

# 유입변압기 고장분류를 위한 PNN 기반 Rogers 진단기법 개발

## PNN based Rogers Diagnosis Method for Fault Classification of Oil-filled Power Transformer

임재윤<sup>†</sup> · 이대종<sup>\*</sup> · 지평식<sup>\*</sup>

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

**Abstract** - Stability and reliability of a power system in many respects depend on the condition of power transformers. Essential devices as power transformers are in a transmission and distribution system. Being one of the most expensive and important elements, a power transformer is a highly essential element, whose failures and damage may cause the outage of a power system. To detect the power transformer faults, dissolved gas analysis (DGA) is a widely-used method because of its high sensitivity to small amount of electrical faults. Among the various diagnosis methods, Rogers diagnosis method has been widely used in transformer in service. But this method cannot offer accurate diagnosis for all the faults. This paper proposes a fault diagnosis method of oil-filled power transformers using PNN(Probability Neural Network) based Rogers diagnosis method. The test result show better performance than conventional Rogers diagnosis method.

**Key Words** : Fault diagnosis, Power transformer, DGA(Dissolved Gas Analysis), Rogers, PNN(Probability Neural Network)

### 1. 서론

변압기는 안정적인 전력전송을 위한 필수 요소로서 한번 설치되면 최소 20년에서 최대 40년까지 오래기간 지속적으로 사용된다. 전력용 변압기의 갑작스런 고장은 가정에서의 불편함뿐만 아니라 상업 및 산업용 손실을 초래하므로 주기적 점검을 통해 상시 유입변압기의 상태를 진단해야한다. 유입변압기가 가동되면 변압기 내부에 다양한 가스들이 발생한다. 유중가스분석(DGA : Dissolved Gass Analysis)은 변압기의 초기 고장 상태를 진단하는데 널리 사용된다[1].

가장 널리 사용되는 방법은 발생 가스의 종류와 조성비를 이용하는 IEEE 표준 C57.104[2]와 IEC 60599 규격이다[3]. 변압기의 운전중에 발생하는 가스로는 수소(H<sub>2</sub>), 일산화탄소(CO), 이산화탄소(CO<sub>2</sub>), 질소(N<sub>2</sub>), 산소(O<sub>2</sub>), 메탄(CH<sub>4</sub>), 아세틸렌(C<sub>2</sub>H<sub>2</sub>), 에틸렌(C<sub>2</sub>H<sub>4</sub>), 에탄(C<sub>2</sub>H<sub>6</sub>) 등이 있다. 이러한 유중 가스 중에서 질소와 산소는 변압기의 고장에 의해 발생하는 가스로 고려하지 않는다[4]. 일반적으로 아크나 부분방전에 의해 나타나는 특징 가스는 수소(아크인 경우 수소 60%, 아세틸렌 30%, 부분방전인 경우 수소 85%, 메탄 13%)이며, 절연유 과열은 에틸렌(에틸렌 63%, 에탄 20%), 절연지 과열은 일산화탄소(일산화탄소 92%)가 특징 가스가

되는 것으로 보고되고 있다[5]. 전력용 변압기 내부에서 발생한 가스들이 증가할수록 변압기 내부의 전기적 또는 열적 고장을 초래할 가능성이 높다. 전기적 고장은 가스를 연소시키는 아크방전 또는 부분방전을 유발하고, 열적고장은 저온, 중온 또는 고온 고장을 초래한다. 변압기 내부의 고장의 형태는 절연부싱, 탭변환기, 케이블에 다양한 형태로 손상을 준다.

변압기의 갑작스런 고장은 전력전송 중단의 치명적 결과를 초리하므로, 사전에 유입변압기의 상태를 진단 및 고장원인을 분석하기 IEC, Duval, Rogers 진단기준 등 다양한 진단기법이 사용된다. 그러나 각각의 진단방법들은 가스 비율이 규정치에 존재하지 않을 때 유입변압기 상태를 진단할 수 없다는 단점이 있다. 이러한 문제점을 해결하기 위하여 지능형 알고리즘을 이용한 개선된 알고리즘이 개발되었다[6-8]. [6]번 논문에서는 확률신경회로망을 이용하여 개선된 지능형 IEC 진단방법을 개발하였다. 본 논문에서는 [6]번 논문에서 제안된 확률신경회로망을 Rogers 진단방법에 적용하여 Rogers 진단방법의 문제점인 판정불능영역에 대해서 효과적인 진단을 수행하는 방법을 제안한다.

