

신경회로망을 이용한 절연 열화진단에 관한 연구

박재준*

요 약

본 논문에서, 부분방전 메카니즘을 진단하고 그리고 신경망을 도입하여 수명을 예측하기 위한 기초연구로서, 온라인상에서 자동진단을 제안했다. 제안한 방법에서 우리는 음향방출 감지시스템과 그리고 펄스 수와 펄스진폭에의해서 정량적인 통계파라메타를 사용하였다. 통계적인 파라메타인 가령, 무게중심(G)와 방전분포 경도(C)를 이용하였고 그리고 초기단계와 중기단계에 대해서 분석하였다. 정량적인 통계파라메타들은 신경망에의해서 학습되어졌다. 초기단계에의해서 수명예측과 절연열화의 진단이 이루어졌다. 열화가 진행되는 동안 신경망 학습을 통한 훌륭한 진단능력이 있음이 근본적으로 드러났고, 신경망이 부분방전에있어서 절연진단 및 수명예측을 위해서 적절하다는 것이 증명되었다.

1. 서론

전력공급의 승압요청에 따라 전력기기(변압기, 케이블, 회전기 등)의 사용전압과 전류가 점점 고전압, 대전류의 추세이다. 절연시스템의 신뢰성은 절연체내부의 결함에 의존되는 상황이어느 때 보다 더욱 중요한 시점에 있다. 그러나 한번 결함이 발생하게 되면 결국 그런 결함부분이 부분방전으로 이어져 치명적인 손해를 미치게 된다. 이에대한 예방책으로서 결함을 탐지하는 방법으로 좀더 정확하고, 단순하며, 신뢰성이 높은 탐지법 및 탐지시스템의 연구개발이 절실히 요청되고있다.^[1]

이러한 열화를 미연에 예지하기 위한 전기 설비의 부분방전 열화진단과 수명예측은 설비의 수명 연장, 전기의 안정적 공급 등의 측면에서

매우 중요하다.

본 논문에서는 신경회로망을 이용하여 절연수명에 치명적인 역할을 하는 부분방전에 의한 절연열화를 진단하여 방지하고, 절연물의 조기수명예측을 목적으로 디지털 신호처리응용과 하드웨어 조합을 통하여 음향방출감지시스템을 구축하여 취득한 데이터를 통해 열화진단 및 수명을 예측하도록 하였다. 열화과정에서 얻은 음향신호를 검출하여 방전시 분포의 무게중심 G와 경도 C 파라메타를 구해 열화초기, 중기시점을 판별하여^{[2][3]} 뇌의 정보처리 방식에 기초를 둔 신경회로망에 적용하였다. 부분방전 열화 진단과 수명예측에 대한 알고리즘은 백프로가이션 인공 신경망을 적용하였다.^{[6][7]} 본 논문에서는 특정 위상각 범위(9°)마다 펄스 평균진폭을 나타내는 AEA 및 평균 펄스 수와 위상분포를 나타내는 AEN을 구하였다.^{[4][5]} AEA와AEN는 각각 두 개의 분포로 나눌수 있다. 양의 반주기에

