
제 5장 인공신경망에 의한 전동기 사례분류	36
5.1 자기조직화지도 신경망에 의한 사례분류	36
5.1.1 사례분석 I의 분류결과	36
5.1.2 사례분석 II의 분류결과	43
5.2 ART-Kohonen 신경망에 의한 사례분류	46

5.3 적용 예	48
5.3.1 문제사례 분석	48
5.3.2 CBR시스템과 비교검증	50
제 6장 결론	52
참고문헌	53

Abnormal Vibration Diagnosis of Rotating Machinery Using Case-Based Reasoning and Artificial Neural Network

Yong-Su Kim

Department of Mechanical Design

The Graduate School

Pukyong National University

Abstract

If the rotating machinery has some faults, we can detect it using vibration or noise signals. However, some maintenance engineers who don't have expert knowledge, need the help of vibration experts for diagnosis rotating machinery. Therefore, This paper presents a new approach integrated Case-Based Reasoning with Self-Organization Map (SOM) and Adaptive Resonance Theory (ART) in diagnosis systems. The causes of faults are obtained by case-base trained from Neural Network. When the vibration problem of rotating machinery occurs, this provides an exact diagnosis method that shows the fault cause of vibration problem. In order to verify the performance of algorithm, we applied it to diagnose the fault causes of the electric motor.

1. 서 론

산업의 현대화와 과학기술의 급속한 발전과 더불어 생산효율과 제품품질을 최대로 향상시키기 위해, 산업 기계는 대형, 고속, 고 하중, 연속운전 및 복잡한 구조로 발전하고 있다. 이러한 특징은 생산의 요구를 만족하는 반면, 설비의 고장발생 가능성과 고장의 다양성도 따라서 증가하게 되고, 고장이 발생시 설비 전체뿐만 아니라 전 생산과정을 파손시키고 이에 다른 막대한 경제적인 손실과 인명 피해도 초래할 수 있다. 특히 실제 산업현장에서 사용되고 있는 각종 회전기계들은 고성능화, 복잡화 및 전문가의 부족으로 인해서 결함발생시 진동의 원인과 발생현상과의 관계를 명확히 표현하기에는 어려움이 있다.

회전기계에 결함이 발생하였을 때 발생하는 진동신호는 기계의 여러 가지 상태변화에 의한 결과이며, 이 때 나타나는 현상 또한 다양하고 복잡하기 때문에 기계의 동특성을 파악하고 원인을 추정하기 위해서는 매우 전문적인 지식과 오랜 경험이 필요하다.

이에 최근에는 진동진단에 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 추론 과정을 모델화하여 만들어지는 회전기계의 진단 시스템에는 확률적, 통계적인 접근 방법을 취하는 것이 적합하다. 그리고 현재 진단에 이용되는 인공지능(artificial intelligence) 알고리즘이나 분류화 알고리즘(classification algorithm)의 경우는 내부 학습방법으로 확률적이고 통계적인 방법을 주로 사용하고 있다. 규칙기반, 모델기반, 사례기반 및 패턴인식 등에 의한 여러 가지 방법이 사용되고 있다. 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 급속도로 발전하고 있다.

그리고 시스템에 대한 정보가 부족하거나 정보량이 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)와 학습과 분류를 동시에 수행하는 적응공진이론(Adaptive Resonance Theory, ART)이 화상신호나 음성신호의 인식과 취득된 신호의 양자화(quantization)에 많이 사용되고 있다.

본 연구에서는 사례기반추론시스템에서 사용되었던 기존의 사례를 통해서 전동기의 고장원인과 발생현상과의 관계를 검토하고, 사례베이스를 이용하여 실제 발생현상을 통한 고장원인을 추정하여 고장진단을 수행하는 SOM과 ART 기반의 알고리즘을 제안하였다.

2. 인공신경망 알고리즘

인공신경망(artificial neural network)은 신경세포들이 상호 연결된 네트워크로 인간 뇌의 구조를 컴퓨터로 구현하여 인간과 유사한 기능을 가진 컴퓨터를 만들어 보자는 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.⁽²⁾ 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 능력을 때문에 많이 사용되고 있다. 대표적인 자기조직화 신경망으로는 Carpenter와 Grossberg가 개발한 ART (Adaptive Resonance Theory) 신경망과 Kohonen의 자기조직화지도(Self-Organizing Map) 신경망 등이 있다.

2.1 자기조직화지도 신경망

Kohonen이 제안한 SOM 신경망은 가장 널리 사용되고 있는 인공신경망으로서, 신경 세포들의 배치가 감지된 외부 자극의 물리적인 특징을 반영하는 방향으로 정돈된다는 이론에 근거를 두고 있으며, 영상처리, 패턴인식, 영상압축, 네트워크의 트래픽 제어, 정보보호에서의 침입방지 등의 여러 분야에 적용할 수 있다.

SOM 신경망의 구조는 Fig. 2.1과 같이 입력층(input layer)과 출력층(output layer)만으로 구성되고, 입력층과 출력층은 결합강도(connection weight)를 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. 뉴런이라는 것은 신경계의 기능적 최소단위를 말한다. 예를 들면, 입력층의 뉴런을 인간의 몸에 비유한다면 인간의 감각기관과 비슷하여 감각기관에 자극이 주어졌을 때 이것을 어떤 유사한 자극에 대하여 군




Figure 2.1 Structure of the SOM network




Figure 2.2 2-dimensional mapping of SOM network

집을 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.

상층의 출력층 뉴런을 배열하는 방법으로는 Fig. 2.1과 같이 1차원 배열과 Fig. 2.2와 같이 2차원으로 배열하는 2가지 방법이 있으며, 출력 뉴런의 형태로는 이웃하는 뉴런들과의 연결형태가 Fig. 2.3과 같은 사각형의 형태를 가지는 사각형 배열과, 육각형의 배열을 갖는 육각형 배열이 존재한다.




Figure 2.3 Two different output neuron type of 2-dimensional map

SOM 신경망의 학습방법을 설명하면 다음과 같다.

Step 1. 초기화

먼저 가중치 w_{ji} 와 학습률 η , 인접영역함수 h_{ji} 를 초기화하여야 한다. 입력층과 출력층의 뉴런 수가 정해지면 가중치의 수가 결정되고, 가중치의 값은 0과 1사이의 값으로 초기화한다. 학습률 η 는 초기에 1의 값을 취하고 학습의 진행에 따라 점차 값을 줄이며, 인접함수 h_{ji} 는 초기에 비교적 큰 값으로 초기화하여 전체 뉴런영역을 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 벡터다.

랜덤하게 선정된 입력벡터를

$$\mathbf{x} = \{x_1, x_2, \dots, x_m\}^T \quad (2.1)$$

로 표시하면, 입력과 출력을 연결하는 가중치 벡터 $\mathbf{w}_j$ 는

$$\mathbf{w}_j = \{w_{j1}, w_{j2}, \dots, w_{jm}\}^T, \quad j = 1, 2, \dots, n \quad (2.2)$$

와 같이 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.

$$i(x) = \arg \min \|x - w_i\|, \quad j = 1, 2, \dots, n \quad (2.3)$$

Step 3. 협동과정(Cooperative process)

승자뉴런을 중심으로 그 이웃뉴런(흥분된 뉴런)들과의 관계를 $h_{j,i}$ (형상학적 이웃, topological neighbourhood)라 하고 식 (2.4)로 정의되는 가우스분포함수의 형태를 띄며 Fig. 2.4와 같은 형태를 가진다. 이 그림은 근접거리(lateral distance) d 와 유효넓이(effective width) σ 와의 관계를 보여주는 것으로 근접거리는 Fig. 2.4에서와 같이 최초단계에서 모든 뉴런에 대해서 이웃관계가 성립되지만, 실질적으로 관계를 맺는 뉴런은 주어진 유효넓이 σ 내에서만 이웃뉴런으로 관계를 갱신하게 되는 것을 나타낸다. 자세히 설명하면, 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 σ 를 설정하여 학습과정에 참여하는 흥분뉴런의 범위를 제한해 주고 있다.

$$h_{j,i}(x) = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2}\right), \quad t=0, 1, 2, \dots \quad (2.4)$$