### 2. 온도에 따른 가스 특성 및 Rogers 진단 기준

#### 2.1. 절연유 온도에 따른 가스 발생 패턴

유입변압기를 장시간 사용하게 되면 내부에 발생된 열에 의해 다양한 가스가 발생된다. 이러한 유중 가스는 그림 1에서 보는 바와 같이 온도에 따라 발생농도 및 종류가 다르고 발생패턴이 다르므로, 가스농도, 종류 및 발생패턴을 이용하여 변압기 상태 및 고장을 진단할 수 있다[9].

그림 1에서 알 수 있는 바와 같이 온도에 따른 발생가스

<sup>†</sup> Corresponding Author : Dept. of Computer Electronics  
Daeduk College, Daejeon, Korea  
E-mail : jyylim@ddc.ac.kr

<sup>\*</sup> Dept. of Electrical Engineering Korea National University  
of Transportation, Korea

접수일자 : 2016년 11월 1일

수정일자 : 2016년 11월 21일

최종완료 : 2016년 11월 23일

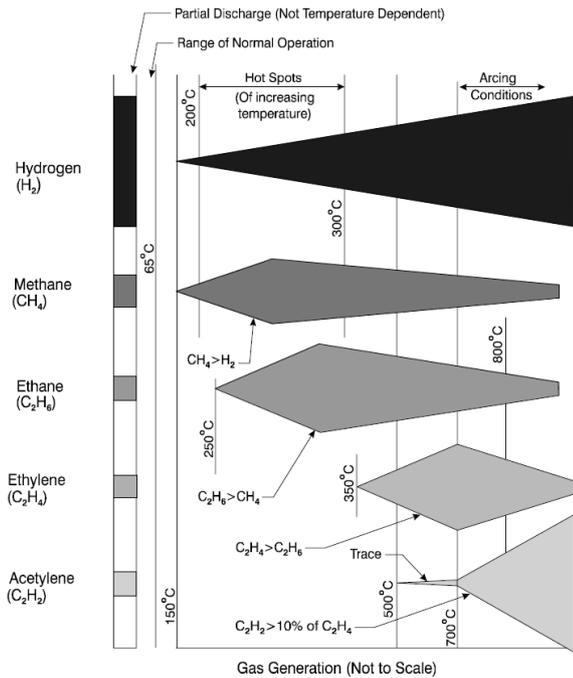


그림 1 절연유 온도에 따른 가스 발생 패턴  
 Fig. 1 Pattern of gas generation according to the temperature of insulation oil

의 양을 추정할 수 있다. 수소 가스는 150[°C]에서 적은 양이 발생되며, 온도가 증가할수록 비례하여 많은 양의 수소가스가 발생됨을 알 수 있다. 메탄가스는 150[°C]에서 적은 양이 발생되고, 에탄가스는 250[°C]에서 적은 양이 발생한다. 수소 가스와 달리 메탄가스와 에탄가스는 임계시점까지는 온도에 따라 발생량이 증가하다고, 그 이후에는 온도가 증가함에 따라 발생량이 적어짐을 알 수 있다. 에틸렌은 350[°C]에서 초기 발생되고, 아세틸렌은 500[°C]에서 700[°C] 사이에서 초기 발생한다. 과거에는 아세틸렌 가스가 존재했을 때만 온도가 최소 700[°C]인 것으로 판정하였으나, 최근에는 500[°C] 열적 고장에 의해서도 약간의 가스가 발생하는 것으로 보고되고 있다. 많은 아세틸렌가스의 발생은 내부 아크에 의해 700[°C] 이상의 열적고장임을 알 수 있다. 200[°C]에서 300[°C] 사이에서 메탄은 수소 발생량을 초과한다. 275[°C]에서부터 에탄 가스는 메탄가스 발생량을 초과한다. 대략 450[°C]에서 800[°C] 사이에서는 수소가스가 다른 가스들에 비해 발생량이 높으며, 그 이상의 온도에서는 아세틸렌의 발생량이 많음을 알 수 있다.

