

XLPE 전력용 케이블 시편의 부분방전원 분류

PD Classification by Neural Networks in Specimen of XLPE Power Cable

박성희^{1,a}, 이강원², 강성화³, 임기조¹

(Seong-Hee Park^{1,a}, Kang-Won Lee², Seong-Hwa Kang³, and Kee-Joe Lim¹)

Abstract

In this paper, neural networks is studied to apply as a PD source classification in XLPE power cable specimen. For 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 parameter is applied to classify PD sources by neural networks. Neural Networks has good recognition rate for three PD sources.

Key Words : PD, Treeing discharges, Statistical distribution, Neural networks

1. 서 론

전력용 케이블의 부분방전은 다양한 경로로 발생한다. 케이블 종단에서의 코로나방전, 절연물내의 기포에 의한 방전, 트리에 의한 방전등이 그 대표적 현상이다. 절연물내의 보이드나 트리의 성장은 결국에는 절연과파를 유발시켜 사고로 진전을 하게 된다. 결국 전력용 케이블내의 방전현상의 원인을 규명하고 방전원의 종류 및 위치에 대한 판단, 열화정도의 판단은 상당히 중요한 과제라 할 수 있겠다[1,6]. 하지만 현재까지도 부분방전원의 완전한 분류 및 규명이 이루어지지 않고 있는 실정이다. 최근에 센서기술의 발달과 컴퓨터 처리기능의 발달로 인해 부분방전에 대한 연구가 활발히 진행이 되고 있지만, 부분방전의 완전한 패턴 분류는 초보적인 수준에 머물러 있다. 이런 점에 착안하여 본 논문에서는 부분방전원의 패턴 분류기법

으로서 패턴분류 및 영상인식 등의 분야에 널리 이용되고 있는 신경회로망에의 적용과 패턴에 대한 인식률[2,3]에 대해 살펴보았다. 부분방전원의 결함으로서는 트리발생을 모의하기 위해 25.8 kV XLPE Cable(제조사 : 대한전선)의 절연물부인 XLPE를 절개하여 침을 삽입한 후 트리를 발생시켰으며, 침결함에 의한 트리방전 모의, 침단에 보이드가 있는 경우의 트리방전 모의와 절연물내에 급속이물질이 있는 경우의 트리방전 모의등 세 가지 경우에 대해서 살펴보았다. 방전데이터의 취득 후에는 δ -q-n분포를 도출하였고, 그를 이용해 방전의 통계적 분포($H_n(q)$, $H_{qn}(\delta)$, $H_n(\delta)$, $H_q(\delta)$) 및 분포에 대한 통계적 분포파라미터(Skewness-왜도, Kurtosis-첨예도, cc-상관계수, asy-비대칭도)를 도출하였다. 네 가지의 통계적 분포는 각각의 방전의 특징을 잘 표현해주고 있기 때문에[3-5] 통계적 분포를 신경회로망의 입력으로 이용하여 분류를 하였으며, 각각에 대한 인식률을 검토하였다.

- 1. 충북대학교 전기전자컴퓨터공학부
(충북 청주시 흥덕구 개신동 산 48)
- 2. 한국철도기술연구원
- 3. 충청대학 산업안전과
- a. Corresponding Author : partenza@hanmail.net
- 접수일자 : 2004. 2. 3
- 1차 심사 : 2004. 5. 13
- 2차 심사 : 2004. 6. 21
- 심사완료 : 2004. 6. 22

2. 실험

2.1 실험시편

그림 1의 (a), (b) (c)는 본 논문에서 트리발생을 위해 제작한 시편을 나타내고 있다.




그림 1. 세 가지 경우의 시편형상.
 Fig. 1. Three type specimens for treeing discharges (tree model #1 : needle specimen, tree model #2 : specimen with void at needle ending, tree model #3 : metal particle included specimen in the solid insulator).

그림 1의 (a)는 XLPE절연물내에 침결함에 의한 트리 발생을 모의한 것이고, (b)는 침 끝단에 기포가 존재할 경우 트리 발생을 모의한 것이다. 또한 (c)는 XLPE절연물내에 금속이물질이 존재할 경우 트리발생을 모의하기 위한 시편을 나타내고 있다.

