

전력용 변압기의 유증가스 해석을 위한 지능형 진단 알고리즘 개발

(Development of Artificial Diagnosis Algorithm for Dissolved Gas Analysis
of Power Transformer)

임재윤* · 이대종 · 이종필 · 지평식

(Jae-Yoon Lim · Dae-Jong Lee · Jong-Pil Lee · Pyeong-Shik Ji)

요 약

일반적으로 변압기의 고장진단을 위해 IEC 코드법이 사용되지만, 이 방법은 가스비율이 규정된 범위 내에 존재하지 않거나 경계조건에 있는 경우 숙련된 전문가에게 의뢰하지 않고는 정확한 고장의 원인을 판정하는데 어려움이 있다. 이러한 문제점을 해결하기 위하여 본 논문에서는 SOM을 이용한 전력용 변압기의 고장진단 알고리즘을 제안한다. 제안된 방법은 훈련 데이터의 경쟁학습을 통하여 자기 구성 맵을 구축한 후, 실증 데이터를 구축된 맵에 적용하여 고장의 진단이 이루어진다. 또한 클러스터링 기법에 의해 구축된 정상/고장모델과 정상 데이터를 비교함으로써 고장의 추이 및 열화정도를 분석한다. 제안된 방법의 유용성을 보이기 위한 실험결과에서 기존의 방법들에 비해 향상된 진단결과를 보임을 확인할 수 있었다.

Abstract

IEC code based decision rule have been widely applied to detect incipient faults in power transformers. However, this method has a drawback to achieve the diagnosis with accuracy without experienced experts. In order to resolve this problem, we propose an artificial diagnosis algorithm to detect faults of power transformers using Self-Organizing Feature Map(SOM). The proposed method has two stages such as model construction and diagnostic procedure. First, faulty model is constructed by feature maps obtained by unsupervised learning for training data. And then, diagnosis is performed by compare feature map with it obtained for test data. Also the proposed method measures the possibility and degree of aging as well as the fault occurred in transformer by clustering and distance measure schemes. To demonstrate the validity of proposed method, various experiments are performed and their results are presented.

Key Words : IEC code, Dissolved gas analysis, Self-Organizing Feature Map(SOM), Aging

* 주저자 : 대덕대학 전기과 교수

Tei : 042-866-0332, Fax : 042-866-0339

E-mail : jylim@ddc.ac.kr

접수일자 : 2007년 4월 24일

1차심사 : 2007년 4월 30일

심사완료 : 2007년 5월 14일

1. 서 론

급속한 산업발달로 인하여 전기 에너지의 수요가

전력용 변압기의 유증가스 애석을 위한 지능형 진단 알고리즘 개발

급증함에 따라 전력설비 용량도 증대하고 있다. 또 고도화된 첨단 산업사회의 전력 소비자들은 고품질의 전력공급을 요구하고 있어 이를 위해서는 전력계통을 구성하는 전력기기의 안정성 및 신뢰도 확보가 선행되어야 한다. 이와 같이 안정적 전력공급을 위해서는 유입전력기기의 내부이상을 조기에 발견하여 미연에 사고를 방지하는 것이 무엇보다도 중요하다. 특히 전력용 변압기는 수요설비의 증가에 맞추어 대형화 및 초고압화로 이러한 전력용 변압기의 예기치 않은 고장은 막대한 경제적 손실을 유발하므로 사전에 이상 유무를 판단하여 갑작스런 고장을 방지하는 시스템 개발이 절실히 요구된다.

변압기의 내부 이상을 조기에 발견하여 사고를 예방하기 위하여 국내 산업현장에서는 수소와 아세틸렌 등의 탄화수소 가스들에 대해 절연유중 용존 가스 관리 기준에 의거하고 있다[1]. 그러나 이 방법은 주요가스 성분의 양이나 가스 조성비를 이용하여 기준값과 비교하는 이분법적인 판단을 하고 있어, 이 분법 자체가 지니고 있는 특성에 의해 오판을 하는 확률이 존재한다. 전력용 변압기는 운전 중 각부의 열화로 전기적 성능이 서서히 감소하므로 기존 진단 방식에 의한 획일적인 이상/정상 판단만으로는 정확한 변압기의 열화 상태를 판단하는 데는 한계가 있다.

앞서 기술된 용존 가스 관리 기준에 의거하여 변압기가 이상이라 판정된 경우 고장의 원인을 판단하기 위하여 다양한 방법들이 국제적으로 적용되고 있다. 대표적인 진단 방법으로서, 유증가스법(DGA : dissolved gas analysis)에 기반한 주요 가스에 의한 진단법, IEC 진단법, Rogers법, Donenberg법 등이 있다[2-5]. 이 중에서도 IEC 코드법에 의한 고장원인 분석법이 널리 사용되고 있으나, 이 방법은 가스비율이 규정된 범위내에 존재하지 않거나 경계조건에 있는 경우 숙련된 진단 전문가에게 의뢰하지 않고는 정확한 고장의 원인을 판정하는데 어려움이 있다.

