

ELM 기반의 지능형 알고리즘과 퍼지 소속함수를 이용한 유입변압기 고장진단 기법

Diagnosis Method for Power Transformer using Intelligent Algorithm based on ELM and Fuzzy Membership Function

임재윤^{*} · 이대종^{*} · 지평식^{*}
(Jae-Yoon Lim · Dae-Jong Lee · Pyeong-Shik Ji)

Abstract - Power transformers are an important factor for power transmission and cause fatal losses if faults occur. Various diagnostic methods have been applied to predict the failure and to identify the cause of the failure. Typical diagnostic methods include the IEC diagnostic method, the Duval diagnostic method, the Rogers diagnostic method, and the Doernenburg diagnostic method using the ratio of the main gas. However, each diagnostic method has a disadvantage in that it can't diagnose the state of the power transformer unless the gas ratio is within the defined range. In order to solve these problems, we propose a diagnosis method using ELM based intelligent algorithm and fuzzy membership function. The final diagnosis is performed by multiplying the result of diagnosis in the four diagnostic methods (IEC, Duval, Rogers, and Doernenburg) by the fuzzy membership values. To show its effectiveness, the proposed fault diagnostic system has been intensively tested with the dissolved gases acquired from various power transformers

Key Words : Fault diagnosis, Power transformer, Fuzzy membership, ELM(Extrem Learning Machine)

1. 서 론

전력수요의 증가에 따라 변전 설비는 지속적으로 확장되고 있으며 그에 따라서 전력 설비의 복잡성이 증가되고 있다. 전력수요의 증가와 더불어 전력 사용자는 고품질의 전력 시스템을 필요로 한다. 그러나 일부 시설은 노후화가 급속히 진행되어 예기치 않은 고장이 발생하게 되어 치명적 손실을 초래한다. 따라서 전력 시스템의 상태를 모니터링하여 갑작스러운 오류를 방지하는 것은 매우 중요하다.

다양한 전력 시설 중에서 전력 변압기는 송전 및 배전 시스템에서 중요한 역할을 한다. 현재, 용존 가스 분석 (DGA) 이 변압기를 진단하는 가장 효과적이고 편리한 방법임이 증명되었다[1-4]. 정상 상태에서 절연유 및 유기 절연물은 점차적인 분해 및 분해로 인한 소량의 가스를 발생시킨다. 용존 가스 분석법은 특정 가스 농도의 비율을 고려하여 결함을 식별하며, 진단방법으로는 IEC 진단법, Duval 진단법, Roger 진단법, Doerenburgburg 진단법 등 다양한 방법이 있다. 용존 가스 분석법은 변압기의 초기 결함을 감지하는 간단하고 저렴하며 방법이지만, 용해된 가스에 대한 데이터

에 많은 불확실성이 존재할 때 정확한 결함 조건을 결정할 수 없다. 예를 들어, 정상 상태의 특수 가스의 양은 변압기의 크기, 오일의 부피, 변압기의 유형 등과 같은 변압기의 특성에 따라 달라질 수 있다. 또한 각각의 진단방법마다 진단기준이 상이하며, 현재까지도 유입변압기 진단에 정확한 진단을 제시하는 기준은 없는 상태이다[5].

최근에, 전력 변압기에서 고장 유형을 결정하기 위해 하이브리드 모델 또는 조합 모델이 도입되었다[6-9]. 하이브리드 모델은 IEC, Rogers, Duval 및 다층 신경회로망을 결합하는 융합 방식을 사용한다. 일반적으로 유입변압기 고장진단을 위해서 다층 신경망이 널리 사용된다. 그러나 다층 신경회로망은 일반적으로 좋은 성능을 얻기 위해 많은 반복 학습을 필요로 하며, 적절하지 못한 학습에 의하여 낮은 적응성을 보이거나 종종 국부 최소해에 수렴하는 단점을 가지고 있다. 본 논문에서 적용한 ELM은 반복학습을 하지 않기 때문에 전형적인 반복 학습 방법들에 비하여 매우 빠른 학습이 가능하고, 학습 오차값이 작은 장점이 있다. 또한 퍼지 소속함수를 이용하여 서로 다른 진단방법을 특성에 맞게 소속도를 부여함으로써 융합이 효과적으로 수행되도록 구현하였다. 본 논문에서 제안된 방법은 지능형 모델의 학습을 위해 각각의 진단기준에 맞는 데이터를 생성한 후 퍼지 클러스터링을 이용하여 대표 데이터를 선택하였다. 다음단계로 선택된 대표 데이터를 이용하여 ELM 학습알고리즘을 이용하여 모델학습이 진행된다. 최종 단계에서는 퍼지 소속함수를 이용하여 각각의 진단방법에 의해 산출된 소속도 값들을 합산한 후 합산된 값들 중에서 가장 큰 값을 갖는 고장을 선택하여 진단이 이루어진다.