2.2 실험장치

그림 2는 부분방전발생으로부터 방전 데이터를 취득하는 과정을 나타내고 있다. 부분방전의 발생시 측정은 아래의 구성도와 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. 실험에서 인가전압은 13 kV로 하였으며, 한 개의 데이터 취득기간은 300주기로 하였다. 또한 초기의 트리 발생시에는 침단에서 매우 빠른 속도로 진전을 하는 관계로 성장이 10 % 이루어

졌을 때를 트리 발생의 시초로 하여 데이터를 취득하였다. 실제적인 부분방전의 분류데이터로서는 트리방전이 본격적인 모습을 드러내고 각각의 특징을 어느 정도 확인할 수 있는 50 % 시점의 데이터를 이용하였다.




그림 2. PD측정시스템의 블록도.
 Fig. 2. Block diagram of PD measuring system.

2.3 데이터처리과정

검출된 방전펄스는 컴퓨터를 이용해 최대방전량, 평균방전전류, 발생빈도수 등을 연산하고 $\int -q-n(\text{위상} - \text{방전전하량} - \text{방전회수})$ 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. 그림 3은 데이터취득에 대한 일련의 과정들을 나타낸 것이다.

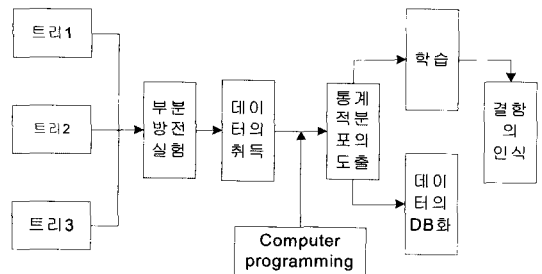


그림 3. PD데이터의 처리흐름도.
 Fig. 3. Block diagram of PD data processing.

3. 통계적 분포

부분방전 데이터를 통계적으로 처리하여 나타내기 위해서는 최소 100주기 이상의 부분방전데이터를 취득하여야 하는데, 데이터는 1주기를 기준으로 sampling한 것의 정보를 갖는다. 본 논문에서는 1주기의 위상각을 64개의 구간으로 구분하고, 방전전하량을 크기별로 64개의 구간으로 분할한 후에 각각의 위상각 구간에서 발생한 부분방전의 개수를 방전전하량의 크기별 구간으로 계수하여 $\emptyset - q - n$ 분포를 도출한다. 이 $\emptyset - q - n$ 분포로부터 네 가지의 통계적 분포가 도출이 되는데, 이는 다음과 같다. 부분방전의 특성분포로서 $H_n(q)$ 분포는 부분방전의 방전전하량의 크기별 발생빈도를 나타내는 특성분포로서 $\emptyset - q - n$ 분포에서 각각의 방전전하량의 크기별 구간에 대하여 모든 위상각 구간에서 발생한 부분방전의 단위시간당 발생빈도를 합계하여 도출한다.

또한 $H_n(\emptyset)$ 분포는 방전 발생빈도의 위상각에 따른 분포로서 위상각 구간에 따른 부분방전의 발생빈도를 계수하여 도출한 특성분포이다.

$H_q(\emptyset)$ 분포는 최대 방전전하량의 위상각에 따른 분포로서 각각의 위상각 구간에서 발생한 최대 방전전하량의 크기를 나타낸 특성분포이다.

$H_{qn}(\emptyset)$ 분포는 펄스 평균 방전전하량의 위상각에 따른 분포로서 각각의 위상각 구간에서 발생한 부분방전의 평균 방전전하량을 도출한 것으로 일반적으로 각각의 위상각 구간에서 발생한 부분방전의 방전전하량과 그 크기의 발생빈도를 곱한 값의 합을 부분방전의 총 발생빈도로 나누어 도출한다. 특성파라미터는 특성분포 자체의 데이터를 이용하지 않고, 분포의 형상을 특성화한 것으로 분포의 형상파라미터이다. 또한 특성파라미터는 데이터량이 특성분포에 비하여 매우 적다.

이상과 같이 네 가지 경우의 통계적 분포를 살펴해보았는데, 이 통계적 분포는 부분방전원의 특징을 나타내는데 있어 효과적인 방식이며, 본 논문에서는 이와 같은 통계적 분포를 신경망이 입력으로 사용하여 학습을 시킨 후 분류를 하였다.

