

Application of LVQ3 for Dissolved Gas Analysis for Power Transformer

田 永 在* · 金 載 哲**
(Young-Jae Jeon · Jae-Chul Kim)

Abstract - To enhance the fault diagnosis ability for the dissolved gas analysis(DGA) of the power transformer, this paper proposes a learning vector quantization(LVQ) for the incipient fault recognition. LVQ is suitable especially for pattern recognition such as fault diagnosis of power transformer using DGA because it improves the performance of Kohonen neural network by placing emphasis on the classification around the decision boundary. The capabilities of the proposed diagnosis system for the transformer DGA decision support have been extensively verified through the practical test data collected from Korea Electrical Power Corporation.

Key Words : Transformer, Fault Diagnosis, Dissolved Gas Analysis, Learning Vector Quantization

1. 서 론

변압기의 유증 가스 분석은 절연유 중에 용해되어 있는 가스를 분석하여 변압기 내부의 고장 유무 및 고장의 종류를 진단하는 방법으로 상태 진단법 중에서 신뢰성이 높아 가장 널리 이용되고 있는 방법이다. 유증 가스 분석을 위한 기준은 여러 가지가 제시되고 있지만 현실적으로 적용하기 어렵고 전문적인 지식을 요구하기 때문에 아직까지 경험적인 판단으로 처리되고 있다.

가스의 추출 및 분석 과정에서의 불확실성을 처리하기 위해 전문가 시스템(Expert System)과 퍼지 이론(Fuzzy Theory)이 함께 적용되었다[1,2]. 이 연구들에서 가스의 추출값에 퍼지 이론을 적용하고 전문가 시스템의 규칙에 퍼지 척도(Fuzzy Measure)를 적용하여 측정치와 규칙의 불확실성을 처리하였다. 유증가스 분석을 위한 신경망 도입도 활발하여 MLP(Multi Layer Perceptron)과 코호넨 네트워크(Kohonen Network)를 이용하여 변압기 진단을 시도하였다[3,4]. 이 외에도 코호넨 네트워크와 전문가 시스템, 퍼지와 유전알고리즘, MLP와 전문가 시스템 등이 혼합되어 진단의 효율을 높이고자 하였다[5-7]. 전문가의 경험과 지식을 규칙으로 만드는 과정에서 규칙들의 충돌이 생기고 추출 과정에서의 불확실성을 처리할 수 없어 퍼지 이론이 적용되었지만 경험적으로 결정해야할 파라메타가 많아 적용에 어려움이 있다. 신경망은 간편하게 적용할 수 있지만 학습시간이 오래 걸리고 사고 상태 데이터가 많아야 한다. 이런 문제를 해결하기 위해 여러 기법들을 혼합한 방법들이 소개되고 있지만 진단 과정

이 복잡하고 운전 환경이나 변압기 상태에 따라 전문가가 결정해야 할 것들이 많다는 단점이 존재하고 있다.

따라서 본 논문에서는 코호넨 네트워크의 지도학습형 모델인 학습 벡터 양자화(Learning Vector Quantization)를 적용하여 전력용 변압기의 유증 가스 분석 기록과 고장 인식 및 해석에 관련된 특징을 대응시킨 새로운 변압기 고장진단 알고리즘을 제안하였다. 또한 기존의 LVQ를 개선시킨 LVQ3 모델까지 가스 구성비에 사용함으로써 빠르고 정확한 진단이 이루어질 수 있도록 하였다. 제안된 LVQ를 이용한 전력용 유입 변압기의 고장 진단 방법은 변압기 유증 가스 기록 자료로 효용성을 검토하였다.

2. 유증 가스 분석법

2.1 유증 가스 분석의 개요

전력용 유입 변압기 내부에서 이상(부분 방전, 아크 방전, 국부 과열 등)이 생기면 반드시 열 발생이 수반된다. 이때 열원에 접촉된 절연 재료는 열 분해되어 H₂(수소), CH₄(메탄), C₂H₂(아세틸렌), C₂H₄(에틸렌), C₂H₆(에탄), CO(일산화탄소), CO₂(이산화탄소), O₂(산소), N₂(질소) 등의 가스가 발생하며, 각 발생 가스는 대부분 절연유중에 용해된다. 그러므로 전력용 변압기에서 절연유를 채취하여 유증 가스를 분석하면 발생 가스 및 가스 발생량의 조성에 따라 내부 이상 유무 및 그 정도를 추정할 수 있다. 유증 가스 분석법을 이용한 전력용 유입 변압기 고장 진단 방법으로는 가스 구성비를 이용한 분석과 주요 가스를 이용한 분석이 있다[8-11].