유압변압기가 정상상태일 때 적은 양의 수소, 메탄 및 일산화탄소가 발생한다. 유압변압기의 절연지의 열적 분해는 일산화탄소, 이산화탄소, 수소, 메탄 및 산소를 발생한다. 절연지의 분해는 대략 100[°C] 또는 그 이하에서 시작되므로 90[°C] 이하에서 유압변압기를 운용하여야 한다.

2.2. Rogers 진단 기준

표 1에 나타난 바와 같이 Rogers 진단기준은 유증가스중 수소(H<sub>2</sub>), 메탄(CH<sub>4</sub>), 에탄(C<sub>2</sub>H<sub>6</sub>), 에틸렌(C<sub>2</sub>H<sub>4</sub>), 아세틸렌(C<sub>2</sub>H<sub>2</sub>)의 5가지의 가연성가스 성분비를 이용한다. Rogers

진단기준을 살펴보면, C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>4</sub> 조성비가 0.1 이하이고, CH<sub>4</sub>/H<sub>2</sub> 조성비는 0.1 이하 또는 1 이상, C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub> 조성비는 1.0 미만일 때 정상으로 판정한다. C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>4</sub> 조성비가 0.1 이하이고, CH<sub>4</sub>/H<sub>2</sub> 조성비는 0.1 이하, C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub> 조성비는 1.0 미만일 때 저에너지 아킹(부분방전)으로 판정한다. C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>4</sub> 조성비가 0.1~3.0이고, CH<sub>4</sub>/H<sub>2</sub> 조성비는 0.1 이하 또는 1 이상, C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub> 조성비는 1.0~3.0 일 때 저온과열로 판정한다. C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>4</sub> 조성비가 0.1 이하이고, CH<sub>4</sub>/H<sub>2</sub> 조성비는 1.0 이하, C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub> 조성비는 1.0~3.0 일 때 중온과열로 판정한다. 중온과열 조건에서 C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub> 조성비가 3.0 초과일 때는 고온과열로 판정한다. 그림 2에서는 Rogers 진단기준의 가스 관계를 분석하여 나타냈다[10].

표 1 Rogers 진단기준  
 Table 1 Rogers diagnosis standard

Case	Characteristic fault	C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>	CH <sub>4</sub> /H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>
0	정상	<0.1	>0.1, <1.0	<1.0
1	저에너지아킹(부분방전)	<0.1	<0.1	<1.0
2	고에너지 아킹(방전)	0.1-3.0	0.1-1.0	>3.0
3	저온 과열	<0.1	>0.1, <1.0	1.0-3.0
4	중온과열 (<700°C)	<0.1	>1.0	1.0-3.0
5	고온과열 (>700°C)	<0.1	>1.0	>3.0

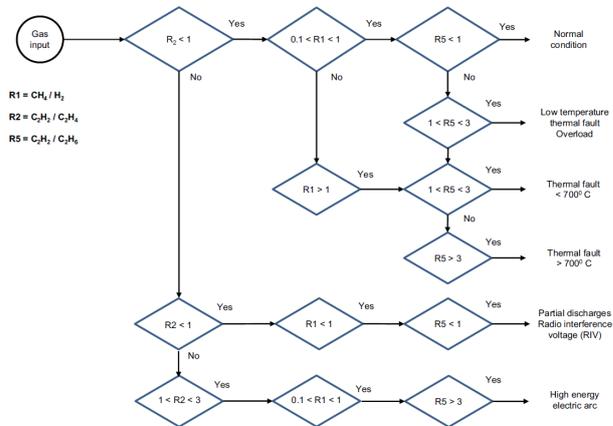


그림 2 Rogers 진단의 가스 관계 분석  
 Fig. 2 Gas relations analysis according to the method of Rogers

