

부분방전원의 분류에 있어서 BP와 SOM의 비교

Comparison of BP and SOM as a Classification of PD Source

박성희^{1,a}, 강성화², 임기조¹

(Seong-Hee Park^{1,a}, Seong-Hwa Kang², and Kee-Joe Lim¹)

Abstract

In this paper, neural networks is studied to apply as a PD source classification in XLPE power cable specimen. Two learning schemes are used to classification; BP(Back propagation algorithm), SOM(self organized map - kohonen network). As a PD source, using treeing discharge sources in the specimen, three defected models are made. And these data making use of a computer-aided discharge analyser, statistical and other discharge parameters is calculated to discrimination between different models of discharge sources. And also these distribution characteristics are applied to classify PD sources by two scheme of the neural networks. In conclusion, recognition efficiency of BP is superior to SOM.

Key Words : PD, Solid insulator, Statistical Distribution, BP, SOM

1. 서론

전력기기에서 부분방전은 다양한 경로로 발생을 하며, 발생기구에 있어서 복잡한 특성을 지니고 있는 관계로 그 검출 및 방전의 종류에 대한 파악은 매우 난해한 점이 있다. 기존에는 PD 검출기로부터 계측된 방전의 양 혹은 오실로스코프의 PD 파형등을 이용해 방전을 분류하였지만, 정확한 검출 및 예측이 불가능하다는 점과 육안으로 판별해야 하는 단점이 있었다[2,3]. 따라서 근래에는 패턴분류 및 인식등에 널리 이용되고 있는 신경망을 이용하여 분류를 하는 방식[1,3,4]이 널리 이용이 되고 있는데, 그 중에서도 PD패턴의 분류에서는 BP(Back Propagation - 역전파 학습알고리즘) 및 코호넨 네트워크에 기반한 SOM(Self Organized

Map - 자기형상화지도)의 학습알고리즘이 많이 사용이 되고 있다. 따라서 본 논문에서는 이 두 경우의 분류기법에 대해서 특징을 살펴보고 이를 이용한 패턴분류의 결과를 도출하여 현장의 적용 가능성이 높은 알고리즘을 제시할 것이다. 부분방전원의 결함으로서는 기중코로나방전(air discharge - PD model #1), 보이드방전(void discharge - PD model #2), 트리방전(tree discharge - PD model #3)의 세 가지 경우를 사용하였다. 방전데이터의 취득 후에는 \emptyset -q-n분포를 도출하였고, 그를 이용해 방전의 통계적 분포($H_n(q)$ - 방전양과 방전회수 분포, $H_{qn}(\emptyset)$ - 방전위상각과 평균방전양 분포, $H_n(\emptyset)$ - 방전위상각과 방전회수의 분포, $H_q(\emptyset)$ - 방전위상각과 최대방전양분포)를 도출하였다. 네 가지의 통계적 분포는 각각의 방전의 특징을 잘 표현해주고 있기 때문에[4,5,6] 통계적 분포를 BP와 SOM의 입력으로 이용하여 패턴분류를 하였으며, 각각에 대한 인식률을 검토하여 부분방전의 패턴분류기구로서 어떤 신경회로망이 적합한 지에 대해 비교하였다.

1. 충북대학교 전기전자컴퓨터공학부
(충북 청주시 흥덕구 개신동 산 48)
2. 충청대학 산업안전과
a. Corresponding Author : partenza@hanmail.net
접수일자 : 2004. 3. 16
1차 심사 : 2004. 5. 13
심사완료 : 2004. 8. 3

2. 실험

2.1 실험시편

그림 1의 (a), (b) (c)는 본 논문에서 부분방전 발생을 위한 모의결함을 만든 시편을 나타내고 있다.




그림 1. 부분방전 발생을 위한 시편.

Fig. 1. Three type specimens for partial discharges(PD model #1 : air discharge(needle to plane), PD model #2 : void discharge, PD model #3 : tree discharge).

그림 1 (a)는 기중 침대 평판 구조의 전극 모형으로서 기중에서 발생하는 코로나 방전을 모의하기 위한 것이다. 이 결함은 케이블이나 절연물의 도체 표면에서 돌기의 존재 시 발생가능한 방전을 모의하기 위한 것으로 전극의 재질은 스테인레스스틸로 되어 있다.