이와 같은 분석 기준은 전력용 유입 변압기 각각의 전압, 용량, 절연유 열화 방지 방식, 운전 경력이 서로 다르므로 해당 변압기의 유증 가스 분석 결과에 따라 어떻게 적용·판정하는가는 매우 어려운 문제이다. 그러므로 유증 가스 분석으로 변압기의 고장 진단을 수행하는데 있어서는 이들 몇 가지 방법을 병용하

* 正 會 員 : 崇 實 大 工 大 電 氣 工 學 科 博 士 課 程
 ** 正 會 員 : 崇 實 大 工 大 電 氣 工 學 科 教 授 · 工 博
 接 受 日 字 : 1999 年 9 月 2 日
 最 終 完 了 : 1999 年 12 月 20 日

표 1 가스 구성비 분석에 따른 IEC의 기준
Table 1 Criteria of IEC with gas ratio analysis

사고종류	가스의 구성비		
	C_2H_2/C_2H_4	CH_4/H_2	C_2H_4/C_2H_6
1 정상	<0.1	0.1~1.0	<0.1
2 <150°C 온도 사고	<0.1	0.1~1.0	1.0~3.0
3 150°C~300°C 온도사고	<0.1	>1.0	<1.0
4 300°C~700°C 온도사고	<0.1	>1.0	1.0~3.0
5 >700°C 온도사고	<0.1	>1.0	>3.0
6 저에너지 부분 방전	<0.1	<0.1	<1.0
7 고에너지 부분방전	0.1~3.0	<0.1	<1.0
8 저에너지 아크	0.1~3.0 to >3.0	0.1~1.0	1.0~3.0 to >3.0
9 고에너지 아크	0.1~3.0	0.1~1.0	>3.0

는 것이 효과적이지만 이 방법 역시 유중 가스 분석을 이용한 고장 진단 방법 자체가 매우 복잡해지는 단점을 지니고 있다. 따라서 본 연구에서는 유중 가스 분석에 관련된 대표적인 방법중에서 가장 일반적으로 사용되고 있는 가스 구성비에 의한 분석 방법을 채택하여 전력용 유압 변압기를 고장 진단하고자 한다.

2.2 가스 구성비를 이용한 분석

유중 가스 분석법에서 가스 구성비를 이용하는 분석 방법은 매우 다양하지만 대표적으로 사용되는 것은 IEC, Rogers, Dornenburg 기준 등이 있다[8-10]. IEC 기준은 그 중에서도 가장 일반적으로 사용되고 있는 것으로 5개의 유중 가스로 조합한 3종류의 가스 구성비를 사용한 것이며, 가스 성분의 비율 (C_2H_2/C_2H_4 , CH_4/H_2 , C_2H_4/C_2H_6)에 따라 코드를 부여한 후 고장 (이상)의 종류를 결정하는 방법으로 진단 유형의 종류는 총 9종이다. 진단 내용의 종류로는 크게 경년 열화(정상), 부분 방전(방전 사고), 아크 방전(방전 사고), 과열(온도 사고)로 나눌 수 있다. 이 방법은 이상의 유형을 설명할 수 있는 기준이 다양하다는 것에 장점이 있다. 표 1은 가스 구성비를 이용해서 분석하는 IEC의 기준을 나타내고 있다.

일반적으로 IEC 기준과 같은 유중 가스 구성비 분석으로 전력용 유압 변압기의 고장 진단을 수행할 수 있지만 현장에 적용하기에는 몇 가지 문제점이 있다. IEC 기준에 기초하여 3종류의 가스 비율 조합으로 코드를 구했지만 부합되는 고장 진단 유형이 나타나지 않을 수도 있다는 것이다. 또한 동시 다발적인 사고에 대응할 수 없고, 고장의 심각도를 판정하기 곤란한 문제점도 가지고 있다.

