

# FCM과 ELM을 이용한 전력용 변압기의 모니터링 알고리즘

## A Monitoring Algorithm using FCM and ELM for Power Transformer

지 평 식\* · 임 재 윤†  
(Pyeong-Shik Ji · Jae-Yoon Lim)

**Abstract** - In power system, substation facilities have become too complex and larger according to an extended power system. Also, customers require the high quality of electrical power system. However, some facilities become old and often break down unexpectedly. The unexpected failure may cause a break in power system and loss of profits. Therefore it is important to prevent abrupt faults by monitoring the condition of power systems. Among the various power facilities, power transformers play an important role in the transmission and distribution systems. In this research, we develop intelligent diagnosis technique for monitoring of power transformer by FCM(Fuzzy c-means) and ELM(Extreme Learning Machine). The proposed technique make it possible to diagnosis the faults occurred in transformer. To demonstrate the validity of proposed method, various experiments are performed and their results are presented.

**Key Words** : DGA, Diagnosis, ELM, FCM, Power transformer

### 1. 서 론

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 국부과열 등에 의하여 이상이 발생하게 되면 열 발생이 수반되어 이 열원에 접촉된 절연재료가 분해되어 여러 종류의 가스가 발생하게 된다. 즉, 변압기 내부의 절연재료인 절연유, 절연지, 프레스 보드 등은 열 분해되어 수소( $H_2$ ), 메탄( $CH_4$ ), 에탄( $C_2H_6$ ), 에틸렌( $C_2H_4$ ), 아세틸렌( $C_2H_2$ ), 일산화탄소( $CO$ ), 이산화탄소( $CO_2$ ) 등의 가스를 발생하게 되며, 각 발생가스의 대부분은 절연유에 용해된다[1][2].

따라서 유입변압기에서 절연유를 채취하여 유증가스를 분석하게 되면, 가스발생 및 가스 발생량의 조성비에 따라 내부 이상 유무 및 그 정도를 추정할 수 있다. 현재 국내 산업 현장에서는 변압기의 내부 이상을 조기에 발견하여 사고를 예방하기 위한 목적으로 수소와 아세틸렌 등의 탄화수소 가스들에 대해 표 1(a)의 절연유중 용존 가스 관리 기준에 의거하고 있다. 이 중에서 절연재의 열화정도를 진단, 변압기의 잔존수명을 예측하여 적절한 교체시기를 결정하기 위해 이산화탄소가스의 농도를 이용한 표 1(b)의 절연유중  $CO_2$  가스 관리기준을 정하여 이 기준에 따라 정상/요주의 등 열화정도를 판정한다[3]. 표 1에 의해 요주의가 발생하였을 경우에는 전문가에 의해 이상의 원인을 분석하고 있다[4].

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 확실적인 이상/정상 판단 만으로는 정확한 변압기의 열화 상태를 판단하는 데는 한계가 있다[5-8]. 이러한 문제점을 해결하기 위하여 최근까지도 다양한 진단방법이 개발되고 있다[9-11]. 따라서 본 논문에서는 단순한 이진법적인 정상/요주의만을 판정하는 단일 가스만을 고려하여 판단하는 방법 대신 FCM(Fuzzy c-means)과 ELM(Extreme Learning Machine)을 이용하여 변압기의 열화에 의해 발생하는 다양한 가스들의 특성값들을 고려한 전력용 변압기의 모니터링 알고리즘을 개발하고 사례연구를 통해 그 타당성을 입증하였다.

### 2. 제안된 전력용 변압기 모니터링 알고리즘

그림 1에서는 KEPCO 규정에 의해 정상으로 판정된 데이터의 일례를 보이고 있다. 그림 1에서 보는 바와 같이 단순한 이진법적인 정상/요주의만을 판정하는 KEPCO 규정에 의하면 정상으로 판별되지만 각각의 가스성분 값들이 표 1(a)의 열화진단기준과 비교해 볼 때, 요주의에 해당하는 임계값에 근접한 것을 알 수 있다. 즉, KEPCO 규정만으로는 이분법적인 정상/요주의만을 판정함으로 변압기의 열화추이 특성을 진단하지 못하고 있다. 따라서 변압기가 정상이라 하더라도 어느 정도 열화가 진행되는 경우가 많으므로 그 열화정도를 수치적으로 제시하여 보다 정밀한 진단결과를 제시해줄 필요성이 있다.

