

신경망을 이용한 보이드 결함에 의한 열화진단

논문
11-10-30

Degradation Diagnosis by Void Defects Using a Neural Network

최재관*, 김성홍*, 김재환*

(Jae-Kwan Choi, Sung-Hong Kim, Jae-Hwan Kim)

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.

As the results of generalization tests by applying neural network to the unknown AE patterns obtained from two kinds of specimen, firstly as to evaluate an objective performance of neural network, the recognition ratio for no-void specimen and 1[mm]-void specimen are appeared to be 98.9% and 92.5%, respectively. Also, in the evaluation for the adaptability of neural network with a new type of 0.2 [mm] -void specimen, it is confirmed that the result appears to be 64% of recognition ratio at 90% of confidence interval coefficient in expectation output 0.2. On the other hand, the recognition capability of the neural network was confirmed by combined data from no-void and 1[mm] void specimen.

The results prove the promising possibility of the application of ANN to discriminate specific void affecting as a main degradation source at partial discharge condition in insulator containing multi-void, by accumulated data base.

Key Words(중요 용어) : AE pattern(음향방출 패턴), Neural Networks(신경망), degradation diagnosis(열화 진단)

1. 서 론

최근 급속히 증가하는 전력 수요에 부응하고자 전력계통의 송압화가 이루어지고 있으며, 또한 송압된 송·배전 계통에 사용되는 전력기 기들의 절연재료로는, 전기적 특성이 우수한 고분자 절연재료가 사용되고 있다.

이러한 고분자 절연재료를 사용하여 절연 제품을 만드는 공정 중에 발생한 결함이나 열악한 사용 환경에 따라 생성된 결함들은 절연 성능을 저하시키

는 원인으로 작용하는데, 보이드(void)나 공동(cavity)은 그 대표적인 결함으로서 전로파괴를 일으킬 수 있는 부분방전 열화를 일으킨다¹⁾.

본 논문은 신경 회로망을 이용하여 전력기기용 절연재료내의 보이드 결함에 의한 열화를 온라인(on-line)으로 자동적으로 진단하기 위한 방안을 제안하고자 한다. 제안된 방법은 부분방전시의 음향신호를 검출하여 전처리 과정으로서 통계적 연산자를 이용하였고 시료에 따른 그 특성을 인공 신경망을 이용하여 조사하였다. 이 방법은 위상각의 함수로 된 펄스의 분포를 측정하여, 이 분포를 발생시키는 현상에 대한 정보를 취득하는 방식이다²⁾³⁾⁴⁾. 따라서 위상각 축을 나타내는 위상창으로 전압파형이 나누어질 수 있다⁵⁾. 지금, 음향방출 펄스의 평

* : 광운대학교 신기술연구소
(서울시 노원구 월계동 447-1, Fax:02-942-0107
E-mail : polymers@chollian.net
1998년 4월 27일 접수, 1998년 7월 27일 심사완료

균진폭을 시료에 인가한 전압의 0 점을 기준으로 한 음향방출 펄스의 발생위상각을 ϕ 로 정의하였고 펄스 평균진폭은 디지털 오실로스코프를 이용하여 어느 시간(1분)마다 평균한 값이다. 본 논문에서는 위상각 함수로서 특정 위상각 범위(9°)마다 펄스 평균진폭을 나타내는 $H_{an}(\phi)$ 및 평균 펄스 수와 위상분포를 나타내는 $H_n(\phi)$ 을 구하였다⁶⁾⁷⁾

$H_{an}(\phi)$ 와 $H_n(\phi)$ 는 각각 두개의 분포로 나눌 수 있다. 양의 반주기에서의 $H_{an}^+(\phi)$ 와 $H_n^+(\phi)$ 및 음의 반주기에서의 $H_{an}^-(\phi)$ 와 $H_n^-(\phi)$ 이다.