[†] Corresponding Author : Dept. of Electrical and Electronic Engineering, Daeduk University, Daejeon, Korea
E-mail : jyylim@ddu.ac.kr

^{*} Dept. of Electrical Engineering, Korea National University of Transportation, Korea
접수일자 : 2017년 10월 23일
최종완료 : 2017년 11월 13일

2. 용존가스 분석법을 이용한 유입변압기 진단방법

2.1 IEC 60599 진단 기준

표 1에서는 IEC 60599 진단기준을 나타냈다. IEC 진단기준은 표 1에 나타낸 바와 같이 6가지의 고장을 두 가스의 비율에 의해 결정한다. 본 논문에서는 다양한 진단기준을 융합하고자 하며, 이를 위해서는 각각의 진단기준의 공통요소로 분류하여 진단이 이루어져야 한다. 따라서 6가지의 고장으로 세분화하지 않고, 부분방전(PD), 방전(D), 과열(T)로 구분하여 진단을 수행한다.

표 1 IEC 60599 진단기준

Table 1 IEC 60599 standard

Case	Characteristic fault	C ₂ H ₂ /C ₂ H ₄	CH ₄ /H ₂	C ₂ H ₄ /C ₂ H ₆
PD	Partial discharge	NS	<0.1	<0.2
D	Low energy discharge	>1	0.1-0.5	>1
	High energy discharge	0.6-2.5	0.1-1	>2
T	Thermal fault (t<300℃)	NS	NS	<1
	Thermal fault(300℃<t<700℃)	<0.1	>1	1-4
	Thermal fault(t>700℃)	<0.2	>1	>4

2.2 Rogers 진단 기준

표 2에서는 Rogers 진단기준을 나타냈다. 표 2에 나타낸 바와 같이 5가지의 고장진단을 수행한다. 그러나 본 연구에서는 서로 다른 상이한 진단기준을 융합하기 위하여 공통요소인 부분방전(PD), 방전(D), 과열(T)로 구분하여 진단을 수행한다.

표 2 Rogers 진단기준

Table 2 Rogers standard

Case	Characteristic fault	C ₂ H ₂ /C ₂ H ₄	CH ₄ /H ₂	C ₂ H ₄ /C ₂ H ₆
PD	Partial discharge	<0.1	<0.1	<1.0
D	Electric arc	0.1-3.0	0.1-1.0	>3.0
T	Thermal fault	<0.1	>0.1,<1.0	1.0-3.0
	Thermal fault (<700℃)	<0.1	>1.0	1.0-3.0
	Thermal fault (>700℃)	<0.1	>1.0	>3.0

2.3 Duval 진단 기준

그림 1에 나타낸 바와 같이 Duval 진단기준은 메탄(CH₄), 에틸렌(C₂H₄), 아세틸렌(C₂H₂)의 세 가지의 백분율 성분비를 계산한 후 삼각법에 의해 진단이 이루어진다. Duval 진단기준은 각 영역마다 기호가 표시되어 있다. PD는 부분방전, T1은 저온과열(<300℃), T2는 중온과열(≤300℃, <700℃), T3는 고온과열(>700℃), D1은 저에너지 방전(스파크), D2는 고에너지방전(아크), DT는 열적 및 전기적 고장 모두 발생한 고장을 의미한다. 본 연구에서는 각각의 진단방법의 공통

요소인 PD로 표현된 부분방전(PD), D로 표현된 방전 (D1과 D2), T로 표현된 과열(T1, T2, T3)로 구분하여 진단을 수행한다. Duval 진단 기준을 적용하기 위해서는 아래 식과 같이 세 가지의 백분율 성분비를 계산한다.

