

XLPE 전력용 Cable 시편의 부분방전원의 분류

박성희, 박재열, 이강원*, 강성화**, 임기조

충북대학교 전기공학과, 한국철도기술연구원*, 충청대학 산업안전공학과**

PD Classification by Neural Networks in Specimen of XLPE Power Cable

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

ChungBuk National University, KRRI*, Chungcheong college**

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, XLPE Cable, 통계적 분포, 신경회로망

1. 서 론


전력용케이블의 부분방전은 다양한 경로로 발생한다. 케이블 종단에서의 코로나방전, 절연물내의 기포에 의한 방전, 트리에 의한 방전등이 그 대표적인 현상이다. 절연물내의 보이드나 트리의 성장은 결국에는 절연파괴를 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, 완전하게 부분방전에 대한 패턴의 분류는 초보적인 수준에 머물러 있다. 이에 본 논문에서는 부분방전원의 패턴 분류로서 패턴 분류 및 영상인식 등에 널리 사용되고 있는 신경회로망에의 적용에 대한 결과 및 인식률[2, 3]에 대해 살펴보았다. 부분방전원의 결함으로서는 트리

발생을 모의하기 위해 25.8kV XLPE Cable(제조사 : 대한전선)의 절연물부인 XLPE를 절개하여 침을 삽입한 후 트리를 발생시켰으며, 침단에 보이드가 있는 경우와 절연물내에 금속이물질이 있는 경우 등 세 가지 경우에서 방전발생을 모의하였다. 방전 데이터의 취득후에는 방전의 통계적 분포($H_n(q)$, $H_{qn}(\varnothing)$, $H_n(\varnothing)$, $H_q(\varnothing)$)를 사용하여 각각의 분포에 대한 통계적 분포파라미터(Skewness, Kurtosis, cc, asy 등)를 도출하였다. 네 가지의 통계적 분포는 각각의 방전의 양상을 잘 표현해줄 수 있으며 [3,4,5], 통계적 분포의 파라미터들을 이용하여 신경회로망의 입력으로 이용하여 분류를 하였으며, 각각에 대한 인식률을 검토하였다.


2. 실험

2.1 실험장치

그림 1의 (a), (b) (c)는 본 논문에서 트리발생을 위한 인공결함을 나타내고 있다.



(a) 트리(칩-평판 전극) (b) 보이드(칩 끝단)



(c) 금속이물질이 존재

그림 1. 시편의 형상

2.2 실험방법

그림 2는 부분방전발생으로부터 방전 데이터를 취득하는 과정을 나타내고 있다. 인가전압은 13kV로 하였으며, 한 개의 데이터 취득기간은 300주기로 하였다. 또한 초기의 트리 발생시에는 칩단에서 매우 빠른 속도로 진전을 하는 관계로 성장이 10%이루어 졌을 때를 트리 발생의 시초로 하여 데이터를 취득하였다. 실제적인 부분방전의 분류데이터로서는 트리방전이 본격적인 모습을 드러내는 50% 시점의 데이터를 이용하였다.




그림 2. 실험장치

검출된 방전펄스는 컴퓨터를 통해 최대방전량, 평균방전전류, 발생빈도수 등을 연산하고 \emptyset -q-n

(위상 - 방전전하량 - 방전회수)분포를 도출하게 된다. 특별히 전기트리 방전시에는 트리가 미세한 부분에서 발생하기 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 성장을 확인하였다.

3. 통계적 분포

부분방전 데이터를 통계적으로 처리하여 나타내기 위해서는 최소 100주기 이상의 부분방전데이터를 취득하여야 한다. 데이터는 1주기를 기준으로 sampling한 것의 정보를 갖는다. 따라서 본 연구에서는 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. 부분방전의 특성분포인 $Hn(q)$ 분포는 부분방전의 방전전하량의 크기별 발생빈도수를 나타내는 특성분포로서 \emptyset -q-n 분포에서 각각의 방전전하량의 크기별 구간에 대하여 모든 위상각 구간에서 발생한 부분방전의 단위시간당 발생빈도수를 합계하여 도출한다.

또한 $Hn(\emptyset)$ 분포는 방전 발생빈도수의 위상각에 따른 분포로서 위상각 구간에 따른 부분방전의 발생빈도수를 계수하여 도출한 특성분포이다.

