

부분방전 진단을 위한 인공신경망 기법의 비교

정교범^{1*}, 객선근²

¹홍익대학교 전자전기공학과, ²(주)코맥스

Comparison of Artificial Neural Network for Partial Discharge Diagnosis

Gyo-Bum Chung^{1*} and Sun-Geun Kwack²

¹Dept. of Electronic & Electrical Engineering, Hongik University

²COMMAX Co. Ltd, Seongnam-si, Gyeonggi-do

요 약 본 논문은 전력기기 열화의 주요한 원인으로 알려진 부분방전의 진단을 위해 널리 사용되는 인공신경망의 계층 구조 및 입력벡터의 구성 요소의 변화에 대한 진단 성능을 검토한다. 은닉층이 1개 또는 2개인 인공신경망의 계층구조 변화에 대한 진단 성능을 비교하였으며, 입력벡터는 세라믹 커패시터를 이용하여 한주기에 2048번 샘플링한 시계열 신호를 직접 사용하는 경우와 특성벡터를 추출하여 사용하는 경우를 비교하였다. 침↔평판, 구↔구, 침↔침, 평판↔평판, 구↔평판 형태의 5가지 전극조합의 부분방전 실험으로 학습데이터를 수집하고, 시뮬레이션 연구를 수행하여 인공신경망의 진단 성능을 평가하였다

Abstract This paper investigates the diagnosis performance of Artificial Neural Network (ANN) depending on the structure and the input vector type of ANN, which has been used to detect the partial discharge to lead to the electric machinery deterioration. The diagnosis performance of one hidden layer and two hidden layer in ANN are compared. The performance using the 2048 time-series data and the performance using the feature input vector are compared. For measuring the partial discharge signal, the tip-to-plate, the sphere-to-sphere, the tip-to-tip, the tip-to-sphere and the sphere-to-plate electrodes are used respectively. For ANN's learning, Matlab and C-code program are used. For evaluating the diagnosis performance of ANNs, the simulation studies are performed.

Key Words : Artificial Neural Network, Feature Vector, Hidden Layer, Partial Discharge, Time Series Data

1. 서론

산업화 및 정보화로 인해 수요가 증가한 대용량 전력기기의 신뢰도 향상을 위한 고장 예방은 매우 중요한 문제이다. 대용량 전력기기 내부의 열화현상은, 절연체와 같은 구성요소에 열변화를 발생시켜, 신뢰도 저감의 원인이 된다. 따라서 전력기기 개발 과정에는, 설계단계에서부터 FEM을 이용한 열해석 연구와 같은 열발생 최소화 대책이 도모되어져 왔다[1]. 그러나 불규칙한 부하용량, 부하 편중에 의한 가열현상 및 외부 환경에 의한 열화와

같이 다양하고 예측하기 어려운 요인에 의해 열화가 진행되므로, 전력기기는 사용연한이 증가하면 신뢰성 확보를 위해 일정 주기마다 규칙적인 점검을 필요로 한다. 전력기기의 열화 예방을 위한 진단 기법은 전기적, 기계적, 화학적 진단기법 및 진단기준에 대한 연구가 수행되었다 [2-4].

전기적 진단 기법인 부분방전 측정법은 다른 진단기법과 비교하여 검출신호에 노이즈가 많을 경우에는 부분방전 신호의 검출이 어렵다는 단점에도 불구하고 전력기기의 운전을 중단하지 않고 실시간 진단을 실시할 수 있는

*Corresponding Author : Gyo-Bum Chung(Hongik Univ.)

Tel: +82-44-860-2595 email: gbchung@hongik.ac.kr

Received June 4, 2013

Revised (1st July 17, 2013, 2nd August 26, 2013)

Accepted September 6, 2013


장점이 있어 몰드변압기의 상태 감시에 많이 사용된다 [5]. 부분방전 신호를 측정하기 위해서 세라믹커패시터, 용량성 안테나, 초음파 센서와 같은 센서개발 연구와 검출된 신호를 이용하여 FFT 분석[6], 시계열분석, 전문가시스템[8], 신경망, 써포트벡터머신[9] 등의 신호처리방법의 영역에서 많은 연구가 수행되어져 왔다. 또한, IEC 60270과 KSC3700과 같은 부분방전시험과 관련된 표준이 완성되었다. 그러나, 대용량 전력기기의 열화진단은 실시간 On-line 진단을 시행하기 어렵고, 열화가 환경에 따라 급속히 진행되는 경우의 진단에는 아직도 어려운 문제점이 많이 있다[10-12].