$$\%CH_4 = \frac{CH_4}{CH_4 + C_2H_2 + C_2H_4} \times 100 \quad (1)$$

$$\%C_2H_2 = \frac{C_2H_2}{CH_4 + C_2H_2 + C_2H_4} \times 100 \quad (2)$$

$$\%C_2H_4 = \frac{C_2H_4}{CH_4 + C_2H_2 + C_2H_4} \times 100 \quad (3)$$




그림 1 Duval 진단기준

Fig. 1 Duval standard

2.4 Doernenburg 진단 기준

Doernenburg 진단기준은 표 3에 나타낸 바와 같이 유입변압기를 T(열적고장), PD(부분방전), D(방전)으로 분류한다. 다른 기준과 달리 Doernenburg 진단기준은 고장의 분류가 세 가지로 적고, 가스의 조성비도 네 가지 비율을 이용한다.

표 3 Doernenburg 진단기준

Table 3 Doernenburg standard

Case	Characteristic fault	CH ₄ /C ₂ H ₄	C ₂ H ₂ /C ₂ H ₄	C ₂ H ₂ /CH ₄	C ₂ H ₆ /C ₂ H ₂
T	Thermal fault	>0.1	<0.75	<0.3	>0.4
PD	Partial discharge	<0.1	NS	<0.3	>0.4
D	Electric arc	>0.1, <1.0	>0.75	>0.3	<0.4

3. 지능형 알고리즘과 퍼지 융합규칙을 이용한 유입변압기 진단기법

3.1 알고리즘 구성도

그림 2에서는 본 논문에서 제안한 지능형 알고리즘과 퍼지 융합규칙을 이용한 유입변압기 진단기법의 구성도를 나타냈다. 그림 2에 나타낸 바와 같이 각각의 진단기준 표를

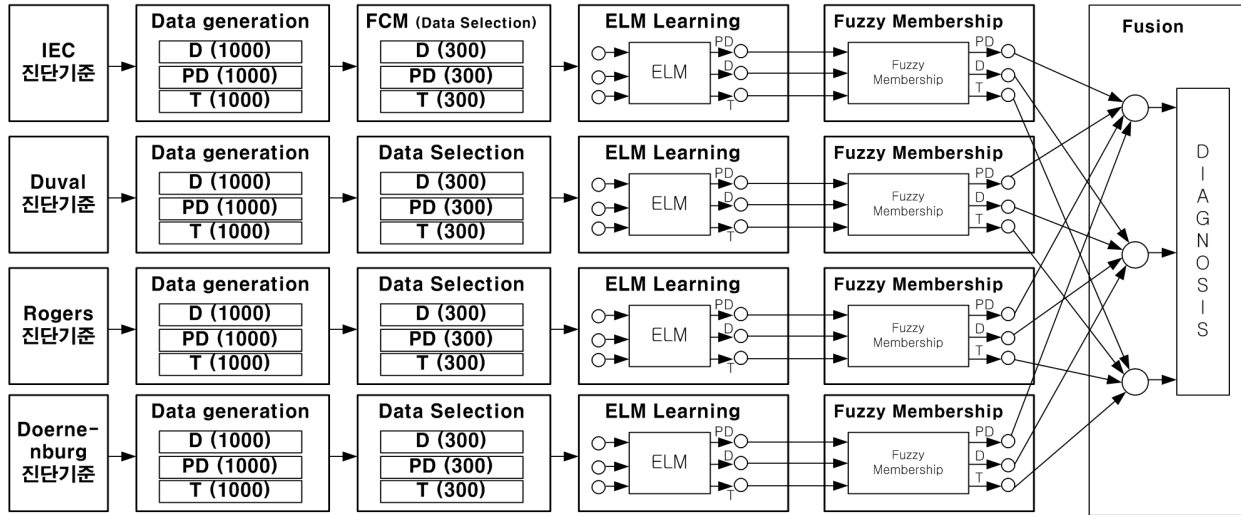


그림 2 지능형 알고리즘과 퍼지 소속함수를 이용한 유입변압기 진단기법

Fig. 2 Diagnosis method using ELM based intelligent algorithm and fuzzy membership function