\* 시니어회원 : 한국교통대학교 전기공학과 교수 · 공박

† 교신저자, 중신회원 : 대덕대학교 전기과 교수 · 공박

E-mail : jyylim@ddu.ac.kr

접수일자 : 2012년 11월 6일

최종완료 : 2012년 11월 20일

표 1 KEPCO 기반 변압기 진단기준

Table 1 KEPCO based Decision standard for power transformers

(a) 절연유중 용존가스 관리 기준 (단위 : ppm)

판정 가스성분	정 상 (Normal)	요주의 (Caution)	이상 (Abnormal)
H <sub>2</sub>	400 미만	400 이상	800 이상
CO	300 미만	300 이상	800 이상
C <sub>2</sub> H <sub>2</sub>	20 미만	20 이상	100 이상
CH <sub>4</sub>	250 미만	250 이상	750 이상
C <sub>2</sub> H <sub>6</sub>	250 미만	250 이상	750 이상
C <sub>2</sub> H <sub>4</sub>	250 미만	250 이상	750 이상

(b) 절연유중 CO<sub>2</sub> 가스 관리 기준 (단위 : ppm)

CO <sub>2</sub> Gas	판 정	조 치 사 항
4000 미만	정상	○ 조치사항 없음
4000 이상	요주의 (Caution)	○ 변압기의 관리방법 변경 1. 절연유 유온을 낮춤 2. 절연유의 절연과피전압 측정 3. 절연유의 함유수분 분석
7000 초과	이상 (Abnormal)	○ 변압기 절연재 열화도 진단 (절연유, 절연지)




그림 1 요주의 근처에 존재하는 정상데이터

Fig. 1 Normal data near caution limit

그림 2에서는 제안된 유입변압기 모니터링 알고리즘의 구성도를 나타냈다. 그림 2에서 보는 바와 같이 제안된 방법은 퍼지함수를 이용한 정규화과정, FCM을 이용한 학습데이터 구축과정과 ELM 신경망을 이용한 진단과정으로 구성되어 있다. DGA(dissolved gas analysis)데이터는 수소, 일산화탄소, 아세틸렌, 메탄, 에탄, 에틸렌, 이산화탄소로 총 7개의 가스성분으로 구성되어 있다. 본 논문에서 정규화는 식 (1)에서 보는 바와 같이 시그모이드 함수를 이용하였다. 식 (1)에서  $a$ 는 시그모이드 함수의 기울기이고,  $c$ 는 시그모이드 함수의 중심점 위치를 나타낸다.

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




그림 2 제안된 유입변압기 진단 알고리즘

Fig. 2 The diagnosis process for the proposed method

### 2.1 FCM에 의한 변압기 상태별 대표 특징 선택

정확한 유입변압기 이상 진단을 위해서는 진단하고자 하는 데이터와 구축된 데이터간의 비교 분석에 의해 이루어짐으로 신뢰성 높은 데이터 구축이 무엇보다도 중요한 요소로 작용하고 있다. 이를 위해 실측한 전 데이터를 이용하여 열화 상태별 DB를 구축할 경우 메모리의 한계 및 처리 속도가 저하되는 문제점으로 인하여, 전 데이터를 사용하는 방법 대신에 신뢰성 있는 데이터의 대표 특징들을 선택하는 것이 바람직하다. 본 연구에서는 이러한 데이터간의 대표특징들을 선택하기 위하여 퍼지기반 군집기법인 FCM 알고리즘을 적용하였다. 퍼지개념을 도입한 군집화 기법인 FCM에 의해 고장모델을 구축하는 방법을 단계별로 간략히 살펴보면 다음과 같다[12].