이러한 문제점을 해결하기 위하여 본 논문에서는 SOM을 이용한 전력용 변압기의 고장진단 알고리즘을 제안한다. 제안된 방법은 훈련 데이터의 경쟁학습을 통하여 자기구성 맵을 구축한 후, 실증 데이터를 구축된 맵에 적용하여 고장의 진단이 이루어진다.

또한 클러스터링 기법에 의해 구축된 정상/고장모델과 정상 데이터를 비교함으로써 고장의 추이 및 열화정도를 분석한다. 제안된 방법은 사례연구를 통하여 적용 가능성과 우수성을 입증하였다.

2. 유증가스분석법을 이용한 진단방법

유입변압기를 오랫동안 사용하게 되면 변압기 절연유나 절연물속에 포함되어 있는 습기, 연소가스, 고체 불순물 등이 증가하여 국부적인 온도 상승이나 절연지 및 절연유의 열화가 생긴다. 변압기 내부에서 부분방전이나 코로나 방전, 혹은 국부파열 등에 의하여 이상이 발생하게 되면 열 발생이 수반되어 이 열원에 접촉된 절연재료가 분해되어 여러 종류의 가스가 발생하게 된다[6]. 즉 변압기 내부의 절연재료인 절연유, 절연지, 프레스 보드 등은 열 분해되어 수소(H₂), 메탄(CH₄), 에탄(C₂H₆), 에틸렌(C₂H₄), 아세틸렌(C₂H₂), 일산화 탄소(CO), 이산화탄소(CO₂) 등의 가스를 발생하게 되며, 각 발생가스의 대부분은 절연유에 용해된다.

따라서 유입변압기에서 절연유를 채취하여 유증가스를 분석하게 되면, 가스발생 및 가스 발생량의 조성비에 따라 내부 이상 유무 및 그 정도를 추정할 수 있다. 현재 국내 산업현장에서는 변압기의 내부 이상을 조기에 발견하여 사고를 예방하기 위한 목적으로 수소와 아세틸렌 등의 탄화수소 가스들에 대해 표 1의 KEPCO 기반 열화진단기준에 의거하고 있다. 이 기준에 따라 정상/요주의 등 열화정도를 판정한다[1]. 표 1에 의해 요주의가 발생하였을 경우에는 표 2에 나타낸 IEC의 진단법에 따라 이상의 원인을 분석하고 있다.

앞서 설명된 유증가스 분석법을 통하여 비교적 정확한 변압기 진단을 수행할 수 있지만 현실에 적용하기에는 몇 가지 문제점이 있다. 즉 유증가스 분석법은 변압기의 설치시기, 구조, 용량, 제조회사 등의 영향을 많이 받고 측정 방법에 따라 계측기가 달라진다. 또한 전력용 변압기는 운전 중 각부의 열화로 전기적 성능이 서서히 감쇄되어 기존 진단방식에 의한 획일적인 이상/정상 판단만으로는 정확한 변압기의 열화 상태를 판단하는 데는 한계가 있다.

표 1. KEPCO 기반 열화 진단 기준
 Table 1. Decision categories in KEPCO

판정 가스성분	정상 (Normal)	요주의 (Caution)	이상 (Abnormal)
H ₂	400 미만	400 이상	800 이상
CO	300 미만	300 이상	800 이상
C ₂ H ₂	20 미만	20 이상	100 이상
CH ₄	250 미만	250 이상	750 이상
C ₂ H ₆	250 미만	250 이상	750 이상
C ₂ H ₄	250 미만	250 이상	750 이상

표 2. IEC 기반 고장원인 분석
Table 2. Decision categories in IEC

Case	Characteristic fault	C_2H_2 / C_2H_4	CH_4 / H_2	C_2H_4 / C_2H_6
PD	Partial discharges	NS	<0.1	<0.2
D1	Discharges of low energy	>1	0.1-0.5	>1
D2	Discharges of high energy	0.6-2.5	0.1-1	>2
T1	Thermal fault ($t < 300 [^\circ C]$)	NS	NS	<1
T2	Thermal fault ($300 [^\circ C] < t < 700 [^\circ C]$)	<0.1	>1	1-4
T3	thermal fault ($t > 700 [^\circ C]$)	<0.2	>1	<4

KEPCO 기준 판정법칙에 의해 요주의로 판정된 경우 고장원인은 IEC 60599 코드법[7]에 의해 수행된다. IEC 코드법은 이상 원인의 진단종류가 다른 분석법 보다 세분화되어 있고 신뢰성이 높아 국제적으로 널리 적용되고 있다. 그러나 가스 조성법에 근거한 IEC 코드법은 가스 비율이 규정치에 존재하지 않거나 경계조건에 있는 경우 진단 전문가에게 의뢰하지 않고는 해석에 어려움이 있다는 단점이 있다. 또한 IEC의 진단방법은 진단영역이 겹치는 부분이 존재함으로 정확한 원인분석을 하는 데는 한계가 있다[8].

