

## 모의결함을 갖는 고체절연체에서 발생하는 부분방전 및 패턴분류

박성희, 이강원, 박재열, 강성화\*, 임기조  
충북대학교, 충청대학\*

### Classification of PD Signals Generated in Solid Dielectrics by Neural Networks

S.H.Park, K.W.Lee, J.Y.Park, S.H.Kang\*, K.J.Lim  
Chungbuk National University, Chungchong college

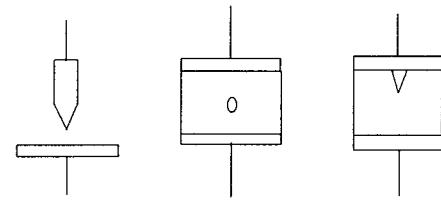
**Abstract** - The recognition of PD(Partial Discharge) phenomenon is useful for classification of defects. The distribution of stochastic parameters which consisted of those PD pulses data and pulses train can show discriminable characteristics of PD sources. But it is not sufficient to discriminate among to PD sources. In this paper, we suggests that classification method of PD source by NN(Neural Networks) are good tools for differentiate of those. The learning scheme of NN is (Back Propagation learning algorithm(BP).

#### 1. 서 론

절연물에 있어서 열화의 정도를 판별할 수 있는 부분방전(PD)은 전로 파괴되기 전의 부분적인 파괴가 발생하는 것으로 크기는 작지만 점진적인 열화로 인해 전로 파괴를 유발하게 된다. 결국 전로 파괴의 발생은 전력시스템의 사고를 유발시켜 큰 장해를 초래하게 된다. 부분방전은 고체, 액체, 기체등 모든 절연물에서 발생이 되며 부분방전 발생에 따른 특성 파라미터들은 절연의 전단에 있어서 이용이 많이 되고 있다. 부분방전의 통계적 파라미터로서 사용되는 여러 값들은 방전 발생시의 정확한 분류를 위해 평거프린트 및 신경망 학습알고리즘에 응용이 되고 있다. 하지만 실제적으로 현장에 적용하기에는 상당한 제약이 있긴 하지만, 이에 대한 연구도 활발히 진행이 되고 있는 실정이어서 앞으로 상당히 강력한 툴로 적용이 될 것으로 예상이 되고 있다. 본 논문은 부분방전 발생으로부터 얻은 방전데이터를 통계적 파라미터를 통해 구현하고 이를 토대로 신경망에 적용을 하였다. 신경망(Neural Networks - NN) 적용 알고리즘은 BP 학습알고리즘(Back propagation learning algorithm)을 사용하였다. BP 알고리즘은 역전파 알고리즘으로서 그것의 기본원리는 입력패턴이 들어오면, 이 신호는 각 유니트에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 기댓값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다. BP 학습알고리즘이 지역최소값에 빠지거나 많은 양의 학습데이터가 필요하다거나 하는 단점이 있지만 부분방전의 분류에 있어서는 좋은 결과를 보이고 있어 많은 이용이 되고 있는 실정이다. 본 논문에서의 실험은 케이블에서 발생할 수 있는 방전의 종류를 모의할 수 있도록 세 가지 결합에 대한 실험을 하고 데이터를 취득하여 분석하였다.

#### 2. 실험장치 및 데이터 취득

##### 2.1 모의결함 전극 형태



(a) air discharge (b) void discharge (c) treeing  
그림 1. 모의 전극

실험은 전력용 케이블의 connector 부분의 방전을 모의하기 위해 기증 침대 평판 구조의 전극을 사용하여 부분방전 데이터를 취득하였다. 케이블 절연물 내의 보이드가 존재할 경우의 모의를 위하여 LDPE Sheet( $50 \times 50 \times 3.5\text{mm}$ )에 보이드( $1 \times 1.5\text{mm}$ )를 인위적으로 생성시켜 그 때 발생하는 방전에 대한 데이터를 취득하였다. 또한 전력용 케이블의 Treeing 방전을 모의하기 위하여 도체에 돌기가 존재할 경우를 설정하여 LDPE Sheet의 고압부의 전극부분에 침을 삽입하여 Tree가 발생하도록 하여 부분방전 데이터를 취득하였다. 그림 2는 부분방전 발생시의 신호를 검출하는 Block diagram을 나타내고 있다