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

$$\mu_{ik} = \mu_{A_i}(x_k) \in [0, 1] \quad (2)$$

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

$$v_{ij} = \frac{\sum_{k=1}^n \mu_{ik}^m \cdot x_{kj}}{\sum_{k=1}^n \mu_{ik}^m} \quad (3)$$

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

$$\mu_{ik}^{(r+1)} = \left[ \sum_{j=1}^c \left( \frac{d_{jk}^{(r)}}{d_{jk}^{(r)}} \right)^{2/(m-1)} \right]^{-1} \quad (4)$$

여기서,  $m$ 은 퍼지화 정도를 나타내는 퍼지 수로써 일반적으로 2를 이용한다. 또한,  $d_{jk}$ 는  $p$  차원을 갖는  $j$ 번째

데이터  $x_j$ 와  $k$  번째 대표 중심값  $v_k$ 와의 유클리디안 거리 값을 의미한다.

$$d_{jk} = d(x_j, c_k) = \left[ \sum_{i=1}^p (x_{ji} - v_{ki})^2 \right]^{-1} \quad (5)$$

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

$$J(U, c_1, c_2, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (6)$$

### 2.2 ELM에 의한 변압기 진단

그림 3에서는 ELM에 의한 변압기 진단과정을 나타냈다. 그림에서 보는 바와 같이 FCM에 의해 선택된 변압기 상태별 데이터에 대하여 정상상태와 5가지의 상태(절연열화, CO<sub>2</sub> 초과, 아크방전, 저온열화, 중온 및 고온과열)를 판정하게 된다.




그림 3 ELM에 의한 유입변압기 진단 알고리즘  
Fig. 3 The diagnosis Algorithm by ELM

본 논문에서 적용한 ELM은 단일 은닉층을 가지는 전방향 신경망으로 최근 Huang등에 의하여 제안되었다[13][14].

최급경사법(gradient descent method)에 기반한 신경 회로망의 학습은 일반적으로 좋은 성능을 얻기 위해 많은 반복 학습을 필요로 하며, 적절하지 못한 학습에 의하여 낮은 적응성을 보이거나 종종 국부 최소해(local minimum)에 수렴하는 단점을 가지고 있다. 그러나 ELM에서 출력 가중치들은 반복적인 학습 구조 대신에 모어-페로스의 일반화된 역행렬(Moore-Penrose generalized inverse)에 의해 분석적으로 계산되어짐으로 반복학습이 이루어지지 않는다.

ELM의 주된 특징은 다른 신경회로망의 학습방법과 달리 반복학습을 하지 않기 때문에 전형적인 반복 학습 방법들에 비하여 매우 빠른 학습이 가능하다는 점과 ELM은 작은 학습 오차값을 가질 뿐만 아니라 가중치들의 가장 작은 해를 얻는 경향이 있다는 점이다. 특히, 경사 기반 학습방법들이 국부최소(local minimum), 과잉적합(over-fitting)과 같은 문

제점이 있는 반면에 ELM은 한 번의 학습으로 최적의 해에 직접적으로 도달한다.

ELM의 학습과정을 설명하기 위해  $m$ 개의 데이터  $\{(x_i, y_i), i=1, 2, \dots, m\}$ 와 한개의 출력노드를 가지고  $N$ 개의 은닉노드들을 가지는 전방향 신경 회로망의 학습을 고려해보자.

여기서, 입력  $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ 이고,  $y_i \in R$ 이며,  $N$ 개의 은닉노드들의 활성화 함수  $g(x)$ 에 의한 전방향 신경 회로망의 출력은 식 (7)과 같이 나타낼 수 있다.

$$g(w_j \cdot x_i) \cdot a = y_i, \quad i=1, 2, \dots, m \quad (7)$$

여기서,  $W_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T, j=1, 2, \dots, N$  은  $j$ 번째 은닉노드와 입력노드들을 연결하는 가중치 벡터로 임의의 값으로 초기화 되며,  $a = [a_1, a_2, \dots, a_N]^T$ 는 은닉노드들과 출력노드를 연결하는 가중치 벡터이다.  $w_j \cdot x_i$ 는  $w_j$ 와  $x_i$ 의 내적을 의미한다. 식 (7)은 식 (8)과 같이 간결하게 표현될 수 있다.