그림 1 (b)는 보이드 방전을 모의하기 위한 것으로 LDPE를 hot press를 이용하여 120 ℃로 가열·압축하여 90×90×5 mm의 판상시편을 제작한 후, 판상시편 3개를 90 ℃로 가열·압착하여

90×90×4.5 mm의 시편을 제작하였다. 시편의 중앙층에는 지름 1.5mm 정도의 보이드를 형성시켰으며, 절연물의 표면에서 방전이 발생하지 않도록 하기 위해 절연유에 함침하여 실험을 하였으며, 전극에서 불필요한 방전을 제거하기 위해 원기둥 형태의 전극과 원형평판 전극을 사용하였다.

마지막으로, 전기트리방전 실험에 사용된 절연재료는 대한전선에서 생산되고 있는 22.9 kV용 피복 전선의 XLPE절연물 부분을 절개한 시편을 사용하였다. 절연물에 침을 삽입할 때 침과 절연물 사이의 경계면이 완전히 밀착되도록 하기 위해 XLPE에 150 ℃ 온도의 hot press를 이용하여 가열·압착한 상태에서 침을 삽입하여 시료를 제작하였다

2.2 실험장치

그림 2는 부분방전 발생원으로부터 방전 데이터를 취득하는 과정을 나타내고 있다. 부분방전의 발생시 측정은 그림 2와 같이 PD free 변압기로 전압인가 후 PDASDA(Partial Discharge Acquisition, Storage and Display System)에서 계측을 한다. 부분방전펄스의 검출은 부분방전 검출기(Biddle Instrument사 제작, AVTM 66270100Ja)로 검출하였다. 기중 및 보이드 방전의 실험에서 인가전압은 PD detector의 방전량이 처음으로 나타나는 방전개시 전압의 1.2배인 10 kV와 12 kV로 하였으며, 한 개의 데이터 취득시간은 300주기로 하였다. 또한 트리 실험시에는 인가전압을 13 kV로 하였으며, 초기의 트리 발생시에는 침단에서 매우 빠른 속도로 진전을 하는 관계로 성장이 10 %이후에 켜를 때를 트리 발생의 시초로 하여 데이터를 취득하였다. 실제적인 부분방전의 분류데이터로서는 트리방전이 본격적인 모습을 드러내고 각각의 특징을 어느 정도 확인할 수 있는 50 % 이상 진행 시점의 데이터를 이용하였다.




그림 2. PD측정시스템의 블록도.

Fig. 2. Block diagram of PD measuring system.

김출된 방전펄스는 컴퓨터를 이용해 최대방전량, 평균방전전류, 발생빈도수 등을 연산하고 \emptyset -q-n(위상 - 방전전하량 - 방전회수)분포를 도출하게 된다. 또한 전기트리 방전시에는 트리가 미세한 부분에서 발생하고 초기 성장시에 빠르게 진전이 되기 때문에 육안 관찰은 어렵다. 그런 이유로 트리의 성장정도를 측정하기 위해 시편에 광학현미경(Olympus, SZ1145TR)을 설치하고 OCD(Hitron K-450) 카메라를 장착하였으며, 카메라 출력을 DT3851(미국 Data Translation사 제작) 화상처리 보드를 이용하여 전기트리 개시 및 성장을 확인하였다.

3. 신경망이론

3.1 신경망이론

3.1.1 BP

BP(back propagation) 학습 알고리즘은 기본적으로 다층퍼셉트론(Multi Layer Perceptron - MLP)에 기반을 두고 있다. MLP는 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 신경망이다. 입력층과 출력층 사이의 중간층을 은닉층(hidden layer)이라고 부른다. 네트워크는 입력층, 은닉층, 출력층 방향으로 연결되어 있으며, 각 층내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향 네트워크다. 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 것인데, BP 학습알고리즘은 기본적으로는 MLP의 학습구조 기반위에서 진행이 되지만 상위층에서 역전하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다는 것이 고유의 특징이다. 그림 3은 MLP의 일반적인 구조를 나타내고 있다.