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




Figure 2.4 Gaussian neighborhood function⁽³⁾

그리고, Fig. 2.5는 승자뉴런 i 를 중심으로 그 이웃뉴런들과의 관계를 갱신하는 과정을 2차원 지도상에 나타낸 것이다. $NE_i(0)$ 는 최초 이웃뉴런의 관계가 생성되었을 때의 영역을 나타내고, 차츰 시간이 지남에 따라 $NE_i(s_1)$ 과 $NE_i(s_2)$ 의 영역 순으로 점점 좁혀지게 되는 것을 보여준다. 이와 같이 식 (2.4)를 이용하여 Fig. 2.5와 같은 과정을 거쳐 이웃관계를 형성하게 된다.⁽⁴⁾




Figure 2.5 Area of topological neighborhood according to time⁽⁴⁾

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 의해서 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. 그러므로, 망각항(forgetting term)인 $g(y_i) w_i$ 항을 고려함으로써 이 결점을 보완하게 된다. 여기서 w_i 는 뉴런 j 의 결합강도 벡터이고, $g(y_i)$ 는 응답 y_i 의 양의 값을 가지는 스칼라 함수이다. 함수 $g(y_i)$ 에 요구되는 조건은 $g(y_i)$ 의 Taylor 급수 전개 상수항은 0이어야 한다는 것이다. 이것은 다음과 같이 쓸 수 있다.

$$g(y_i) = 0 \quad (y_i = 0 \text{ 일 때}) \quad (2.5)$$

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

$$\Delta w_i = \eta y_i x - g(y_i) w_i \quad (2.6)$$

여기서, η 는 학습률(learning rate)을 나타낸다. 학습률이란 결합강도의 변화 정도를 조절하는 것으로서, 신경망의 구조 및 응용 목적에 따라서 다르다. 이 알고리즘에서는 되도록 작은 값을 선택하면 좋은 수렴결과를 나타내지만, 시간지연이 많은 단점이 있다. 본 논문에서는 학습률은 시간에 따라서 학습률이 곱해짐으로써 감소하게 된다. 보통 $\eta(t)$ 는 $0 < \eta(t) < 1$ 이다. 식 (2.6)에서 우변의 첫째 항은 Hebbian항이고, 둘째 항은 망각항이다. 식 (2.5)의 조건을 만족시키기 위해서 선형인 $g(y_i)$ 를 고려하면

$$g(y_i) = \eta y_i \quad (2.7)$$

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

$$y_i = h_{j,i}(x) \quad (2.8)$$

다음으로 식 (2.6)에 식 (2.7)과 식 (2.8)을 사용하여 다음 식을 얻을 수 있다.

$$\Delta \mathbf{w}_j = \eta h_{j,i(x)} (\mathbf{x} - \mathbf{w}_j) \quad (2.9)$$

마지막으로, 이산시간지형(discrete-time formalism)을 도입함으로써 시간 t 의 뉴런 j 의 결합강도벡터 $\mathbf{w}_j(t)$ 와 시간 $t+1$ 에서 갱신된 결합강도벡터는 다음 식에 의해 정의된다.

$$\mathbf{w}(t+1) = \mathbf{w}_j(t) + \eta(t) h_{j,i(x)}(t) (\mathbf{x}(t) - \mathbf{w}_j(t)) \quad (2.10)$$

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 최대 값을 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.^(3, 4)

이와 같은 학습을 통하여 지도(map)라는 출력층 뉴런을 생성하게 되면, 이 지도에 우리가 원하는 분류화가 정보가 담겨져 있다.

2.2 ART 신경망 알고리즘

적응공진이론(adaptive resonance theory: ART)은 1970년대 Boston대학의 Stephen Grossberg 박사 연구그룹인 Center for adaptive Systems에서 제안되어 발전하였으며, ART 이론을 기초로 한 인공신경망 모델은 Grossberg 및 Carpenter박사가 1987년부터 지속적으로 체계적인 논문을 발표하여 왔다.

인간의 두뇌는 이미 기억하고 있는 정보를 상실하지 않고 새로운 정보를 학습하고 기억할 수 있는 기능을 하고 있다. 현재 대부분의 인공 신경망은 우선 모든 특징을

표현할 수 있는 훈련집합이 있어야 하며, 이러한 훈련집합으로 신경망을 훈련시킨 후 사용이 가능하고, 새로운 지식을 학습하려면 이전에 학습한 지식을 완전히 상실하게 된다. 현실적으로 훈련집합에 있어서, 어떤 특징들은 용이하게 취득 할 수 있지만, 또 다른 특징들은 얻기 힘들므로 모든 특징을 표현 할 수 있는 훈련집합을 구축하는 것은 매우 어렵고 사용상 많은 제한을 받고 있다.

그러므로 인공신경망에 대한 요구는 인간의 두뇌와 같이 초기 지식이 없는 상태에서 사용하는 과정에서 지식을 점차 학습하고, 또 새로운 지식을 학습하는 과정에서 이전의 지식을 상실하지 않고 지속적으로 확장하여 가는 기능이 필요하게 된다. 이러한 문제를 해결하기 위하여 개발된 것이 ART 신경망이다.

2.3 ART-Kohonen 알고리즘

화상식별이나 음성식별 등 분야에서 신호의 절대 크기는 단지 전체가 밝고 어두움, 음성이 크고 작음을 나타내므로, 식별에 있어서 신호의 절대 크기는 의미가 없고 서로의 상대 크기만 중요하기 때문에 신호를 입력할 때 정규화 하는 것이 유리하다. 그러나 기계의 고장진단에 있어서 진동신호의 절대 크기는 매우 중요한 정보이며, 어떠한 패턴을 갖고 있다하더라도 절대 크기만 충분히 작으면 고장으로 볼 수 없다. 그러므로 신경망으로 기계고장을 식별할 때 입력신호를 정규화 하는 것은 정보를 상실할 수 있고, 또 판단의 오류를 야기할 수 있다.

진단 대상기계의 모든 고장의 진동신호를 취득하는 것은 현실적으로 불가능하고 충분한 고장유형이 포함되지 않은 신호로 신경망을 훈련하면 새로운 고장유형의 신호가 입력되었을 때 판단의 오류가 발생하게 된다.

ART 신경망의 교사 없는 자기조직화는 모든 특징으로 미리 훈련할 필요가 없이 사용하는 과정에서 분류와 학습이 동시에 이루어지는 특징을 가지고 있고, 이러한 특징은 기계고장진단에서 매우 유리한 특징이다.

본 연구에서는 ART 신경망과 Kohonen 신경망의 장점을 결합한 ART-Kohonen신경망⁽¹⁷⁾을 이용하였다. 이 신경망은 기계의 고장진단에 유리한 특징을 이용한 알고리즘이다.

ART-2 신경망의 식별층에서 승자뉴런을 구하는 연산과 식별층에서 유사도를 평가하는 연산은 정규화 된 벡터에만 해당하기 때문에 입력벡터를 정규화하지 않은 ART-Kohonen은 Kohonen 신경망의 알고리즘을 이용하여 승자뉴런을 구하고 유사성을 평가하였다.

Kohonen 신경망 기법은 입력벡터를 다차원 유클리드 공간상의 점으로 취급하여

공간상의 유클리드 거리로 각 벡터의 유사도를 나타내는 것이다.

$$d = \|X - Z\| = \left[\sum_{i=1}^n (x_i - z_i)^2 \right]^{1/2} \quad (2.11)$$

여기서 X, Z 는 2개의 벡터이고, d 는 두 벡터 X, Z 의 유클리드 거리이다.

Kohonen 신경망의 학습과정은 우선 입력벡터에 대하여 몇 개의 패턴으로 나눌 것인가를 지정하여야 한다. 나눌 패턴의 개수가 주어지면 공간상의 거리가 제일 가까운 벡터를 같은 패턴에 포함하여 지정한 수만큼의 패턴을 구성하고, 각 패턴은 이 패턴에 속하는 모든 벡터의 평균으로 표시한다.

Kohonen의 분류과정은 입력된 벡터와 저장된 각 패턴사이의 거리를 구하여 제일 가까운 패턴으로 입력벡터를 분류한다.

ART-Kohonen 신경망은 입력벡터와 저장된 패턴과 유클리드 거리를 구하여 거리가 제일 가까운 뉴런을 승자뉴런으로 하고, 승자뉴런에 대응하는 저장된 패턴과 입력벡터의 유클리드 거리를 구하여 거리가 지정한 경계치에 속하면 입력벡터를 이때의 승자뉴런이 갖고 있는 패턴으로 분류하고 가중치를 수정하여 실행을 완료한다. 만일 지정한 경계치에 속하지 않으면, 비록 이때의 승자뉴런이 입력벡터와 거리는 제일 가깝지만 충분히 유사하지 않기 때문에 승자뉴런의 패턴으로 분류하지 않고 실행을 복귀하여 새로운 뉴런을 구성하고 입력벡터의 패턴을 새로 구성한 뉴런의 패턴으로 한다.