따라서 판정 불가(unknown)라는 결과보다는 현재의 유중 가스 분석 기록으로 어느 쪽의 진단 유형에 포함될 확률이 가장 큰 지를 파악하는 것이 더욱 효과적일 수 있다. 본 연구에서는 이와 같은 문제를 해결하기 위하여 유중 가스 구성비 분석의 각 진단 내용을 LVQ로 학습하여 입력과 출력이 항상 대응될 수 있는 새로운 고장 진단 알고리즘을 제시한다.

3. 학습 벡터 양자화(Learning Vector Quantization)

3.1 LVQ의 개요

벡터 양자화법 자체는 이전부터 알려진 패턴 분류 기법이며, 패턴 공간을 유한개의 참조 벡터로 양자화하는 것이다. 그림 1에 표시한 것처럼 패턴 공간은 모자이크 형상으로 나누어진다. 분할된 각 영역에는 참조 벡터가 있고, 이 참조 벡터는 그 영역 내에 포함되는 모든 벡터들에 대한 근접 벡터들로 되어 있다.

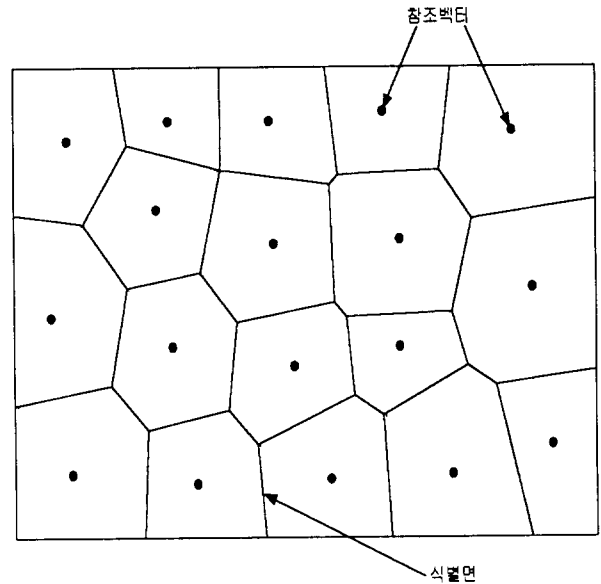


그림 1 벡터 양자화의 개념
Fig. 1 Concept of vector quantization

각 영역에 하나의 참조 벡터를 대응시킴으로써 패턴 분류가 가능해진다. 벡터 양자화법에서는 이 참조 벡터를 어떻게 잘 선택하는 것인가가 문제이다. LVQ법은 벡터 양자화법을 발전시킨 것으로 참조 벡터를 뉴런들 간의 시냅스 결합에 대응시키고 지도학습을 이용함으로써 적절한 참조 벡터를 구하는 방법이다. 비교적 간단한 학습 알고리즘으로 고도의 패턴 분류가 가능하기 때문에 요즘에 주목을 받고 있다. 이 기법은 Kohonen의 SOFM(Self-Organization Feature Map) 모델을 패턴 분류에 적합하도록 수정한 모델이라고 할 수 있다.

3.2 LVQ1 알고리즘

몇 개의 영역으로 구성된 표본 공간 상에서 각 카테고리의 참조 벡터가 해당 카테고리의 표본 벡터들이 이루는 군집의 중심에 위치한다고 가정한다. 일반적으로 한 카테고리에 여러개의 참조 벡터를 배정할 수 있다. 미지의 입력 벡터 x 는 가장 가까운 거리에 위치한 참조 벡터의 소속 카테고리와 같은 카테고리에 해당되는 것으로 결정될 수 있다. 이 개념은 코호넨의 SOFM과 같은데 구조가 그림 2처럼 출력층이 1차원으로 된 것이 다르다.