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

$Hqn(\emptyset)$ 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 발생빈도수를 곱한 값의 합을 부분방전의 총 발생빈도수로 나누어 도출한다. 특성파라미터는 특성분포 자체의 데이터를 이용하지 않고, 분포의 향상을 특성화한 것으로 분포의 형상파라미터이다. 특성파라미터는 데이터량이 특성분포에 비하여 매우 적다.


이상에서 도출된 분포에 대한 통계적 분포파라미터를 이용해 신경망에 적용을 하게 된다. 신경망

적용시의 통계적 분포파라미터는 Skewness, Kurtosis, 상관계수, 비대칭도 등을 이용하게 되며 이 분포 파라미터는 방전의 특징을 규정짓는 중요한 인수이다.

4. 실험결과 및 고찰


4.1 $\emptyset - q - n$ 분포

그림 3은 세 가지 결함에 대한 통계적 분포인 $\emptyset - q - n$ 분포를 나타내고 있다.



(a) 칩단트리

(b) 보이드존재시



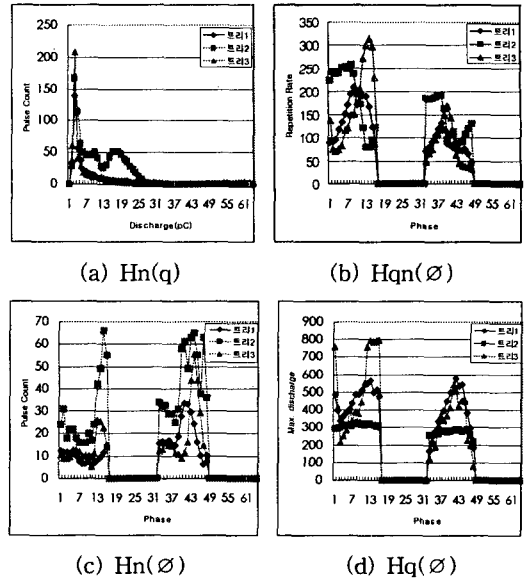
(c) 금속이물질 존재시

그림 3. $\emptyset - q - n$ 분포

통계적 분포인 $\emptyset - q - n$ 분포는 방전형태에 따른 특성을 잘 표현해주고 있다. 그림의 통계적 분포에서 살펴보면 각 방전에 대해 방전발생위상각, 방전회수, 방전양에 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 나타낸 네 가지 경우의 통계적 분포는 방전의 양상을 비교적 정확하게 나타낸다고 할 수 있다.

4.2 통계적 분포

그림 4는 세 경우의 트리결함에 대한 네 가지의 통계적 분포를 도시하고 있다.



(a) $H_n(q)$

(b) $H_{qn}(\emptyset)$

(c) $H_n(\emptyset)$

(d) $H_q(\emptyset)$

그림 4. 결함에 따른 통계적 분포의 양상

그래프에서 트리 1은 칩결함의 트리, 트리 2는 보이드의 존재시, 트리 3은 금속이물질의 존재시의 트리방전을 나타내고 있다. 각각의 분포에 대한 특징은 다음과 같다.

$H_n(q)$ 분포에서는 트리 1과 트리 3의 경우는 비교적 양상이 비슷하지만, 트리 2의 경우에는 7pC - 25pC 까지 범위에서 방전이 발생하는 것을 볼 수 있다. 이것은 보이드의 절연파괴로 인한 방전의 크기가 증가한 것으로 보인다.

$H_{qn}(\emptyset)$ 분포에서는 트리 1, 2, 3의 모든 경우가 양의 주기에서는 $0^\circ - 90^\circ$ 범위와 음의 주기에서는 $180^\circ - 270^\circ$ 범위에서 발생하는 것을 볼 수 있다. 하지만 평균방전발생빈도수는 트리 2의 경우가 전체적으로 큰 값을 나타내고 있다.

$H_n(\emptyset)$ 분포에서는 위상에 따른 방전의 발생 빈도수는 트리 2, 3의 경우가 대체적으로 트리 1보다는 많이 나타났다. 하지만 대체적으로 살펴보면 기포가 존재할 경우의 방전의 회수가 높게 나타나고 있음을 확인할 수 있다.