3. 제안된 진단 알고리즘

변압기의 고장진단 및 열화추이 특성을 분석하기 위하여 제안한 진단기법의 기본 구성도는 그림 1에서 보여준다. 제안된 기법은 우선 KEPCO 기준법에 의해 정상/요주의 여부를 판정하고, 요주의로 판정된 경우 SOM에 의해 고장원인을 판정한다. 정상으로 판별된 경우에는 거리 유사도판정에 의해 열화추이를 분석한다.

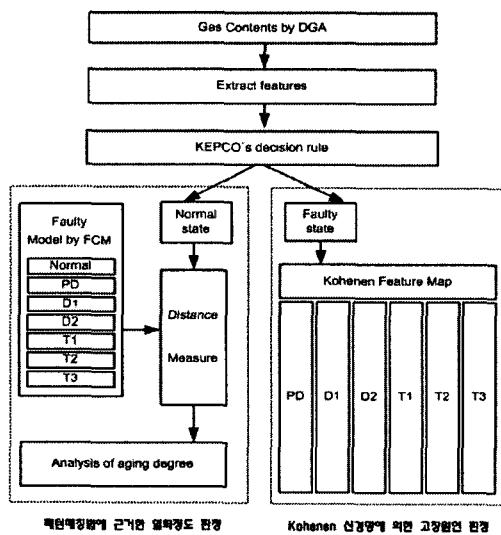


그림 1. 제안한 진단 알고리즘
Fig. 1. Proposed diagnosis algorithm

3.1 SOM에 의한 고장진단

변압기의 이상 유무와 열화의 원인을 판별하기 위해 비교사학습의 대표적인 신경회로망인 SOM을 사용하였다. 유증 가스로 구성된 N 차원의 입력패턴, 즉 가스패턴을 2차원 평면에 맵핑할 수 있는 능력을 갖고 있는 SOM은 입력층에 N 개의 입력노드와 변압기의 이상유무와 열화 원인을 나타낼 수 있는 출력층은 M 개의 뉴런으로 구성되어 있다. 출력 뉴런은 2차원의 격자 형상으로 입력노드 i 와 출력 뉴런 j 와의 연결 가중치 W_{ij} 로 연결되어 있다. 그러므로 출력층 각 뉴런은 N 차원의 연결가중치 벡터 W_j 를 갖게 되며, 총 M 개의 연결가중치 벡터로 구성되어 진다.

전력용 변압기의 유증가스 애석을 위한 지능형 진단 알고리즘 개발

입력패턴의 구성 요소는 유증의 주요 가스성분으로 하였으며, 입력패턴을 구성하기 위하여 시그모이드 함수에 의해 입력패턴을 0과 1사이로 정규화하였다. SOM의 학습은 식 (1)과 같은 입력패턴이 입력되면, 식 (2)와 같이 경쟁학습 원리에 따라 초기 가중치벡터와 입력패턴 벡터와의 거리를 계산하고, 가장 가까운 거리에 있는 연결가중치 벡터를 갖는 최적 뉴런을 찾게 된다. 그리고 최적 뉴런을 중심으로 설정된 근방뉴런들의 연결가중치를 식 (3)과 같이 수정하고, 계속적으로 근방 뉴런 수를 감소시키면서 경쟁학습을 진행한다.

$$x_p = [x_{p1}, x_{p2}, x_{p3}, \dots, x_n] \quad (1)$$

$$\|x_p - \hat{w}_i\| = \min \|x_p - \hat{w}_j\| \quad (2)$$

$$w_{ij}^{(k+1)} = \begin{cases} w_{ij}^{(k)} + \alpha^{(k)}[x_i^{(k)} - w_{ij}^{(k)}] & \text{for } i \in N_j^{(k)}, \\ w_{ij}^{(k)} & \text{otherwise} \end{cases} \quad (3)$$

SOM은 그림 2에서 보인 바와 같이 근방 뉴런을 포함한 반복적인 학습을 통하여 입력패턴들의 공간적인 순서 관계나 위상을 2차원 평면에 보존하는 지형학적 맵핑이 실현된다. 학습이 완료 후 입력패턴들은 맵핑된 뉴런 위치에 따라 이상 유무 및 열화원인을 나타내게 된다. 학습된 SOM의 출력층에서 동일한 위치의 뉴런에 맵핑된 입력패턴들은 SOM의 학습 원리에 따라 입력패턴들이 거의 동일함을 의미하며, 이웃 뉴런에 맵핑된 입력패턴과의 유사성은 지형학적 거리의 정도뿐만 아니라, 맵핑된 뉴런들이 갖는 연결 가중치 벡터의 유클리드거리에 의하여 패턴의 유사성 정도를 나타내기도 한다[9-11].