4. 실험결과 및 고찰

4.1 $\emptyset - q - n$ 분포

그림 4는 세 가지 결합에 대한 통계적 분포인 $\emptyset - q - n$ 분포를 나타내고 있는데, 통계적 분포인 $\emptyset - q - n$ 분포는 방전형태에 따른 특징을 잘 표현해주고 있다. 그림의 통계적 분포에서 살펴보면 각 방전에 대해 방전발생위상각, 방전회수, 방

전양에 있어서 특징을 지니고 있음을 확인할 수 있다. 하지만 이 분포는 육안상으로 정확한 값을 도출하기에는 약간의 어려움이 있다. 결국 $\emptyset - q - n$ 분포는 간단한 방전의 특성만을 구별할 수 있을 뿐이다. 그런 면에서 4.2절에 나타난 네 가지 경우의 통계적 분포는 방전의 양상을 비교적 정확하게 나타낸다고 할 수 있다.

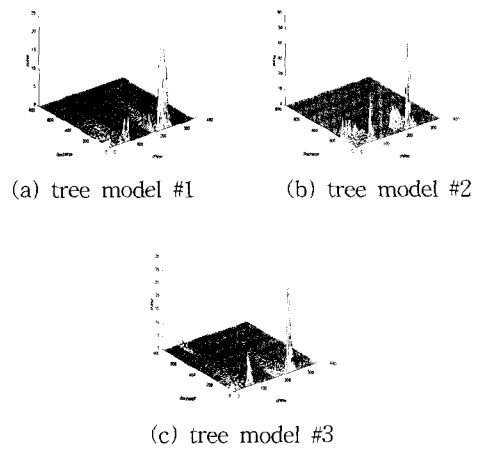


그림 4. $\emptyset - q - n$ 분포.
Fig. 4. $\emptyset - q - n$ distribution.

4.2 통계적 분포

그래프에서 tree model #1은 침결합의 트리, 트

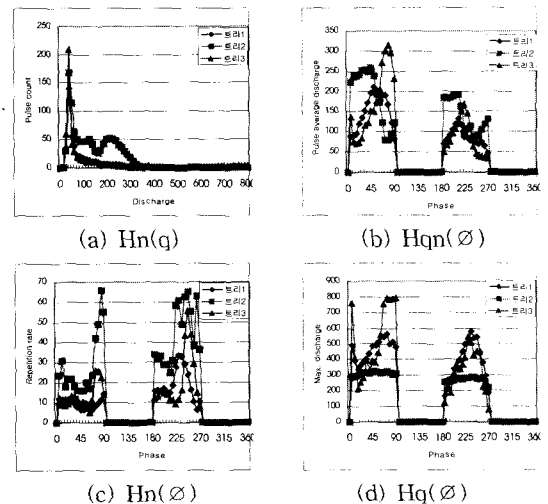


그림 5. 트리방전의 통계적 분포.
Fig. 5. Statistical distribution of tree discharges

리 2는 보이드의 존재시, 트리 3은 금속이물질의 존재시의 트리방전을 나타내고 있다. 각각의 분포에 대한 특징은 다음과 같다.

Hn(q) 분포에서는 트리 1과 트리 3의 경우는 비교적 양상이 비슷하지만, 트리 2의 경우에는 100 pC - 250 pC 까지 범위에서 방전의 회수가 많이 발생하는 것을 볼 수 있다. 이것은 보이드의 절연 파괴로 인한 방전의 크기가 증가한 것으로 보인다.

Hqn(∅) 분포에서는 트리 1, 2, 3의 모든 경우가 양의 주기와 음의 주기의 범위에서 일정한 특징을 지니며 발생하는 것을 볼 수 있다. 하지만 평균방전발생빈도수는 트리 2의 경우가 전체적으로 큰 값을 나타내고 있다.

Hn(∅) 분포에서는 위상에 따른 방전의 발생 빈도수는 트리 2, 3의 경우가 대체적으로 트리 1보다 많이 나타났다. 하지만 대체적으로 살펴보면 기포가 존재할 경우의 방전의 회수가 높게 나타나고 있음을 확인할 수 있다.

Hq(∅) 위상에 따른 최대 방전량의 분포에 있어서는 앞서의 결과는 상이하게 트리 1과 3 경우의 최대방전량이 높게 나타나고 있으며, 특히 트리 1인 경우는 최대 방전량의 크기가 월등히 높게 나타나고 있음을 알 수 있다.

