

신경회로망을 이용한 절연열화의 수명추정 A Life Prediction of Insulation Degradation Using Neural Networks

이영삼^{*} 김성홍^{*} 심종탁^{*} 윤현주^{*} 임윤석^{*} 김재환^{*} 박재준^{**}
광운대학교 전기공학과^{*}
중부대학교 컴퓨터과학부^{**}

Young-Sang Lee^{*} Sung-Hong Kim^{*} Jong-Tak Sim^{*} Hun-Ju Yoon^{*} Yun-Suk Lim^{*}
Yun-Suk Lim^{*} Jae-Hwan Kim^{*} Jae-Jun Park^{**}
Dept. of Electrical Eng. Kwangwoon University^{*}
Dept. of Computer Sci. JoongBu University^{**}

<ABSTRACT>

In this paper, we obtained the data, which is required in training the neural network and diagnosing the degradation degree, by introducing the AE detection that is effective method in ordinary degradation diagnosis on activation. Automatic detection system to detect acoustic

As the results of generalization tests by applying neural network to the unknown AE patterns obtained from specimens, firstly as to evaluate an objective performance of neural network, the recognition ratio for no-void specimen is appeared. Also, in the evaluation for the adaptability of neural network with a untrained type of no-void specimen, it is confirmed that the result appears.

1. 서 론

전기설비 절연 열화진단은 전기에너지의 안정적 공급, 설비의 수명연장 측면에서 매우 중요하다. 그러나 운전중의 절연진단이 어려운 이유로 전력설비의 안전 확보와 사고 방지를 위한 예방진단 기술이 요구되고 있다. 본 연구에서는 진단의 자동화를 위하여 음향방출감지시스템을 이용 열화과정에서 얻은 데이터를 뇌의 정보처리 방식에 기초를 둔 신경회로망에 적용하여, 파라미터 학습에 의해 방전의 군소화 시점을 판별하였다. 부분방전 수명 예측에 대한 알고리즘은 백프로파게이션 인공 신경망을 적용하였다. 신경회로망의 일반화된 특성에는 병렬처리를 통한 정보처리가 가능한 추론 능력과 모호한 입력에 대응할수 있는 퍼지 추론 능력이 내재되어 있기에 부분 방전 수명 예측에 적용하기에 적합함을 보였다.

2. 시스템구성 및 실험

음향방출 감지 시스템의 블록선도는 그림2에서 표시하였다. 시스템의 인가전압은 교류60[HZ]이며 50[KV/s]로 음향방출 개시의 1.5배까지 승압한 후 일정하게 유지하였다. 음향센서는 최대 공진 주파수 480[KHZ]되는 PZT 변환기를 사용하였고 평판전극 바로 아래 10[mm]되는 장소에 설치하였다. 40[db]의 차동증폭기로 음향의 원신호를 증폭하고 80[Khz] High Pass Filter를 사용하였다. 문턱준위는 증폭된 신호를 0.03[V]로하여 음향신호를 얻었다. 위상각 특성을 보기 위해 인가전압을 고전압Probe(HP34300A)로 전압강하시켜 디지털 오실로스코프(HP54501)의 채널1에 입력시켰다.

증폭기를 통과한 음향방출 펄스는 동기화를 거쳐 인가전압 한 주기 동안의 펄스를 디지털 오실로스코프 채널2에 입력하여 인터페이스(GPIB Card)를 통하여 PC로 전송하고 각 펄스의 위상정보와 펄스 크기 정보를 얻는다. 음향방출의 평균 펄스는 인가 전압 1사이클을 정의 제로 크로스 점에서부터 40개의 위상창으로 구분하여 각 위상창 구간마다 1분 동안의 펄스 값을 평균하여 사용하였다. 데이터의 취득은 음향방출 개시 전압의 1.5 배를 인가한 후 2분에서 3분에 한번씩 총 10번에 걸쳐 음향방출 데이터를 얻었다

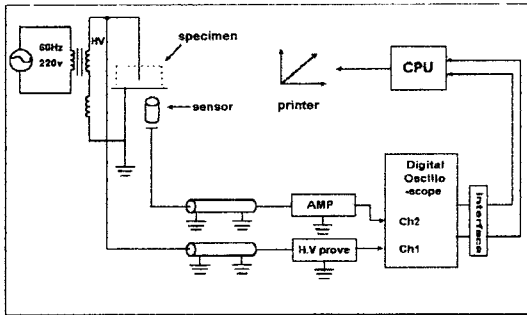


그림 1. 실험 장치 블록선도

Fig 1. Block Diagram of Experimental Device

3. 신경회로망 구성과 학습

3-1 신경회로망구성

신경회로망의 성능은 초기연결강도, 전처리 과정에서의 명확한 특성추출, 학습과정의 오차허용범위, 히든층의 뉴런수 등 여러 가지 요인에 의하여 영향을 받는다. 본 연구에서는 신경회로망은 12개의 입력뉴런 20개의 히든 뉴런 1개의 출력뉴런으로 구성하였고 오차 허용범위는 0.02 초기 연결강도는 난수발생기를 사용하여 초기값으로 사용하여 학습시키는 최적의 신경회로망을 구성하였다. 그림2는 신경회로망 구성을 나타낸 것이다. 적용하게될 역전파 학습이론은 미분의 반복규칙을 여러번 적용하여 확률 근사치를 유도해내는 알고리즘으로서 연결강도 공간의 결합점에서 오차의 표면이 기울기를 따라가는 방법이며, 일반화된 델타법이라고 한다.




