

PD 분류에 있어서 핑거프린트법과 신경망의 비교

박성희, 박재열, 이강원^{*}, 강성화^{**}, 임기조

충북대학교 전기공학과, 철도기술연구원^{*}, 충청대학 산업안전과^{**}

Comparison with Finger Print Method and NN as PD Classification

Sung-Hee Park, Jae-Yeol Park, Kang-Won Lee^{*}, Seong-Hwa Kang^{**} and Kee-Joe Lim

Dept. of Electrical Eng. Chungbuk National Uni., KRAL^{*},

Dept. of Industrial Safety Eng. Chungcheong College.^{**}

Abstract

As a PD classification method, statistical distribution parameters have been used during several ten years. And this parameters are recently finger print method, NN(Neural Network) and etc. So in this paper we studied finger print method and NN with BP(Back propagation) learning algorithm using the statistical distribution parameter, and compared with two method as classification method. As a result of comparison, classification of NN is more good result than Finger print method in respect to calculation speed, visible effect and simplicity. So, NN has more advantage as a tool for PD classification.

Key Words : PD, Finger print, Neural Network, Statistical Distribution

1. 서 론

전력기기에서의 결함은 국부적인 전계집중에 의한 부분방전을 수반하며, 이것으로 인한 피해는 상상할 수 없을 정도의 규모이다. 하지만 부분방전의 현상에 대한 규명은 아직도 연구수준에 머물러 있으며, 이에 대한 검출 방식이 소개가 되고 있지만 검출 센서의 사용에 대한 정보는 아직은 명확하지 않은 실정이다. 특히 현대의 산업이 고용량화, 대형화되어 감에 따라 GIS 및 각종 전력기기에 있어서 안정적인 전력공급은 필수요건이 되고 있다. 안정적인 전력공급의 중요시되는 항목 중 하나는 절연의 지속적인 유지이다. 하지만 전력기기에 있어서 절연성능의 지속적인 유지는 여러 가지 요인으로 인해 상당히 어려운 요구사항이며, 이런 점을 감안해 볼 때 전력기기의 적절한 교체 및 유지, 보수는 중요한 작업이라고 할 수 있겠다. 이것은 절연재료의 열화정도에 따라 교체 등의 적절한 시기를 판단할 수 있는데, 열화정도의 지표로서 부분방전의 검출에 의한 분석 및 기법 등이 널리 이용이 되고 있다. 부분방전의 양상은 매우 다양하게 나타

나며 부분방전 양상에 대한 정확한 분류는 적절한 교체 시기와 유지, 보수의 선정에 있어서 유용한 정보를 제공해 줄 수 있다. 이에 본 논문에서는 부분방전의 양상을 모의 실험을 통하여 구현한 후 부분방전 데이터를 취득 및 정리하고, 통계적 분포 파라미터를 이용하여 각각의 결함에 대한 핑거프린트법을 처리하였으며, 이와 함께 BP 학습 알고리즘을 이용한 신경망에 적용한 분류 방식에 대한 결과를 나타내어 서로에 대한 장·단점을 비교 분석하였다.

2. 실험장치 및 데이터 취득

2.1 실험장치

고분자 절연물의 접속부에서 발생하는 부분방전을 모의하기 위해 기중 침대 평판 구조의 전극을 사용하여 부분방전 데이터를 취득하였다. 고분자 절연물 내의 보이드가 존재할 경우의 모의를 위하여 LDPE Sheet(50×50×3.5mm)에 보이드(1×1.2mm)를 인위적으로 삽입시켜 그 때 발생하는 방전에 대한 데이터를 취득하였다. 절연물내부의

금속 및 도체부위의 돌기부에서 발생하는 Treeing 방전을 모의하기 위하여 도체에 돌기가 존재할 경우를 설정하여 LDPE 절연물의 표면과 고압부의 전극부분에 침을 삽입하여 tree가 발생하도록 하여 부분방전 데이터를 취득하였다. 그림 2는 부분방전 발생시의 신호를 검출하는 Block diagram을 나타내고 있다.

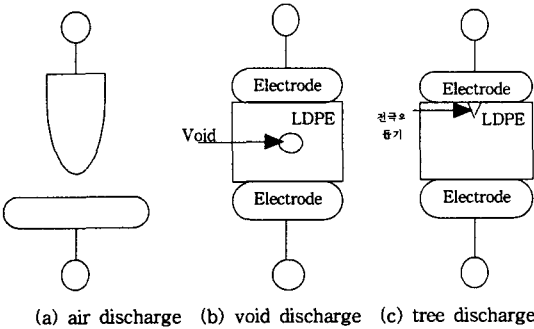


그림 1. 모의 전극 형태.




그림 2. Block diagram of Experiment.