ART-Kohonen 신경망의 구성은 **ART-1**과 같다.

초기 입력벡터를 입력하면 G_1 은 1이므로 입력 · 비교층은 입력상태로 되고, 입력 벡터는 원 상태로 식별층으로 전송된다. 식별층에서는 입력벡터와 각 식별층의 뉴런과 유사도를 비교하여 가장 유사한 승자뉴런을 구한다. **ART-Kohonen** 신경망은 유클리드 공간상의 거리 d 로 유사도를 평가한다.

$$d = \|Z - X\| = \left[\sum_{i=1}^n (z_i - x_i)^2 \right]^{1/2} \quad (2.12)$$

식별층 각 뉴런의 벡터(학습된 template)와 입력벡터 사이의 유클리드 거리를 구하여 거리가 가장 짧은 식별층 뉴런을 승자뉴런으로 한다.

$$\|B_j - x\| < \|B_j - x\|; \quad j, J = 1, 2, \dots, n; \quad j \neq J \quad (2.13)$$

여기서 B 는 아래서 위로 향한 가중치, j 는 식별층 뉴런의 번호, J 는 식별층의 승자뉴런의 번호다. 다음 승자뉴런의 출력을 1로 하고, 그 외 뉴런의 출력은 0으로 하여 위에서 아래로 향한 가중치와 곱한 후 비교·입력층으로 귀환한다.

$$r_j = \begin{cases} 1, & j = J \\ 0, & j \neq J \end{cases} \quad (2.14)$$

$$P_i = \sum_{j=1}^N t_{ji} r_j \quad i=1, \dots, M \quad (2.15)$$

이때 r_j 는 모두가 0이 아니므로 G_1 은 0이 되고, 비교·입력층은 비교상태로 된다. 비교층에서 P_i 와 x_i 를 비교하여 식별층의 J 번째 뉴런에 저장된 패턴과 입력 벡터의 패턴의 유사도를 평가한다.

$$S = \frac{\|P\| - \|P - X\|}{\|P\|} \quad (2.16)$$

여기서 P 와 X 가 같으면 $\|P - X\|$ 는 0이 되고, S 는 1의 값을 갖게되며, P 와 X 의 거리가 멀수록 S 는 작아진다.

경계치 ρ 를 도입하여 S 가 ρ 보다 크면 충분한 유사성을 갖고 있다고 판단하여 입력벡터를 식별층 J 번째 뉴런이 갖고 있는 패턴으로 분류하고 가중치를 수정하고 실행을 완료한다. 경계치 S 가 작으면 충분한 유사성이 없다고 판단하여 실행을 복귀하여 식별층의 뉴런을 추가하고 새로운 패턴을 구성하여 실행을 완료한다.

ART-Kohonen 신경망의 가중치는 본질적으로 보면, Kohonen 신경망의 가중치와 같이 각 클러스터의 중심위치를 표현하는 벡터의 집합이다. 그러므로 가중치는 클러스터 당 1개의 자기중심을 표현하는 벡터를 갖고 있다고 볼 수 있다. 각 클러스터에 해당하는 가중치벡터는 이 클러스터에 포함하는 모든 벡터의 평균과 같다. 그러나 실제에서 입력벡터는 하나씩 주어지기 때문에 가중치의 학습도 하나씩 처리되며 다음과 같이 계산된다.

$$B_j = (B_{j0} * n + x_i) / (n+1) \quad (2.17)$$

$$T_j = (T_{j0} * n + x_i) / (n+1) \quad (2.18)$$

여기서 B_{j0} 와 T_{j0} 는 새로 학습하기 전의 가중치, n 은 학습한 회수, x_i 는 입력벡터이다. 이러한 학습방법은 이전의 학습되었던 전체 벡터와 새로 입력된 벡터의 평균으로 새로운 가중치의 값으로 하므로 ART의 현재 입력된 벡터로 대치하는 학습방법과 비교하면 학습된 패턴이 점차 변화하여 다른 패턴으로 되는 것을 방지할 수 있다.

3. 사례기반추론

3.1 사례기반추론의 정의

Risebeck과 Schank는 사례기반추론(case-based reasoning, CBR)을 "과거의 어떤 문제를 해결하기 위해 사용했던 경험을 바탕으로 새로운 문제를 해결하는 방법(A case-based reasoner solves new problems by adapting solutions that were used to solve old problems)" 이라고 정의하였다.

실제로 의사들이 환자를 진단하는데 필요한 지식을 정형화된 규칙만으로는 완전하게 표현하기는 어려우며, 과거의 경험을 기초로 진단하는 경우가 많이 있다. 특히 의사들이 새로운 환자를 진단할 때 과거의 환자 사례와 비교하는 경우가 많으며, 많은 경우 자신의 경험을 기초로 원인을 설명하게 된다.

사례기반추론(CBR)이란 무엇인가? 앞서 언급한 내용을 정리하면, 새로운 문제를 직면했을 때, 이를 해결하는 방법으로 예전의 비슷한 상황을 기억하고 그 상황에서 사용했던 정보와 지식을 재 사용함으로써 새로운 문제를 해결하는 것이다. 이 방법은 최근에 금융분석, 보험금 평가, 의학적 진단, 소프트웨어 결정 시스템, 예고 계획, 설계, 실제 감정 평가 등과 같은 여러 영역에서 널리 보급되어 있다. CBR의 응용을 선도하는 상업용 도구들은 1990년대 초에 나타났고, 현재 데이터베이스, graphical user interface tools등 다른 소프트웨어 도구들과 결합하여 발전하고 있다.

3.2 사례기반추론의 배경과 역사

과거 사례의 사용을 통한 추론은 인간이 문제를 해결할 경우에 강력하고 빈번히 적용되고 있는 방법이다. 이러한 주장에 대해 많은 심리연구 결과에서 입증되고 있는데, Schank는 경험의 유지와 기억구조의 발달에 기초로 한 학습과 재기억(remind) 이론을 발전시켰고, Adnerson은 사람들이 문제를 해결하기 위해 학습 시, 특히 초기 학습의 모델로서 과거의 사례를 이용한다는 것을 보여주었다. 그리고 Rouse는 과거 사례의 사용은 숙련자들 중에서도 뛰어난 문제 해결방법이라는 것을 보여주었다.

인공지능 분야에서 사례기반추론의 시작은 Roger Schank의 동적 메모리(Dynamic Memory)에 관한 연구⁽⁵⁾에서 비롯되었다. 그리고 사례기반추론에 관한 다른 영역에

서의 연구는 철학 및 심리학에서 유사적인 추론에 관한 연구⁽⁶⁾로부터 비롯되었다.

사례기반추론기(Case Base Reasoner)라 불리는 최초의 시스템은 예일대학 Schank의 연구그룹의 Janet Koloder에 의해 명명된 CYRUS시스템^(7, 8)이다. CYRUS는 미국 국무부장관의 출장 및 모임에서의 다양한 행동패턴을 사례로써 색인(indexing)한 것에 대해 메모리를 조직화한 질의-응답시스템이다. CYRUS는 Schank의 동적 메모리 모델(dynamic memory model)과 문제해결 학습의 기억조직 패킷(memory organization packets) 이론에 근거하여 개발되었고, 이후의 많은 사례기반추론시스템의 기본 개념으로 이용되었다. 또 다른 사례기반추론의 기초 모델은 Bruce Porter와 그의 텍사스 대학에 있는 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 PROLOS 시스템으로 발전되었다.

또 다른 영역에서의 사례기반추론시스템은 JUDGE, HYPO, CABARET과 같은 법률의 응용 분야에 이용되었으며, CHEF는 사례기반 계획시스템(case-based planning system)으로 중국의 사천요리에 이용되었다. 동적 메모리는 과거의 요리경험사례를 그것이 충족해야 할 목표(요리)와 그것이 피해야 할 실패에 의해 색인되어 상기(想起)에 이용되었다.