* 중부대학교 정보공학부 조교수

서의 AEA^+ 와 AEN^+ 및 음의 반주기에서의 AEA^- 와 AEN^- 이다

II. 실험장치 및 방법

2.1. 실험장치

실험장치의 블록선도는 그림1에 표시하였다. 자체 제작한 음향방출 감지 시스템의 인가전압은 교류 60[Hz]이며 50[kVrms]까지 연속으로 변화시킬 수 있다. 전압 인가방식은 승압속도 1[kV/s]로 음향방출 개시의 1.5배 까지 승압한 후 일정하게 유지하였다. 고전압 회로는 음향방출 검출회로의 잡음을 일으킬 수 있는 코로나 방전을 억제하기 위하여 실리콘 오일에 함침하였다. 음향센서는 최대 공진 주파수 480[kHz]인 PZT 변환기를 사용하였고 평판 전극 바로 아래 10[mm]되는 위치에 설치하였다. 음향의 원 신호 자체는 너무 미약하여 40[dB]의 차동 증폭기로 증폭하고 80[kHz]의 High Pass Filter를 사용하였다. 설계시 최대한의 노이즈를 제거하였고 문턱 준위는 증폭된 신호를 3[mV]로하여 확실한 음향 신호를 얻을 수 있었다. 위상각 특성을 보기 위해 인가전압을 고전압 Probe(HP 34300A)로 전압을 강하시켜 디지털 오실로스코프(HP54501)의 채널1에 입력시켰다. 그렇게 한 후 음향방출 감지 시스템을 연결하여 동시에 측정하였다^[4].

증폭기를 통과한 음향방출 펄스는 동기화를 거쳐 인가전압 한 주기 동안의 펄스를 디지털 오실로스코프 채널4에 입력하여 인터페이스(GPIB Card)를 통하여 PC로 전송하고 각 펄스의 위상정보와 펄스 크기 정보를 얻는다. 음향

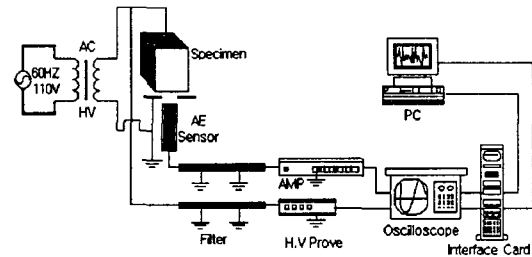


그림1. 실험 장치 블록선도

Fig.1. Block Diagram of Experimental Device

방출의 평균 펄스는 인가 전압 1사이클을 정의제로 크로스 점에서부터 43개의 위상창으로 구분하여 각 위상창 구간 마다 1분 동안의 펄스값을 평균하여 사용하였다.

III. 신경회로망 구성과 학습

3.1. 신경회로망구성

신경회로망의 성능은 초기연결강도, 전처리 과정에서 명확한 특성추출, 학습과정의 오차허용범위, 히든층의 뉴런수 등 여러 가지 요인에 의하여 영향을 받는다. 본 연구에서는 신경회로망은 12개의 입력뉴런 20개의 히든 뉴런 1개의 출력 뉴런으로 구성하였고 오차 허용범위는 0.02 초기 연결강도는 난수발생기를 사용하여 초기값으로 사용하여 학습시키는 최적의 신경회로망을 구성하였다.

그림2와 3은 신경회로망의 구성을 나타낸 것이다




그림2. 3층 역전파 신경망의 구조
 Fig. 2. Structure of a three-layer back-propagation neural network

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




그림3. 역전파 신경망의 활성화 함수 (시그모이드 함수)
 Fig. 3. Activation function for BP network(Sigmoid function)

초기라 하였다.그림3은 신경회로망의 활성화 함수를 나타낸 것이다. G값과 C값의 변화양상을 통해 알 수 있는 방전 균소화시점 패턴을 신경회로망에 학습을 시켰고 비슷한 양상의 패턴을 테스트 패턴으로 하여 신경회로망 적용을 통한 신뢰성을 평가해보았다.

3.3. 입력데이터의 특성추출

본 연구에서는 부분방전 분포의 형상을 나타내는 파라메타로서 분포의 중심 G값과 경도 C값을 정의하여 진단과 수명예측에 적용하였다. 그림4는 분포의 패턴과 파라미터 G-C와의 관계를 나타낸 것이다. 이들의 파라메타값은 파괴의 전조 현상이라 생각되어지는 방전의 균소화를 상징한다.




그림4. 분포의 패턴과 파라메타 C, G와의 관계
 Fig. 4. Relation between distribution patterns and parameters C and G.