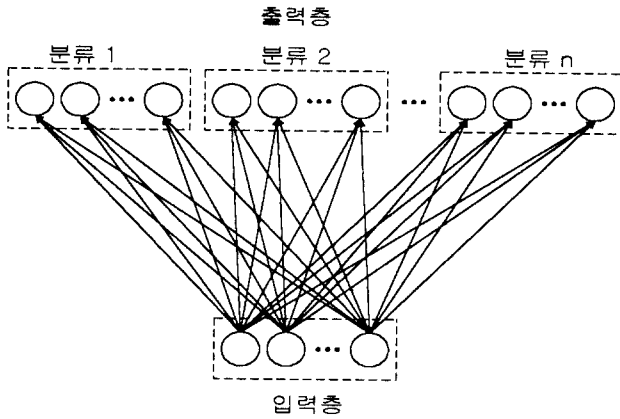


그림 2 LVQ 네트워크의 구조
Fig. 2 Architecture of the LVQ network




그림 3 LVQ의 학습
Fig. 3 Learning of a LVQ network

알고리즘 상에서 코호넨의 SOFM과 다른 점은 LVQ가 지도학습형이기 때문에 입력에 대한 승자 참조 벡터를 통해서 구분이 제대로 되었는지 아닌지를 알 수 있다. 따라서 SOFM에서 처럼 무조건 승자 참조 벡터를 중심으로 갱신하는 것과는 달리 그림 3처럼 분류를 올바르게 했을 경우와 그렇지 않았을 경우 참조 벡터를 갱신하는 방향이 다르다.

그림 3에서 보이는 것처럼 분류를 정확히 했을 경우와 그렇지 않을 경우에 다른 학습 규칙을 사용함으로써 분류의 정확성에 상관없이 일률적인 학습규칙을 적용하는 다른 신경망보다 좋은 결과를 보여준다. 다음은 LVQ의 기본적인 학습 절차이다[12].

단계 1. 초기화

참조 벡터를 랜덤하게 초기화한다.

단계 2. 각 벡터에 대해 학습 과정에서 단계 2a와 2b를 차례로 실행

단계 2a. 승자 참조 벡터 k를 결정

$$i(x(p)) = k \text{ where } \|W_k - x(p)\| < \|W_j - x(p)\|, j = 1, 2, \dots, n \quad (1)$$

단계 2b. 참조 벡터 k의 갱신

$$W_k^{new} = \begin{cases} W_k^{old} + \eta(x(p) - W_k^{old}) & \text{if 분류 정확} \\ W_k^{old} - \eta(x(p) - W_k^{old}) & \text{if 분류 부정확} \end{cases} \quad (2)$$

단계 3. 학습률 조정

학습률은 반복을 할수록 감소시킨다.

단계 4. 종료 조건 점검

종료 조건을 만족하면 중단하고 그렇지 않으면 단계 2로 간다.

3.3 LVQ2.1 알고리즘

LVQ 2.1 알고리즘은 훈련시 입력 패턴 x 에 근접한 두 개의 참조 패턴 W_i 와 W_j 를 동시에 갱신한다는 점을 제외하면 LVQ1 알고리즘과 동일하다[13,14]. 승자 참조 벡터가 정확히 분류를 못했을 경우 그 참조 벡터를 포기하고 가장 좋은 두 개의 참조 벡터를 선택한다. 선택된 두 개의 참조 벡터 중의 하나는 입력 벡터 x 와 같은 부류에 속해야만 하고 다른 참조 벡터는 입력 패턴 x 와 서로 다른 부류에 속해야 한다. 또한, 입력 벡터 x 는 일정한 윈도우 영역내에 위치해야만 한다.




그림 4 LVQ2.1의 창 조건

Fig. 4 Window condition of LVQ2.1

이 윈도우는 선택된 참조 벡터 W_i 와 W_j 의 중앙 평면상에 정의되는 영역으로, d_i 를 입력 벡터 x 와 참조 벡터 W_i 간의 유클리드 거리로, d_j 를 입력 벡터 x 와 참조 벡터 W_j 간의 유클리드 거리로 정의할 때 입력 벡터 x 가 식 (3)을 만족하면 상대적인 너비인 ϵ 크기 만큼의 윈도우 영역내에 위치하게 된다. 그림 4에서 알 수 있듯이 ϵ 의 크기에 따라 창의 넓이가 달라지며 두 참조 벡터의 중간에 위치한 창 안에서만 LVQ2.1의 알고리즘이 적용되어 두 참조 벡터가 겹치는 부분의 분별력을 높였다.