유럽에서의 CBR 연구는 미국보다 조금 늦게 시작되었다. 그러나 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.⁽⁹⁾

3.3 사례기반추론의 원리

모든 사례기반추론시스템의 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 검색을 기반으로 한(retrieval-oriented) 여러 가지 기법들이 지능형 시스템을 개발하는데 점차 도입되고 있으며, 이는 과거의 사례가 현재 문제의 해결에 결정적인 도움을 제공하는 진단 분야에 매우 적합한 것으로 알려져 있다. 특히 사례기반추론 과정에서 새로운 사례의 추가가 용이하므로 지식의 습득이 자연스럽게 이루어질 수 있으며, 다양한 사례가 확보될수록 보다 정확한 진단이 가능하게 된다.⁽¹⁰⁾

CBR의 기본이 되는 아이디어는 흔히 사람들이 과거 문제의 해결에 사용한다는 것이다. 이 같은 문제 해결과정의 재사용을 통해서 자동 학습이 가능해지므로 CBR은 전문가 시스템의 구축에서 가장 어려운 문제인 지식습득 문제를 자연스럽게 해결해 준다.

사례기반추론시스템은 Fig. 3.1과 같이 4개의 과정에 의해서 그 추론 과정을 설명할 수 있다.




Figure 3.1 Case-based reasoning cycle⁽⁹⁾

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

1) 사례기반추론 수행과정

사례기반추론시스템의 주된 두 가지 요소는 사례베이스(case base)와 문제 해결자(problem solver)이다. 사례베이스는 이전에 해결된 문제의 특성들을 기술한 사례를 저장하며, 문제 해결자는 사례 검색기(case retriever)와 사례 추론기(case reasoner)로 구성된다. 어떤 문제가 주어지면, 사례 검색기는 사례 베이스에서 가장 적절한 사례를 식별하여 사례 추론기에 제공한다. 일반적으로 사례 추론기는 검색된 사례를 조사하여 필요한 경우 적응(adaptation) 과정을 거쳐서 새로운 문제의 해결을 시도한다. 그러나 응용 분야의 특성이나 사례 베이스의 내용에 따라서 사례 추론기가 필요치 않을 수도 있다. 즉, 거의 정확한 사례를 찾을 경우, 이를 사용자에게 제시하고 사용자가 필요한 약간의 수정을 가하도록 할 수 있다.




Figure 3.2 Construction of CBR system⁽¹¹⁾

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 적응(adaptation)이라 한다. 시험(test) 단계는 적응 과정을 거쳐서 제안된 해결책을 현재 문제에 실제로 적용하는 단계이며, 성공이나 실패로 그 결과가 나타나게 된다.




Figure 3.3 Performance process of CBR system

3.4 사례기반추론의 장점

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

1) 인간의 추론과 심리학적으로 유사

사례기반추론은 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 사례기반추론을 사용하는 예가 대부분이고 많은 연구에서 이것이 증명되었다.

2) 규칙기반 추론의 문제점을 해결

사례기반추론은 규칙기반추론의 문제점을 해결하기 위한 방법으로 발전하였기 때문에, 규칙기반추론에 비해 다음과 같은 장점을 가진다.

(1) 지식획득(knowledge acquisition)

사례는 추상적인 규칙보다 쉽게 기억될 수 있으므로, 전문가가 과거의 문제 및 해를 기억하여 새로운 해를 만드는 것이 수많은 규칙으로 문제를 해결하는 것보

다 쉽다. 즉, 사례기반의 전문가 시스템을 만드는 것이 규칙기반의 시스템 구축보다 더 용이하다.

(2) 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 사례기반추론시스템은 규칙기반시스템보다 계산비용의 절감효과가 뛰어나다.

(3) 적용성

규칙기반추론시스템은 모든 지식이 규칙으로 기록되므로 문제가 규칙과 일치하지 않을 경우, 문제를 해결하기 어렵다. 그러나 사례기반추론시스템은 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 결과를 사례베이스에 저장하므로, 추후 동일한 추론을 반복할 필요가 없다. 또한 사례기반추론시스템은 새로운 문제가 입력되어 적용되고, 성공 혹은 실패의 사례로 저장됨으로써 과정의 반복을 통해 시스템의 성능이 향상된다. 또한 과거의 실패를 예측하고 회피할 수 있다.

4. 전동기의 결함진동

전동기가 정상상태로 운전되고 있을지라도 어느 정도의 진동이나 소음을 발생한다. 하지만 이상상태 운전 시에는 정상운전상태와 다른 진동이나 소음을 발생한다. 따라서 진동과 소음을 이용한 주기적인 진단은 중요한 유지, 보수에 한 방법이다. 전동기의 운전 개폐기를 OFF 했을 때, 동시에 이상 진동이나 소음이 줄어든다면 그것은 전기적인 요인으로 볼 수 있고, 그 주파수를 분석하는 것으로 원인을 추정할 수 있다. 그러나 현장에서 발생하는 문제의 대부분은 기계적인 요인에 의해 전기적 불평형을 일으키고 이것이 이상 진동이나 소음을 유발시키는 복합적인 요인에 의한 원인이 대부분을 차지한다.

4.1 전동기 결함

전동기에서 발생하는 결함은 크게 전기적인 결함과 기계적인 결함으로 나눌 수 있다. 결함들은 진동 및 전류신호의 스펙트럼을 비교해 보면 고유한 특징을 가지고 있는데, 그 중에서도 전동기의 상태감시 및 고장진단에 사용되는 방법에는 진동 변위, 속도 및 가속도를 감시 파라미터로 하는 진동신호를 이용한 방법을 널리 사용되고 있다. 대부분의 전기적인 문제는 전원주파수(line frequency)의 2배 성분에서 정상상태보다 높은 진동진폭이 발생하며, 기계적인 문제는 운전주파수 성분이 탁월하다. 불평형과 정렬불량 등의 기계적인 문제가 회전자(rotor)와 고정자(stator) 사이의 공극(air-gap) 변화와 같은 전기적인 문제를 발생시킨다. 따라서 기계적인 문제를 먼저 검토하고, 그 원인을 제거한 후 전기적인 문제를 검토하는 것이 바람직하다.

4.1.1 전동기의 기계적인 결함

회전기계에 영향을 미치는 기계적인 결함들은 또한 전동기에 동일한 문제를 일으킨다. 질량 불평형, 헐거움, 공진, 정렬불량, 편심, 베어링 결함 등이 포함된다. 전동기의 기계적인 결함의 요소는 베어링, 축, 커플링의 3가지로 나눌 수 있으며, 각각의 결함요소에 대한 기계적인 결함은 Table 4.1과 같다.

Table 4.1 Mechanical fault

결함요소	기계적 결함
베어링(bearing)	· 구름요소베어링 결함(bearing defect) · 저널베어링 결함(oil whip/whirl)
축(shaft)	· 질량 불평형(mass unbalance) · 축 굽힘(bent shaft) · 헐거움(looseness) · 접촉(rubbing) · 공진(resonance)
커플링(coupling)	· 정렬불량(misalignment)

1) 불평형

불평형은 회전체의 기하학적인 중심(축 중심선)과 질량 중심이 일치하지 않는 경우에 발생하며, 회전체의 제작 시나 조립시의 정도에 의해 발생한 오차나, 운전시의 마모나 부식에 의한 변형이 원인이 된다. 불평형력은 회전주파수로 발생되며, 때로는 정렬불량과 구분하기 어렵다. 그러나 불평형은 반경방향의 회전력을 발생시키지만, 정렬불량에 의한 가진력은 방향성을 가진다. 일반적인 기계 구조물에서는 수평방향의 진폭이 수직방향에서 측정된 진폭보다 크게 나타난다. 기계의 구조에 따라서 질량불평형으로 인해서 베어링 지지대에서 운전속도성분의 큰 축방향 진동이 발생할 수 있다.

2) 정렬불량(misalignment)

3개 이상에서 반경방향의 하중을 가하는 베어링을 가진 회전체와 같이, 과도하게 지지된 회전체의 정렬불량은 베어링, 축 그리고 외부 커플링에서 축 속도의 주파수로 회전하는 예압(preload)을 일으킨다. 결과적으로 진동의 크기는 계를 구성하는 요소들인 베어링, 축, 실(seal), 커플링 등의 반경방향 강성에 좌우된다. 정렬불량이 심해지면, 베어링의 비대칭성과 베어링 지지대 그리고 기초의 강성에 따라 한쪽 혹은 양방향으로 비선형적인 베어링 특성을 일으킬 수 있다. 정렬불량이 있으면 회전축이 강제적으로 굽혀지기 때문에, 외관상의 초기 굽힘이 생기고 그것에 의해 진동을 발생시킨다.