2. 시편제작 및 실험장치

본 실험에 사용된 시편은 저밀도 폴리에틸렌(이하 LDPE)으로서 밀도 $0.92[g/cm^3]$ 인 펠렛(Pellet)을 사용하였다. 순수한 LDPE 펠렛을 자체 제작한 시료 제작기의 주형 위에 올려놓고 $120[^\circ C]$ 에서 5분간 예열한 후 시료 중앙에 바늘을 꽂고 압력이 $100[kgf/cm^2]$ 가 될 때까지 5분간 단계적으로 가압하였다. 다시 5분 동안 주형을 가열한 후 시료의 투명도를 위하여 $10[^\circ C]$ 의 물에서 급냉 하였다.

시편의 규격은 $30 \times 40 \times 3.5[mm^3]$ 이며 전극의 형태는 극간 거리가 $2[mm]$ 인 침대 평판 전극이다. 침전극은 직경 $0.56[mm \phi]$ 인 스테인레스 스틸 재질의 바늘을 예칭법에 의해 침 선단 곡률 반경 $5[\mu m]$ 로 예칭하여 시편에 고정하였고 평판전극은 실버 페스트(Silver Paste)로 도포하여 사용하였다. 시편의 종류는 무보이드 시편과 보이드 시편($0.2, 1[mm]$)을 사용하였는데, 이때 보이드 시편의 제조과정은 무보이드 시편에서 전극을 빼내어 다시 삽입함으로써 인공적인 보이드를 만들었다. 이때 주입된 공기는 1기압으로 하였다.

실험장치의 블록선도는 그림1에 표시하였다. 자체 제작한 음향방출 감시 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 감시 시스템을 연결하여 동시에 측정하였다⁸⁾

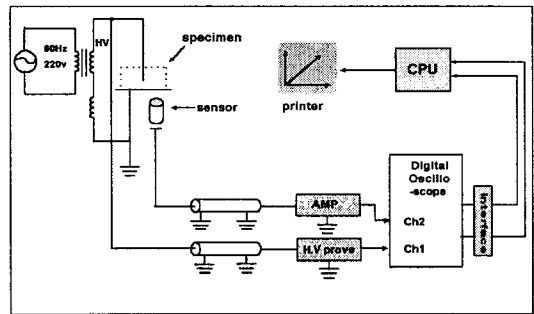


그림 1. 실험 장치 블록선도

Fig. 1. Block Diagram of Experimental Device

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 인가전압 1사이클을 정의 제로 크로스 점에서부터 40개의 위상상으로 구분하여 각 위상상 구간마다 1분 동안의 펄스 값을 평균하여 사용하였다. 데이터의 취득은 음향방출 개시 전압의 1.5배를 인가한 후 2에서 3분에 한번씩 총 10번에 걸쳐 음향방출 데이터를 얻었다

3. 절연 결함 분류를 위한 신경 회로망 학습과정

본 논문에서 사용한 신경 회로망은 다층구조로 한 개의 히든층과 입력, 출력층으로 구성하였다. 입력층은 13개의 뉴런으로 구성하였고, 히든층과 출력층은 각각 30개와 1개로 구성하였다. 제안된 시스템의 학습방법은 역전파 알고리즘(back propagation algorithm)을 이용한 교사 학습법(supervised learning)을 사용하였으며, 초기 연결

강도는 0과 1사이의 난수를 발생시키는 난수 발생기를 사용하여 지정하였다. 그림2에 3층 역전파 신경망 구조를 나타내었고, 그림3에 역전파 신경망의 활성화 함수를 나타내었다.

본 논문에서는 두 종류의 보이드 패턴을 학습시켰으며, 각각의 보이드 패턴에 대한 학습패턴은 340개로 하였다. 교사 학습을 위한 출력 값은 무보이드 시료의 경우는 0으로 설정하였으며, 1[mm] 보이드 시료는 1로 설정하였다. 또한 학습과정에서 출력의 오차가 ± 0.02 이하의 값으로 되면 신경망 학습을 종료하도록 하였다.

패턴인식과 같이 일반적으로 원형(prototype)이 정해져 있는 경우에 오차는 가능한 0에 가깝게 수렴시키는 것이 바람직하다. 그러나, 절연 열화 과정 중의 음향방출 펄스는 변화가 다양하고 일정하

게 나오는 것이 아니기 때문에 본 논문의 학습 과정에서는 다소 오차를 허용함으로써 특이한 패턴에 의하여 연결강도가 크게 영향을 받지 않도록 하였으며 오차에 대한 의존성을 줄이면서 전체적인 성능 향상을 모색하였다.