$$\min \left[\frac{d_i}{d_j}, \frac{d_j}{d_i} \right] > \frac{1-\epsilon}{1+\epsilon} \quad (3)$$

LVQ2.1 알고리즘은 다음과 같이 동작한다.

$$W_i^{new} = W_i^{old} + \eta(x(p) - W_i^{old}) \quad (4)$$

$$W_j^{new} = W_j^{old} - \eta(x(p) - W_j^{old}) \quad (5)$$

여기서, 참조 벡터 W_i 와 W_j 는 입력 벡터 x 에 근접한 두 개의 참조 벡터로, 입력 벡터 x 와 참조 벡터 W_i 는 서로 같은 부류에 속하고, 입력 벡터 x 와 참조 벡터 W_j 는 서로 다른 부류에 속해야 하며, 입력 벡터 x 는 윈도우 영역내에 위치해야 한다.

3.4 LVQ3 알고리즘 [13,14]

LVQ2.1 알고리즘은 두 부류간의 경계를 입력 벡터 x 에 따라 서로 다른 방향으로 학습을 시키고 있으나 학습 진행에 따라 W_i 및 W_j 의 위치가 어떻게 될 것인가는 고려하지 않고 있다. 따라서, LVQ3에서는 학습 진행에 따라 W_i 및 W_j 가 그들의 부류로 계속 근접해 가는 것을 보장하기 위하여 W_i 및 W_j 가 학습할 수 있는 환경으로 확장하였다[13,14].

세가지 버전의 알고리즘은 단독으로 사용되는 것이 아니고 기본적으로는 LVQ1의 알고리즘이 사용되며 위에서 설명했던 몇가지 조건을 만족할 때만 LVQ2.1과 LVQ3이 사용된다.

승자 참조 벡터가 제대로 분류하지 못했을 경우 입력 벡터가 윈도우 내에 있고 두 개의 참조 벡터가 각각 다른 부류에 속해 있다면 LVQ2.1에 따라 두 개의 참조 벡터를 갱신하고 그렇지 않을 경우에 LVQ1에 의해 하나의 참조 벡터만 갱신을 한다. 승자 참조 벡터가 제대로 분류하지 못했을 경우 두 참조 벡터의 부류가 다를 때 LVQ2.1을 사용하지만 두 참조 벡터가 입력 벡터와 같은 부류에 속하고 LVQ3의 윈도우 안에 있다면 입력 벡터가 참조 벡터 쪽으로 이동할 수 있도록 LVQ3을 사용하는 것이다. 따라서 LVQ3에서도 LVQ2.1에서처럼 두 참조 벡터의 부류가 다르다면 식 (4), (5)를 사용하고 부류가 같다면 식 (6)을 사용한다.

$$W_k^{new} = W_k^{old} + \beta(x(p) - W_k^{old}) \quad (6)$$

여기서, k 는 i 또는 j 로 입력 벡터 x 와 참조 벡터 W_i 및 W_j 가 모두 같은 부류에 속한 경우이다. $\beta = m\eta$ 이고 m 은 작은 상수이다.

4. LVQ의 적용

4.1 변압기 고장진단을 위한 LVQ의 적용

제안한 알고리즘으로 학습을 시키기 위해 2528개의 가스 데이터 중에서 IEC 기준으로 판정 가능한 1781개의 가스 데이터를 선택하였다. 입력 벡터는 IEC 가스 구성비를 0과 1 사이로 정규화 하였고 초기 참조 벡터는 같은 부류에 속하는 입력 벡터에서 랜덤하게 선택하였다. 정규화를 할 때 처음에는 IEC 기준에서 사용되는 5개의 가스를 가지고 3가지 조합으로 만든 후 가장 큰 값으로 나누어 0과 1 사이로 정규화 하였다. 그러나 대부분의 가스 비율이 낮은 값으로 이루어져 있어 패턴 분류시 오분류가 많아 로그 함수를 사용하여 0에 가까운 많은 입력 벡터들을 0과 1 사이에 고르게 분포하도록

하였다. 참조 벡터의 각 부류의 갯수는 '정상'과 '150℃~300℃ 온도사고'가 많기 때문에 각각 6개로 지정하였고 '고에너지 부분 방전'은 참고한 데이터 중에 없기 때문에 제외하여 나머지 각 부류마다 3개씩 정한 참조 벡터의 수를 더해 모두 30개이다. 참조 벡터의 수는 많은 시뮬레이션을 통해 적절한 수로 정해야 하지만 가스 데이터 중에서 사고 데이터가 부족하여 최적의 참조 벡터의 수를 선택하지 못했다. '고에너지 부분방전'을 뺀 것을 보면 알겠지만 특히 부분 방전 데이터가 부족하여 많은 수의 참조 벡터로 학습시킬 수 없었다.