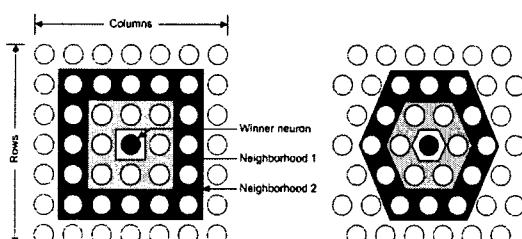


그림 2. SOM의 이웃뉴런

Fig. 2. Neighborhood neurons of SOM

3.2 FCM 및 거리 유사도에 의한 열화 추이 분석

그림 3에서는 정상데이터의 열화추이 특성 분석 과정을 나타낸다. 정확한 유입변압기 이상 진단을 위해서는 진단하고자 하는 데이터와 구축된 데이터 간의 비교 분석에 의해 이루어짐으로 신뢰성 높은 데이터 구축이 무엇보다도 중요한 요소로 작용하고 있다. 이를 위해 본 연구에서는 데이터간의 대표특징들을 선택하는 퍼지기반 군집기법인 FCM(fuzzy c-means)을 적용하여 그림 3에서 보는 바와 같이 고장 모델을 구축하였다[12].

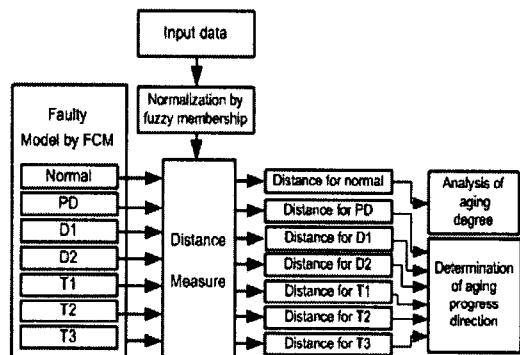


그림 3. 고장추이 및 진행방향 분석

Fig. 3. Analysis of aging degree and progress direction

퍼지기반 대표특징들을 적용하기에 앞서 데이터들의 0과 1사이에 값을 갖도록 정규화 과정을 행하게 된다. 기존방식에서 사용되는 최대값-최소값 정규화 방법 대신에 본 과제에서는 시그모이드 함수를 이용한 정규화를 하고자 한다. 이 방식은 기존의 정규화 방법에 사용되는 선형 매핑 대신에 식 (4)에 나타낸 시그모이드 함수에 의한 비선형 매핑을 함으로써 인간의 판단방식에 근사하도록 데이터를 분류한다.

$$f(x) = \frac{1}{1 + \exp[-a(x - c)]} \quad (4)$$

여기서 a 는 시그모이드 함수의 기울기이고, c 는 시그모이드 함수의 중심점 위치를 나타낸다. 이러한

중심값 및 기울기에 관련된 인자는 실측데이터의 각적인 분석을 통하여 설정하였다.

입력 데이터의 정규화과정을 수행한 후, 퍼지기반 군집화 기법을 통하여 데이터의 대표 특징 점을 선정하고자 한다. 퍼지기반 군집화 기법은 초기에 임의로 설정된 퍼지값을 갖는 분할행렬의 값을 갱신함으로써 이루어진다. 분할행렬의 갱신과정은 초기 대표점과 데이터간의 거리에 반비례하는 비례하는 퍼지값을 부여함으로써 이루어진다. 퍼지 c-Means 군집화 기법을 단계별로 간략히 설명하면 다음과 같다.

[단계 1] 취득하고자 하는 대표점의 수 즉, 클러스터의 수 c ($2 \leq c \leq n$)를 정하고, 초기 분할행렬 $U^{(0)}$ 를 초기화한다. 분할행렬에 할당될 소속정도의 값 μ_{ik} 는 다음 식을 만족한다.

$$\mu_{ik} = \mu_{Ai}(x_k) \in [0, 1] \quad (5)$$

[단계 2] 각 단계에서 데이터 x 와 초기 분할 행렬 값 u 를 이용하여 대표 특징의 중심 $v_{i^{(r)}}$ 를 계산한다.

$$v_{ij} = \frac{\sum_{k=1}^n \mu_{ik}^m \cdot x_{kj}}{\sum_{k=1}^n \mu_{ik}^m} \quad (6)$$

[단계 3] 단계 2에서 계산된 대표 특징들의 중심값과 데이터 x 와의 거리값 d 에 의하여 분할 행렬 $U^{(r)}$ 를 다음과 같이 갱신한다.

$$\mu_{ik}^{(r+1)} = \left[\sum_{j=1}^c \left(\frac{d_{jk}^{(r)}}{d_{ik}^{(r)}} \right)^{2/(m-1)} \right]^{-1} \quad (7)$$

여기서 m 은 퍼지화 정도를 나타내는 퍼지 수로써 일반적으로 2를 이용한다. 또한 d_{jk} 는 j 번째 데이터 x_j 와 k 번째 대표 중심값 v_k 와의 유clidean 거리값을 의미한다.

$$d_{jk} = d(x_j, c_k) = \left[\sum_{i=1}^p (x_{ji} - v_{ki})^2 \right]^{-1} \quad (8)$$

[단계 5] 다음과 같이 목적함수를 계산한 후, 만약 $\|J(U^{(r)}, v^{(r)}) - J(U^{(r-1)}, v^{(r-1)})\| \leq \epsilon$, 이면 알고리즘을 종료하고 그렇지 않으면 [단계 2]로 가서 반복 수행한다.