- (1) 정렬불량에 의해 예하중이 작용이 작용하게 되고, 반경방향으로 진동 발생
 통상 $1 \times \text{rpm}$: 반경방향

(2) 극도의 정렬불량


2×rpm : 반경방향(경우에 따라서 축방향)

3) 헐거움(looseness)

헐거운 기계요소는 1회전 당 1회의 충격이 발생되어 운전주파수의 진동과 차수 성분들의 진동이 나타난다. 통상 헐거움이 있으면 f_0 , $2f_0$, $3f_0$ 의 조화성분이나 $1/2f_0$, $1/3f_0$ 인 분수조화진동이 발생할 수 있다. 고유진동수 혹은 그에 근접한 차수의 성분은 공진에 의해서 가진력이 증폭되기 때문에 큰 진동이 발생된다.




(a) Time signal




(b) Frequency spectrum

Figure 4.1 Vibration signal of unbalance condition



(a) Time signal



(b) Frequency spectrum

Figure 4.2 Vibration signal of parallel misalignment condition




Figure 4.3 Vibration signal of mechanical looseness condition⁽¹²⁾

4.1.2 전동기의 전기적인 결함

전기적인 결함 문제는 전원주파수의 2배 진동과 극 수에 슬립주파수를 곱한 측대역 성분들이 발생한다. 회전자나 고정자의 슬롯 수에 전동기 속도를 곱한 것과 동일한 주파수의 진동이 편심된 전동기 혹은 고정자와 전동기의 슬롯 수가 유사할 때에 발생된다. Table 4.2는 전기적인 결함요소에 대한 결함을 나타내었다.

Table 4.2 Electrical fault

결함요소	전기적 결함
공극(air-gap)	· 공극 불평형(고정자 편심, 회전자 편심)
회전자(rotor), 단락링(end ring)	· 회전자 봉(rotor bar)의 파손/크랙 · 회전자 봉의 헐거움/개방 · 회전자 적층의 단락 · 회전자의 불규칙한 국부가열에 의한 열 굽힘(thermal bow) · 단락 링의 파손/크랙
고정자(stator)	· 유연한 고정자 · 고정자 적층(lamination)의 단락 · 고정자 철심의 느슨함

1) 공극(air-gap)의 편심 문제

(1) 정적 편심

고정자와 회전자 사이의 축심이 일치하지 않고 편심이 발생하게 될 때, 일어나는 현상으로 최소 공극의 위치를 통과할 때 공극이 작은 곳에서는 자기흡입력이 크게 작용하고 반대로 최대 틈새 지점에서는 자기 흡입력이 최소가 되어 불평형 전자력을 발생하게 된다. 이 때문에 전동기에서는 전원주파수 2배 성분을 갖는 전자기진동이 발생한다.




Figure 4.4 Static eccentricity of air-gap

(2) 동적 편심

경년 변화나 외력에 의해 발생하는 축 굽힘(shaft bent)이나 회전자의 중량 불평형 등에 의한 휘돌림 등이 원인으로 회전자가 고정자 내에서 최소 공극점이 편심으로 휘도는 것에 의해 기계적인 진동이 불평형 전자력을 조장하게 되어 불평형 전자력 $2s \times$ 전원주파수의 2배 성분(여기서, s 는 전동기 슬립)으로서 맥동한다. 그리고 전동기 부하를 증가하면 슬립(s)이 크게 되기 때문에 주기는 짧게 되며, 전동기는 진동의 맥동에 의해 맥놀이(beat)음을 발생하게 된다.




Figure 4.5 Dynamic eccentricity of air-gap




Figure 4.6 Vibration data of a 4,000HP electric motor with an air-gap problem⁽¹²⁾

2) 회전자 문제

회전자 봉의 파손이나 헐거움 또는 회전자 봉과 엔드 링(end ring) 사이의 접촉이 단락되는 결함들은 전동기가 부하와 체결되어 있는 경우에만 명백하게 나타난다. 회전자 봉이 파손되면, 운전주파수 주위에 극 수와 슬립주파수를 곱한 것과 같은 간격의 측대역 성분들이 나타난다. 단락된 철심적층은 권선보다 회전자에 국부적인 온도 상승점을 발생시키며 회전자를 휘게 한다. 결과적으로 운전속도의 진동이 나타난다. 아래의 Table 4.3는 회전자에서 발생하는 문제와 발생증상을 정리한 것이다.




Figure 4.7 Vibration data of rotor problem

Table 4.3 Rotor problem

회전자 문제	발생 증상
· 회전자 봉과 단락 링의 파손/크랙 · 회전자 봉과 단락 링 사이의 불량 결합 · 회전자 적층의 단락	· 운전속도(1X)성분의 높은 진동과 극 통과주파수의 측대역 성분 발생
· 크랙이 발생한 회전자 봉	· 운전속도(1X)의 높은 진동과 극 통과주파수의 측대역과 성분 발생. 종종 조화성분(2X, 3X, 4X, 5X)의 주위에 극 통과주파수의 측대역과 성분 발생
· 헐겁거나 개방된 회전자 봉	· 회전자 봉 통과주파수와 이의 조화성분 및 주위에 전원주파수×2배성분의 측대역과 성분
· 회전자 봉과 End ring 사이의 전기적 아크	· (2×전원주파수 2배성분)과 (2×회전자 봉 통과주파수) 성분의 높은 레벨

(1) 회전자의 적층의 단락(shorted rotor laminations)

회전자의 철심의 적층은 회전자 철심을 절연하고, 전류 흐름을 방지하기 위한 것이 목적이므로 슬롯에서의 권선을 제외한 표면의 단락은 이 목적을 파괴하고 높은 국부적인 가열을 야기 시킨다. 다음은 회전자 적층의 결합 원인을 나열한 것이다.

- 과대한 거친 부분과 불량한 철심 적층 정렬
- 회전자 외경의 부적절한 가공
- 고정자와 회전자의 마찰(Rubbing)
- 철심 판의 부적절한 절연이나 절연 결합

(2) 회전자 봉 파손

회전자 봉의 파손 또는 헐거움은 전동기가 부하와 체결되어 있는 경우에 발생하며 운전 주파수부근에 극 수와 슬립주파수를 곱한 극 통과주파수와 같은 간격의 측대역 성분이 발생한다.





Figure 4.8 Vibration signal of a 2,000HP electric with a broken motor bar

(3) 헐겁거나 개방된 회전자 봉

회전자 봉 통과 주파수의 매우 높은 주파수의 진동과 이의 조화성분들이 발생하고 조화 성분 주위에는 정확하게 전원주파수 2배 성분의 측대역파(sideband)성분이 존재한다.






Figure 4.9 Vibration signal of a electric with a loose or open bar⁽¹²⁾

3) 고정자 문제

고정자와 회전자 사이에는 자극에 의한 전자력(흡입력)이 있고, 고정자를 변형시키도록 작용하므로 진동을 발생시킨다. 고정자 이상에 의한 진동의 특징을 살펴보면 다음과 같다.

- 진동수는 전원주파수의 2배
- 진동기 전원을 차단하면, 이 진동성분은 일순간에 소멸
- 고정자 프레임이나 베어링등에 발생
- 극 통과주파수의 측대역 성분이 발생되지 않음

(1) 고정자 편심(Stator Eccentricity)

고정자 편심의 원인은 연약 지반과 뒤틀림 기초에 의해서 발생되며 매우 지향성의 진동을 발생시키는 회전자와 고정자 사이의 불균일한 정지된 공극을 발생시킨다.




Figure 4.10 Vibration signal of stator eccentricity⁽¹²⁾

(2) 고정자 적층 및 권선 단락(Shorted Stator Laminations)

고정자 적층 단락은 불량 철심 구조로부터 발생하는데, 예를 들면 불량 적층 정렬, 너무 무겁거나 혹은 너무 가벼운 철심 압력 등을 들 수 있다. 일반적으로 고정자와 회전자 모두 진동의 두드러진 증가는 철심 단락의 존재를 나타낸다.

고정자 권선 단락의 경우는 전원 주파수의 2배 성분과 그 배수 성분들의 반경 방향 진동이 탁월하다.




Figure 4.11 Vibration signal of a 200HP motor with shorts in the stator wiring⁽¹²⁾

4.2 전동기 사례베이스

전동기의 사례베이스는 진동진단 전문가가 현장에서 다양하게 발생하는 현상을 관찰하여 진동의 원인을 발견하고, 이에 따른 대책수립을 수행하였던 많은 양의 사례에 대한 기술보고서를 정리한 기계건강진단 사례집에 수록된 전동기 사례를 이용하였다.