모든 입력 벡터에 대해 제안한 알고리즘으로 참조 벡터를 결정하였고 전체 반복 횟수 500회를 반복하면 종료가 되도록 하였다. 학습률 η 는 처음에 0.5로 시작을 했다가 학습이 진행되면서 0으로 감소하도록 하였고, LVQ2.1과 LVQ3에서 ϵ 과 m 은 각각 0.2, 0.1의 값으로 사용하였다.

학습이 끝나면 학습된 30개의 참조 벡터를 얻을 수 있는데 IEC 기준에 따라 0 과 1 사이의 3개의 값을 가지게 된다. 30개의 참조 벡터 중에 '고에너지 아크'에 해당하는 참조 벡터는 3개가 있고 그 중의 하나가 (0.24752, 0.112938, 0.580691)이다. 어떤 가스 데이터를 입력받게 되면 입력 벡터와 같이 정규화를 해서 0과 1 사이의 3개 값을 가지게 된다. 이 값들을 미리 학습해서 얻은 30개의 참조 벡터와의 유클리드 거리를 계산하고, 만약 (0.24752, 0.112938, 0.580691)의 값을 가진 참조 벡터가 가장 가깝다면 그 가스 데이터를 가진 변압기는 '고에너지 아크' 사고로 분류할 수 있다는 것이다. LVQ 알고리즘은 비교적 간단한 학습 과정과 분류 과정을 통해 매우 뛰어난 분류 성능을 보여준다.

제안한 알고리즘은 *Pentium II 350MHz*에서 1781개의 데이터를 500회 반복하여 32초의 수행시간이 걸렸고 학습된 30개의 참조 벡터와 4.2절의 각 사례의 유클리드 거리를 통해 가스 데이터에 해당하는 사고 유형을 분류할 수 있었다.

4.2 사례 연구

제안한 알고리즘의 효용성을 검증하기 위해 다음과 같은 사례 연구를 실시하였다. 사례 연구에서 사용한 데이터는 참고문헌 [3]에 나오는 가스 데이터이다. IEC 규격을 사용하는 전력회사에서 조사한 데이터를 가지고 사례 연구를 하는 것

표 2 가스 데이터

Table 2 Gas data

사례	H ₂	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CH ₄
1	280	140	1200	150	15000
2	130	65	56	7	98
3	1700	16000	89000	84000	110000
4	300	140	160	14	240
5	1565	0	47	34	93
6	320	9	1980	417	1370
7	1400	4	3500	560	3000
8	1000	360	450	31	720

표 3 테스트 결과

Table 3 Test result

*ND - No Decision

사례	IEC	Rogers	참고문헌 3	물리적 조사	제안한 방법
1	ND	ND	온도	온도	>700℃ 온도
2	고에너지 아크	단락전류를 동반하는 아크	아크&온도	아크	고에너지 아크
3	ND	ND	온도	온도	150~300℃ 온도
4	고에너지 아크	단락전류를 동반하는 아크	아크&온도	아크	고에너지 아크
5	ND	ND	부분방전	부분 방전	저에너지 부분방전
6	>700℃ 온도	ND	온도	온도	>700℃ 온도
7	>700℃ 온도	순환전류에 의한 접속부 과열	온도	온도	>700℃ 온도
8	고에너지 아크	단락전류를 동반하는 아크	아크	아크	고에너지 아크

이 바람직하겠지만 국내에서는 구하기 어려워 물리적인 조사를 한 참고문헌 [3]의 데이터를 참조했다. 사례 연구는 모두 8개로 IEC 규격, Rogers 규격, 참고문헌 [3], 물리적 조사, 제안한 방법을 비교하였고 데이터와 비교 내용은 표 2, 3에 나와있다.