$$Ga = y \quad (8)$$

여기서

$$G = \begin{bmatrix} g(w_1 \cdot x_1) & g(w_2 \cdot x_1) & \dots & g(w_N \cdot x_1) \\ g(w_1 \cdot x_2) & g(w_2 \cdot x_2) & \dots & g(w_N \cdot x_2) \\ \vdots & \vdots & \ddots & \vdots \\ g(w_1 \cdot x_m) & g(w_2 \cdot x_m) & \dots & g(w_N \cdot x_m) \end{bmatrix} \quad (9)$$

$$y = \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix}_{m \times 1} \quad (10)$$

$G$ 는 전방향 신경 회로망에서 은닉층의 출력으로  $G$ 의  $i$ 번째 열은 입력  $x_1, x_2, \dots, x_m$ 과 관련된  $i$ 번째 은닉노드들의 출력 벡터이다. 최종적으로, 식 (11)과 같이 최소자승법에 의하여 출력 가중치  $\hat{a}$ 을 구한다.

$$\hat{a} = G^+ y \quad (11)$$

여기서  $G^+$ 는 은닉층의 출력  $G$ 의 모어-페로스의 일반화된 역행렬이다. 만일  $G^T G$ 가 비정칙인 경우,  $G$ 의 모어-페로스의 일반화된 역행렬은 식 (12)와 같이 얻어진다.

$$G^+ = (G^T G)^{-1} G^T \quad (12)$$

최종 분류는 식 (13)에 의해 결정된다.

$$\hat{y} = G^+ \hat{a} \quad (13)$$

### 3. 실험 및 결과

#### 3.1 데이터 구성

제안된 기법의 유용성을 보이기 위해 사용된 데이터는 표 2에서 보인 바와 같이 1992년에서 1997년 동안 지역 2곳의 154[kV]와 345[kV]용 변압기에서 취득한 KEPCO 데이터를 이용하였다[8]. 지역 (A)에서는 64개 변전소에 설치 운용중인 177개 변압기에서 942개의 데이터를 취득하였고, 다른 지역 (B)에는 38개의 변전소에 설치된 98개의 변압기에서 472개의 가스성분을 취득하였다. 따라서 데이터는 수소, 일산화탄소, 아세틸렌, 메탄, 에탄, 에틸렌, 이산화탄소로 총 7개의 가스성분으로 구성되어 있는 1414개이다. 데이터의 구조를 자세히 살펴보면 사용된 데이터 1414개 중 요주의 데이터는 319개이고 정상데이터는 1095개로 구성되어 있다. 요주의 데이터를 KEPCO 규정에 기반을 둔 전문가에 의해 판정된 고장원인별로 살펴보면, 절연열화 159개, CO<sub>2</sub> 초과 33개, 아크방전 48개, 저온과열 16개, 중온 및 고온과열 63개로 이루어져 있다.

표 2 데이터의 구성

Table 2 Data structure

Case		지역(A)	지역(B)	합계
요주의	절연열화	125	34	159
	CO <sub>2</sub> 초과	23	10	33
	아크방전	11	37	48
	저온과열	15	1	16
	중온및고온과열	52	11	63
	소 계	226	93	319
정 상	716	379	1095	
합 계	942	472	1414	