검출된 부분방전 신호로부터 결함의 원인을 분석하는 것은 많은 경험과 높은 전문성을 요구하고, 전력기기 내부의 신호전달특성 및 센서특성에 의해서 왜곡된 검출신호는 방전원인 진단에 오류가 발생할 가능성이 있어서, 방전신호 패턴으로부터 방전의 원인을 자동으로 분석해주는 인공지능 진단기법의 연구가 수행되고 있다[13,14].

본 논문은 부분방전 진단에 많이 사용되는 인공신경망의 구조 및 입력 벡터의 특성이 인공신경망의 진단 성능에 미치는 영향을 연구한다. 인공신경망의 학습은 오류역전파 알고리즘을 채택하였고, 입력벡터는 한주기에 2048번 샘플링한 시계열데이터를 사용하는 경우와 특성벡터를 추출하여 사용하는 경우의 인공신경망 진단 성능을 비교하였다. 은닉층이 1개인 경우와 2개인 경우의 인공신경망의 계층구조 변화에 대한 진단 성능을 비교하였다. 진단 성능을 비교하기 위해서 학습되지 않은 패턴에 대한 성공률을 제시하였다.

2. 인공신경망의 구조

Fig. 1은 정량화하기 어려운 문제의 해결을 위해 학습된 퍼셉트론이 다층으로 구성된 일반적인 인공신경망이다.



[Fig. 1] Multi-layer Artificial Neural Network

다층 구조 인공신경망의 학습을 위해 식 (1)-(5)에 기술된 평균 제곱 오차 성능지표의 최적화를 위해 최급강하법 및 가중치 갱신을 위해 역전파 알고리즘이 일반적으로 사용된다[15].

$$F(x) = [e^2] = E[(t-a)^2] \quad (1)$$

$$W^m(k+1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad (2)$$

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) \quad (3)$$

$$b^m(k+1) = b^m(k) - \alpha s^m \quad (4)$$

$$s^m = F^m(n^m)(W^{m+1})^T s^{m+1} \quad (5)$$


여기서, 식 (1)의 F 는 평균제곱오차 성능지표, t 는 목표값, a 는 뉴런의 출력, 식 (2)의 W 는 가중치, s 는 입력에 대한 성능지표의 감도, α 는 학습률, k 는 가중치 계산 반복횟수, m 은 다층신경망의 층번호, 식 (3)의 f 는 뉴런의 전달함수, b 는 바이어스이다. 인공신경망의 뉴런수(m 또는 n), 다층구조 및 입력 특성벡터 p 의 구성요소 선정은 인공신경망의 수렴성능을 결정하는 핵심 사항이다. 입력층과 출력층으로 구성된 단층 구조 신경망은 판정경계선이 선형이어서 XOR 형태의 문제점을 구별할 수 없는 단점이 있다. 그러나, 2층 구조 신경망은 오목한(concave) 또는 볼록한(convex) 모양의 최종 판정경계선을 가질 수 있고, 3층 구조 신경망의 최종 판정경계선은 임의의 형태를 가질 수 있다[15].

본 논문에서는 정량화하기 어려운 부분방전 진단을 위해서 2층 구조 신경망 및 3층 구조 신경망의 진단 성능을 비교한다. 또한, 입력벡터로 시계열 데이터를 사용한 경우와 특성벡터를 추출하여 사용한 경우의 진단 성능도 비교하여 검토한다.