$$J(U, c_1, c_2, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (9)$$

최종적으로 열화진행정도는 입력데이터와 FCM에 의해 기 구축된 정상데이터 간의 거리척도에 의해 열화의 진행정도를 결정하였다. 즉 열화가 어느 정도 진행된 입력데이터인 경우 기 구축된 정상데이터와의 거리척도의 값이 상대적으로 크고, 열화가 진행되지 않은 데이터인 경우 거리척도의 값이 상대적으로 작다는 점에 착안하여 열화정도를 수치적으로 제시하고자 한다. 거리척도에 의해 열화추이 진행정도가 판단된 후, 열화의 진행 방향은 FCM에 의해 이미 구축된 정상데이터를 제외한 6개의 고장데이터(PD~T3)와 입력데이터간의 거리 척도를 구한 후, 거리척도 값이 적은 즉, 유사도가 높은 고장모델을 선정함으로써 고장진행방향을 결정하고자 한다.

4. 실험 및 결과

제안된 기법의 유용성을 보이기 위해 사용된 데이터는 표 3에서 보인 바와 같이 1992년에서 1997년 동안 지역 2곳의 154[kV]와 345[kV]용 변압기에서 취득한 KEPCO 데이터를 이용하였다[5]. 지역 (A)에서는 64개 변전소에 설치 운용중인 177개 변압기에서 907개의 데이터를 취득하였고, 다른 지역 (B)에는 38개의 변전소에 설치된 98개의 변압기에서 456개의 가스성분을 취득하였다. 따라서 구성된 데이터는 수소(H₂), 일산화탄소(CO), 아세틸렌(C₂H₂), 메탄(CH₄), 에탄(C₂H₆), 에틸렌(C₂H₄)으로 총 6개의 가스성분으로 구성되어 있는 1,363개이다. 데이터의 구조를 자세히 살펴보면 사용된 데이터 1,363개 중 요주의 데이터는 268개이고 정상데이터는 1,095개로 구성되어 있다. 요주의 데이터를 국내 전문가에 의해

전력용 변압기의 유증가스 해석을 위한 지능형 진단 알고리즘 개발

판정된 고장원인별로 살펴보면, 절연열화 153개, 아크방전 45개, 저온과열 16개, 중온과열 19개, 고온과열 35개로 구성되어 있다.

표 3. 데이터의 구성

Tabel 3. Data structure

Case		지역(A)	지역(B)	합계
요주의	절연열화	121	32	153
	아크방전	11	34	45
	저온파열	15	1	16
	중온파열	16	3	19
	고온파열	28	7	35
	소계	191	77	268
정상		716	379	1095
합계		907	456	1,363

4.1 SOM에 의한 고장 진단

표 3에서 보는 바와 같이 국내의 원인진단 분류로는 절연열화, 아크방전, 저온파열, 중온파열, 고온파열로 구분하지만, 국제적으로 통용되는 IEC 코드법은 표 2에서 보는 바와 같이 부분방전(PD), 저에너지 방전(D1), 고에너지 방전(D2), 저온파열(T1), 중온파열(T2), 고온파열(T3)로 구분하여 진단과의 차이점을 갖는다. SOM에 의한 고장원인별 특징맵을 구축하기 위해서는 신뢰성 높은 데이터의 확보가 선행되어야 하지만 국내규정과 IEC 코드법의 상이성으로 인하여 표 3에서 전문가에 의해 분류된 요주의 데이터를 직접적으로 사용하기에는 문제점이 있다. 또한 요주의 데이터 268개만으로 모든 고장의 특성을 반영하기에는 데이터의 양이 적으므로 제안된 진단모델의 신뢰성이 저하될 우려가 발생한다. 따라서 본 연구에서는 하나의 대안으로서 표 2에서 주어진 IEC 코드법을 이용하여 각각의 고장조건에 맞는 데이터를 생성하였다. 생성된 데이터는 각각의 고장 조건별로 조건 범위 내에서 균등분포를 갖는 30,000개의 데이터를 생성하여 총 180,000(3,000개×6조건)개의 데이터를 얻었다. 데이터 생성에 의해 얻어진 고장데이터를 학습시간을 향상시키기 위하여 FCM을 이용하여 고장상태별로 100개의 대표 틀릿 각들

을 선정한 후, SOM의 자기학습과정을 수행한다. 이 때, 출력층은 패턴이 충분히 맵핑될 수 있도록 2차원 평면상에 30행과 30열, 총 900개의 뉴런으로 구성하였다. 초기 연결 가중치는 임의로 설정하였다. 학습 횟수는 입력 패턴이 출력 뉴런층에 충분히 맵핑되도록 각 근방뉴런별로 100회씩 반복학습 하도록 설정하였다.