이용하여 고장범위에 해당되는 데이터를 각각 1000개씩 랜덤하게 발생시킨다. 다음 단계로 퍼지 클러스터링기법인 FCM을 이용하여 각각의 고장을 대표할 수 있는 대표 데이터를 선택한다. 선택된 데이터를 이용하여 계산속도가 매우 우수한 ELM 알고리즘을 이용하여 학습이 이루어진다. 학습이 이루어진 후 퍼지 소속함수를 이용하여 소속도가 높을수록 큰 값을 갖도록 하였. 최종 단계에서는 각각의 진단방법에 의해 산출된 소속도 값들을 합산한 후 합산된 값들 중에서 가장 큰 값을 갖는 고장을 선택하여 진단이 이루어진다.

3.2 퍼지 클러스터링 알고리즘

클러스터링의 목적은 주어진 데이터로부터 유사한 클러스터들을 나누는 것이다. Bezdek에 의해 제안된 FCM(Fuzzy C-Means) 클러스터링은 목적함수를 최소화하도록 하는 반복적인 알고리즘으로서 주어진 데이터로부터 유사한 클러스터를 나누며 생성된 클러스터는 시스템의 특성적인 동작을 기술하는 규칙으로서 사용되어진다[10].

FCM 알고리즘을 단계별로 간략히 설명하면 다음과 같다.

[단계 1] 취득하고자 하는 대표점의 수 즉, 클러스터의 개수 $c(2 \leq c \leq n)$ 를 정하고, 초기 분할행렬 $U^{(0)}$ 를 초기화한다. 분할행렬에 할당될 소속정도의 값 u_{ik} 는 식 (4)를 만족한다.

$$u_{ik} = u_{A_i}(x_k) \in [0, 1] \tag{4}$$

여기서, $i = 1, 2, \dots, c$ 로 클러스터의 개수를 의미한다.

[단계 2] 데이터 \mathbf{x} 와 초기 분할행렬값 $U^{(0)}$ 를 이용하여 대표 특징의 중심 $v_{ij}^{(r)}$ 을 계산하면 식 (5)와 같다.

$$v_{ij}^{(r)} = \frac{\sum_{k=1}^n u_{ik}^m \cdot x_{kj}}{\sum_{k=1}^n u_{ik}^m} \tag{5}$$

여기서, m 은 퍼지화 정도를 나타내는 퍼지 수로써 일반적으로 2를 이용한다.

[단계 3] [단계 2]에서 계산된 대표 특징들의 중심값과 데이터 \mathbf{x} 와의 거리값 d 에 의하여 분할행렬 $U^{(r)}$ 를 식 (6)과 같이 갱신한다.

$$u_{ik}^{(r+1)} = \left[\sum_{j=1}^c \left(\frac{d_{ik}^{(r)}}{d_{jk}^{(r)}} \right)^{2/(m-1)} \right]^{-1} \tag{6}$$

여기서, d_{jk} 는 p 차원을 갖는 j 번째 데이터 x_j 와 k 번째 대표 중심값 v_k 와의 유클리디안 거리값을 의미한다.

[단계 4] 식 (7)와 같이 목적함수를 계산한 후, 계산된 값과 이전에 계산된 값의 차이가 설정된 값 이내이면 알고리즘을 종료하고 그렇지 않으면 [단계 2]로 가서 반복 수행한다.

$$J(U, c_1, c_2, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n \sum_{k=1}^m u_{ij}^m d_{ij}^2 \tag{7}$$

7

3.3 ELM 기반의 지능형 알고리즘

ELM은 단일 은닉층을 가지는 전방향 네트워크로 Huang[11]등에 의하여 제안되었다. ELM에서 출력 가중치들은 반복적인 학습 구조 대신에 역행렬에 단 한번의 계산으로 학습이 이루어지므로 계산속도가 매우 빠른 특징이 있다. ELM에 의한 학습과정을 살펴보면 다음과 같다.

m 개의 데이터 $\{(\mathbf{x}_i, y_i), i = 1, 2, \dots, m\}$ 와 한개의 출력노드를

가지고 N 개의 은닉노드들을 가지는 전방향 신경 회로망의 학습을 고려해보자. 여기서, 입력 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ 이고, $y_i \in R$ 이며, N 개의 은닉노드들의 활성화 함수 $g(x)$ 에 의한 전방향 신경 회로망의 출력은 다음과 같이 나타낼 수 있다.