전체적으로 살펴보면, 침결함의 방전기구 이외에 다른 방전 기구가 가해질 경우에 전체적으로 방전의 회수 및 방전의 평균크기가 높아졌으며, 특히 보이드가 존재하는 경우에는 그 차이가 현격하게 구분이 되었다. 방전의 양상을 주기별로 살펴볼 때, 양의 주기에서는 방전의 크기는 음의 주기보다 크지만 방전의 회수는 음의 주기가 빈도수가 많게 나타나고 있음을 확인할 수 있다.

5. 신경망을 이용한 패턴 분류


4.2절에서 표현한 통계적 분포로부터 방전의 패턴은 어느 정도 특징을 갖고 있으며, 그 특징들을 이용해 방전의 패턴은 구별할 수 있음을 확인하였다. 하지만 통계적 분포 그래프 자체의 특성만으로는 on-line 감시진단 시스템에의 적용은 무리가 있다. 따라서 본 논문에서는 부분방전의 통계적 분포를 신경회로망의 입력으로 사용하여 방전패턴을 학습시킨 후 패턴을 분류하였으며, 그것의 결과로서 각각의 방전패턴에 대한 인식률을 나타내었다. 신경회로망 학습알고리즘으로는 BP(Back Propagation - 역전파 학습알고리즘)를 사용하였다. 학습은 RMSE(Root Mean Square Error)값이 '0'으로 수렴이 될 경우가 완전한 학습이 이루어진 것이므로 RMSE값을 '0'으로 수렴하게 하도록 PE를 선정하였다.

5.1 PE(Processing Elements)의 선정


본 논문에서 패턴분류를 위해 사용한 PE (Processing Elements - 학습율, 은닉층의 수, 반복회수)의 값들은 다음의 선정과정을 거쳐 선택이 되었다.

5.1.1 학습율의 선정

그림 6은 학습율이 0.5, 0.3, 0.2, 0.15, 0.1인 경우의 학습율의 변화양상을 나타내고 있다. 그래프에서 RMSE값의 변화양상을 살펴볼 때 학습율은 0.15이하, 0.08이상의 값을 가지는 것이 학습에서 최적의 결과를 나타내고 있음을 확인할 수 있다. 따라서 본 논문에서는 $0.08 < \text{학습율} < 0.15$ 의 범위에서 임의의 학습율을 선정하여 적용하였다.



(a) RMSE variation according to learning rate



(b) RMSE final value

그림 6. RMSE 변화율.

Fig. 6. RMSE variation rate.

5.1.2 은닉층의 수 선정

그림 7은 은닉층의 수에 따른 RMSE값의 변화를 나타내고 있다. 대체적으로 은닉층이 작을수록 RMSE값은 작은 값을 나타내고 있다. 은닉층의 수는 입력수의 1.8 - 1.9배 사이의 값을 택하는 것이 보통이지만 학습회수가 어느 정도 이상이 되면 거의 일정한 값을 유지하므로 학습시간을 고려하여 적은 값을 택하는 것이 효과적이다. 본 논문에서는

10 - 20층 사이의 값에서 선택을 하였다.




그림 7. 은닉층의 수에 따른 RMSE변화양상.
Fig. 7. RMSE variation characteristic according to hidden layer.

5.1.3 학습반복회수의 선정

그림 8은 반복회수에 따른 RMSE의 최종오차를 나타내고 있다. 그림에서 학습회수가 많아질수록 RMSE값은 작아지고 있다. 하지만 20,000회 이상의 값에서는 거의 변화가 없는 것으로 나타났다. 본 논문에서는 20,000 - 30,000회의 값을 선택하였다. 하지만 실제적으로 학습시간을 고려한다면 약 10,000회 이하의 학습으로도 패턴을 분류하는데 있어서는 큰 영향을 주지 않기 때문에 데이터의 양이 매우 많고, 방전의 양상의 특징 파라미터의 수도 많아 실제 문제적용에 있어서는 10,000회 이하의 값을 선택하는 것이 바람직하다. 하지만 본 논문에서는 RMSE값이 '0'가까이 수렴이 되는 학습회수를 우선적으로 고려하여 선택을 하였다.




그림 8. 반복회수에 따른 최종오차의 양상.
Fig. 8. RMSE final value according learning cycles.