$H_q(\emptyset)$ 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 조합해 보면, 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 살펴보았을 때, 양의 주기에서는 방전의 크기는 음의 주기보다 크지만 방전의 회수는 음의 주기가 빈도수가 많게 나타나고 있음을 확인할 수 있다.

이렇듯 통계적 분포는 각각의 서로 다른 방전에 대한 양상을 비교적 잘 나타낼 수 있는 장점이 있다. 하지만 통계적 분포는 방전특성을 전체적으로 파악하고 구별하는 데에는 용이하지만 이것을 실제적으로 적용하기에는 정확성에서 문제가 있을 수 있다. 따라서 본 논문에서는 통계적 분포의 양상을 신경망에 학습시켜 각각의 특성을 인식시켜 주므로써 방전원의 패턴을 분류하였다.


4.3 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 분포는 육안 및 계산상으로는 명확한 패턴을 분류하기에는 어려운 점이 많다. 따라서 본 절에서는 부분방전의 통계적 분포를 신경회로망의 입력으로 사용하여 방전패턴을 학습시킨 후 그것의 결과로서 각각의 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. 본 논문에서 패턴분류를 위해 사용한 PE의 값들을 아래에 나타내었다.


- 학습률(Learning Rate) : 0.12
- 모멘텀(Momentum) : 0.75
- 학습회수(Epoch) : 30000회
- 은닉층의 수(Hidden Layer) : 250

그림 5의 (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 5. 신경망 학습 결과 ('0'은 침결함, '0.4'는 보이드 존재시, '0.8'은 금속이물질 존재시)

신경망 학습결과 RMSE 값은 거의 '0'으로 수렴을 하였으며, 학습한 결과도 100% 분류되었다. 분류결과에서도 1, 2개의 데이터를 제외하고는 거의 분류가 되었다. 그래프의 y축값의 '0'은 침결함의 패턴분류에 대해 fitting된 결과를, '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 1에 나타내었다.

표 1. 방전분류에 대한 인식률

학습된 패턴	분류용 패턴(모든결함에 대해)		
	침결함	보이드존재	금속이물질
	인식률		
침결함	100%	5%	-
보이드존재	-	95%	5%
금속이물질	-	-	95%

표 1은 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. 그러면 각각의 방전에 대해서만, 즉 입력데이터로서 침결함, 보이드, 금속이물질 중 하나의 패턴에 대해서만 인식률을 나타내도록 하겠다. 표 2는 이것에 대한 패턴의 인식률을 보이고 있다.

표 2. 한 가지 패턴에 대한 인식률

학습된 패턴	분류용 입력 패턴 (한 개의 패턴에 대해)		
	침결함만입력	보이드만입력	금속이물질만입력
	인식률		
침결함	100%	-	-
보이드존재	-	100%	-
금속이물질	-	-	100%

한 개의 패턴에 대한 인식률은 각각의 결함에 대해 모두 100%의 인식률을 보였다.

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

5. 결 론

XLPE 전력용 케이블에서 발생할 수 있는 트리방전의 방전양상에 대해 신경망을 이용한 패턴분류에 대한 인식률은 매우 좋은 결과를 나타내었다. 이는 신경망의 학습결과로 인한 분류가 매우 잘 이루어졌으며, 그에 대한 적용가능성도 상당히 높다는 것을 의미한다. 비록 본 논문에서 사용한 BP 학습알고리즘이 오랜 학습시간과 국부최소점에 빠지는 등의 문제가 있지만, 분류결과적인 측면과 부분방전의 불특정한 특성을 고려해 볼 때 이런 결과는 on-line 분류시스템과 전문가 시스템에의 적용가능성을 높여주는 것이라고 사료된다.

참고 문헌

- [1] 한국전기연구원, "전력기기 절연진단기술", Vol 4, No. 5, p209-274, 2001.
- [2] F. H. Kreuger, E. Gulski, and A. Krivda, "Classification of Partial Discharge", IEEE Trans. on EI, Vol. 28, No. 6, p. 917 - 922, 1993.
- [3] E. Gulski and F. H. Kreuger, "Computer-aided recognition of Discharge Sources", IEEE Trans. on EI, Vol. 27, No. 1, p. 82 - 97, 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 - 65, 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 - 545, 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 - 456, 2002..