사례베이스의 기본양식은 Fig. 4.12과 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 인용문헌으로 구성된다. 실제 고장진단을 수행하기 위해서는 각 사례마다 서술되고 있는 진동 발생현상과 원인을 정리하는 작업이 필요하다.

전동기8발전기		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 연속적이다.	
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 기어미의 마끄러짐을 방해하였다. 이것은 토크 자물쇠(torque lock)를 제거하고 2X와 3X 진동주파수를 마거시켰다. 재정렬과 윤활을 실시하여 전동기를 보수한 후 진동 신호는 정상적인 진동레벨을 보였다.	
인용문헌	K.R. Guy, Case Histories : Power Industry, Vibration Institute, 1993	

Figure 4.12 An example of standard case

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 않을 수도 있다.

표준 사례는 전동기에서 발생되었던 실제 진동트러블을 해결한 기술자료를 바탕으로 작성되었다. 현재의 사례를 **SOM** 신경망과 **ART**신경망에 이용하기 위해서는 사례를 분석하는 작업이 필요하다.

현재의 사례베이스는 기계건강진단 사례집⁽¹²⁾에 있는 전동기 사례 중에서 원인추정이 정확하지 않은 사례와 앞장에서 언급한 결함에 포함되지 않은 사례를 제외한 35개와 진단관련 업체의 기술보고서 그리고 각종 해외저널에 실린 **Case History**를 포함해서 총 50개의 사례로 구성되어 있다.

5. 인공신경망에 의한 전동기 사례분류

5.1 자기조직화지도 신경망에 의한 분류화

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 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 자기조직화지도(SOM) 신경망에 의한 분류화는 전동기에서 전기 또는 기계적이 결함이 발생했을 경우, 진동 데이터의 분석을 통한 원인규명이 어렵거나, 규명된 원인에 대한 조치활동을 결정하는 지원 도구로써 이용할 수 있다.

5.1.1 사례분석 1의 분류 결과

SOM 신경망을 통한 결함진단을 수행하기 위해서는 현재의 사례베이스를 분석을 통해서 각 사례에 해결방안을 마련하기 위해서 수행했던 해석 및 자료분석과 결함 발생 당시에 보고된 발생현상을 토대로 하여 사례베이스에 포함된 모든 진동현상들을 추출하고 그것들을 원인별로 분류하는 작업이 이루어져야 한다. 이 작업은 각 사례가 가진 특징들을 분석하는 일을 말한다. 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 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,

Table 5.1 Causes and symptoms of electric motor defects

원인	기계적 결함	헐거움, 정렬불량, 불평형
	전기적 결함	회전자 손상, 고정자 이상, 공극불량
발생현상	전동기 베어링 부 진동 베어링 수직방향 진동 베어링 수평방향 진동 베어링 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 운전속도 성분 운전속도 분수 및 배수조화성분 울림 주파수 성분 전원주파수 및 2배 성분주위의 측대역파 성분 전원주파수 2배 성분 주기적 소음 단순 이상음 울림의 주파수 과전류 윤활유 변색 베어링 손상, 교체 회전자 손상	

우선 사례 분석을 통해서 사례를 구분하고, SOM 신경망에 대입하여 신경망을 훈련하여야 한다. 즉, 훈련과정(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 기억

된 원인사이의 유사성(similarity)을 비교하여 제일 유사한 원인으로 사례를 분류한다. 이를 분류과정이라 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 50개의 사례에 대해 앞장의 사례분석을 통해서 분류한 6가지 원인별로 사례를 구분하고, 이 중 45개는 훈련용 입력벡터로 사용하고 나머지 5개는 테스트용 입력벡터로 사용하여 자기조직화지도를 구성하였다.

상태분류를 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 출력뉴런의 수를 데이터의 수보다 크게 하였다.

Table 5.2는 각 학습과 테스트를 위한 상태를 정리한 것이다.

Table 5.2 Training condition of SOM

Item	Number of data
Training set	45
Test set	5
Attribute of input vector	6
Input neuron	26
Output neuron	200

각 원인별 사례분포는 회전자 이상 20건, 고정자 이상 5건, 기계적 헐거움 6건, 정렬불량 7건, 불평형 3건, 공극 편심 9건이다. Fig. 5.2는 최종적으로 학습된 자기조직화지도를 나타낸다.




Figure 5.2 Unified map of all component after training

여기서 Table 5.3은 출력 뉴런의 상태를 기호로 표시한 것이다.

Table 5.3 Symbol of defect cause

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

Fig. 5.2에서 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.⁽¹⁷⁾ 실제 진동 데이터를 가지고 특징을 추출하여 연

은 수치들은 동일 속성에 대해서 유사한 값을 나타내기 때문인데, 사례베이스를 통한 결과는 각 사례 속에 실제 진동 데이터 이외에도 겹으로 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.

1) 입 · 출력 뉴런의 크기의 영향

출력뉴런의 수를 변화해가면서 분류율의 변화를 조사하였다. 여기서는 데이터의 수가 적은 관계로 인해, 총 데이터에서 임의로 5건을 선택하여 총 5회의 테스트를 통해서 평균치를 구하였다. Fig. 5.3을 보면 알 수 있듯이, 출력뉴런수가 너무 적거나 많을 때는 분류율이 낮고 약 300개에서 분류율이 높게 나타남을 알 수 있다.

실제 진동 데이터를 가지고 분류를 할 경우^(13,17)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.




Figure 5.3 Effect of neuron number for output layer

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.

2) 사례수의 영향

이번은 훈련 데이터의 수에 따라서 분류율이 어떻게 변화하는지는 알아보기 위한 테스트이다. 먼저 기계건강진단사례집에 나와있는 35건의 사례를 가지고 먼저 테스트를 실시하고, 사례집 외에 추가로 진단관련 업체의 기술보고서 그리고 각종 해외 저널에 실린 사례를 합한 50건의 사례에 대해 테스트를 실시하였다. 테스트 방법은 앞과 동일하게 총 데이터에서 테스트를 위한 데이터 5건을 제외한 나머지로 훈련을 실시하고 5건의 데이터로 테스트를 실시했다. Fig. 5.4는 분류 결과를 나타내며, 전체적인 경향을 보면 사례수가 많을 경우에 분류 성공율이 높은 것을 알 수 있다.

50건의 사례를 통한 분류율을 보면 전체 분류율은 약 65% 정도이다. 이것은 다른 참고문헌에서 보는 분류율과 비교해 볼 때 낮은 수치이다. 그 이유는 첫째, 사례수의 부족이다. 50개의 사례를 보면 회전자 손상의 경우가 20건으로 가장 많은 비율을 차지하고 있다. 테스트에서도 다른 원인보다는 훨씬 나은 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 진동 데이터 스펙트럼 분석외에도 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.




Figure 5.4 Effect of number for output layer

5.1.1 사례분석 II의 분류 결과

앞선 사례분석은 각 사례가 26개의 발생현상들을 포함하고 있는지 없는지에 대해서 단순 정렬한 것일 뿐 각 사례가 가지는 특징들을 분석해내지 못했다. 각 결함별로 사례를 다른 구성특징들을 나타낼 것이며, 그것을 가장 효과적으로 표현할 수 있는 방법이 필요하겠다. 이에 각 사례들을 나타낼 수 있는 특징영역을 다음의 5개의 영역별로 나누어서 사례의 특징을 추출하였다.

진동수성분을 운전속도 성분들과 진원주파수 성분들을 분리하고 않고 특징을 구분하여 가중치를 설정할 경우, 기계적인 결함과 전기적인 결함이 여러 현상들의 합으로 구성되어서 거의 유사한 수치를 보이기 때문에 진동수성분을 2가지 영역으로 분리하였다. 진동방향에 따라 결함 원인이 다르게 나타날 수 있다. 기계적인 진동발생 메카니즘에 따라 반경방향의 진동성분이 탁월하게 나타난다. 하지만 극심한 정렬불량의 경우, 축 방향의 진동 성분이 반경방향 성분보다 탁월하게 나타남을 알 수 있다.

그리고 작동환경 영역 또한 각 원인들을 구분할 수 있는 결정적인 증거가 되는데 전원차단시 진동소멸은 기계적인 결함과 전기적인 결함을 구분할 수 있는 현상이다.