$$\mathbf{g}(\mathbf{w}_j \cdot \mathbf{x}_i) \cdot \mathbf{a} = y_i, \quad i = 1, 2, \dots, m \quad (8)$$

여기서, $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T, j = 1, 2, \dots, N$ 은 j 번째 은닉노드와 입력노드들을 연결하는 가중치 벡터로 임의의 값으로 초기화 되며, $\mathbf{a} = [a_1, a_2, \dots, a_N]^T$ 는 은닉노드들과 출력노드를 연결하는 가중치 벡터이다. $\mathbf{w}_j \cdot \mathbf{x}_i$ 는 \mathbf{w}_j 와 \mathbf{x}_i 의 내적을 의미한다.

식 (8)은 다음과 같이 간결하게 표현될 수 있다.

$$\mathbf{G}\mathbf{a} = \mathbf{y} \quad (9)$$

\mathbf{G} 는 전방향 신경 회로망에서 은닉층의 출력으로 \mathbf{G} 의 i 번째 열은 입력 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m$ 과 관련된 i 번째 은닉노드들의 출력 벡터이다. 최종적으로, 식 (10)과 같이 최소자승법에 의하여 출력 가중치 $\hat{\mathbf{a}}$ 을 구한다. 식 (10)에서 \mathbf{G}^\dagger 는 식 (11)과 같다.

$$\hat{\mathbf{a}} = \mathbf{G}^\dagger \mathbf{y} \quad (10)$$

$$\mathbf{G}^\dagger = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T \quad (11)$$

최종 출력값은 다음과 같이 얻어진다.

$$\hat{\mathbf{y}} = \mathbf{G}\hat{\mathbf{a}} \quad (12)$$

3.4 퍼지 멤버함수를 이용한 소속도 계산

보통집합은 전체집합 X 내의 원소 x 에 대해 0 또는 1이라는 명백한 값을 가지는 반면, 퍼지 집합은 집합에 속하는 원소에 대해 소속정도로 표현된다. 그러므로, 퍼지 집합의 특성함수는 주어진 집합에서 0과 1사이의 값으로 소속도를 표현한다. 전체 집합 X 에서 퍼지 집합 A 는 식 (13)과 같은 순서된 쌍의 집합으로서 정의된다[10].

$$A = \{(x, \mu_A(x)) | x \in X\} \quad (13)$$

여기서 $\mu_A(x)$ 는 A 에서 x 의 소속도라고 하며, 이것은 X 에서 소속공간 $M(M=[0, 1])$ 으로 사상된다. 다양한 퍼지 소속함수가 존재하지만 본 논문에서는 식 (14)로 표현된 가우시안 소속함수를 사용하였다. 식 (14)로 표현된 가우시안 소속함수는 두 파라미터인 $\{c, \sigma\}$ 에 의해 소속도가 결정된다.

$$\text{gaussian}(x; c, \sigma) = e^{-\frac{1}{2} \left(\frac{x-c}{\sigma} \right)^2} \quad (14)$$

식 (14)에서 보는 바와 같이 가우시안 소속함수는 중심인

c 와 소속함수의 폭인 σ 에 의해 결정되어진다. 즉, 그림 3에 나타난 바와 같이 표준편차가 작을수록 데이터가 중심 근처에 대부분 분포되고 있고, 표준편차가 클수록 데이터의 분포도가 널리 퍼져있음을 알 수 있다. ELM 학습모델은 해당되는 고장 데이터가 입력되면 분류하고자 하는 고장에 해당하는 출력값이 1이 되도록 학습되므로 1에 근접할수록 소속도가 높다. 따라서 중심은 1로 설정하였고, 표준편차인 σ 는 다양한 실험에 의해 결정하였다. 그림 3에서는 중심이 1일 때 표준편차에 의해서 소속도가 다르게 계산됨을 나타냈다.