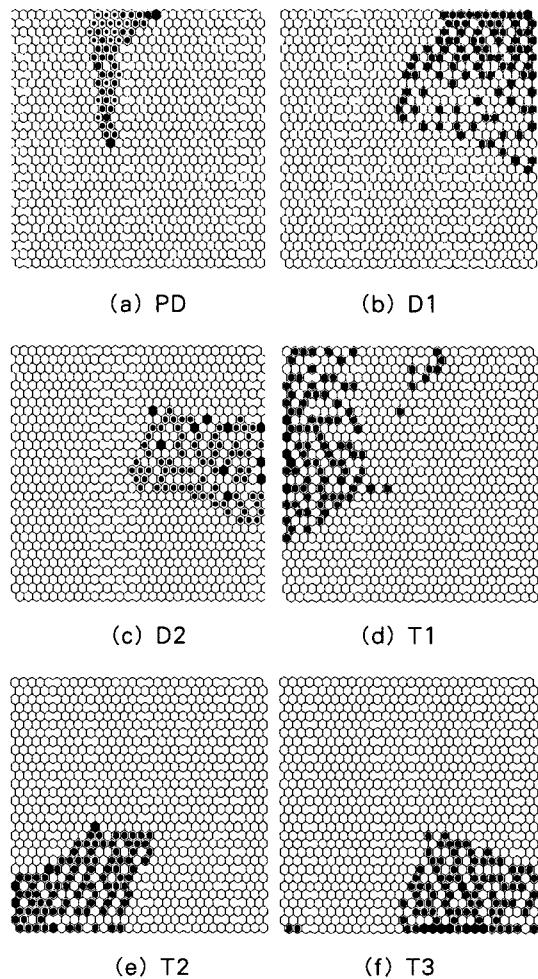


그림 4. SOM에 의해 얻어진 특징맵
Fig. 4. Feature map by SOM

그림 4에서는 SOM에 의해 학습한 후, FCM에 의해 얻어진 훈련데이터에 대한 출력층의 매핑 구조를 나타냈다. 그림 4에서 보는 바와 같이 고장상태별로 일부 결치는 부분이 존재하지만 대부분부의 데이터들

이 고장상태별로 패턴특성이 구분됨을 알 수 있다. 그림 5에서는 그림 4에서 얻어진 맵의 구조를 이용하여 고장상태별로 특징맵을 설계하였다.

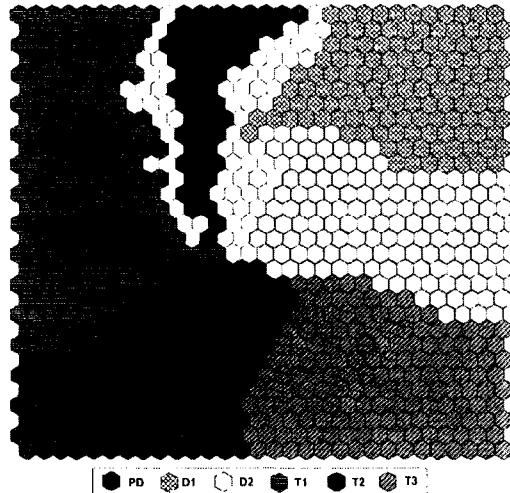


그림 5. 고장상태별 특징맵 설계

Fig. 5. Design of feature map according to fault conditions

표 4. 고장 진단결과

Table 4. Fault identification results

Case	IEC	SOM		
		조건 범위내	조건 범위외	계
PD	0	0	0	0
D1	9	9	2	11
D2	2	2	12	14
T1	70	70	23	93
T2	76	76	18	94
T3	42	42	14	56
판정불능	69	0	0	0
합 계	268	199	69	268

표 4에서는 KEPCO 데이터 중 요주의 데이터 268개를 이용하여 고장원인을 분석한 결과를 나타냈다. 표 4에서 보인 바와 같이 IEC 코드법으로는 총 데이터 268개 중 69개가 고장의 원인을 분류할 수 없는 판정불능으로 진단결과를 보이지만 제안된 SOM은 자기학습에 의해 구축된 특징맵에서 진단이 이루어

지므로 판정불능으로 진단을 하는 영역은 존재하지 않는다. 진단결과를 세부적으로 살펴보면, IEC 코드법에 의해 특정영역으로 고장원인을 분류한 결과와 SOM에 의해 고장원인을 분류한 결과는 일치함을 확인할 수 있었다. 즉 표 4에서 IEC 코드법에 의해 D1으로 판정된 9개의 데이터는 제안된 방법으로도 모두 D1 영역으로 판정되었고, IEC 코드법에 의해 판정불능으로 진단된 69개의 데이터 중 D1영역에 2 개의 데이터가 존재하여 총 11개의 데이터로 나타났다.

4.2 FCM과 거리유사도에 의한 열화추이 분석

본 연구에서 제안된 열화진행정도 분석방법으로 입력데이터와 FCM에 의해 미리 구축된 정상데이터 간의 거리척도에 의해 열화의 진행정도를 결정하고, 열화 진행 방향은 입력데이터와 고장데이터(D1~T3)간의 거리척도를 구한 후, 거리척도 값이 적은 즉, 유사도가 높은 고장모델을 선정함으로써 고장진행방향을 결정하였다. 여기서 KEPCO 데이터가 표 5에서 보인 바와 같이 고장원인이 PD인 데이터가 존재하지 않아 고장원인이 PD인 경우에는 고려하지 않았다.