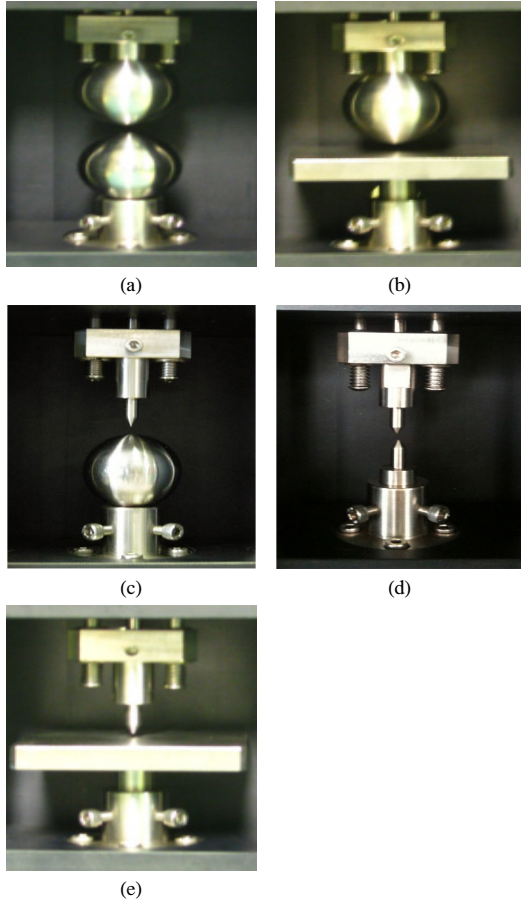
3. 부분방전 학습용 DB 구축

3.1 실험 구성

신경망의 부분방전 진단을 위한 학습데이터 취득을 위해서 Fig. 2와 같은 부분방전 모의를 위한 실험장치를 구성하였다[16].




[Fig. 2] Circuit diagram to measure the partial discharge signal



[Fig. 3] Electrodes for measuring the partial discharge signal. (a) sphere-to-sphere, (b) sphere-to-plate, (c) tip-to-sphere, (d) tip-to-tip, (e) tip-to-plate

Fig. 3은 부분방전 발생장치에 사용된 전극의 구성이다. 전극 모양은 침형, 판형, 구형의 3가지이며, 구-구, 구-판, 침-구, 침-침, 침-판의 5가지 전극조합으로 부분방전 실험을 수행하였다. 각각의 전극조합에 대해서, 전극 간격은 1mm, 3mm, 5mm의 3 단계, 인가전압은 0kV ~ 7kV

구간에서 1kV씩 증가시키는 8단계의 조합으로 120개의 변화된 조건에서 2회 실험을 진행하였다. 절연파괴 현상이 발생한 경우를 제외한 189개의 학습용 데이터를 취득하였으며, Fig. 4는 측정한 부분방전 신호의 일례이다.



[Fig. 4] Partial discharge signals of the tip-to-tip electrode by the applied voltages of 3, 5 and 7kV.

3.2 인공신경망 입력벡터

기본파 전력성분, 고조파, 부분방전신호, 노이즈 등이 포함된 측정신호로부터 인공신경망 학습을 위한 입력벡터의 추출은 신경망의 진단 성능을 결정짓는 중요한 요소이며, 신경망 연산속도 및 연산량에 많은 영향을 미친다. 입력벡터가 학습 대상의 특성을 명확히 나타내고, 벡터 구성요소의 갯수가 작다면, 연산량의 감소와 판정의 정확도를 동시에 달성할 수 있다.

본 논문은 입력벡터의 특성과 인공신경망 진단성능의 변화를 파악하기 위해서, 한주기에 2048번 샘플링한 데이터에서 기본파 성분을 제거한 시계열 데이터를 사용하는 경우와 특성벡터만을 추출하여 입력벡터로 사용하는 경우의 인공신경망 진단성능을 비교하였다.

3.2.1 시계열 데이터 입력

실험을 통해 취득한 기본파 한주기에 2048번 샘플링한 데이터를, 고역통과 FIR필터를 사용하여 기본파 주파수를 제거하고 인공신경망 입력으로 사용하는 구조이다. 부분방전의 위상특성이 2048개 입력벡터에 포함되어 있으므로, 0~90°, 180~270° 에서 주로 발생하는 부분방전 신호의 특징 판별에 유용하다.

3.2.2 특성벡터 입력


실험을 통해 취득한 기본파 한주기에 2048번 샘플링한 데이터를, 고역통과 FIR필터를 사용하여 처리한 후에 기본파 전체구간 및 0~90°, 90~180°, 180~270°, 270~360°로 세분화된 4개 구간에서 평균값/최대값의 비율로 구성된 5개 특성값을 신경망의 입력벡터로 사용하였다. 입력 데이터 갯수가 작아서 연산횟수가 작은 장점이 있다.