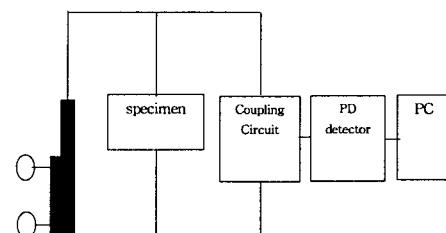


그림 2. Block diagram of experimental setup

##### 2.2 PD Data 취득

PD 데이터는 PD Detector(BIDDLE사)시스템을 이용하여 취득하였으며, 이를 이용해 데이터에 대한 분석을 하였다. 각각의 방전 데이터들은 적당한 과정을 거쳐  $\Phi(\text{위상각})-q(\text{방전량})-n(\text{방전회수})$ 로 나타내었으며 이를 이용해 특성파라미터를 산출한 후 그를 이용해 신경망에 적용을 하였다. 본 논문에서 사용된 특성 파라미터들은 첨예도, 웨도, 상관계수 등이며 이는 방전의 특성을 구별하는데 있어서 유용한 데이터로 사용이 되었다. 그림 3은 PD 신호의 처리과정을 보여주고 있다.

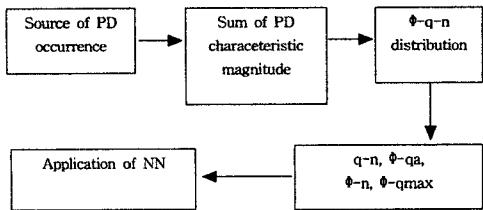


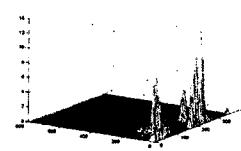
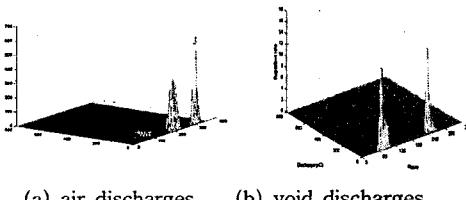
그림 3. Block-diagram for PD signal processing

### 2.3 BP 학습알고리즘

Back propagation 학습 알고리즘은 기본적으로 다층 퍼셉트론(Multi layer perceptron-MLP)에 기반을 두고 있다. MLP는 입력층과 출력층 사이에 하나 이상의 중간 층이 존재하는 신경망이다. 입력층과 출력층 사이의 중간 층을 은닉층(hidden layer)라고 부른다. 네트워크는 입력층, 은닉층, 출력층 방향으로 연결되어 있으며, 각 층 내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향 네트워크다. 일반적인 다층 퍼셉트론의 학습 방법은 입력층의 각 유니트에 입력 데이터를 제시하면 이 신호는 각 유니트에서 변환되어 중간 층에 전달되고 최종적으로 출력층으로 나오게 된다. 이 출력값과 원하는 출력값을 비교하여 그 차이를 줄여나가는 방향으로 연결강도를 조정하는 것이다. BP 학습 알고리즘은 기본적으로는 MLP의 학습구조 기반에서 진행이 되지만 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다는 특징이 있다.