3. PNN 기반 Rogers 진단기법을 이용한 유압변압기의 고장분류 알고리즘

3.1 구성도

본 논문에서 제안된 알고리즘의 구성도는 그림 3과 같다. 그림 3에서 보는 바와 같이 C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>4</sub>, CH<sub>4</sub>/H<sub>2</sub>, C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub> 와 같은 세 가지 조성비를 이용하여 진단을 수행한다. 확률 신경회로망 학습을 위해 훈련 데이터와 검증 데이터를 사용한다. 여기서 훈련데이터는 확률신경회로망의 파라미터, 구

조 등을 수립하기 위해 사용되는 데이터이며, 검증 데이터는 미리 구축된 확률신경회로망의 성능을 평가하는데 사용된다. 본 논문에서는 표 1의 범위에 맞는 데이터를 고장 상태별로 1,000개를 생성한 후, 그림 3의 (a)에서 보는 바와 같이 FCM(fuzzy c-means) 군집화 알고리즘을 이용하여 대표점들을 선택한 후[6], 선택된 대표점들을 이용하여 확률신경회로망을 학습시켰다. 모든 데이터를 이용하여 학습을 할 경우 오버피팅(over-fitting)의 문제점이 있으므로 데이터의 규모가 클 경우 FCM 군집화 알고리즘을 사용할 경우 효과적인 것으로 나타나 본 논문에서도 모든 데이터를 사용하기 보다는 대표가 되는 특징을 선택하여 학습을 수행하였다. 학습과정에 확률신경회로망의 가중치와 구조를 산출하고, 산출된 가중치와 구조를 이용하여 그림 3의 (b)에서 보인 바와 같이 검증 데이터에 대한 성능을 평가한다.

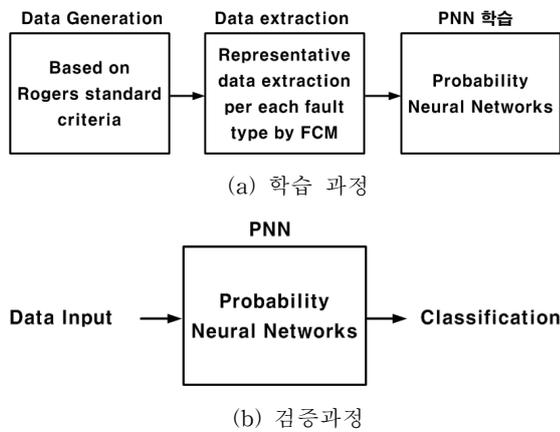


그림 3 제안된 알고리즘 구성도  
Fig. 3 The proposed algorithm configuration

### 3.2 PNN 기반 Rogers 진단기법

확률 신경회로망은 널리 사용되는 다층신경회로망(MLP : Multi Layer Perceptron)과 달리 학습 데이터를 이용하여 각각의 클래스에 대한 확률밀도함수(PDF : Probability Density Funtion)을 정의한 후, 검증 데이터의 분류는 클래스별 확률밀도함수에 의해 계산된 확률값들 중에서 가장 높은 값을 갖는 클래스를 선택하는 분류기이다. 훈련데이터에 대한 확률밀도함수는 Parzen의 확률밀도함수를 이용하고, 검증데이터의 분류는 베이시언의 결정규칙을 이용하는 분류기로 1988년 Specht에 의해 제안되었다[11]. 확률 신경회로망은 그림 4에서 보는 바와 같이 입력층, 패턴층, 합산층 및 출력층 등 4층 구조의 전방향 구조로 되어 있다.

그림 4에서 보는 바와 같이 입력벡터의 차원은 3개, 즉  $x_1(C_2H_2/C_2H_4)$ ,  $x_2(CH_4/H_2)$ ,  $x_3(C_2H_4/C_2H_6)$ 로 구성되었으며, 분류하고자 하는 클래스는 5개, 즉  $y_1(PD)$ ,  $y_2(D1)$ ,  $y_3(D2)$ ,  $y_4(T2)$ ,  $y_5(T3)$ 로 구성하였다.