사례 연구 2, 4, 8은 IEC, Rogers 규격을 통해서 사고 내용을 알 수 있고 제안한 방법도 정확한 분류를 한다. 참고문헌 [3]에서는 사례 연구 2, 4에서 아크외에 과열이 포함되었다고 분류를 하였지만 실제 검사에서는 아크로 판정이 되었다.

사례 연구 1은 IEC, Rogers 규격을 통해서 알 수 없지만 실제 검사나 참고문헌 [3]에서는 온도 사고로 분류를 하고 논문에서 제안한 방법은 '>700℃ 온도' 사고로 분류한다. 사례 연구 3은 수소(H₂)가 많아서 부분 방전일 가능성이 많지만 온도 사고에 영향을 많이 주는 에틸렌(C₂H₄), 에탄(C₂H₆), 메탄(CH₄) 또한 많아서 실제 조사와 참고문헌 [3]에서 온도로 판정했고 본 논문에서 제안한 방법도 '150~300℃ 온도' 사고로 판정하였다. 사례 연구 5는 IEC, Rogers 기준으로 알 수 없지만 수소(H₂)가 많기 때문에 쉽게 부분 방전으로 생각할 수 있다. 그러나 IEC, Rogers 규격에서 사용하는 CH₄/H₂의 비율이 대부분 1.0 내외이거나 상당히 작기 때문에 이를 고려한 정규화를 하지 않을 경우 '<150℃ 온도' 사고로 판정이 나오게 된다. 사례 연구 6, 7은 IEC 규격으로 알 수 있으며 제안한 방법으로도 쉽게 '>700℃ 온도' 사고를 알 수 있다.

IEC 기준이 가지고 있는 문제점이 많기 때문에 이를 보완하기 위해 본 논문에서 LVQ를 이용한 새로운 알고리즘을 제안하였다. 문제가 많은 IEC 규격을 바탕으로 학습시켜서 본 논문에서 제안한 알고리즘이 완전하지는 않지만 사례 연구를 통해 알 수 있듯이 IEC, Rogers 기준으로 알 수 있는 사례는 정확히 분류하고, 이들 규격으로 알 수 없는 사례 또한 실제 조사 내용과 일치하는 분류를 함으로써 현실적으로 적용할 수 있다는 것을 보였다.

5. 결 론

본 논문에서는 유중 가스 분석을 이용한 변압기 고장 진단 문제에 LVQ를 적용하였다. 패턴 인식을 위해 자율학습형인 코호넨 네트워크를 지도학습형으로 바꾼 LVQ는 대부분의 알고리즘이 분류와 관계없이 학습하는 것을 탈피하여 잘못된 분

류를 하였을 경우 반대 방향으로 이동하게 함으로써 보다 정확한 분류가 가능하도록 만든 알고리즘이다. 또한 LVQ1을 개선한 LVQ2.1과 LVQ3의 학습 알고리즘을 변압기 진단 문제에 적용하여 빠른 학습시간과 정확한 분류가 가능해졌다. 제안한 알고리즘은 전력용 유입 변압기의 유중 가스 기록으로 효용성을 입증하였다. 따라서 유중 가스 분석으로 변압기 진단 및 상태 추정이 보다 정확하게 되었고, 이것의 적용으로 적절한 유자 및 보수 대책 방안을 제시할 수 있게 되었다. 향후 기존 유중 가스 기록 자료의 적극적인 활용으로 사고 원인에 대한 철저한 분석이 요구되고, 또한 가스 구성비 분석 뿐만 아니라 주요 가스 분석도 유중 가스 분석을 이용한 전력용 변압기 진단에 사용되어야 할 것이다.