### 3. 통계적 파라미터 분포

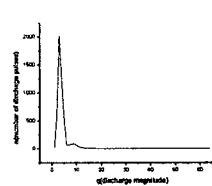
방전양과 방전의 강도에 대한 관계는 3차원적 통계적 분포에 대한 display 방식과 2차원적인 display 방식의 두 종류를 이용하였다. 3차원적인 해석은  $\Phi$ (phase)-q (discharge magnitude) - n(number of pulses)으로 나타내며 이것은 세 경우의 파라미터들의 상관관계를 파악하는데 용이하다. 하지만 일반적으로 부분방전의 분류를 위한 분포는 2차원적인 통계적 분포를 사용한다. 2차원 통계분포는  $q-n$ ,  $\Phi-n$ (average discharge magnitude),  $\Phi-n$ ,  $\Phi-q_{\max}$ (maximum value of discharge)를 사용하였다. 이 네 경우의 분포 중에 분포의 형태가 양호하고 특징을 잘 표현할 수 있는  $q-n$  distribution과  $\Phi-n$  distribution이 BP 학습 알고리즘을 위한 통계적 분포 데이터로서 사용이 되었다. 그림 4 ~ 7은 통계적 분포의 3차원적인 그래프와 2차원적인 그래프를 나타내고 있다.



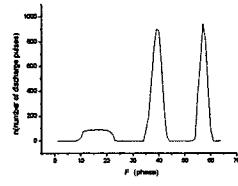
(c) tree channel discharges

그림 4.  $\Phi$ - $q$ - $n$  3D distribution

그림 4는 각각의 방전에 대해  $\Phi$ - $q$ - $n$  3D 분포를 보여 주고 있는데 각 방전의 양상이 명확히 구별이 되고 있는 것을 볼 수 있다.

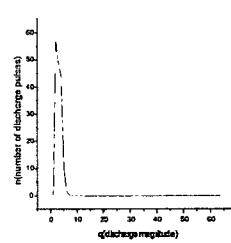


(a)  $q$ - $n$  distribution

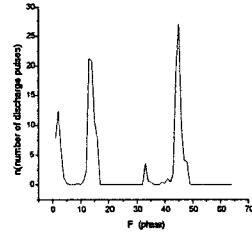


(b)  $\Phi$ - $n$  distribution

그림 5. 2D distribution of air discharges

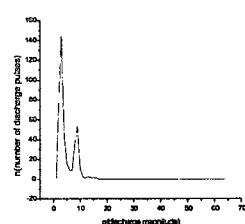


(a)  $q$ - $n$  distribution

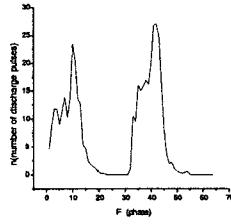


(b)  $\Phi$ - $n$  distribution

그림 6. 2D distribution of void discharges



(a)  $q$ - $n$  distribution



(b)  $\Phi$ - $n$  distribution

그림 7. 2D distribution of treeing discharges

그림 5-7은 방전의 분포양상을 2D Distribution으로 나타낸 것으로 각각의 결합에 대해 방전양과 방전위상각에 따른 방전 횟수가 차이가 구별이 되고 있음을 알 수 있다.

BP 학습 알고리즘은 아래와 같은 변수를 가지고 있으며, 학습속도는 12초였다.

- Hidden layer number : 40
- Learning cycles : 10,000
- Learning rate : 0.1
- Momentum : 0.1

모든 PE(Processing Elements)는 BP 학습 알고리즘 이 최적의 구현을 하도록 하였다.