2.2 PD 데이터 취득

부분방전의 발생 시 PD detector(according to IEC 270, BIDDLE)로부터 위상(Φ - phase), 방전크기(q - discharge magnitude) 및 방전회수(n - number of pulse)에 관련한 데이터를 얻을 수 있다. 이는 부분방전의 분포양상을 비교적 명확하게 판단할 수 있게 해주며, 이를 이용한 통계적 분포 파라미터의 산출은 Finger print method 및 신경망에의 적용을 용이하게 해준다. 본 논문에서도 이런 점을 고려하여 통계적 분포 파라미터를 이용한 분류기법으로서 위의 두 경우에 대해 비교 분석하였다. 그림 3은 통상적인 방식의 PD acquisition의 과정으로서 PD의 발생에서부터 NN(Neural Network) 및 Finger print에의 적용과정을 나타내고 있다.




그림 3. Block-diagram of PD signal processing.

부분방전 발생에 대한 조건은 다음과 같다. 침-평판 전극구조에서의 부분방전의 경우는 방전발생 전압의 1.2배인 10.5kV에서 방전의 양상이 잘 파악할 수 있는 조건에서 실험을 하였으며, 적당한 시간을 주어 방전현상에 대한 데이터를 안정적으로 획득할 수 있도록 하였다. 절연물 내의 Void 방전은 침-평판의 기중방전과 동일하게 1.2Vi(11kV) 전압에서 측정을 하였다. 또한 Tree 방전시에는 트리발생 전압(10kV)에서 측정을 하였고, 트리발생 후 10% 경과한 시점에서 측정을 하였다.


3. 통계적 분포 파라미터

방전양과 방전의 강도에 대한 관계는 3차원적 통계적 분포에 대한 display 방식과 2차원적인 display방식의 두 종류를 이용하였다. 3차원적인 해석은 Φ (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 $q-n$, $\Phi-qa$ (average discharge magnitude), $\Phi-n$, $\Phi-qmax$ (maximum value of discharge)를 사용하였다. 핑거프린트법은 통계적 분포 파라미터의 값을 이용하여 방전이 분류양상에 이용하는 것이고, 본 논문에서 핑거프린트방법과 비교하기 위한 NN에 의한 방식은 네 경우의 분포 중 방전에 대한 특징을 잘 나타내주고 있는 $q-n$ 과 $\Phi-n$ 분포를 이용하여 방전에 대한 패턴을 분류하였다. 그림 4, 5, 6은 기중방전, 보이드방전, 트리방전에서의 분포를 나타내고 있다.


4. 핑거프린트법

핑거프린트법에 사용된 통계적 분포파라미터는 $q-n$, $\Phi-qa$, $\Phi-n$, $\Phi-qmax$ 에 대한 Skewness,

Kurtosis, 방전비대칭도 및 상관계수 등을 포함하고 있다. 세로축의 1 - 19번은 네 경우의 통계적 분포에서 분포파라미터를 표시하고 있으며 자세한 내용은 표 1과 같다.




(a) q-n distribution (b) Φ -qa distribution




(c) Φ -n distribution (d) Φ -qmax distribution

그림 4. 기중방전의 통계적 분포.




(a) q-n distribution (b) Φ -qa distribution




(c) Φ -n distribution (d) Φ -qmax distribution

그림 5. 보이드방전의 통계적 분포.



(a) q-n distribution (b) Φ -qa distribution



(c) Φ -n distribution (d) Φ -qmax distribution


그림 6. Tree방전의 통계적 분포.

표 1. 통계적 분포 파라미터.


번호	통계적분포	파라미터
1	q-n	avg-Qmax
2		Skewness
3		Kurtosis
4	Φ -qa	방전비대칭도
5		상관계수(cc)
6		Skewness +
7		Skewness -
8		Kurtosis +
9	Kurtosis -	
10	Φ -n	Skewness +
11		Skewness -
12		Kurtosis +
13		Kurtosis -
14	Φ -qmax	방전비대칭도
15		상관계수(cc)
16		Skewness +
17		Skewness -
18		Kurtosis +
19	Kurtosis -	

그림 7의 (a), (b), (c)는 기중방전, 보이드방전, 트리방전에 대한 핑거프린트를 나타내고 있는데 그래프에서 보면 각각의 방전에 대해 통계적 분포 파라미터의 값이 다르게 나타나며 그래프 전체의 특징도 다르게 나타남을 알 수 있다. 핑거프린트를 이용한 방전의 분류는 이런 형식으로 이루어지게 된다. 하지만 많은 통계적 분포 파라미터 (Skewness, Kurtosis 등)에 대한 계산결과가 선행이 되어야 하며, 육안으로의 확인은 상당히 난해한 점이 있다. 그래프에 대한 수치적인 해석이 병행이 되어야 하며, 계산시간도 많이 걸린다는 단점이 있다. 또한 온라인 상태에서의 적용은 무리가 있다. 하지만 다음절에서 적용하게 될 NN에 의한 방식


은 이런 핑거프린트의 단점을 보완할 수 있는 장점을 지니고 있다.