4. 시뮬레이션 연구


신경망의 부분방전 진단 특성의 비교를 위해서 189개의 학습용 패턴, Matlab 및 C-program을 이용하여 시뮬레이션 연구를 수행하였다[15,16]. 실험을 통해 얻어진 학습용 패턴은 부분방전 특징을 보이는 신호의 크기에 따라, 식 (1)의 목표값 t 를 0.05, 0.6, 0.7, 0.8, 0.9로 설정하였다.

4.1 시계열데이터를 사용한 경우

Fig. 5는 은닉층이 1개이고, Fig. 6은 은닉층이 2개이며, 한주기에 2048개의 시계열 데이터를 입력벡터로 사용하는 인공신경망이다. 은닉층 1단의 뉴런은 16개 또는 32개, 은닉층 2단의 뉴런은 4개이다. 시계열데이터의 위상 $0^\circ \sim 90^\circ$ 를 의미하는 0~512번째 데이터와 $180^\circ \sim 270^\circ$ 를 의미하는 1024~1536번째 데이터는 부분방전 신호를 포함하고 있을 확률이 높기 때문에 신경망 가중치 W 의 초기값을 크게 인가하고, 다른 위상 영역의 신호는 부분방전 신호가 포함되어 있을 확률이 낮기 때문에 신경망 가중치의 초기값을 작게 인가하여 학습을 진행하였다.



[Fig. 5] One hidden layer ANN using time-series data.



[Fig. 6] Two hidden layer ANN using time-series data.

학습의 진행 횟수는 신경망 연결강도의 초기값에 영향을 받으며, 역전파 알고리즘의 특성으로 지역 최소값으로 수렴하여 학습에 실패할 수도 있다. 학습 횟수가 증가하여도 목표값에 도달하지 않거나 학습을 진행하여도 오차에 변화가 없을 경우는 학습율[α]과 가중치[W], 바이어스[B] 등을 변경하였다.


Table 1은 시계열 데이터를 사용한 4가지 인공신경망의 최종 학습 결과를 나타낸 표이다. 은닉층 1단에 뉴런 16개, 은닉층 2단에 뉴런 4개인 (16,4) 신경망 구조에서 목표값 대비 평균제곱오차가 30%이상인 패턴은 189개의 학습데이터에서 1개이고, 1단 은닉층(32) 구조에서 오차율 50%이상인 패턴은 189개의 학습데이터에서 1개이다.

[Table 1] Learning results of ANN using time-series data


ANN Structure	Neurons	Patterns of 30% Error	Patterns of 50% Error
One Hidden Layer	(16)	0/189	0/189
	(32)	0/189	1/189
Two Hidden Layers	(16,4)	1/189	0/189
	(32,4)	0/189	0/189

4.2 특성벡터를 사용한 경우

Fig. 7은 은닉층이 1개이고, Fig. 8은 은닉층이 2개이며, 입력벡터로 5개 요소로 구성된 특성벡터를 사용하는 인공신경망이다. 진단 성능의 비교를 위해서 시계열데이터를 사용한 경우와 동일하게 은닉층 1단의 뉴런은 16개 또는 32개, 은닉층 2단의 뉴런은 4개를 사용하였다.



[Fig. 7] One hidden layer ANN using feature vector



[Fig. 8] Two hidden layer ANN using feature vector

Table 2는 특성 벡터를 사용한 4가지 인공신경망의 최종 학습 결과를 나타낸 표이다. 189개의 학습데이터에서 1단 은닉층(32) 구조에서 목표값 대비 평균제곱오차가 30%이상인 패턴은 3개, 50%이상인 패턴은 1개이고, 2단 은닉층 (16,4) 구조에서 평균제곱오차가 30%이상인 패턴은 2개, 50%이상인 패턴은 3개이다.

[Table 2] Learning results of ANN using feature vector

ANN Structure	Neurons	Patterns of 30% Error	Patterns of 50% Error
One Hidden Layer	(16)	0/189	0/189
	(32)	3/189	1/189
Two Hidden Layers	(16,4)	0/189	0/189
	(32,4)	2/189	3/189

Table 2의 결과는 Table 1의 시계열 데이터 인공신경망과 비교하여, 1단 은닉층에 32개의 뉴런을 갖는 1단 은닉층 구조와 2단 은닉층 구조의 특성벡터 인공신경망은 평균제곱오차가 크게 발생하는 학습데이터가 많이 발생하여, 진단 신뢰성이 상대적으로 낮음을 알 수 있다.