학습 대상 시료의 데이터 분포는 그림 4, 5에 표시하였으며 여기서, $H_{an}(\Phi)$ 와 $H_n(\Phi)$ 분포는 절연 열화 과정에서 취득한 패턴들이다. 실험에서 데이터의 취득은 신경 회로망의 성능과 평가에 중요한 영향을 미치므로 본 논문에서는 한 시료에 대해 절연 열화 진행에 따른 10개의 패턴들을 취득해 사용하였다.




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)



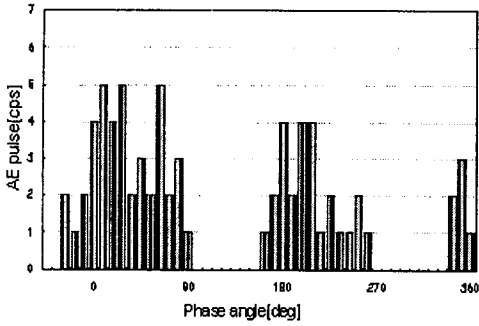
(a) $H_n(\Phi)$ 분포 패턴




(b) $H_{ax}(\Phi)$ 분포 패턴

그림 4. 무보이드의 $H_n(\Phi)$ 와 $H_{an}(\Phi)$ 분포패턴

Fig. 4. $H_n(\Phi)$ and $H_{an}(\Phi)$ distribution patterns of no void



(a) $H_n(\phi)$ 분포 패턴




(b) $H_{an}(\phi)$ 분포 패턴

그림 5. 1[mm] 보이드의 $H_n(\phi)$ 와 $H_{an}(\phi)$ 분포 패턴


Fig. 5. $H_n(\phi)$ and $H_{an}(\phi)$ distribution patterns of 1[mm] void

그림 6은 시료에 따른 ϕ -AE 분포 형태의 취득 데이터를 통계적 연산자를 사용하여 분석한 결과들이다. 본 논문에서는 신경 회로망의 학습효율을 향상시키기 위하여 검출된 ϕ -AE에서 통계처리하여 그림 6과 같은 분포특성의 데이터를 추출하고, 추출된 데이터를 신경 회로망의 입력으로 사용하였다. 통계 연산을 살펴보면 왜도(Sk)는 분포의 비대칭성을 나타내고, 첨쇄도(Kur)는 분포의 날카로움을 나타낸다.

그리고 양주기와 음주기의 $H_{an}(\phi)$ 와 $H_n(\phi)$ 의 분포를 분석하기 위하여 다음과 같은 통계학적 연



(a) 무보이드 시료에 대한 특성 분포



(b) 1[mm] 보이드 시료에 대한 특성 분포

그림 6. 그림 4와 5의 위상 위치분포인 $H_n(\phi)$ 와 $H_{an}(\phi)$ 에서 얻은 특성 분포

Fig. 6. Feature distribution for the phase-position distribution of $H_n(\phi)$ and $H_{an}(\phi)$ shown in Fig. 4 and 5.

산자를 사용한다. 방출 계수(Q)는 양주기와 음주기의 음향방출 평균 방출레벨 $H_{an}(\phi)$ 의 지수이다.

Q가 1이면 같은 방출 레벨이며, Q가 0이면 완전히 다른 방출 레벨이다.

위상계수(ϕ)는 양주기와 음주기 내의 $H_n(\phi)$ 분포의 개시 전압의 차를 조사하는데 사용된다.