#### 4. Classification results by NN

세 경우의 모의 실험 결과에 대한 분류는 명확하게 구분이 되었다. 3D 분포로부터 얻어진 2D 분포의 양상은 방전의 패턴 분류에 있어서 상당한 정보를 제공해 줄 수 있다. 위에서도 언급하였지만 네 경우의 2D 분포 중  $\alpha$ -n distribution과  $\Phi$ -n distribution을 이용한 방전 패턴의 분류는 좋은 결과를 나타내었다. 그림 8은 오차율을 표시하는 RMSE(Root mean square error)값을 나타내고 있다. 그래프에서 보면 '0'에 가까운 값을 나타내어 학습에 대한 오차는 크지 않은 것으로 나타나고 있다. 그림 9는 Classification의 결과를 보여주고 있다. 그림에서 각각 '0'은 air discharge, '1'은 void discharge, '2'는 treeing discharge를 나타내고 있다. 또한 패턴 분류 시에는 입력데이터의 절반은 학습을 위한 Training data로 나머지 반은 정확한 분류의 확인을 위하여 Checking data로 사용을 하였다. 그래프에서는 Training data와 Checking data 모두 100%의 분류 결과를 나타내었다. 이런 결과로 유추해 볼 때 BP 학습알고리즘을 이용한 NN적용시의 부분방전에 대한 패턴분류는 좋은 결과를 보여주었으며, 현장의 적용에 있어서도 강력한 툴을 제공할 것으로 사료된다.

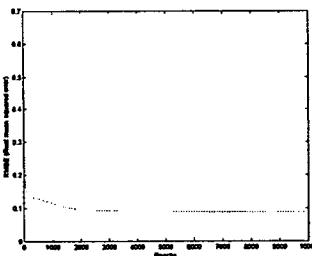


그림 8. RMSE Value

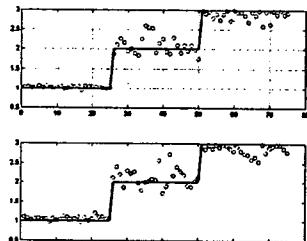


그림 9. Classification results

(Upper side : training data, Lower side : checking data  
 '0' fitted air discharge, '1' fitted void discharge,  
 '2' fitted tree discharge)

전력케이블 등의 진단에 있어서 유용한 정보를 제공해 줄 수 있는 부분방전에 대한 검출 및 진단기법으로서 본 논문에서 연구한 BP 학습 알고리즘을 이용한 방전의 분류는 좋은 결과를 보여주었다. 케이블에서 발생할 수 있는 방전을 세 경우로 모의하였을 경우 방전의 양상은 명확히 구별이 되었다. 하지만 부분방전원의 분류로서 BP 학습 알고리즘은 많은 데이터양과 학습시간에 있어서 문제점을 유발시킬 가능성이 있다. 따라서 이런 문제점을 감안하여 BP 학습알고리즘에 대한 연구가 이루어져야 하겠다. 이 논문에서 사용된 방법은 기존 3D분포로부터 통계적 파라메터를 계산하는 과정을 생략하였으므로, 데이터 취득 후 특징추출에 의한 분류시간을 감소시켰으며, 분명한 차이를 보여주는 2D 분포를 특성값으로서 사용하여, 분류의 정확도를 높일 수 있었다.

#### [참 고 문 헌]

- [1] Kai Gao and Chengqi Wu, "PD Pattern Recognition for Stator Bar Models with Six Kinds of Characteristic Vectors Using BP Network". IEEE Trans. EI, Vol. 9, No. 3, pp. 381-388, 2002.
- [2] M. Hoof, B. Freisleben and R. Patsch "PD Source Identification with Novel Discharge Parameters using Counterpropagation Neural Network". IEEE Trans., EI, Vol. 4 No. 1, pp. 17-32, October, 1997.
- [3] H. Suzuki and T. Endoh, "Pattern Recognition of Partial Discharge in XLPE Cables Using a Neural Network". IEEE Trans., EI, Vol. 27, pp. 543-552, 1992.
- [4] F.H. Kreuger, E. Gulski and A. Krivda, "Classification of Partial Discharges". IEEE Trans., EI, Vol. 28, pp. 917-931, 1993.
- [5] A. Mazroua, M.M.A. Salama and R. Bartnikas "PD Pattern Recognition with Neural Networks Using Pattern Recognition with Neural Networks Using
- [6] E. Gulski and A. Krivda, "Neural Networks as a Tool for Recognition of Partial Discharges". IEEE Trans., EI, Vol. 28, No. 6, p. 984-1002, 1993.