(a) air discharge



(b) void discharge



(c) tree discharge

그림 7. 모의 방전에 대한 핑거프린트.

5. NN에 의한 방전분류

4절에서 통계적 분포파라미터의 핑거프린트법에 적용하는 실험을 살펴보았다. 이번 절에서는 통계적 분포 파라미터를 사용하여 NN에 적용하여 그 특성에 대해 살펴보았으며, NN에 대한 적용 알고리즘은 BP(Back propagation-역전파 알고리즘) 학습 알고리즘을 사용하였고, BP의 PE(Processing elements)는 다음과 같다.

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

BP 학습알고리즘은 기본적으로 다층 퍼셉트론(Multi layer perceptron-MLP)에 기반을 두고 있다. 일반적인 다층 퍼셉트론의 학습방법은 입력층의 각 유닛에 입력 데이터를 제시하면 이 신호는 각 유닛에서 변환되어 중간층에 전달되고 최종적으로 출력층으로 나오게 된다. 이 출력값과 원하는 출력값을 비교하여 그 차이를 줄여나가는 방향으로 연결강도를 조정하는 것이다. BP 학습알고리즘은 기본적으로는 MLP의 학습구조 기반 위에서 진행이 되지만 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다는 특징이 있다. 또한 BP 학습알고리즘이 정확한 학습이 이루어졌는지에 대한 여부는 RMSE(Root mean square error)로 나타내게 되는데 이 값이 '0'으로 수렴이 되는 것이 학습이 지역 최소값 및 발산하지 않고 수렴이 된 것이라고 할 수 있겠다.




그림 8. RMSE Value(Upper line : checking data, Lower line : training data).




그림 9. Classification result(Upper side : training data, Lower side : checking data).

그림 8과 9는 BP 학습 알고리즘을 이용한 분류 결과의 RMSE값으로 Training data, Checking data 모두 거의 '0'으로 수렴이 되는 것을 볼 수 있다. 이는 학습이 잘 이루어졌으며 이것에 대한 검증 데이터인 Checking data도 또한 분류가 잘 이루어졌음을 나타낸다. Checking data는 학습이 이루어진 후에 학습에 의한 서로 다른 방전 양상에 있어서의 input data에 대한 분류결과를 확인하기 위한 데이터이다. 결국 Checking data는 미지의 방전에 대한 입력데이터로서 사용이 되고 있는 것이다. 방전의 분류에서 BP 학습알고리즘을 이용한 신경망에의 적용은 통계적 분포에서 방전의 특징을 잘 파악할 수 있는 q - n 분포와 ϕ - n 분포를 이용하였다. 이는 핑거프린트법에서 네 경우의 통계적 분포에서 통계적 분포 파라미터들을 이용한 것과 달리 특징이 잘 반영되고 있는 두 경우의 분포에 대해 그래프 자체를 인식하여 신경망에 적용을 한 것이다. 이런 방식은 통계적 분포 파라미터의 처리 과정을 간소화시켜 방전 분류에 있어서 상당한 시간 절약을 가져다 주었다. 또한 분류에 있어서도 명확하게 분류가 되었다는 것을 그림 8과 그림 9에서 확인할 수 있다. 즉, 핑거프린트가 복잡한 여러 단계를 거치고, 분류 결과에 대해서도 각각의 확인을 거쳐야 하는 과정을 거치는 반면 신경망을 이용하면 단계가 간소해지며, RMSE 그래프나 분류결과에 대한 그래프를 육안으로 바로 확인할 수 있다는 장점이 있다.

6. 결론

부분방전 분류 방법은 현재 여러 종류의 기법이 소개가 되고 있다. 이중 통계적 분포 파라미터를 이용한 핑거프린트 및 NN의 방식이 사용이 되고 있고, 이들은 방전 특성 분석 및 방전의 분류에 적용할 수 있다. 본 논문에서는 이러한 두 방법을 비교, 검토하였다. 그 결과 핑거프린트법은 계산과정이 복잡하고 시간이 많이 걸리는 반면, BP를 이용한 NN에의 적용은 처리 시간이 짧고, 핑거프린트법 보다 적은 수의 통계적 분포 파라미터를 이용하여 보다 간소화시킬 수 있다는 장점이 있었다. 또한 부분방전의 온라인 검출에서도 NN의 적용이 비교적 용이하다.

참고 문헌

- [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 Counter-propagation 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] 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.