Table 5.4 Characteristic domain

특정 영역	세부 사항
주 진동방향 및 측정위치	· 베어링 반경방향 진동 · 베어링 축 방향 진동 · 전동기 기초(바닥)에서 진동 · 전동기 케이싱 진동
작동환경	· 부하에 따른 진동변화 · 유량에 따른 진동변화 · 전원차단 시 즉시 진동소멸
운전속도성분	· 운전속도성분 · 운전속도배수성분 · 운전속도분수성분 · 운전속도주위의 측 대역파 · 운전속도성분보다 조화성분의 현저한 증가
전원주파수 성분	· 울림(beat)발생 · 전원주파수 및 2배 성분 주위의 측대역파 · 전원주파수 2배 성분
기타	· 주기적 소음 · 단순 이상음 · 베어링 손상 · 회전자 손상

table 5.4는 5개의 영역별로 분리한 사례 특징의 구성표이며, Fig. 5.5는 5개 영역별로 구분하여 새롭게 구성된 사례 베이스의 일부분을 나타낸 것이다.

0.8	0	0.35	0	0.3	L
0	0	0.4	0	0	L
0	0	0.1	1.0	0	A
0.3	0	1.6	0	0	M
0.5	0.7	0	1.0	0	A
0	0.7	0.8	0.25	0	A
0	0	0	1.0	0	S
0.5	0.7	0	1.0	0	A
0.3	0	0	1.75	0	R
0	0	0.8	0.4	0	A
0	0	0	1.0	0	S
0	0.7	0	1.0	0	R
0.5	0	0.8	0.25	0	A
0	0	0.8	0	0	R
0	0.7	1.05	1.0	0	A
0.5	0.7	0	1.5	0	R
0	0	0.35	0	0	R
0.5	0	0	1.0	0	S
0	0	0.35	1.75	0	R
0.5	0.7	0	1.5	0	R
0.3	0	0.1	1.5	0	R
0.5	0	0	1.0	0	S
0	0	0	1.5	1.2	R

Figure 5.5 Case base for new case analysis

Fig. 5.6는 새롭게 구성한 사례특징으로 분류한 결과를 나타낸다. 결과를 보면 알 수 있듯이 기존의 단순정렬보다는 월등한 분류 성능을 보여주고 있다.




Figure 5.6 Effect of case analysis

5.2 ART-Kohonen 신경망에 의한 사례분류

SOM 신경망을 이용한 전동기 사례분류는 5개의 특징영역에서 90%에 가까운 분류 성능을 갖고 있지만, 그러나 먼저 각각의 결함원인 사례를 이용한 훈련이 수행되어야만 사용이 가능하고 훈련에서 각 원인을 표현하는 사례가 부족하면 훈련되지 않는 상태의 사례가 입력되면 오분류를 야기한다. 특히 현재의 사례 베이스는 6가지의 원인에 대해서 50건의 사례로 구성되어 있어 전체적으로 사례가 부족하며 사례 구성도 고르지 못하여 오분류를 야기시킬 수 있다.

이러한 문제점을 해결하기 위한 방안으로, 본 연구에서는 적응공진이론(adaptive resonance theory)을 도입하여 전동기 사례분류를 수행하였다.

ART-Kohonen 신경망은 분류와 학습이 동시에 이루어지므로, 미리 훈련할 필요없이 직접 사용할 수 있어 현재의 전동기 사례베이스를 이용한 사례분류에 적합한 신경망이다.

ART-Kohonen 신경망은 입력데이터가 입력되면, 우선 내부에 저장된 각 패턴과의

거리를 계산하여 거리가 가장 가까운 뉴런을 승자뉴런으로 하고 승자 뉴런과 입력 뉴런의 유사성을 평가하여 유사하면 이때의 승자뉴런으로 분류하고 가중치를 개선하며, 유사성이 낮으면 새로운 뉴런을 추가하고 가중치를 학습하여 새로운 패턴을 구성한다.

새로운 패턴이 형성될 때는 입력벡터의 속성(결함원인)을 지정하여야 하며, 속성이 지정되면 새로 형성된 패턴을 지정한 속성으로 표현하고 앞으로 이 패턴에 속하는 입력이 들어 왔을 때 속성으로 출력을 표현하면 사용자는 속성으로부터 결함원인을 알 수 있다. 실제 사용하는 과정에서 유사도 계수(similarity factor) ρ 를 지정하여야 한다. ρ 는 1보다 작은 값($\rho \leq 1$)을 갖으며, ρ 가 크면 내부에 저장된 각 패턴의 공간을 좁아지고, 너무 크면 한 개의 클러스터를 표현하는 뉴런수가 많아지고 효율이 떨어진다. 그리고 작으면, 패턴공간이 넓어지고 한 개의 뉴런이 여러 클러스터를 포함하기 때문에 분류율이 떨어지게 된다. 적절한 ρ 값은 실제 상황에 따라 정하여야 한다.

ART-Kohonen 신경망에서 식별층의 뉴런 수는 입력벡터의 클러스터 수의 증가에 따라 증가하지만, 일정한 입력에 있어서는 유사도 한계치 ρ 의 변화에 따라 변화하고, 분류율도 ρ 의 변화에 따라 변화하게 된다. 그 변화를 Fig. 5.7에 나타내었다.

신경망의 분류율은 ρ 가 0.9일 때 96%에 도달한다. 따라서 본 연구에서 사용된 전동기 사례분류는 ρ 가 0.9일 때가 적당하다.




Figure 5.7 Relation of classification accuracy and similarity coefficient ρ

5.3 적용 예

본 절에서는 시스템의 검증을 위해 실제 발생했던 사례에 대한 기술자료를 시스템에 적용하여 분류를 실시하였다.


5.3.1 문제사례 분석

검증을 위해 사용한 자료⁽²³⁾는 국제학술대회에서 발표된 사례로써 결함 원인은 회전자 손상으로 판명된 자료이다.


문제 사례를 기계건강진단사례집의 표준사례 형식으로 정리하면 다음과 같다.

Table 5.4 Problem case

Motor Case	전동기 회전자봉의 결합진동	전동기
		전자기진동, 회전자 손상
대상기계	전동기(1,899 rpm, 259 HP)	
발생현상	맥놀이 주파수가 진동레벨과 소음진폭 모두 매우 현저하였다. 초기의 신호는 2차, 3차의 조화성분 뿐만아니라 운전속도에서 과대한 진동을 나타내었다. 3개의 조화성분(1X, 2X, 3X)은 1분 동안 여러번 증가 및 감소하였다. 또한 진동 스파이크(spike)가 FFT상에서 일반적인 것 보다 더 넓게 관측되었다. 광대역에서 진폭의 증가 및 감소는 맥놀이 주파수를 유발하는 측대파(sideband)를 나타내었다.	
해석 및 자료분석	이것을 확인하기 위해, 확대(zoom) 기능을 가진 분석기를 3개의 조화성분 주위의 분해능을 증가시키기 위해 사용되었다. 그 결과는 중요한 측대파가 3개의 조화성분 주위에서 발견되었다. 과거의 시험을 통해 이것들은 회전자봉이 파손된 것을 나타낸다. 그러므로 전동기는 복구를 위해 수리소에 보내어졌다. 전동기를 분해하기 전에, 동력계에서 0~100% 부하에 대해 일련의 시험운전을 실시하였다. 시험의 목적은 전동기의 부하범위에 대해 파손된 회전자봉을 가진 회전자의 응답을 얻기 위한 것이다. 2가지 방법으로 응답이 측정되었다. 첫째는 전동기의 양단에서 수평, 수직 및 축방향에 대해 장착된 가속도계를 이용하였다. 두 번째는 전동기의 전류파형으로 파손된 봉의 영향을 측정하기 위해 전류센서(current probe)를 이용하였다. 전류센서의 출력은 저항기(resistor)를 통해 전류에 비례하는 출력전압을 공급하는 장치를 통해 제공되었다. 전류센서와 가속도센서로 부터의 출력은 분석을 위해 FFT에 입력되었다.	
원인 추정	전류파형 분석이 가능한 진동분석기를 이용하여 회전자봉(rotor bar)의 파손을 검출하고, 이를 원인으로 추정	



(a) Before repair



(b) After repair

Figure 5.8 Vibration and current spectra

위의 표준사례를 토대로 하여 SOM과 ART에 적용하기 위해서 발생현상과 해석 및 자료분석 영역에서 문제 사례가 가진 특징을 조사하여야 한다. 다음은 문제사례의 특징과 입력 데이터의 형식과 결과를 정리한 것이다.