패턴층에서는 입력값  $x_i$ 와 입력층과 패턴층 사이에 있는 가중치  $w_{ij}$ 의 곱에 의해 출력값  $z_j$ 를 출력한다. 다음으로  $z_j$ 는 식 (1)과 같은 비선형 활성화함수를 사용하여 출력  $\phi_j$ 를 산출한다. 식 (1)에서  $j$ 는 패턴 번호,  $\sigma$ 는 표준편차를 의미한다.

$$\phi_j = \exp\left[\frac{(z_j - 1)}{\sigma^2}\right] = \exp\left[\frac{(X \cdot w_{ij} - 1)}{2\sigma^2}\right] \quad (1)$$

합계층에서는 패턴별로 분류된 뉴런으로부터 식 (2)와 같이 합산하여 출력한다. 식 (2)에서  $V_{ij}$ 는 패턴층과 합산층 사이의 가중치를 의미한다.

$$S_q = \sum_{i=1}^{n_p} \phi_j V_{ij} \quad (2)$$

출력층은 최종 출력을 결정하는 층으로서 최대확률밀도를 갖는 출력을 1로, 나머지 해당되지 않는 출력은 0으로 설정한다.

확률신경망에서는 확률밀도함수 추정이 매우 중요하며, 훈련패턴에 근거하여 식 (3)으로 표현되는 parzen windows 방법을 이용하여 추정할 수 있다. 결국  $f_A(X)$ 는 클래스 A에 포함된 다수의 훈련패턴을 중심으로 한 다변수의 작은 가우시안 분포들의 단순합으로 표현된다.

$$f_A(x) = \frac{1}{(2\pi)^{P/2} \sigma^P} \frac{1}{m} \exp\left[-\frac{(X - X_{Ai})^T (X - X_{Ai})}{2\sigma^2}\right] \quad (3)$$

식 (3)에서  $X$ 는 분류되어야 할 훈련벡터,  $m$ 은 클래스  $\theta_A$ 에 속한 훈련벡터의 수,  $X_{Ai}$ 는 클래스  $\theta_A$ 에서의  $i$ 번째 훈련벡터,  $\sigma$ 는 표준편차를 의미한다.

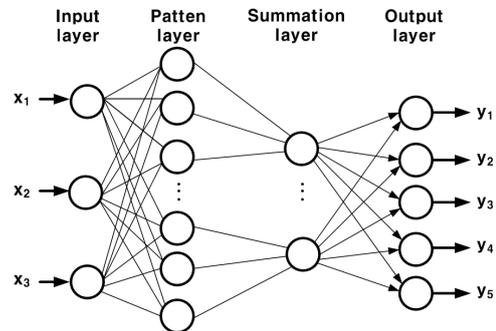


그림 4 PNN 구조  
Fig. 4 Structure of PNN

### 4. 실험 결과

IEC TC 10 데이터 베이스를 이용하여 개발 진단모델의 성능을 평가하였다[12]. IEC TC 10 데이터 베이스는 PD고장 데이터는 9개, D1 고장 데이터는 26개, D2 고장 데이터는 48개, T2 고장 데이터는 16개, T3 고장 데이터는 18개로 총 117개로 구성되어 있다. 그림 5에서는 Rogres 진단기준에 맞는 데이터를 FCM에 의해 생성한 그림을 나타냈다. 그림 5에 나타난 데이터를 이용하여 PNN 학습을 수행한다.

PNN 학습 후에 IEC TC 10 PD(부분방전)를 검증데이터로 이용하여 진단한 결과를 표 2에 나타냈다. 표 2에서 보는 바와 같이 Rogers 진단기준에 불능으로 진단된 7번을 제외한 모든 시료는 제안된 방법에 의해 PD로 정확하게 진단함

을 알 수 있다.