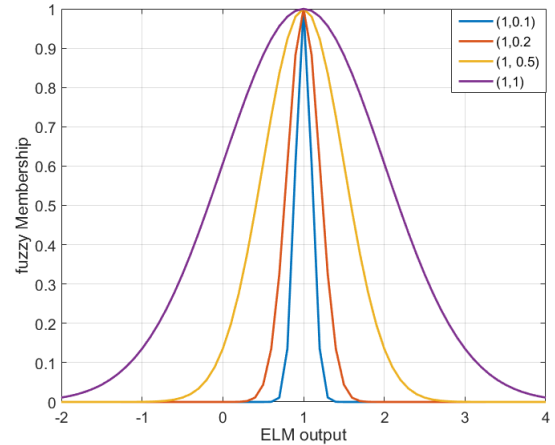


그림 3 표준편차에 따른 가우시안 소속함수
Fig. 3 Gaussian membership function according to standard deviation

4. 실험 결과

제안된 방법의 타당성을 검증하기 위하여 대표적인 고장 DB인 IEC TC 10 DB[12] 뿐만 아니라 다양한 논문에서 사용된 DB[13-16]를 이용하였다. 데이터의 구성은 부분방전 데이터는 19개, 방전 데이터의 개수는 125개, 온도 과열 데이터의 개수는 107개로 총 251개의 데이터를 이용하였다.

표 4에서는 IEC 기준에 의한 진단결과를 나타냈다. 표 4에서 보는 바와 같이 19개의 부분방전(PD) 데이터 중에서 4개만을 부분방전(PD)으로 진단하여 21.1[%] 진단 성능을 보였다. 125개의 방전(D) 데이터에 대해서는 89개를 방전으로 진단하여 71.2[%]의 진단 성능을 보였다. 107개로 구성된 열적고장 데이터에 대해서는 80개를 열적고장으로 진단하여 74.8[%]의 진단 성능을 보였다.

표 5에서는 Duval 기준에 의한 진단결과를 나타냈다. 표 5에서 보는 바와 같이 19개의 부분방전(PD) 데이터 중에서 9개의 샘플을 부분방전(PD)으로 진단하여 47.4[%] 진단 성능을 보였다. 125개의 방전(D) 데이터에 대해서는 117개를 방전으로 진단하여 93.6[%]의 진단 성능을 보였다. 107개로 구성된 열적고장 데이터에 대해서는 101개를 열적고장으로 진단하여 94.4[%]의 진단 성능을 보였다.

표 6에서는 Rogers 기준에 의한 진단결과를 나타냈다. 표 6에서 보는 바와 같이 19개의 부분방전(PD) 데이터 중에서 5개의 샘플을 부분방전(PD)으로 진단하여 26.3[%] 진단 성능을 보였다. 125개의 방전(D) 데이터에 대해서는 72개를

방전으로 진단하여 57.6[%]의 진단 성능을 보였다. 107개로 구성된 열적고장 데이터에 대해서는 80개를 열적고장으로 진단하여 74.8[%]의 진단 성능을 보였다.

표 7에서는 Doernenburg 기준에 의한 진단결과를 나타냈다. 표 7에서 보는 바와 같이 19개의 부분방전(PD) 데이터 중에서 5개의 샘플을 부분방전(PD)으로 진단하여 26.3[%] 진단 성능을 보였다. 125개의 방전(D) 데이터에 대해서는 88개를 방전으로 진단하여 70.4[%]의 진단 성능을 보였다. 107개로 구성된 열적고장 데이터에 대해서는 103개를 열적고장으로 진단하여 96.3[%]의 진단 성능을 보였다.

표 8에서는 제안된 ELM 기반의 지능형 알고리즘과 퍼지 융합 규칙에 의한 진단결과를 나타냈다. 제안된 방법에서 FCM의 개수는 각각 300개로 설정하였고, 은닉층의 수는 다양한 실험을 통하여 결정하였다. 표 8에서 보는 바와 같이 19개의 부분방전(PD) 데이터 중에서 13개의 샘플을 부분방전(PD)으로 진단하여 68.4[%] 진단 성능을 보였다. 125개의 방전(D) 데이터에 대해서는 118개를 방전으로 진단하여 94.4[%]의 진단 성능을 보였다. 107개로 구성된 열적고장 데이터에 대해서는 103개를 열적고장으로 진단하여 96.3[%]의 진단 성능을 보였다.