Table 5.5 Characteristic, input data and classification result of new problem

문제 사례 특징	· 부하에 따른 진동 증가 · 울림(beat) 발생 · 운전속도성분에서 과대한 진동 · 운전속도의 조화성분(1X, 2X, 3X) 증가 · 맥놀이(울림) 주파수 존재 · 전원주파수주위의 측대역파 존재
입력 데이터	00000001000001111100010000
분류 결과	O(회전자 손상)

5.3.2 CBR 시스템과 비교검증

분류결과와 비교하기 위해서 기존의 사례기반 추론시스템에 문제 사례를 입력하여 유사사례 검색을 하였다. 입력 파라미터는 동일하게 하였고, 사례기반추론 시스템에서 발생현상을 제외한 것은 입력하지 않은 동일한 상태로 사례검색을 실시하였다.

CBR SYSTEM

각 항목을 선택하고, 현재 문제에 대한 선택항목의 기여도를 선택하시오.

Specification

Power [weight] From [weight] Poles [weight] Line Frequency [weight]

Driven Machine

	weight
모터	
펌프	
송풍기	
압축기	

Accurring Ti

	weight
전동기 과열	
전동기 과전압	
전동기 과전류	

순위를 클릭하시면, 원하는 사례를 보실 수 있습니다.

유사도 순위 1 motor 19 = 0.58554004

유사도 순위 2 motor 74 = 0.52489065

유사도 순위 3 motor 16 = 0.47633051

유사도 순위 4 motor 12 = 0.43915503

유사도 순위 5 motor 43 = 0.42521003

유사도 순위 6 motor 30 = 0.39477101

Phenomena

	weight
과전 발생	
울림(beat) 발생	1
운전속도 성분	1
운전속도의 조화성분	1
운전속도의 조화성분(1X, 2X, 3X) 증가	1
맥놀이(울림) 주파수 존재	1
전원주파수 주위의 측대역파 성분	1
전원주파수 2배 성분	
조각제 사용	

Figure 5.9 Retrieval result of CBR system

Fig. 5.9에서 보이듯이 CBR에서의 유사도 평가를 통한 사례검색결과를 보면, 사례 19, 74가 각각 유사도가 0.586, 0.525로써 가장 유사한 결과를 보이고 있다.

Table 5.6 Comparison of reasoning result

	문제 사례	전동기 사례-19	전동기 사례-74
자료분석	· 부하에 따른 진동 증가 · 울림(beat) 발생 · 운전속도성분에서 과대한 진동 · 운전속도의 조화성분 (1X, 2X, 3X)증가 · 울림주파수 존재 · 전원주파수주위의 측대역파 존재	· 베어링 수직방향 진동 · 울림(beat)발생 · 울림주파수 성분 · 전원주파수 및 2배 성분 주위의 측대역파 · 울림의 이상음	· 울림(beat)발생 · 전원주파수 및 2배 성분 주위의 측대역파 · 울림의 이상음

제 6장 결론

본 연구에서는 진동의 결함진단을 목적으로 종래부터 사용되어온 오차역전파법과는 다른 순방향 2층 신경망이며 교사 없는 학습을 하는 SOM과 분류와 학습이 동시에 이루어져 사전 학습 없이 직접 사용할 수 있는 ART-Kohonen 신경망에 과거의 어떤 문제를 해결하기 위해 사용했던 경험을 바탕으로 새로운 문제를 해결하는 방법인 사례기반추론 시스템을 이용하여 결함진단에 적용 가능성을 검토하였다.

일반적인 진동 데이터가 아닌 사례기반추론시스템의 사례베이스를 가지고 SOM신경망과 ART-Kohonen 신경망에 이용하기 위해서 자연어로 만들어진 표준형식의 사례를 재 표현하였고, 각 사례가 가진 전동기의 기계적인 결함과 전기적인 결함을 분석하여 사례베이스를 6가지의 고장원인으로 분류하고, 사례를 구성하는 발생현상들을 26개의 단순정렬 및 5개 영역별로 사례의 특징을 분석하여 SOM과 ART-Kohonen 신경망을 이용하여 전동기 사례를 분류하였다. 사례의 수와 출력 뉴런이 분류결과에 미치는 영향을 조사하였고, 현재 시스템의 적합한 출력 뉴런수를 설정하고, 사례의 수가 전동기 결함진단에 더 나은 결과를 보인다는 것도 조사하였다. 뿐만 아니라 효과적인 사례분석을 통해서 사례가 가진 특징을 정확하고 효과적으로 표현되어야 함을 알게되었다.

기계건강진단 사례집과 국내·외의 기술보고서 그리고 각종 해외저널에 실린 Case History를 이용하여 시스템을 검증하고, 실제 문제 사례를 가지고 시스템에 적용하여 분류를 실시한 후 기존의 CBR시스템과 비교검증 결과 본 연구에서 제안한 시스템이 전동기의 결함원인을 규명하는데 효과적임을 증명하였다. SOM 및 ART-Kohonen과 사례기반추론을 이용한 결함진단 시스템은 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.

참고문헌

- (1) R. P. Lippmann, An Introduction to Computing with Neural Nets, IEEE ASSP Mag., pp. 4-22, April 1987.
- (2) 조영인, 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 and People, Cambridge University 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. Aamodt and E. Plaza, Case-Based Reasoning: Foundational Issue Methodological Vibrations, and System Approaches, IOS Press Vol. 7, NO. 1, pp.39-59(1).
- (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, 신장 질환 진단을 위한 규칙 기반 추론과 사례기반추론의 통합, 정보과학논문지 제 24권 10호, pp. 1093-1100, 1997.
- (12) 양보석, 기계건강진단 사례집, 효성출판사, 1998.
- (13) 서상윤, 임동수, 양보석, 자기조직화지도를 이용한 회전기계의 이상진동 진단, 한국소음진동공학회 추계학술대회논문집, 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) 이창묵, 양보석, 회전기계의 이상진동진단을 위한 사례기반 추론시스템의 개발, 한국소음진동학회 춘계학술대회, 2000.
- (16) J. S. Mitchell, Introduction to Machinery Analysis and Monitoring, Pennwell Books, pp. 470, 1993
- (17) 안경룡, 인공신경망을 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, 페트리 넷를 이용한 CBR시스템의 사례검색” 석사학위논문, 부경대학교, 2001.
- (21) 최성필, 신경회로망을 이용한 볼베어링의 결함진단에 관한 연구, 석사학위논문, 부경대학교, 1994.
- (22) 조영천, 임동수, 양보석, Fuzzy ID3를 이용한 회전기계의 진동진단, 한국소음진동공학회, 춘계학술대회, 1999, pp. 118-122.
- (23) N. L. Baxter, Vibration Analysis in Electric Motors, Case History, Proceedings of the 11th Annual Meeting, Vibration Institute, pp. 78-80, 1987.

감사의 글

먼저, 실험실 생활을 통해서 부족한 저에게 많은 가르침을 주신 교수님께 감사의 마음을 드립니다. 연구에 많은 조언을 해주신 안영공 교수님과 처음 실험실에 왔을 때 많은 도움을 주신 선배님들에게도 일일이 언급할 수 없지만 이 글을 빌어서 감사의 말을 전합니다.

같이 졸업을 하는 영찬형과 동춘 선배 그리고 동기인 호일 이에게는 축하의 말을 전하고 싶고, 다음 학기에 졸업을 하실 예정(?)인 용한형, 장기 집권이 확실시 되는 진대형, 멀리 중국에서 공부하러 온 천이, 지금도 같이 생활하고 있는 1년차 후배인 형은, 상일, 원우, 종룡 그리고 동기인 광진이, 학부생인 종덕, 민찬, 지의에게 평소에 하지 못했던 고맙다는 말을 전합니다. 지금은 취업을 한 용민형, 학업을 마치고 무사히 중국으로 가신 정룡형에게도 감사의 말을 전합니다. 이제 대학원에 들어온 병일이는 공부 열심히 하기 바란다.

10년 동안 변함없는 우정을 통해서 즐거움을 안겨줬던 낙구회 친구들 진웅, 수근, 정엽, 정대, 선욱, 승권, 영훈, 은규, 성우 그리고 뒤늦게 가입한 하석이에게도 감사의 말을 전합니다.

지금은 모두들 취업 전선에서 힘들게 일하고 있는 94학번 친구들에게도 감사의 말을 올립니다.

무엇보다 자상하신 부모님의 은혜에 감사드리고 귀염둥이 동생과 힘들 때 나에게 큰 힘이 되어준 사랑하는 윤주에게 이 논문을 바칩니다.