참 고 문 헌

- [1] C.E. Lin, J.M. Ling, and C.L. Huang, "An Expert System for Transformer Fault Diagnosis Using Dissolved Gas Analysis," *IEEE Transactions on Power Delivery*, Vol. 8, No. 1, pp. 231-238, January 1993.
- [2] K. Tomsovic, M. Tapper, and T. Ingvarsson, "A Fuzzy information Approach to Integrating Different Transformer Diagnostic Methods," *IEEE Transactions on Power Delivery*, Vol. 8, No. 3, pp. 1638-1646, July 1993.
- [3] Y. Zhang, X. Ding, Y. Lie, and P. J. Griffin, "An Artificial Neural Network Approach to Transformer Fault Diagnosis," *IEEE Transactions on Power Delivery*, Vol. 11, No. 4, pp. 1836-1841, October 1996.
- [4] 윤용한, 전영재, 김재철, "유중가스 분석을 이용한 전력용 변압기 고장진단용 코호넨 네트워크," *대한전기학회*, 제 47권, 6호, pp. 741-745, 1998년 6월.
- [5] Jae-Chul Kim, Yong-Han Yoon, Do-Hyuk Choi, Young-Jae Jeon, "A Kohonen Neural Network Approach for Transformer Fault Diagnosis using Dissolved Gas Analysis," *Proceeding of the International Conference on Intelligent System*

- [3] Y. Zhang, X. Ding, Y. Lie, and P. J. Griffin, "An Artificial Neural Network Approach to Transformer Fault Diagnosis," *IEEE Transactions on Power Delivery*, Vol. 11, No. 4, pp. 1836-1841, October 1996.
- [4] 윤용환, 전영재, 김재철, "유증가스 분석을 이용한 전력용 변압기 고장진단용 코호넨 네트워크," *대한전기학회*, 제 47권, 6호, pp. 741-745, 1998년 6월.
- [5] Jae-Chul Kim, Yong-Han Yoon, Do-Hyuk Choi, Young-Jae Jeon, "A Kohonen Neural Network Approach for Transformer Fault Diagnosis using Dissolved Gas Analysis," *Proceeding of the International Conference on Intelligent System Application to Power System at Seoul, Korea*, pp. 336-340, July 1997.
- [6] Y.C. Huang, H.T. Yang, and C.L. Huang, "Developing a new transformer fault diagnosis system through evolutionary fuzzy logic," *IEEE Transaction on Power Delivery*, Vol. 12, No. 2, pp. 761-767, 1997.
- [7] Zhenyanuan Wang, Yilu Liu, and Paul J. Griffin, "A Combined ANN and Expert System Tool for Transformer Fault Diagnosis," *IEEE Transaction on Power Delivery*, Vol. 13, No. 4, pp. 1224-1229, October 1998.
- [8] R.R. Rogers, "IEEE and IEC Codes to Interpret Incipient Faults in Transformers Using Gas in Oil Analysis," *IEEE Transaction on Electrical Insulation*, Vol. 13, No. 5, pp. 349-354, October 1978.
- [9] IEC Publication 599-1978, Interpretation of The Analysis of Gases in Transformers and Other Oil-Filled Electrical Equipment in Service
- [10] J.J. Kelly, "Transformer Fault Diagnosis by Dissolved Gas Analysis," *IEEE Transactions on Industry Application*, Vol. 16, No. 6, pp. 777-782, November 1980.
- [11] 남창현, 이태원, 원도영, "변압기 유증 가스 상시 감시 시스템의 운용 연구(연구 보고서), 전력연구원, 1995.
- [12] T. Kohonen, "Self-Organization and Associative Memory," (3rd ed), 1989.
- [13] T. Kohonen, "Statistical Pattern Recognition revisited," *Advanced Neural Computers*, pp. 137-144, 1990.
- [14] T. Kohonen, "LVQ PAK - The Learning Vector Quantization Program Package," Helsinki University of Technology, Finland, 1992.

저 자 소 개



전 영 재(田 永 在)

1972년 6월 30일생. 1995년 숭실대 전기공학과 졸업. 1997년 숭실대 대학원 전기공학과 졸업(석사). 현재 동 대학원 전기공학과 박사과정

Tel : 02-817-7966 Fax : 817-0780

E-mail : mayoung@ee.ssu.ac.kr



김 재 철(金 載 哲)

1955년 7월 22일생. 1979년 숭실대 전기공학과 졸업. 1983년 서울대 대학원 전기공학과 졸업(석사). 1987년 서울대 대학원 전기공학과 졸업(공학). 1988년~현재 숭실대 공대 전기공학과 교수

Tel : 02-820-0647, Fax : 817-0780

E-mail : jckim@ee.ssu.ac.kr