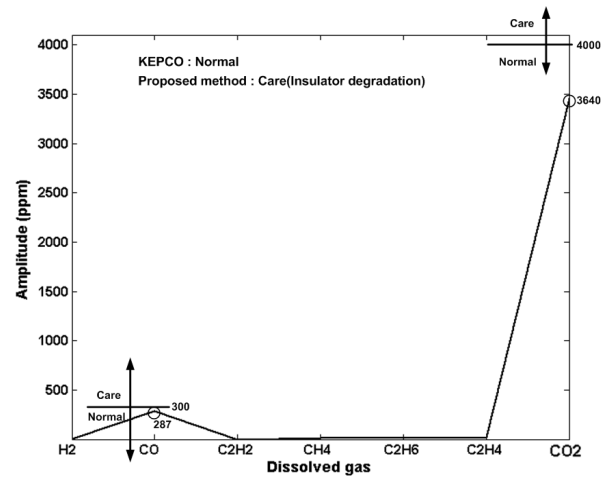
#### 3.2 진단 결과

ELM 기반의 신경망을 이용하여 유입 변압기의 상태를 진단하기 위하여 학습데이터를 이용한 진단 모델의 구축이 선행되어야 한다. 학습데이터는 지역 (A)에서 취득한 실측 데이터 942개를 이용하여 FCM에 의해 대표 데이터를 구축하였다. FCM에 의해 구축된 대표 데이터는 각각의 상태별 8개로 구성되어 있다. ELM 신경망의 출력의 개수는 정상, 절연열화, CO<sub>2</sub> 초과, 아크방전, 저온과열, 중온 및 고온과열의 출력값을 의미하는 6개로 구성되어 있다. ELM 학습은 각각의 상태에 대해 1일 출력되도록 목표값을 설정하였다.


표 3 KEPCO규정에 의해 정상으로 판정된 데이터의 진단결과

Table 3 Diagnosis results for normal data determined by KEPCO decision rule

변압기 상태	전문가 판정	제안방법	비고
정상	379	370	9개 차이 발생
절연열화	0	5	
CO <sub>2</sub> 초과	0	2	
아크방전	0	1	
저온과열	0	1	



(a) 사례 1



(b) 사례 2

그림 4 제안방법과 KEPCO 규정에 의한 진단결과가 상이한 데이터 분석

Fig. 4 Data analysis in those shown in different diagnosis results

검증 데이터에 대한 최종 판단은 ELM 출력층에서 1에 가장 가까운 출력값을 갖는 출력노드를 선택하여 이루어진다. ELM의 히든층은 25개로 설정하여 학습하였다. 표 3에서는 KEPCO 규정에 기반을 둔 전문가에 의해 정상으로 판정된 데이터의 진단결과를 나타냈다. 표 3에서 보는 바와 같이 정상데이터 379개 중에서 9개의 데이터는 요주의로 판정되었다. 정상 데이터 중 요주의로 판정된 9개의 데이터의 진단결과가 KEPCO에 기반을 둔 전문가의 진단 결과와의 차이점을 분석하기 위해 그림 4에 대표적인 사례를 나타냈다.

그림 4(a)에 나타난 데이터의 경우 가스 CO와 CO<sub>2</sub> 성분의 크기가 287과 3640으로 나타나 두 가스성분들이 임계값인 300과 4000에 근접해 있음을 알 수 있다.

또한, 그림 4(b)에 나타난 사례 3의 데이터의 경우 가스 CO와 CO<sub>2</sub> 성분의 크기가 288과 3842로 나타나 두 가스성분들이 임계값인 300과 4000에 근접해 있음을 알 수 있다. 따

라서 기존의 KEPCO에 기반을 둔 전문가 판정법은 개별적인 가스성분만을 고려할 경우 정상/요주의를 판단하지만, 제안된 방법은 고려되는 가스성분들의 모든 값들을 고려하여 열화상태를 판단함으로써 기존 방법에 비하여 효과적인 진단결과를 보임을 확인 할 수 있다. 표 4에서는 요주의로 판정된 데이터의 열화원인을 나타냈다. 표 4에서 보는 바와 같이 KEPCO 규정에 기반을 둔 전문가에 의해 판정된 결과와 제안방법에 의해 판정된 결과가 동일함을 확인할 수 있다.

**표 4** KEPCO 규정에 의해 요주의로 판정된 데이터의 진단결과

**Table 4** Diagnosis results for caution data determined by KEPCO decision rule

열화 분류	KEPCO 규정	제안방법	비고
절연열화	34	34	
CO <sub>2</sub> 초과	10	10	
아크방전	37	37	
저온과열	1	1	
고온과열	11	11	

#### 4. 결 론

국내 전력용 변압기 진단방법으로 KEPCO의 절연유중 용존가스 관리기준에 의해 변압기의 정상/요주의를 판정한다.

그러나 KEPCO 규정은 주요가스 성분의 양과 기준값과 비교하는 이분법적인 판단을 하고 있어 이분법 자체가 지니고 있는 특성에 의해 오판을 할 확률이 높다. 이러한 문제점을 해결하기 위하여 본 연구에서는 FCM과 ELM을 이용한 전력용 변압기의 모니터링방법을 제안하였다. 진단방법은 FCM에 의해 미리 구축된 변압기 상태별 대표특징값들을 이용하여 ELM의 학습이 이루어진다. 제안된 방법의 타당성을 보이기 위해 실측 데이터를 이용하여 실험한 결과, 단일 가스 성분의 크기만을 고려한 기존 방법에 비하여 제안된 방법의 진단결과가 효과적인 것으로 나타났다.