5. 실험 및 인공신경망 성능

구-구, 구-판, 침-구, 침-침, 침-판의 5가지 전극조합을 사용하여 취득한 데이터를 이용하여 학습된 인공신경망의 진단성능은 추가 실험을 통해 취득한 100개의 새로운 패턴을 이용하여 평가하였다. 100개의 패턴은 학습에 사용된 189개의 데이터와 동일한 실험조건에서 얻어진 데이터이며 절연파괴현상이 발생하지 않은 데이터로 이루어져 있다.

5.1 2048개 시계열데이터

Table 3은 2048개의 시계열 데이터를 입력벡터로 사용하는 4가지 인공신경망의 진단 결과이다.

[Table 3] Performance of ANN using Time-series data

Number of Hidden Layers	Neurons	Patterns of 10% Error	Patterns of 30% Error	Patterns of 50% Error
One	(16)	1/100	0/100	0/100
	(32)	27/100	0/100	0/100
Two	(16,4)	22/100	0/100	0/100
	(32,4)	0/100	0/100	0/100

성능 검증용 데이터 100개에 대해서 식(1)의 목표값 t 를 0.05, 0.6, 0.7, 0.8, 0.9로 설정하였고, 목표값 대비 평균제곱오차 성능지표 $F(x)$ 가 30%이상인 경우는 발생하지 않았다. 그러나, 검증용 패턴 100개에 대해서 오차율이 10~20%인 경우는 1단 은닉층(16)에서 1개, 1단 은닉층(32)에서 27개, 2단 은닉층(16,4)에서 22개가 발생하였다. 2단 은닉층(32,4) 구조에서는 진단 오차가 발생하지 않았다. 시계열 데이터 신경망 구조는 10%대의 오차를 발생하므로, 부분방전 발생 유무를 판단할 수 있다고 평가할 수 있다.

5.2 특성벡터를 사용한 경우

Table 4는 특성벡터를 입력벡터로 사용하는 4가지 인공신경망의 진단 결과이다.

[Table 4] Performance of ANN using feature vector

Number of Hidden Layers	Neurons	Patterns of 10% Error	Patterns of 30% Error	Patterns of 50% Error
One	(16)	22/100	4/100	0/100
	(32)	24/100	3/100	0/100
Two	(16,4)	23/100	3/100	0/100
	(32,4)	36/100	4/100	2/100


시계열 데이터를 사용하는 경우와 동일하게 식(1)의 목표값 t 를 0.05, 0.6, 0.7, 0.8, 0.9로 설정하였다. 검증용 패턴 100개에 대해서 목표값 대비 평균제곱오차 성능지표 $F(x)$ 가 10% 및 30% 인 경우는 모든 구조에서 발생하였고, 50%이상인 경우도 2단 은닉층(32,4)에서 2개 발생하였다. 전체적인 성능검증 결과는 시계열 데이터에 비해

정확성이 떨어진다.

5.3 시계열 입력단 구조 변경

시계열데이터 인공신경망 구조는 특성벡터 신경망 구조보다 진단 성능이 우수하지만 특성벡터 신경망에 비해 많은 연산 횟수가 필요하다. 따라서 시계열데이터 인공신경망 구조의 연산 횟수를 줄이고 진단 성능은 유지할 필요가 있다.

Fig. 9는 본 논문에서 제안한 최적 인공신경망 구조로서 연산 횟수를 줄이기 위해서 시계열 데이터에서 입력 벡터와 첫번째 은닉층의 연결 노드를 변형한 인공신경망이다. 부분방전 신호가 $0^\circ \sim 90^\circ$, $180^\circ \sim 270^\circ$ 위상구간에서 주로 발생하는 특징을 고려하여 시계열데이터를 64개씩 묶어서 1단 은닉층의 32개 뉴런에 연결하여 위상영역 정보를 유지하였다.