5.2 패턴분류결과

4.2절에서는 여러 경우의 시뮬레이션을 통해 적절한 PE 값을 선택하였다. 이번 절에서는 이를 토대로 실제적으로 신경망에 적용하였을 경우의 분류결과와 인식률에 대해 언급하도록 하였다.


신경망에 있어서 중요한 점은 학습이 얼마나 잘 이루어졌나 하는 것이다. 즉 방전패턴을 명확하게 분류하기 위해서는 많은 경우의 PE들을 선정하여 가장 정확한 학습이 이루어졌을 경우의 weight (neuron) 값을 선정하는 것이 가장 중요한 작업이라 할 수 있다. 표 1의 학습시에 사용되었던 PE값은 이런 과정을 거쳐 선택된 것이며, 이 결과로 학습된 weight값이 최종적으로 패턴분류시에 적용되었다.

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	20

그림 9의 (a), (b), (c)는 각각 RMSE값의 변화, 학습결과, 분류결과를 나타내고 있다. 방전데이터는 세 가지 경우에 대해 각각 40씩 총 120개의 데이터를 이용하였으며, 데이터의 절반은 학습용으로, 나머지 반은 분류용으로 사용을 하였다



(a) Variation of RMSE Value



(b) Training Result (c) Classification Result

그림 9. 신경망 분류 결과.
Fig. 9. Results of pattern classification.

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 침결함의 패턴분류에 대해 fitting된 결

과를, '0.4'는 보이드 존재시, '0.8'은 금속이물질의 존재시의 fitting된 분류결과를 나타내고 있다. 실험을 통해 얻은 트리방전의 학습하지 않은 데이터의 분류 결과에 대한 인식률을 표 2에 나타내었다.

표 2. 방전분류에 대한 인식률.

Table 2. Recognition rate.

학습된 패턴	분류용 패턴		
	tree model #1	tree model #2	tree model #3
tree model #1	100%	5%	-
tree model #2	-	95%	5%
tree model #3	-	-	95%

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. 침결함에 대해서는 100 % 인식률을 보였지만, 보이드의 존재시는 95 % 인식률을 나타냈고, 금속이물질의 존재시도 95 %의 인식률을 나타냈다. 보이드에서 나머지 5 %는 침결함에 대한 오차로서 보이드방전의 패턴에서 5 %가 침결함의 패턴과 유사하다는 것을 나타낸다. 금속이물질의 인식률도 마찬가지로 보이드존재시의 패턴과 유사한 패턴이 5 % 정도로 되어 인식률이 95 %를 보였다. 결과적으로 전체의 인식률은 97 %로 나타났다. 이것은 외국의 선행된 논문[6,7]의 인식률 결과와 동등하거나 그 이상의 높은 인식률을 보이고 있다.

결론적으로 트리방전의 패턴 분류로서 BP 학습 알고리즘을 이용한 신경회로망의 적용은 인식률의 측면에서 매우 좋은 결과를 나타내었다.

6. 결 론

XLPE 전력용 케이블에서 발생할 수 있는 트리방전의 부분방전 분포 특성에 대해 신경망을 이용한 패턴분류에 대한 연구를 진행하였으며 다음과 같은 결과를 얻을 수 있었다.

1. 부분방전 데이터로부터 도출된 통계적 분포는 결합의 종류가 다른 방전의 양상을 잘 나타내주고 있다. 일반적으로 통계적분포는 위상각과 방전량, 방전회수의 관계를 통계적, 정량적으로 표시한 것인데, 결합의 종류가 달라지게 되면 이들의 분포양상이 다르게 나타나고 있는 것을 확인할 수 있었다.

2. 통계적 분포를 신경망의 입력으로 하여 학습을 시킨 후 패턴을 분류한 결과는 기존의 선행된 연구결과와 비교하여 동등 혹은 그 이상인 97 %의 인식률을 보여 좋은 결과를 나타내었다.

위와 같은 결론은 신경망의 학습결과로 인한 분류가 잘 이루어졌으며, 그에 대한 적용가능성도 상당히 높다는 것을 의미한다. 비록 본 논문에서 사용한 BP학습알고리즘이 오랜 학습시간과 국부최소점에 빠지는 등의 문제가 있지만, 분류결과적인 측면과 부분방전의 불특정환 특성을 고려해 볼 때 이런 결과는 on-line 분류시스템과 전문가 시스템에의 적용가능성을 높여주는 것이라고 사료된다.

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, 17권, 1호, p. 101, 2004.