파라메타에 의한 진단과 수명예측의 판별기준은 G값이^{[2][3]} 증가하고 C값이 감소할때 방전의 균소화가 일어나고 이때를 열화 초기라 하였고, 열화가 진행됨에 따라서 균소화가 몇 번 더 발

생하는 것은 열화면적이 넓어져서 각각의 가지마다 독립적으로 방전이 발생하는 것으로 사료되며, G값이 감소하고 C값이 증가하는 것으로 보아 열화증기를 나타내고 있는 것으로 볼 수 있다. 그림 5, 6 는 AEN과 AEA간의 경도 C와 분포의 무게중심 G의 시간에 따른 변화를 나타낸 것이다.




그림 5. AEN과 AEA간의 경도C의 시간변화
Fig. 5. The variation of C-parameter between AEN and AEA In each phase






그림6. AEN과 AEA간의 무게중심G의 시간변화
Fig. 6. The variation of G-parameter between AEN and AEA In each phase

학습대상 시료의 데이터 분포는 그림7, 8 에 표시하였으며 여기서 AEN과 AEA분포는 절연 열화 과정에서 취득한 패턴들이다.




(a) [AEN] 분포 패턴




(b) [AEA] 분포 패턴

그림7. 열화초기의 [AEN]과[AEA] 분포 패턴
Fig.7. [AEN] and [AEA] distribution patterns of the early degradation age



(a) [AEN] 분포 패턴


그림9은 구간에 따른 ϕ -AE 분포형태의 취득 데이터를 통계적 파라미터를 사용하여 분석한 결과들이다. 본 논문에서 신경회로망의 학습효율을 향상시키기 위하여 검출된 ϕ -AE에서 통계처리를 행하여 그림9과 같은 분포특성의 데이터를 추출하고, 이를 신경회로망의 입력으로 사용하였다.




(b) [AEA] 분포 패턴

그림8. 열화말기의 [AEN]과 [AEA] 분포 패턴
Fig. 8. [AEN] and [AEA] distribution patterns of the last degradation age

통계 연산자를 살펴보면 왜도(Sk)는 분포의 비대칭성을 나타내고, 첨쇄도(Kur)는 분포의 날카로움을 나타낸다.



(a) 열화초기 시료에 대한 입력데이터



(a) 열화말기 시료에 대한 입력데이터

그림9. 신경회로망 입력 데이터 분포
Fig.9. Input data distributions of a neural network

IV. 신경회로망의 학습과정과 성능평가

본 논문에서 사용한 신경 회로망은 다층구조로 한 개의 히든층과 입력, 출력층으로 구성하였다. 입력층은 12개의 뉴런으로 구성하였고, 히든층과 출력층은 각각 25개와 1개로 구성하였다. 제안된 시스템의 학습방법은역전파 알고리즘(back propagation algorithm)을 이용한 교사 학습법(supervised learning)을 사용하였으며, 초기 연결강도는 0과 1사이의 난수를 발생시키는 난수 발생기를 사용하여 지정하였다.

본 논문에서는 열화 진전도에 따른 두 패턴을 학습시켰으며, 각각의 패턴에 대한 학습패턴은 216, 215개로 하였다. 교사 학습을 위한 출력 값은 열화초기 시료의 경우는 0으로 설정하였으며, 열화말기 시료는 1로 설정하였다. 또한 수명예측을 위해 파괴 시간에 따른 두 패턴을 학습시켰으며, 각각의 패턴에 대한 학습패턴은 90개로

하였다. 40분이하 시료의 경우 0으로 설정하였으며, 50분이상의 시료는 1로 설정하였다. 또한 학습과정에서 출력의 오차가 ± 0.02 이하의 값으로 되면 신경망 학습을 종료하도록 하였다. 절연 열화 과정 중의 음향방출 펄스는 변화가 다양하고 일정하게 나오는 것이 아니기 때문에 학습 과정에서는 다소 오차를 허용함으로써 특이한 패턴에 의하여 연결강도가 크게 영향을 받지 않도록 하였으며 오차에 대한 의존성을 줄이면서 전체적인 성능 향상을 모색하였다.