그림 3. MLP-BP의 구조.

Fig. 3. Architecture of MLP-BP.

3.2.2 SOM

SOM(self-organizing feature maps)은 기본적으로는 Kohonen network에 기반을 두고 있다. 그림 4는 SOM의 네트워크 구조를 나타내고 있다.





그림 4. SOM의 구조.

Fig. 4. Architecture of SOM.

SOM의 학습원리는 기본적으로 코호넨의 학습 규칙과 동일하다. 즉, 학습이 이루어질 때 각 뉴런들은 연결강도 벡터와 입력벡터가 얼마나 가까운가를 계산한다. 그리고 각 뉴런들은 학습할 수 있는 특권을 부여받으려고 서로 경쟁하는데 거리가 가장 가까운 뉴런이 승리하게 된다. 이 승자 뉴런이 출력 신호를 보낼 수 있는 유일한 뉴런이다. 또한 이 뉴런과 이와 인접한 이웃 뉴런들만이 제시된 입력벡터에 대하여 학습이 허용된다. 결국, 이 네트워크의 학습철학은 '승자독점(winner take all)'이다. 오직 승자만이 출력을 낼 수 있으며, 승자와 그의 이웃들만이 그들의 연결강도를 조정할 수 있다. SOM의 출력층은 $x \times x$ 의 2차원 mesh 형태를 취하고 있으며, mesh에서 경쟁에서 승리한 입력데이터가 출력층의 clustering으로서 나타나는 형태로 패턴을 분류하게 된다.

4. 실험결과 및 고찰

4.1 \emptyset - q - n 분포



(a) PD model #1




그림 5. $\emptyset - q - n$ 분포.
Fig. 5. $\emptyset - q - n$ distribution.

그림 5는 3종류의 부분방전발생모델에 대한 통계적 분포인 $\emptyset - q - n$ 분포를 나타내고 있는데, $\emptyset - q - n$ 분포는 방전형태에 따른 특성을 잘 표현해주고 있다. 그림 5 (a), (b), (c)에서 살펴보면 각 방전에 대해 방전발생위상각, 방전회수, 방전양에 있어서 특징을 지니고 있음을 확인할 수 있다. 또한 기중 방전과 보이드 방전에서는 방전현상이 전극형상에 따라 상이하게 나타나는데 이는 전극형상에 따른 물리적인 의미를 갖고 있다. 즉, 기중 방전에서는 침대평판에 따른 불균등 전계를 형성하는 관계로 양, 음주기가 변화할 때 방전의 특성이 양, 음주기에서 심한 불균형을 보이고 있는 것을 확인할 수 있다. 반면에 보이드 방전에서는 침대평판 구조와는 달리 보이드 양단의 형상, 재질이 유사하기 때문에 부분방전의 양상은 음, 양 반주기가 서로 유사한 모습을 보인 것으로 이해할 수 있다. 하지만 이 분포는 전체적으로 보았을 때 육안상으로 방전의 양상을 파악하기에는 난해한 점이 있다. 결국 $\emptyset - q - n$ 분포는 간단한 방전의 특성만을 구별할 수 있을 뿐이다. 그런 면에서 4.2절에 나타낸 네 가지 경우의 통계적 분포는 방전의 통계적인 분포로 특징을 비교하여 방전간의 양상을 비교적 정확하게 나타낸다고 할 수 있다.

4.2 통계적 분포

그림 6은 $\emptyset - q - n$ 분포로부터 도출된 네 가지 경우의 통계적 분포를 나타내고 있는 것으로서, 방전원별로 일정한 특성을 보이고 있는 것을 확인할 수 있다.