그림 4에서는 진단기준에 따른 유입변압기 진단 결과를 나타냈다. 그림 4에서 보는 바와 같이 IEC 진단기준은 68.9[%]의 진단 성능을 보였다. Duval 진단기준은 90.4[%], Rogers 진단기준은 62.5[%], Doernenburg 진단기준은 78.1[%]의 진단 성능을 보였다. 제안된 방법을 적용하였을 때 진단성능은 93.2[%]을 나타내 기존의 진단방법 중에서 가장 우수한 Duval 진단기준에 비하여 2.8[%]의 성능 향상을 보였다.

표 4 IEC 기준에 의한 진단결과

Table 4 Diagnosis results by IEC standard

Case	PD	D	T	ND	Diagnosis
PD(19)	4	1	0	12	21.1%
D(125)	0	89	0	36	71.2%
T(107)	1	0	80	26	74.8%

표 5 Duval 기준에 의한 진단결과

Table 5 Diagnosis results by Duval standard

Case	PD	D	T	ND	Diagnosis
PD(19)	9	3	5	2	47.4%
D(125)	0	117	6	2	93.6%
T(107)	2	0	101	4	94.4%

표 6 Rogers 기준에 의한 진단결과

Table 6 Diagnosis results by Rogers standard

Case	PD	D	T	ND	Diagnosis
PD(19)	5	1	1	12	26.3%
D(125)	2	72	1	50	57.6%
T(107)	1	1	80	25	74.8%

표 7 Doernenburg 기준에 의한 진단결과

Table 7 Diagnosis results by Doernenburg standard

Case	PD	D	T	ND	Diagnosis
PD(19)	5	1	3	10	26.3%
D(125)	4	88	3	30	70.4%
T(107)	2	0	103	2	96.3%

표 8 제안된 방법에 의한 진단결과

Table 8 Diagnosis results by proposed method

Case	PD	D	T	ND	Diagnosis
PD(19)	13	3	3	0	68.4%
D(125)	4	118	3	0	94.4%
T(107)	2	2	103	0	96.3%

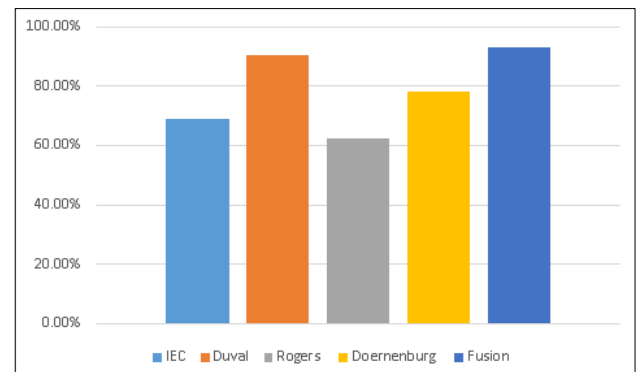


그림 4 진단기준에 따른 유입변압기 진단 성능 비교

Fig. 4 Comparison of diagnosis performance for power transformer according to each diagnosis method

5. 결 론

본 논문에서는 ELM 기반의 지능형 알고리즘과 퍼지 융합규칙을 이용한 유입변압기 진단방법을 제안하였다. 제안된 방법은 퍼지 클러스터링 기법에 의해 선택된 대표적인 데이터를 이용하여 ELM 지능형 알고리즘을 학습한 후, 퍼지 소속함수를 이용하여 출력결과에 대한 소속도를 계산하였다. 최종적으로 각각의 진단기준에 의해 계산된 소속도를 고려하여 최종 진단이 이루어진다. 제안된 방법의 타당성을 검증하기 위하여 다양한 데이터를 이용하여 실험한 결과 기존의 진단방법에 비하여 향상된 진단 성능을 보였다. 향후 다양한 데이터를 이용하여 제안된 방법의 타당성을 지속적으로 비교자 한다.

감사의 글

이 논문은 한국전력공사의 재원으로 기초전력연구원의 2015년 선정 기초연구개발과제의 지원을 받아 수행된 것임(과제번호 : R15XA03-42).