신경 회로망의 성능은 객관적으로 평가가 되어야 하는데 본 논문에서는 학습에 사용되지 않은 패턴들의 신경망 응답 특성을 가지고 성능을 평가하였다 그림10,11 는 열화초기와 열화말기 시료에서 얻은 패턴들 중 신경 회로망 학습에 사용되지 않은 패턴들에 의한 응답 특성을 보여주고 있다. 열화초기 시료의 경우, 신경 회로망의 인식율은 출력 값을 0.02이하로 하였을때 98.5%의 인식율을 보였고, 열화말기 시료의 경우는 출력 값을 0.98이상으로 하였을때 93%의 인식율을 보였다. 그림12은 신경 회로망 학습에 전혀 사용되지 않은 형태의 열화중기 시료에서 얻은 \emptyset -AE패턴에 대한 분류 결과를 나타내고 있다.

기대 출력 값을 0.5로 하였을 때 신뢰도 90%의 출력 구간인 0.4~0.6에서의 인식율이 74%정도 보였다. 이는 직접 학습에 사용되지 않은 형태의 시료에 대한 신경망의 적응성을 나타내는 것으로서, 열화초기와 열화말기에 학습된 신경 회로망이 학습되지 않은 다른 단계의 열화진단에도 적용될 수 있음을 보이는 중요한 반응이다




그림 10. 열화초기 시료에 대한 응답특성
Fig. 10. Output characteristics of a neural network for the early degradation segment




그림 11. 열화말기 시료에 대한 응답특성
Fig. 11. Output characteristics of a neural network for the last degradation segment




그림 12. 열화중기 시료에 대한 응답특성
Fig. 12. Output characteristics of a neural network for the middle degradation segment

그림13,14는 40분 이하에서 절연 파괴된 시료에서 얻은 패턴과 50분 이상에서 파괴된 시료에 대한 신경 회로망 응답 특성을 보여주고 있다. 40분 이하에서의 경우 신경회로망의 인식율은 출력값을 0.1 이하로 하였을 때 91%의 인식율을 보였다. 50분이상에서의 경우는 기대출력값을 0.92로 하였을 때 94%의 인식율을 보였다. 역시 신경회로망의 성능을 객관적으로 평가 되어야 하기에 본 연구에서는 40분에서 50분 사이에 절연파괴된 시료를 바탕으로 평가하였다. 그림 15은 40분에서 50분사이의 학습에 전혀 사용되지 않는 시료에 대한 신경회로망의 응답 특성을 보여주고 있다. 기대 출력값을 0.5로 하였을 때 신뢰도 구간 90% 출력구간인 0.4 ~ 0.6 사이에서 인식율은 78 % 정도 보였다




그림 13. 40분 이하 시료에 대한 응답특성
Fig. 13. Output characteristics of a neural network for the segment less than 40min.




그림 14. 50분 이상 시료에 대한 응답특성
Fig. 14. Output characteristics of a neural network for the segment more than 50min.




그림 15. 40분에서 50분 사이 시료에 대한 응답특성
Fig. 15. Output characteristics of a neural network for the segment between 40min and 50min.

V. 결론

본 논문에서는 신경회로망을 도입하여 부분방전 메커니즘의 열화진단 및 수명예측을 위한 온라인 자동진단의 기초연구를 제안하였다. 제안된 방법은 신경 회로망을 이용하여 부분방전시

음향방출 패턴을 학습시켰고, 미지의 AE 펄스 패턴을 이 패턴과 대응시켜 진단과 수명예측을 수행하였다.