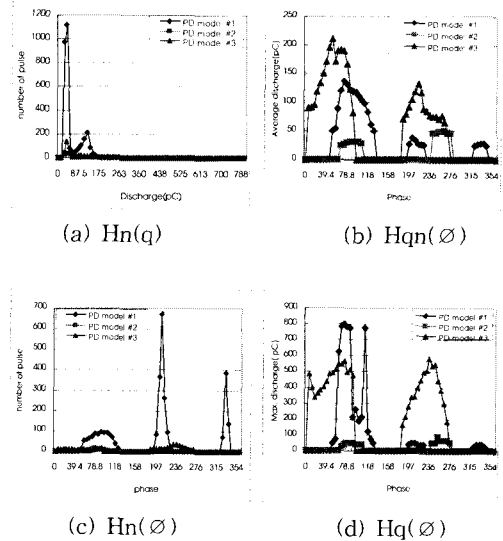


그림 6. 통계적 분포.
Fig. 6. Statistical distribution

그래프에서 PD model #1은 기중코로나 방전, PD model #2는 보이드 방전, PD model #3은 트리방전을 나타내고 있다. 각각의 분포에 대한 특징은 다음과 같다.

각각의 방전은 그 발생 위상각에서 서로 다른 양상을 보이고 있으며, 방전의 크기 및 방전의 발생 빈도수에 있어서도 각기 다른 특징을 보이고 있다. 즉, 이는 부분방전 발생기구의 각각의 특징을 나타내고 있는 것이다. 이런 특징은 부분방전의 패턴을 분류의 가능성을 내포하고 있다는 의미이다.

5. 패턴 분류 결과 비교

4절에서 통계적 분포들은 방전의 특징을 비교적 잘 표현해 주고 있으며, 신경망의 입력으로 사용하여 학습을 시킨 후 패턴을 인식시키는 데에도 유용하다는 것을 확인하였다. 이번 절에서는 부분방전원의 패턴분류에 있어서 신경망을 사용하는 기

법 중 BP학습알고리즘과 SOM에 대해 비교한 결과에 대해 나타내었다.

BP와 SOM의 입력데이터로서는 네 가지의 통계적분포 중에서 특징을 보다 잘 표현한 두 개의 분포만을 이용하였다. 특징적인 것은 통계적 분포 파라미터가 아닌 통계적 분포 그래프 자체의 특징을 신경망에 적용하여, 파라미터의 구현 시 무시될 수 있는 작은 방전에 대한 정보를 입력에 포함시켜 보다 나은 패턴에 대한 학습이 이루어지도록 하였다.

5.1 BP의 분류결과


그림 7은 BP학습시 패턴에 대한 분류결과를 나타내고 있다. 학습은 RMSE(Root Mean Square Error)값이 '0'으로 수렴이 될 경우가 완전한 학습이 이루어진 것이므로 RMSE값을 '0'으로 수렴하게 하도록 PE(processing elements)를 선정하였다. 표1은 BP학습시에 사용되었던 PE를 나타내고 있다.

표 1. PE값의 선정.


Table 1. Selection of optimized processing elements.

학습율 (learning rate)	모멘텀 (momentum)	반복회수 (epoch)	은닉층 수 (hidden layer)
0.12	0.7	25,000	10

그림 7의 (a), (b), (c)는 각각 RMSE값의 변화, 학습결과, 분류결과를 나타내고 있다. 방전데이터는 세 가지 경우에 대해 각각 40씩 총 120개의 데이터를 이용하였으며, 데이터의 반은 학습용으로, 나머지 반은 분류용으로 사용을 하였다.



(a) Variation of RMSE Value



(b) Training Result (c) Classification Result

그림 7. 은닉층의 수에 따른 RMSE변화양상.

Fig. 7. RMSE variation characteristic according to hidden layer.

신경망 학습결과 RMSE 값은 거의 '0'으로 수렴을 하였으며, 학습한 결과도 100 % 분류되었다. 분류결과에서도 1, 2개의 데이터를 제외하고는 거의 분류가 된 것을 확인할 수 있다. 그래프의 y축 값의 '0'은 기준 침대평판에 대해 fitting된 결과물, '0.4'는 보이드 방전시, '0.8'은 트리발생시의 fitting된 분류결과를 나타내고 있다.