표 5. 열화진행정도가 90[%] 이상인 정상데이터

Table 5. Normal data above 90(%) aging degree

사례	가스성분 및 편집조건						열화 정도 (%)	진행 방향
	H ₂	CO	C ₂ H ₂	CH ₄	C ₂ H ₆	C ₂ H ₄		
	400	300	20	250	250	50		
1	52	62	0	159	118	21	98	T2
2	14	139	0	147	73	25	98	T2
3	49	64	19	38	36	31	92	D1
4	17	230	0	146	94	21	94	T2

그림 6에서는 KEPCO 데이터 중에서 정상데이터인 1,095개를 입력데이터로 사용하여 FCM에 의해 구축된 정상모델과의 거리비교에 의해 산출된 열화추이값을 값을 나타냈다. 그림 5에서 y축 값은 열화진행 정도를 나타낸다. 여기서 y축 값 1의 의미는 정

전력용 변압기의 유증가스 애석을 위한 지능형 진단 알고리즘 개발

상과 요주의의 경계범위를 나타내므로 y축 값이 1에 근접한 데이터인 경우 열화의 진행정도가 심해짐을 나타낸다. 실험결과 정상데이터 중에서 열화의 진행정도가 0.9이상 즉, 90[%]이상 진행된 사례들을 표 6에 나타냈다.

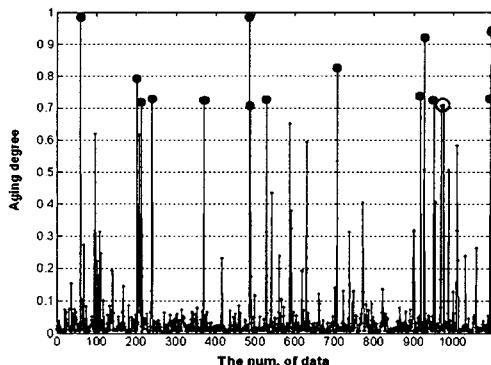


그림 6. 정상데이터에 대한 열화정도 분석
Fig. 6. Analysis of aging degree for normal data

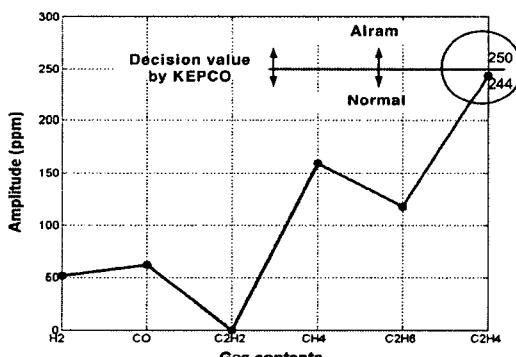


그림 7. 사례 1에 대한 열화정도(98(%)) 분석
Fig. 7. Analysis of aging degree for case (1)

그림 7에서는 표 5에 나타낸 사례값 중에서 사례 1에 대한 가스 성분값을 KEPCO의 판정기준과 비교하여 나타냈다. 그림 7에서 보인 바와 같이 C_2H_2 의 가스성분값이 244로서 KEPCO의 판정기준인 250 미만으로 정상이라 판정되지만, 해당 가스값이 그림 7에서 보는 바와 같이 판정기준에 매우 근접해 있으므로 열화가 98[%] 진행되고 있다고 판단할 수 있다. 또한 사례 1의 데이터를 FCM에 의해 이미 구축된 고장모델과 유클리디언 거리기반 오차값을 계산한

결과, D1과는 1.4087, D2와는 1.4113, T1은 1.3617, T2는 0.2553, T3는 1.3305로 나타나 오차값이 가장 작은 T2로 진행방향을 결정하였다. 따라서 제안된 기법은 이러한 열화진행정도가 정량적인 값을 제시함으로써 보다 정밀한 정보를 사용자에게 제공할 수 있음을 확인할 수 있다.

그림 8에서는 열화진행 정도가 0.5[%] 이하인 정상 데이터의 가스 성분값을 나타냈다. 그림 8에서 보는 바와 같이 각각의 가스 성분값의 크기가 매우 작아 열화가 거의 진행되지 않음을 확인할 수 있었다.

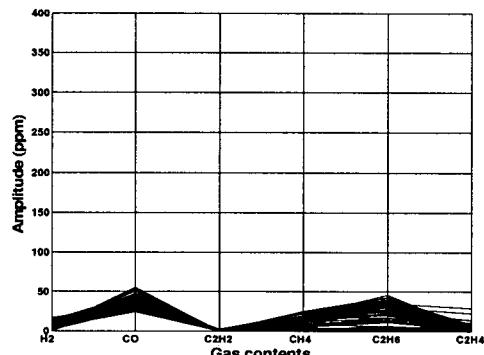


그림 8. 열화진행정도 0.5(%) 이하인 정상 데이터
Fig. 8. Normal data below 0.5(%) aging degree

4. 결 론

국내 전력용 변압기 진단방법으로 KEPCO의 판정기준에 의해 변압기의 정상/요주의를 판정한 후, 요주의로 판정될 경우 IEC 코드법에 근거하여 고장원인을 판단한다. 그러나 KEPCO 규정은 주요가스 성분의 양과 기준값과 비교하는 이분법적인 판단을 하고 있어 이분법 자체가 지니고 있는 특성에 의해 오판을 할 확률이 높다. 또한 고장원인 분석을 위해 사용되는 IEC 코드법은 가스비율이 규정치에 존재하지 않거나 경계조건에 있는 경우 전문가에게 의뢰하지 않고는 해석에 어려움이 있다는 단점이 있다.