표 3에서는 IEC TC 10 T3(고온과열)로 구성된 데이터에 대한 진단결과를 나타냈다. 표 3에서 보는 바와 같이 Rogers 진단기준은 전체 18개의 시료 중에서 11개의 시료에 대해 정확하게 판단하였으며, 5개의 시료에 대해서는 판단불능(시료번호 6, 9, 10, 14, 15), 1개의 시료에 대해서는 T2(시료번호 1번), 1개의 시료에 대해서는 D(시료번호 8번) 진단 결과를 보였다. Rogers 진단 기준에 근거한 지능형 모델을 적용한 결과 13개 시료에 대해 T3로 진단하였으며, 3개의 시료는 T2(시료번호 1, 9, 10번), 2개의 시료는 D(시료번호 8, 14번)로 진단하였다.

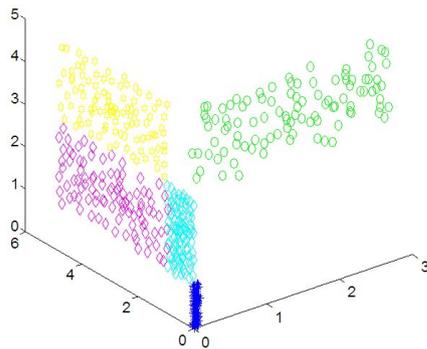


그림 5 FCM을 이용한 고장상태별 조성비 생성  
Fig. 5 Gas ratio generation per fault state by FCM

표 2 IEC TC 10 PD 데이터의 조성비

Table 2 Gas ratio for PD dataset in IEC TC 10

No	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	Rogers	PNN
1	32930	2397	—	—	157	ND	PD
2	37800	1740	8	8	249	ND	PD
3	92600	10200	—	—	—	ND	PD
4	8266	1061	—	—	22	ND	PD
5	9340	995	7	6	60	ND	PD
6	36036	4704	10	5	554	ND	PD
7	33046	619	—	2	58	PD	PD
8	40280	1069	1	1	1060	ND	PD
9	26788	18342	—	27	2111	ND	PD

표 4에서는 IEC TC 10 전체 데이터에 대한 Rogres 진단 기준과 제안된 PNN 모델의 진단 결과를 나타냈다. 표 4에서 보는 바와 같이 9개로 구성된 PD(부분방전)에 대해 Rogers 진단방법은 11.1[%]로 나타났으며, 제안방법인 확률 신경회로망 기반의 지능형 모델은 100[%]의 성능을 보였다. 74로 구성된 D1(저에너지 방전)과 D2(고에너지 방전)에 대해 Rogers 진단방법은 67.6[%], 제안방법인 PNN는 89.2[%]로 나타나 Rogers 진단방법에 비해 성능이 개선됨을 알 수 있다. 16개로 구성된 T1(저온과열)과 T2(중온과열)로 구성된 데이터에 대해 Rogers 진단방법은 31.3[%], 제안방법인 PNN는 68.7[%]로 나타나 우수한 성능을 보였다. 18개로 구성된 T3(고온과열)에 대해 Rogers 진단방법은 61.1[%], 제안방법인 PNN는 72.2[%]로 나타났다. 117개의 전체 데이터에 대한 진단 결과 Rogers 진단방법은 57.3[%] 성능을 보였

으며, 제안방법인 PNN는 84.6[%]의 진단 성능을 보여 Rogers 진단방법에 비하여 우수한 결과를 나타냈다.

표 3 IEC TC 10 T3 데이터의 조성비

Table 3 Gas ratio for T3 dataset in IEC TC 10

No	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	Rogers	PNN
1	8800	64064	—	95650	72128	T2	T2
2	6709	10500	750	17700	1400	T3	T3
3	1100	1600	26	2010	221	T3	T3
4	290	966	57	1810	299	T3	T3
5	2500	10500	6	16500	4790	T3	T3
6	1860	4980	1600	10700	—	ND	T3
7	860	1670	40	2050	30	T3	T3
8	150	22	11	60	9	D	D
9	400	940	24	82	210	ND	T2
10	6	2990	67	26076	29990	ND	T2
11	100	200	11	670	110	T3	T3
12	290	1260	8	820	231	T3	T3
13	1550	2740	184	5450	816	T3	T3
14	3910	4290	1230	6040	626	ND	D
15	12705	23498	5188	34257	6047	ND	T3
16	1	8	6	100	8	T3	T3
17	300	700	36	1700	280	T3	T3
18	107	143	2	222	34	T3	T3