상호 상관계수(cc)는 $H_n^+(\phi)$ 와 $H_n^-(\phi)$ 분포 형태의 차이를 평가하는데 사용된다.

cc = 1은 100% 위상대칭을 의미한다. 그리고 cc = 0은 완전한 비대칭을 가르킨다. 그러나 cc는 우리에게 분포의 높이에 대한 어떤 것도 알려주지 않는다. 이 변수들 둘 다는 완전 대칭분포의 경우에는 1이고 비대칭 분포의 경우는 1보다 훨씬 더 작

다고 정의한다. 그러므로, 몇몇 비대칭 factor들은 서로 곱할 수 있다. 그 결과 연산자 수정 상호상관 계수(mcc)가 도입되었다. mcc는 양주기와 음주기에서 음향방출 패턴들 사이의 차를 평가하는데 사용되는데, mcc는 Q, cc의 곱으로 정의된다.

$$mcc = Q \cdot cc$$

4. 신경 회로망의 성능 평가

신경 회로망의 성능은 초기 연결강도, 전처리 과정에서 명확한 특성 추출, 학습과정의 오차 허용 범위, 히든층의 뉴런수 등 여러 가지 요인에 의하여 영향을 받는다. 본 논문에서 신경 회로망은 13개의 입력 뉴런, 30개의 히든 뉴런, 1개의 출력 뉴런으로 구성하였고 오차 허용 범위는 0.02, 초기 연결강도는 난수 발생기를 사용하여 초기값으로 사용하여 학습시키는 신경 회로망을 구성하였다.

신경 회로망의 성능은 객관적으로 평가가 되어야 하는데 본 논문에서는 학습에 사용되지 않은 패턴들의 신경망 응답 특성을 가지고 성능을 평가하였다. 그림 7과 8은 무보이드와 1[mm] 보이드 시료에서 얻은 패턴들 중 신경 회로망 학습에 사용되지 않은 패턴들에 의한 응답 특성을 보여주고 있다. 무보이드 시료의 경우, 신경 회로망의 인식율은 출력 값을 0.02이하로 하였을 때 98.9%의 인식율을 보였고, 1[mm] 보이드 시료의 경우는 출력 값을 0.98이상으로 하였을 때 92.5%의 인식율을 보였다.

그림 9는 신경 회로망 학습에 전혀 사용되지 않은 형태의 결함인 0.2[mm] 보이드 시료에서 얻은 \emptyset -AE패턴에 대한 분류 결과를 나타내고 있다.

기대 출력 값을 0.2로 하였을 때 신뢰도 90%의 출력 구간인 0.1 ~ 0.3에서의 인식율이 64%정도 보였다. 이는 직접 학습에 사용되지 않은 형태의 시료에 대한 신경망의 적응성을 나타내는 것으로서, 무보이드와 1[mm] 보이드에 학습된 신경 회로망이 학습되지 않은 다른 형태의 보이드 열화 판별에도 적용될 수 있음을 보이는 중요한 반응이다.




그림 7. 무보이드에 대한 신경 회로망의 응답 특성
Fig. 7. Output Characteristics of neural network for no void

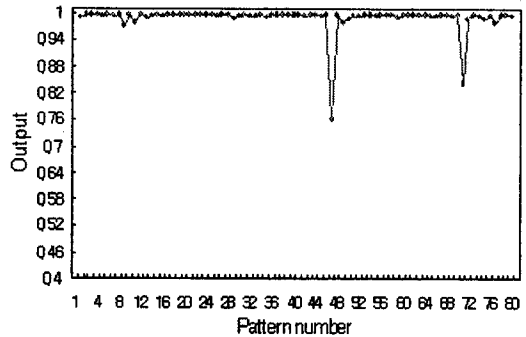


그림 8. 1[mm]보이드에 대한 신경 회로망의 응답 특성
Fig. 8. Output Characteristics of neural network for 1[mm] void

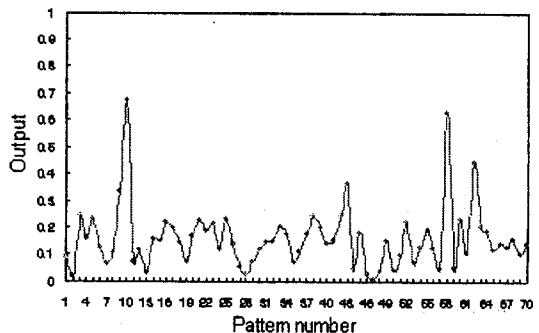


그림 9. 0.2[mm] 보이드에 대한 신경 회로망의 응답 특성
Fig. 9. Output Characteristics of neural network for 0.2[mm] void

신경 회로망의 인식 능력을 확인하기 위해, 두 결함에서 취득한 데이터를 조합한 데이터를 신경 회로망에 입력하였는데, 그에 대한 응답비를 그림 10과 같이 측정하였다.