References

- [1] 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.
- [2] M. Duval, "Dissolved gas analysis : It can save your transformer," *IEEE Electrical Insulation Magazine*, vol. 5, no. 6, pp. 22-26, 1989.
- [3] 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
- [4] Y. Kamata, "Diagnostic methods for power transformer insulation," *IEEE Trans. Electrical Insulation*, vol. EI-21, no. 6, pp. 1045-1048, 1986.
- [5] Jae-Yoon Lim, Dae-Jong Lee, Pyeong-Shik Ji, "Fault Diagnosis of Oil-filled Power Transformer using DGA and Intelligent Probability Model," *The Transactions of the Korean Institute of Electrical Engineers*, vol. 65P, no. 3, pp. 188-193, 2016.
- [6] Karel Octavianus, Bambang Anggoro, Adang Suwandi Ahmad, "Power transformer condition monitoring and performance calculation method based on information fusion," *2015 International Conference on Quality in Research (QiR)*, pp. 163-166. 2015.
- [7] Yang Xu, Tianxi Xie, Zhicheng Zhou, Yuncai Lu, Jia Jun, Chen Shu, Jiansheng Li, Yong Ma, Chao Jiang, "Research of practical expert system for transformer fault diagnosis based on multidimensional data fusion," *2016 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, pp. 300-304, 2016.
- [8] H. Hooshmand, M. Parastegrai, Z. Forghani, "Adaptive Neuro-Fuzzy Inference System Approach for Simultaneous Diagnosis of the Type and Location of Faults in Power Transformers," *IEEE Electrical Insulation Magazine*, vol. 28, no. 5, pp. 32-42, 2012.
- [9] S. Souahlia, K. Bacha, A. Chaari, "MLP neural network-based decision for power transformers fault diagnosis using an improved combination of Rogers and Doernenburg ratios DGA," *International Journal of Electrical Power & Energy Systems*, vol. 43, no. 1, pp. 1346-1353, 2012.
- [10] J. C. Bezdek, *Pattern recognition with fuzzy objective function algorithms*, Plenum Press, New York, 1981.
- [11] G. B. Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: a new learning scheme of feedforward neural networks," in *Proc. 2004 IEEE Int. Conf. Neural Networks*, vol. 2, pp. 985-990, 2004.
- [12] Michel Duval, Alfonso DePablo, "Interpretation of Gas-In-Oil Analysis Using New IEC Publication 60599 and IEC TC 10 Databases," *IEEE Electrical Insulation Magazine*, vol. 17, no. 2, pp. 31-41, 2001.
- [13] Chin-Pao Hung, Mang-Hui Wang, "Diagnosis of incipient faults in power transformers using CMAC neural network approach," *Electrical Power Systems Research*, vol. 71, pp. 235-244, 2004.
- [14] Ganyun Lv, Haozhong Cheng, Haibao Zhai, Lixin Dong, "Fault diagnosis of power transformer based on multi-layer SVM classifier," *Electrical Power Systems Research*, vol. 74, pp. 1-7, 2005.
- [15] ZHANG Shen, MIAO Chang-xin, LI Jing-meng, "Improved BP Neural Network for Transformer Fault Diagnosis, SUN Yan-jing," *Journal of China Univ. of Mining & Technology*, vol. 17, no. 1, pp. 138-142, 2007.
- [16] D. V. S. S. Siva Sarma, G. N. S. Kalyani, "ANN Approach for condition monitoring of power transformess using DGA," *TENCON 2004. 2004 IEEE Region 10 Conference*, vol. 3, pp. 444-447, 2004.

저 자 소 개



임 재 윤(林 裁 尹)

1986년 충북대 대학원 전기공학과 졸업 (공학석사), 1995년 홍익대 대학원 전기공학과 졸업(공학박사), 1999~2000 Texas A&M Univ. Post Doc. 2006~2007 캐나다Victoria Univ. 방문교수, 현재 대덕대학교 교수

E-mail : jyylim@dpu.ac.kr



이 대 종(李 大 鍾)

1995년 충북대학교 전기공학과 졸업. 1997년 동 대학원 졸업(공학석사), 2002년 동 대학원 졸업(공학박사). 2006년~2008년 충북대학교 BK21충북정보기술사업단 초빙 조교수

E-mail : leebigbell@gmail.com



지 평 식(池 平 植)

1994년 충북대학교 대학원 전기공학과 석사과정 졸업(공학석사), 1998년 동대학원 박사과정 졸업(공학박사), 현재 한국교통대학교 전기공학과 교수

E-mail : psji@ut.ac.kr