[Fig. 9] Modified ANN with two hidden layer using Time-series data

[Table 5] Performance of modified ANN with two hidden layer using Time-series data

Two Hidden Layers Structure	Neurons (32,4)	Patterns of 10% Error	Patterns of 30% Error	Patterns of 50% Error
		0/189	0/189	0/189
		0/100	0/100	0/100

Table 5는 Fig. 9의 시계열데이터를 사용한 2단 은닉층 구조의 변형된 신경망의 학습 결과 및 진단 결과이다. 학습에 사용된 189개의 부분방전 데이터에서 목표값 대비 평균제곱오차가 10%이상의 데이터는 발생하지 않았으며, 성능 검증용 데이터 100개에 대해서도 목표값 대비 평균제곱오차 성능지표 $F(x)$ 가 10%이상인 경우는 발생

하지 않았다. 따라서 Fig. 5 및 6의 시계열데이터 인공신경망에 비해 적은 연산 횟수로 개선된 진단 성능을 보인다.

6. 결론

본 논문은 인공신경망을 이용한 부분 방전의 진단 성능을 향상시키기 위해서, 신경망 구조 및 입력벡터의 특성과 진단 성능의 관계를 검토하였다. 신경망의 학습을 위한 DB 구축을 위해 다양한 형상의 전극조합을 이용하여 부분방전 신호를 검출하였다. 한주기에 2048번 샘플한 시계열 신호로 구성된 입력벡터와 기본파의 전체구간 및 $0 \sim 90^\circ$, $90 \sim 180^\circ$, $180 \sim 270^\circ$, $270 \sim 360^\circ$ 로 세분화된 4개 구간에서 평균값/최대값의 비율로 구성된 5개 특성값으로 구성된 입력벡터를 사용하는 경우의 인공신경망 진단 성능을 비교하였다. 그리고, 은닉층의 갯수 및 각층의 뉴런수를 변경한 인공신경망의 진단 성능을 비교하였다. 그 결과, 진단 성능은 인공신경망의 구조 및 입력벡터의 구성요소에 영향을 받음을 확인하였고, 2048개의 시계열 입력벡터를 32개 구간으로 나누어 입력하는 구조의 인공신경망이 다른 구조의 인공신경망보다 우수함을 검증하였다.

References

- [1] Hyun-Jin Lee, Jung-Il Jeong, Chang-Su Huh, Han-Goo Cho, "Analysis on Thermal Transfer Characteristics of 50 kVA Mold-Transformer," Journal of the Korea institute of Illuminating and Electrical Installation Engineers Vol.16, No.3 pp.47-54 May, 2002
DOI: <http://dx.doi.org/10.5207/JIEIE.2002.16.3.047>
- [2] M. Darveniza, T.K. Saha, D.J.T. Hill, T.T. Le, "Investigations into effective methods for assessing the condition of insulation in aged power transformers," IEEE Trans. on Power Delivery, Vol. 13, No. 4, pp. 1214-1223, October, 1998.
DOI: <http://dx.doi.org/10.1109/61.714487>
- [3] Tapan K. Saha, "Review of Modern Diagnostic Techniques for Assessing Insulation Condition in Aged Transformers," IEEE trans on Dielectrics and Electrical Insulation, Vol. 10, No. 5, pp. 903-917, October 2003.
DOI: <http://dx.doi.org/10.1109/TDEI.2003.1237337>
- [4] Dong-Jin Kweon, Kyo-Sun Koo, Joo-Sik Kwak, Jung-Wook Woo, Yeon-Woog Kang, "Establishment of Diagnostic Criteria in the Preventive Diagnostic System