표 4 진단결과

Table 4 Diagnosis result

고장분류(샘플개수)	Rogers (진단개수)	PNN(진단개수)
PD (9개)	11.1%(1개)	100%(9개)
D1, D2(74개)	67.6%(50개)	89.2%(66개)
T1,T2(16개)	31.3%(5개)	68.7%(11개)
T3(18개)	61.1%(11개)	72.2%(13개)
Total(117개)	57.3%(67개)	84.6%(99개)

### 5. 결 론

본 논문에서는 확률신경회로망을 이용한 전력용 유입변압기의 고장원인을 분류하는 알고리즘을 개발하였다. 개발된 알고리즘의 성능을 평가하기 위하여 실험한 결과 Rogers 진단 방법은 57.3[%] 성능을 보였으며, 제안된 알고리즘을 적용한 결과 84.6%의 진단 성능을 보여 다른 진단방법에 비하여 우수한 결과를 나타냈다. 향후 제안된 방법을 현재 국내에서 사용 중인 유입변압기에 적용하여 그 유용성을 보이고자 한다.

### 감사의 글

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

References

- [1] Kelly, J. J. "Transformer fault diagnosis by dissolved-gas analysis.", IEEE Transactions on Industry Applications, Vol. 16, No. 6, pp.777 - 782, 1980.
- [2] Institute of Electrical and Electronics Engineers, "IEEE C57.104-2008 guide for the interpretation of gases generated in oil-immersed transformers," pp.1 - 27, 2009.
- [3] International Electrotechnical Commission, "IEC 60599 Ed. 2.1 Mineral oil-impregnated electrical equipment in service - Guide to the interpretation of dissolved and free gases analysis," IEC, 2007
- [4] Bhalla, D., Bansal, R. K., Gupta, H. iO. "Function analysis based rule extraction from artificial neural networks for transformer incipient fault diagnosis," Electrical Power and Energy Systems, Vol. 43, No. 1, pp.1196 - 1203, 2012.
- [5] Cristina M. Quintella, "Development of a spectrofluorimetry -based device for determining the acetylene content in the oils of power transformers, Talanta, Vo.,117, pp.263 - 267, 2013.
- [6] Jae-Yoon Lim, Dae-Jong Lee, Pyeong-Shik Ji, "Fault Diagnosis of Oil-filled Power Transformer using DGA and Intelligent Probability Model", Trans. KIEE, Vol, 65P, No. 3, pp. 188-193, 2016.
- [7] Myeong-Seok Seo, Pyeong-Shik Ji, "A Fault Diagnosis Method of Oil-Filled Power Transformers Using IEC Code based Neuro-Fuzzy Model", Trans. KIEE, Vol, 65P, No. 1, pp. 41-46, 2016.
- [8] A. J. C. Trappey, C. V. Trappey, L. Ma, J.C. M. Chang "Intelligent engineering asset management system for power transformer maintenance decision supports under various operating conditions", Computers & Industrial Engineering, Vol. 84 pp. 3 - 11, 2015.
- [9] Y. Kamata, "Diagnostic methods for power transformer insulation," IEEE Transaction on Electrical Insulation, Vol EI-21, No.6, pp.1045-1048, 1986.
- [10] H. F. Jr, J. G. S. Costa, J. L. M. Olivas, "A review of monitoring methods for predictive maintenance of electric power transformers based on dissolved gas analysis", Renewable and Sustainable Energy Reviews, Vol. 46, pp. 201-209, 2015.
- [11] J. D. F. Specht, "Probabilistic neural networks", Neural Networks, Vol. 3, pp. 109-118. 1990.
- [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.

저 자 소 개



임재윤 (林 裁 尹)

1984년 충북대 공대 전기공학과 졸업, 1986년 동 대학원 전기공학과 졸업(공학석사), 1995년 홍익대 대학원 전기공학과 졸업(공학박사), 1999~2000 Texas A&M Univ. 방문교수, 현재 대덕대학교 교수

E-mail : jyylim@ddc.ac.kr



이대종 (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



지평식 (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