P_i 를 입력층에서의 i 번째 입력 패턴이라 하고 P_{ai} 와 P_{bi} 는 각각 무보이드와 1[mm] 보이드 결함에서 얻은 i 번째 입력패턴이라 하면, P_i 는 다음과 같이 된다.

$$P_i = P_{ai} \cdot w_a + P_{bi} \cdot w_b$$

여기서, $w_a + w_b = 1$ 이고 w_a 와 w_b 는 무보이드와 1[mm] 보이드의 가중치를 나타내는 양의 실수이다. 그림 10은 w_a 에 대한 응답비를 나타내고 있다. w_a 는 무보이드 데이터에 대한 1[mm] 보이드 데이터의 데이터 조합비로 결정된다. 1[mm] 보이드에 대한 인식비는 가중치가 0.45를 넘어설 때 급격히 감소하여 무보이드 반응과 반대로 되는데, 여기서 무보이드와 1[mm] 보이드에 대한 반응이 거의 100%에 가까운 상태는 각각의 가중치가 어느 한쪽으로 치우쳐 있을 때이고, 감소하거나 증가하면서 서로 교차하는 영역은 가중치가 서로 비슷할 때이다.

이것으로 우리는 두 결함 중에서 한 결함의 신호 집중도가 다른 결함보다 강하게 되면 신경 회로망의 출력은 더 우세한 쪽으로 출력을 낸다는 것을 알 수 있다.




그림 10. 두 결함의 입력 패턴 조합에 대한 인식비
Fig. 10. Recognition ratio for the combination of the input pattern of no void and 1[mm] void

이 결과는 대부분의 다중 결함을 가지고 있는 절연체 내에서 절연 열화가 발생할 때 주 열화 상태에 있는 특정 방전 원에 대한 정보와 이에 따른 적절한 절연 열화 상태 판정의 가능성을 보여주고 있다.

5. 결 론

본 논문에서는 절연열화 진단의 자동화를 위한 기초 연구로서, 신경 회로망을 이용하여 기기용 절연재료내의 보이드 결함에 따른 열화를 온라인(on-line)으로 진단하기 위한 방안을 제안하였다. 제안된 방법은 신경 회로망을 이용하여 부분방전시 음향방출 패턴을 학습시켰고, 미지의 AE 펄스 패턴을 이 패턴과 대응시켜 진단을 수행하였다. 또한 본 논문에서는 활선상에서 열화진단 측정에 효과적인 방법인 초음파 검출법을 적용하여 신경망 학습과 진단에 필요한 데이터를 얻었다.

1. 학습에 사용되지 않은 미지의 AE 패턴들에 대한 신경망의 일반화 시험에서 무보이드 시료는 98.9%의 인식율을, 1[mm] 보이드 시료는 92.5%의 인식율을 보였다.
2. 미학습 모델인 0.2[mm] 보이드에 대하여 신경 회로망으로 판별한 결과 기대 출력 값을 0.2로 하였을 때 90% 신뢰도에서 64%의 인식율을 가짐을 확인하였다.
3. 다중 보이드를 갖는 절연체에서 부분방전시 주 열화 요인으로 작용하는 특정 보이드를 신경 회로망 학습을 통하여 판별이 가능함을 확인하였다.

앞으로 판정 기준의 경계부근에서 판단이 명확히 구분되는 단점을 보완하기 위한 판정경계 전후에 여유치를 고려하는 퍼지이론의 도입과 많은 양의 패턴으로 충실한 학습 데이터 베이스 축적이 이루어지면 진단의 자동화와 효율적인 진단이 가능한 장치의 개발에 도움이 되리라 사료된다.

감사의 글

본 연구는 한국전력공사의 지원에 의하여 기술전력공학 공동연구소(96-014) 주관으로 수행되었으며 이에 감사드립니다.

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 전하와 음향방출 펄스의 동시 측정에 의한 트리잉 파괴진단", KIEE, Vol.10, No.3, pp.247~254. 1997