- for the Power Transformer” The Trans. of KIEE ,Vol. 54A. No 9. pp 449~456. SEP 2005
- [5] Kim Doyoon, Jung Hosung, Park Young, Han Seokyoung, Lee Sang Bin, “A case study of condition monitoring for mold transformers on urban railway transit,” The Korean Society for Railway, Proceedings of Autumn Annual Conference,, pp. 235-240, Novemver, 2008.
- [6] Bong-Keun Oh, Hyun-Il Kim, Seong-Hwa Kang, Hee-Joe Lim, “Analysis and Test of On-line and Off-line PD Testing for High Voltage Ritating Machines Stator Windings using Ceramic Coupler,” Journal of the Korea Institute of Electrical & Electronic Material Engineers, Vol.20, No.10 pp.895~900 October 2007
DOI: <http://dx.doi.org/10.4313/JKEM.2007.20.10.895>
- [7] Young-Ki Chung, Jong-Wook Jung, Jae-Chul Kim, Hee-Ro Kwak, “FFT and AR Coefficient Analysis of Vibration Signal in Mold Transformer,” Journal of the Korea institute of Illuminating and Electrical Installation Engineers , Vol. 12, No. 4, pp.136-145, 1998.11.
- [8] Jong-Fil Moon, Jae-Chul Kim, Tae-Hoon Im, “Development of the Expert System for Diagnosing Silicone Oil-filled Transformer,” Journal of the korean institute of Illuminating and Electrical installation Engineers Vol, 18.No 2,pp. 55~62 March 2004
- [9] Dae-Jong Lee, Jong-Pil Lee, Pyeong-Shik Ji, Jae-Yoon Lim, “Fault Diagnosis of Power Transformer Using Support Vector Machine,” Journal of the korean institute of Illuminating and Electrical installation Engineers Vol, 23. No 2, pp. 62-69, February 2009
- [10] E. Howells, E. T. Norton "Detection of Partial Discharges in Transformers using Acoustic Emission Techniques" IEEE Transformers on Power Apparatus and Systems, Vol. PAS-97 No 5, Sept/Oct 1978
DOI: <http://dx.doi.org/10.1109/TPAS.1978.354646>
- [11] D.S. Kang, J.H. Sun, K.H. Cho.....S.M. Lee, Y.H. Yun., “ Development of Partial Discharge Measuring Sensor and System for Mold Transformer,” KIEE Proceedings of Fall Conference for Electrical Installation Committee, pp. 99-102, Novemberm 2005.
- [12] Chan-Yong Park, Sung-Wook Kim, Jae-Sung Choi, Dae-Won Park, Gyung-Suk Kil, “Comparison Analysis of Partial Discharge Detection Methods in Cast Resin Dry Type Transformers,” KIIEE Proceedings of Autumn Annual Conference, pp 301-306, Octorber 2008.
- [13] June-Ho Lee, Chin-Woo Yi, “Recognition of Partial Discharge Patterns,” Journal of the Korea institute of Illuminating and Electrical Installation Engineers Vol.14, No.2 pp.8-17 March, 2000.
- [14] Ho-Keun Lee, Jeong-Tae Kim, “Comparative Study on Neural Network Algorithms for Partial Discharge Pattern Recognition,” KIEE Proceedings of Spring Conference for Electrical Installation Committee, pp.109-112, May, 2005.
- [15] Martin T. Hagan , Howard B. Bemuth , Mark H. Beale (translated by Byun Younshik *et al.*), “ Neural Network Design,”, ISBN 9788956674452, Intervision Publishing, Korea, 2008.
- [16] Hyeong-Taek Jang, Sun-Geun Kwack, Pan-Seok Shin, Chang-Eob Kim, Gyo-Bum Chung, “Investigation of Simulation and Measuring Algorithm of Partial Discharge for Diagnosis of Electric Machinery Deterioration,” Journal of the Korean Institute of Illuminating and Electrical Installation Engineers, Vol.25 Np.8, pp. 30~38, August, 2011.
DOI: <http://dx.doi.org/10.5207/JIEIE.2011.25.8.030>

정 교 범(Gyo-Bum Chung)

[정회원]



- 1983년 2월 : 서울대학교 전기공학 졸업 (학사)
- 1985년 2월 : 서울대학교 대학원 전기공학과 졸업 (석사)
- 1992년 5월 : University of Florida 졸업 (박사)
- 1992년 6월 ~ 1993년 6월 : Virginia Tech (Post Doc.)
- 1993년 9월 ~ 1995년 1월 : 한국전기연구소 선임연구원
- 1995년 3월 ~ 현재 : 홍익대학교 전자전기공학과 교수

<관심분야>

전력전자, 전력품질, 인공신경망, 폐지제어, 신재생에너지

곽 선 근(Sun-Geun Kwack)

[정회원]



- 2009년 2월 : 홍익대학교 대학원 전기공학과 졸업 (석사)
- 2004년 9월 ~ 2006년 3월 : (주) 피에스디테크 근무
- 2006년 4월 ~ 2008년 2월 : 마이크로파워 근무
- 2009년 9월 ~ 현재 : (주)COMMAX 부설연구소 선임연구원

<관심분야>

전력품질, 인공신경망