그림 2. 3층 역전파 신경망의 구조

Fig 2. Structure of a three-layer back-propagation neural network




그림 3. 역전파 신경망의 활성화 함수 (시그모이드 함수)

Fig 3. Activation function for BP network (Sigmoid function)


3-2. 신경회로망 학습

본 연구에서는 부분 방전 분포의 형상을 나타내는 값으로 분포의 중심 G값과 경도 C값을 정의하여, 신경회로망 학습을 하여 파괴예지의 유효성을 검토하였다. 파라메타 학습에 의한 파괴예지의 판별기준은 G값이 증가하고 C값이 감소할 때 방전의 균소화가 일어나며 이때를 열화 초기라 하였다. 그림3은 신경회로망의 활성화 함수를 나타낸 것이다. G값과 C값의 변화양상을 통해 알 수 있는 방전 균소화 시점 패턴을 신경회로망에 학습을 시켰고 비슷한 양상의 패턴을 테스트 패턴으로 하여 신경회로망 적용을 통한 신뢰성을 평가해보았다.


4. 실험 결과 및 검토 고찰

그림4는 AEN(ϕ)와 AEA(ϕ) 분포는 음향방출 평균펄스수와 폭을 나타낸것이다.이 패턴은 절연 열화 과정에서 취득한 것으로 실험에서 데이터의 취득은 신경 회로망의 성능과 평가에 중요한 영향을 미치므로 본 논문에서는 한 시료에 대해 절연 열화 진행에 따른 패턴들을 취득해 사용하였다.

그림 5는 AEA와 AEN간의 G값의 시간 변화를 나타낸 그래프로서 7~10분 사이에 최초의 방전 군소화가 일어났고 이때에 파라메타를 이용하여 파괴를 예지해 보았다. 열화가 진행됨에 따라서 군소화가 몇번 더 발생하는 것은 열화 면적이 넓어져서 각각의 가지마다 독립적으로 방전이 발생하는 것으로 사료되며 G값이 적어지고 C값이 증가하는 것으로 보아 열화증기를 나타내고 있는 것으로 볼 수 있다.



(a) AEN(ϕ) 분포 패턴



(b) AEA(ϕ) 분포 패턴

그림4 AEA(ϕ)과 AEN(ϕ) 분포 패턴
Fig. 4. AEA(ϕ) and AEN(ϕ) distribution patterns

그림 6은 AEA와 AEN간의 C값의 시간변화를 나타내는 것으로서 6와 같이 위상 영역이 ϕ 8과 ϕ 9에서 C파라메타를 나타내는 것으로 7분에서 10분 사이에 C값이 감소하고 있음을 보여주고 있다. 이는 G파라메타와 비교하여 좋은 대조를 보여주고 있다. 그러므로 이 그림에서 파괴의 전조에 C값의 감소에 의해 파괴예지가 가능하다. 이와 같은 C값 G값은 같은 방전의 군소화를 포착하기 위한 값이기는하지만 G값보다는 C값이 보다 군소화를 명확히 표시하는 경우가 많다.




그림5. AEA(ϕ)와AEN(ϕ)간의 경도(G)의 시간변화

Fig.5. The Variation of C-parameter between AEA(ϕ) and AEN(ϕ) in each phase




그림6. AEA(ϕ)와AEN(ϕ)간의 경도(C)의 시간변화

Fig.6. The Variation of G-parameter between AEA(ϕ) and AEN(ϕ) in each phase

5. 결론

부분 방전 분포의 형상을 나타내는 값으로 분포의 중심 G값과 경도 C값을 통하여 방전의 군소화 지점을 알아내어, 실험을 통해 얻어진 파라미터값을 이용하여 신경회로망 학습을 통하여 수명예측을 할 수 있었다..

참 고 문 헌

1. L. A. Dissado and J. C. Fothergill, Electrical Degradation and Breakdown in Polymers, Peter Peregrinus, London, 1992
2. E. Gulski and F. H. Kreuger, Diagnostics of Insulation Systems using Statistical Tools, Conf. Rec. 1992 IEEE Inter. Symp. Elect. Insul. pp. 393~396, 1992
3. E. Gulski and A. Krivda, Neural Networks as a Tool for Recognition of Partial Discharge, IEEE Trans. Elect. Insul., Vol. 28, No. 6, pp. 984~1001, 1993
4. N. Hozumi, T. Okamoto and T. Imajo, Discrimination of Partial Discharge Patterns Using a Neural Network, IEEE Trans. Elect. Insul. Vol. 27, No. 3, pp. 550~556, 1992
5. E. Gulski and F. H. Kreuger, Computer-aided recognition of Discharge Sources, IEEE Trans. Elect. Insul. Vol. 27, No. 1, pp. 82~92, 1992
6. T. Okamoto and T. Tanaka, Change in Pulse-Mean Φ -Q Distribution Patterns of Partial Discharge due to Treeing Propagation, Trans. Insul. Elect. Eng. Japan, Vol. 102, No. 12, pp. 665~672, 1982
7. 김성홍, 박재준, 김재환. "부분방전 전하화 음향 방출 펄스의 동시 측정에 의한 트리잉 파괴진단", KIEE, Vol.10, No.3, pp.247~254. 1997