5.2 SOM의 분류결과

그림 8은 신경망 학습 알고리즘의 기법 중 som의 적용에 대한 학습결과와 checking한 결과를 나타내고 있다. x축의 일련번호는 데이터번호(1-20 : PD model #1, 21-40 : PD model #2, 41-60 : PD model #3)를 나타내고 있으며, y축은 출력층 유니트의 번호를 나타내고 있다. 본 논문에서 사용한 출력층 유니트의 수는 8 by 8의 크기를 선정하였다.

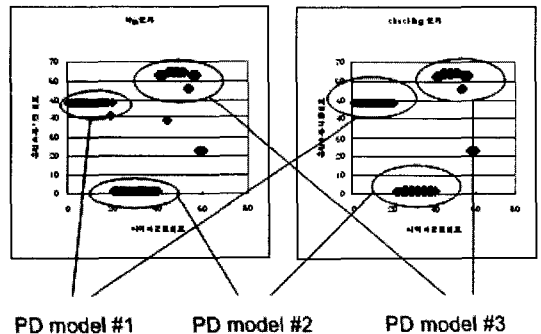


그림 8. SOM의 분류결과.

Fig. 8. Classification result of SOM.

SOM의 분류결과에서 살펴보면 세 가지 경우에

대한 방전의 학습이 완벽하게 이루어지지 않고 있는 것을 확인할 수 있다. 또한 분류결과에 있어서도 몇 개의 미분류 데이터가 PD model #3에서 나타나고 있음을 확인할 수 있다.

BP와 SOM의 학습에 대한 결과를 비교해 볼 때, BP가 PD 데이터의 적용시 학습능력에서 SOM보다 다소 나은 결과를 나타내었다. 이는 BP가 100 % 학습이 이루어진 반면, SOM은 학습시에도 몇 개의 데이터가 미분류 되어있는 것으로 확인할 수 있다. 또한 비록 BP와 SOM이 분류한 결과에서 비슷한 수의 미분류 데이터가 있지만, 우선적으로는 학습이 완벽하게 이루어져야 하는 전제가 있기 때문에 BP가 PD데이터 분류의 적용시에 좀더 향상된 결과를 보일 것이라는 추측을 뒷받침할 수 있다. 이것은 다음절에서 설명할 120개의 새로운 입력데이터를 사용한 인식률의 비교에서도 그 결과가 나타나고 있다.

5.3 인식률의 비교

표 2는 BP와 SOM의 학습을 통해 구한 연결강도 값을 이용하여 새로운 방전데이터 120개를 적용하였을 경우의 두 알고리즘의 인식률 값을 비교하고 있다.

표 2. 방전분류에 대한 인식률.

Table 2. Recognition rate.

학습된 패턴	분류용 패턴					
	PD model #1		PD model #2		PD model #3	
	인식률(%)					
	BP	SOM	BP	SOM	BP	SOM
PD model #1	100	100	-	5	-	5
PD model #2	-	5	100	100	2.5	15
PD model #3	-	2.5	-	5	97.5	85

표 2는 각각의 방전에 대한 인식률을 나타낸 것인데, 분류용 입력 데이터로서 세 가지 방전의 데이터가 모두 포함된 것이다. 즉, 세 가지 방전데이터를 입력으로 사용하여 각각의 학습된 패턴에 대해 인식률을 나타낸 것이다. 완전하게 분류가 되었다면 세 가지에 대해 100 %의 값이 나타나야 한다. 우선 BP의 경우를 살펴보면 기중방전에 대해서는 100 % 인식률을 보였고, 보이드 방전의 경우에는 100 % 인식률을 나타냈고, 트리방전의 존재시

도 97.5 %의 인식률을 나타냈다. 트리방전에서 나머지 2.5 %는 보이드 방전에 대한 미분류 오차로서 트리방전의 패턴에서 2.5 %가 보이드방전의 패턴과 유사하다는 것을 나타낸다. 결과적으로 전체의 인식률은 99 %로 나타났다.

반면에 SOM에 의한 분류 인식률의 결과는 기중방전에 대해서 92.5 %, 보이드방전에서 90 %, 트리방전에서 85 %로 나타났으며, 전체적인 인식률에서도 89 %로 나타났다.