1. 열화진단을 위해 학습에 사용되지 않은 미지의 AE 패턴들에 대한 신경망의 일반화 시험에서 열화초기 시료는 98.5%의 인식율을, 열화말기 시료는 93%의 인식율을 보였으며 미학습 모델인 열화중기 시료에 대하여 신경 회로망으로 판별한 결과 기대 출력 값을 0.5로 하였을 때 90% 신뢰도에서 74%의 인식율을 가짐을 확인하였다.
2. 수명예측을 위해 학습에 사용되지 않은 미지의 AE 패턴들에 대한 신경망의 일반화 시험에서 파괴시간이 40분이하인 시료들에 대한 인식율은 91%, 50분이상인 시료들에 대한 인식율은 93%를 보였으며 미학습 모델인 40분-50분대에 대하여 신경 회로망으로 판별한 결과 기대 출력 값을 0.5로 하였을 때 90% 신뢰도에서 78%의 인식율을 가짐을 확인하였다.

신경회로망 학습을 통해 절연열화시의 패턴들의 인식능력의 우수성이 나타났고, 이를 바탕으로 부분방전시 절연재료의 열화진단과 수명예측이 가능함을 확인하였다. 앞으로 학습되지 않았거나 학습된 패턴에 비해 변형이 크게 된 패턴에 대한 관련성을 인정하는 퍼지이론의 적용, 최근 등장한 웨이브렛(wavelet) 이론, 카오스이론 등의 도입과 많은 양의 패턴으로 충실한 학습데이터 축적이 이루어지면 진단의 자동화와 효율적인 진단이 가능한 장치의 개발에 도움이 되리라 사료된다.

참고문헌

1. 박재준, "음향방출계측법을 이용한 트리잉 파괴진단에 관한 연구", 광운대학원 박사학위논문, 1993
2. L. A. Dissado and J. C. Fothergill, *Electrical Degradation and Breakdown in Polymers*, Peter Peregrinus, London, 1992
3. Masumi Ito, Tairo Ito, Takao Sakai, Youshiyasu Ehara, "Prediction of Breakdown by Void Discharge Aging," *電學論A*, Vol.110, No.11, pp.773~780, 1990
4. Koji Urano, Youshiyasu Ehara, Haruo Kishida, Tairolto, "Analysis of Treeing Phenomena by Discharge magnitude and Discharge Luminescence in Each Phase Angle," *電學論A*, Vol.115, No.11, pp.1151~1156, 1995
5. 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
6. 박재준, 김성홍, 김재환. "부분방전 전하와 음향방출 펄스의 동시 측정에 의한 트리잉 파괴진단", *KIEE*, Vol.10, No.3, pp.247~254. 1997
7. H. Suzuki, T. Endoh, "Pattern Recognition of Partial Discharge in XLPE Cables Using a Neural Network", *IEEE Trans. Elect. Insul*, Vol.27, No.3, pp.543~549, June 1992
8. R. Bozzo. C. Gemme. F. Guastavino. L.

Sciutto, "Diagnostic by Means of Neural Networks Having Inpus Derived from the Statistical Analysis of PD Patterns", Conf. Rec. 1996 IEEEInter. Symp. Elect. Insul. pp.389~392, 1996

9. 김성홍, 최재관, 김재환, "신경망을 이용한 보이드 결함에 의한 열화진단", 한국전기전자재료학회논문지, Vol.11. No.10, pp.940-946. 1998.

A Study on Insulation Degradation Diagnosis Using a Neural Network

Jae-Jun Park*

Abstract

In this paper, we purpose automatic diagnosis in online, as the fundamental study to diagnose the partial discharge mechanism and to predict the lifetime by introduction a neural network. In the proposed method, we use AE(acoustic emission) sensing system and calculate a quantitative statistic parameter by pulse number and amplitude. Using statically parameters such as the center of gravity(G) and the gradient of the discharge distribute(C), we analyzed the early stage and the middle stage. the quantitative statistic parameters are learned by a neural network. The diagnosis of insulation degradation and a lifetime prediction by the early stage time are achieved

On the basis of revealed excellent diagnosis ability through the neural network learning for the patterns during degradation, it was proved that the neural network is appropriate for degradation diagnosis and lifetime prediction in partial discharge.

* Division of Information Engineering, Joongbu University.