#### 감사의 글

이 논문은 2012년도 한국교통대학교 교내학술연구비의 지원을 받아 수행한 연구임.

#### 참 고 문 헌

[1] 문종필, 김재철, 임태훈, "실리콘 유입변압기 진단을 위한 전문가시스템 개발", 조명·전기설비학회논문지, Vol.18, No.1, pp. 55-62, 2004.  
 [2] Fu Yang, Jin Xi, Lan Zhida, "A neural network approach to power transformer fault diagnosis", ICEMS 2003, Electrical Machines and Systems, Vol. 1, pp. 351-354, 2003.

[3] 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. 1026-1029, 1999.  
 [4] 최인혁, 정길조, 권동진, 신명철, "가스분석기법을 이용한 전력용 변압기 내부 이상진단을 위한 알고리즘 및 전문가시스템 개발", 조명·전기설비학회 논문지, Vol. 15, No. 5, pp. 68-74, 2001.  
 [5] Z. Yan, M. Dong, Y. Shang, M. Muhr, "Ageing Diagnosis and Life Estimation of Paper Insulation for Operating Power Transformer", International Conference on Solid Dielectrics, Vol. 2, pp. 715-718, 2004.  
 [6] Zhenyuan Wang, Yilu Liu, Paul J. Griffin, "A Combined ANN and Expert System Tool for Transformer Fault Diagnosis", IEEE Transactions on Power Delivery, Vol. 13, No. 4, pp. 1224-1229, 1998.  
 [7] Ganyun Kv, Haozhong Cheng, Haibao Zhai, Lixin Dong, "Fault diagnosis of power transformer based on multi-layer SVM classifier", Electric Power System Research, Vol. 75, pp. 9-15, 2005.  
 [8] Q. Su, L. L. Lai, P. Austin, "A Fuzzy Dissolved Gas Analysis Method for the Diagnosis of Multiple Incipient in a Transformer", International Conference on Advances in Power System Control, Operation and Management(APSCOM), pp. 344-348, 2000  
 [9] A. Abu-Siada, S. Islam, "A New Approach to Identify Power transformer Criticality and Asset Management Decision Based on Dissolve Gas-in-Oil Analysis", IEEE Tran. on Dielectrics and Electrical Insulation, Vol. 19, No. 3, pp. 1007-1012, 2012.  
 [10] W. H. Tang, J. Y. Goulermas, Q. H. Wu, Z. J. Richardson, J. Fitch, "A Probabilistic Classifier for Transformer Dissolved Gas Analysis With a Partical Swarm Optimizer", IEEE Tran. on Power Delivery, Vol. 23, No. 2, pp. 751-759, 2008  
 [11] Ke Meng, Z. Y. Dong, D. H. Wang, K. P. Wong, "A Self-Adaptive RBF Neural Network Classifier for Transformer Fault Analysis", IEEE Tran. on Power Delivery, Vol. 25, No. 3, pp. 1350-1360, 2010  
 [12] Bezdec, J.C., Pattern Recognition with Fuzzy Objective Function Algorithms, Plenum Press, New York, 1981.  
 [13] 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.  
 [14] G. B. Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: theory and applications," Neurocomputing, Vol. 70, No. 1-3, pp. 489-501, 2006.

저 자 소 개



**지 평 식 (池平植)**

1964년 3월 5일생. 1989년 2월 국립 한밭대학교 전기공학과 졸업, 1994년 충북대학교 대학원 전기공학과 졸업(공학석사), 1998년 동대학원 전기공학과 졸업(공학박사), 현재 국립 한국교통대학교 전기공학과 교수

Tel : 043-841-5152

E-mail : psji@ut.ac.kr



**임 재 윤 (林栽尹)**

1961년 8월 4일생. 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 대덕대학 전기과 교수

E-mail : jyylim@ddc.ac.kr