결론적으로 인식률에서 95 % 이상을 패턴 분류로서 높은 수준의 인식률 값이라고 보았을 때 BP 학습알고리즘을 이용한 PD 데이터의 신경회로망 적용은 인식률의 측면에서 매우 좋은 결과를 나타낸 반면, SOM의 분류결과는 BP의 학습율과 비교해 낮은 인식률 값을 나타내었다. 이는 학습이 완전하게 이루어지지 않은 결과로 사료가 되며, 실제적으로 on-line 시스템에의 적용에 대해서도 상당한 미비점이 노출될 것으로 보인다.

6. 결론

고체 절연물내에서 발생할 수 있는 여러 가지 방전에 대해 패턴분류의 한 방법으로써 신경망 학습알고리즘 중 BP와 SOM을 이용한 분류의 최종적인 결과는 BP가 SOM보다 향상된 결과를 나타내었다. 이는 BP는 학습이 완전하게 이루어진 반면 SOM은 학습이 완벽하게 이루어지지 않은데서 비롯되는 결과라고 사료가 된다. 비록 본 논문에서 사용한 학습 데이터의 개수가 적었지만, BP와 SOM의 특징을 살펴보았을 때, BP는 학습데이터로서 상당히 많은 양의 데이터를 필요로 하는 반면, SOM은 적당한 양으로도 학습이 가능하다는 특징이 있다. 결국 학습데이터의 개수가 적은데도 불구하고 학습이 완전하게 이루어졌으며, 인식률도 상당히 높게 나타나는 것으로 보아 PD데이터의 분류적용은 많은 양의 학습데이터의 필요로 인한 학습시간의 길어지는 등의 단점에도 불구하고 BP가 좀더 적합하며, 감시/진단 시스템에의 적용성에도 상당한 장점이 있을 것이라고 판단이 된다.

감사의 글

이 논문은 2004년도 충북대학교 학술연구지원사업의 연구비 지원에 의하여 연구되었음.

참고 문헌

- [1] 한국전기연구원, “전력기기 절연 진단 기술”, 기술교육교재, 2001.
- [2] F. H. Kreuger, E. Gulski, and A. Krivda, “Classification of partial discharge”, IEEE Trans. on EI, Vol. 28, No. 6, p. 917, 1993.
- [3] E. Gulski and F. H. Kreuger, “Computer-aided recognition of discharge sources”, IEEE Trans. on EI, Vol. 27, No. 1, p. 82, 1992.
- [4] B. Fruth and L. Niemer, “The importance of statistical characteristics of partial discharge data”, IEEE Trans. on EI, Vol. 27, No. 1, p. 60, 1992.
- [5] H. Suzuki and T. Endoh, “pattern recognition of partial discharges in xlpe cables using a neural networks”, IEEE Trans. on EI, Vol. 27, No. 3, p. 543, 1992.
- [6] M. M. A. Salama, and R. Bartnikas, “Determination of neural network topology for partial discharge pulse pattern recognition”, IEEE Trans. on NN, Vol. 13, No. 2, p. 446, 2002..
- [7] E. Gulski and A. Krivda, “neural network as a tool for recognition of partial discharge”, IEEE Trans. on EI, Vol. 28, No. 6, p. 991, 1993.
- [8] 이강원, 박성희, 강성화, 임기조, “STFT 및 통계적 처리에 의한 공기 중 부분방전원 식별”, 전기전자재료학회논문지, 제17권, 제1호, p. 101, 2004.
- [9] 권동진, 박재준, “변압기 부분방전 상시 감시기법에 관한 연구”, 전기전자재료학회논문지, 제14권, 제12호, p. 1032, 2001.
- [10] L. L. Alston, “High Voltage Technology”, p 17, 1986.
- [11] N. G. Trich, “Partial Discharge ; Discharge in Air part 1 : Physical Mechanisms”, IEEE Trans. on NN, Vol. 11, No. 2, p. 23, 1995.
- [12] 丁性桂, 李德出, “高電壓工學”, 文運當
- [13] 박우현, 이기식, “에폭시/고무 거시계면에서 장시간 절연파괴전압에 대한 연구”, 전기전자재료학회논문지, 제15권, 제11호, p. 1003, 2002.