이러한 문제점을 해결하기 위하여 본 연구에서는 SOM을 이용한 전력용 변압기의 고장진단 기법을 제안하였다. 제안한 방법은 KEPCO 규정에 의해 입력데이터가 요주의로 판정된 경우 자기학습에 의해 구성된 SOM에 의해 고장원인을 판정하였다. 또한

입력데이터가 KEPCO 규정에 의해 정상으로 판정된 경우 FCM에 의해 구축된 고장모델과 정상데이터간의 거리 척도를 이용하여 잠재적 열화추이를 분석하였다. 제안된 방법의 타당성을 보이기 위해 실험한 결과 기존 방법에 비하여 향상된 진단 결과를 볼 수 있었다.

이 논문은 2005년 정부(교육인적자원부)의 재원으로 학술진흥재단의 지원을 받아 수행된 연구임.
(KRF-2005-041-D00293)

References

- (1) Pyeong Shik Ji,Jae Yoon Lim; Jong Pil Lee, "Aging characteristics of power transformer oil and development of its analysis using KSOM," TENCON 99, Proceedings of the IEEE Region, vol. 2,pp. 1026- 029, Sept. 1999.
- (2) H. Tsukioka, K. Sugawara, E. Mori and H. Yamaguchi, "New apparatus for detecting transformer faults," IEEE Trans.Electrical Insulation, vol. EI-21, no. 2, pp. 221-229, 1986.
- (3) M. Duval, "Dissolved gas analysis : It can save your transformer," IEEE Electrical Insulation Magazine, vol. 5, no. 6, pp. 22-26, 1989.
- (4) H. Yoshida, Y. Ishioka, T. Suzuki, T. Yanariand T. Teranishi, "Degradation of insulating materials of transformers," IEEE Trans. Electrical Insulation, vol. EI-22, No. 6, pp. 795-800, 1987.
- (5) Y. Kamata, "Diagnostic methods for power transformer insulation," IEEE Trans.Electrical Insulation, vol EI-21, no.6, pp.1045-1048, 1986.
- (6) 문종필, 김재철, 임태훈, "실리콘 유입변압기 진단을 위한 전문가 시스템", 한국조명전기설비학회 논문집, Vol. 18, No. 1, pp. 55-61, 2004.
- (7) IEC Publication 60599, "Mineral oil-impregnated electrical equipment in service" March 1999.
- (8) Adriana R.C., Vladimiro Miranda, "Knowledge Discovery in Nerual Networks with Application to Transformer Failure Diagnosis", IEEE trans. Power Systems, VOL. 20, NO. 2, pp.717-724, 2005.

- (9) LiMin Fu, Neural Network in computer Intelligence, McGraw-Hill, pp. 48-55, 1994.
- (10) Xuegong Zhang, Yanda Li, "Self- Organizing Map As a New Method for Clustering and Data Analysis", Proceedings of International Joint conference on Neural Network, pp.2448-2451, 1993.
- (11) J.P. Lee etal, "Aging Characteristics Power Transformer Oil and Development of It's Analysis Using KSOM", ICEE'98, Vol. II, Kyongju Korea, pp.461-464, 1998.
- (12) Bezdek, J.C., Pattern Recognition with Fuzzy Objective Function Algorithms, Plenum Press, New York, 1981.

◇ 저자소개 ◇

임재윤 (林裁尹)

1961년 8월 4일생. 1984년 충북대학교 공대 전기공학과 졸업. 1986년 동대학원 전기공학과 졸업(석사). 1995년 흥의대학교 대학원 전기공학과 졸업(박사). 1999~2000년 미국 Texas A&M 대학 방문교수. 2006년 ~ 2007 캐나다 Victoria 대학 방문교수. 1991년~현재 대덕대학 전기과 교수.

이대종 (李大鍾)

1969년 2월 25일생. 1995년 충북대학교 공대 전기공학과 졸업. 1997년 동대학원 전기공학과 졸업(석사). 2002년 동대학원 전기공학과 졸업(박사). 2004~2005년 캐나다 일바타대학교 박사 후 연수. 2006년~현재 충북대학교 BK21정보기술사업단 초빙 조교수.

이종필 (李鍾弼)

1970년 12월 14일생. 1996년 충북대학교 공대 전기공학과 졸업. 1999년 동대학원 전기공학과 졸업(석사). 2003년~현재 동대학원 박사과정.

지평식 (池平植)

1964년 3월 5일생. 1989년 한밭대학교 전기공학과 졸업. 1994년 충북대학교 대학원 전기공학과 졸업(석사). 1998년 동 대학원 전기공학과 졸업(박사). 2000~2003년 충주대학교 BK21사업단 계약교수. 2003년~현재 충주대학교 전기공학과 교수.