

SOM 알고리즘을 이용한 부분방전 패턴인식에 대한 연구

論 文
53C-10-5

A Study on the Partial Discharge Pattern Recognition by Use of SOM Algorithm

金正泰[†] · 李鎬根* · 林銳錫** · 金智鴻** · 具滋允***
(Jeong-Tae Kim · Ho-Keun Lee · Yoon Seok Lim · Ji-Hong Kim · Ja-Yoon Koo)

Abstract - In this study, we tried to investigate that the advantages of SOM(Self Organizing Map) algorithm such as data accumulation ability and the degradation trend trace ability would be adaptable to the analysis of partial discharge pattern recognition. For the purpose, we analyzed partial discharge data obtained from the typical artificial defects in GIS and XLPE power cable system through SOM algorithm. As a result, partial discharge pattern recognition could be well carried out with an acceptable error by use of Kohonen map in SOM algorithm. Also, it was clarified that the additional data could be accumulated during the operation of the algorithm. Especially, we found out that the data accumulation ability of Kohonen map could make it possible to suggest new patterns, which is impossible through the conventional BP(Back Propagation) algorithm. In addition, it is confirmed that the degradation trend could be easily traced in accordance with the degradation process. Therefore, it is expected to improve on-site applicability and to trace real-time degradation trends using SOM algorithm in the partial discharge pattern recognition

Key Words : Partial Discharge, Pattern Recognition, SOM, BP, Kohonen Map

1. 서 론

전력설비에 대한 부분방전 진단의 해석 방법으로는 각종 결함에 따라 패턴의 차이를 나타내기 때문에 1960년대 이후로 부분방전 해석으로 PRPDA(Phase Resolved Partial Discharge Analysis)[1]가 가장 널리 사용되고 있다. 이 방법은 소위 Φ -q-n에 의한 통계적인 분석방법으로 인가전압의 위상 Φ 에 대해 나타나는 최대 또는 평균 방전 전하량이나 방전 수를 증첩하여 표기하고, 이에 대해 가우지언 분포에 따른 첨도(kurtosis)와 왜도(skewness) 및 정부극성의 비교를 통해 각 결함의 패턴을 특징짓는 방법이다.

그 이후, 부분방전 패턴인식 분야에 신경회로망(Neural Network : NN) 기법이 적용되기 시작하였는데, 1990년대초 Gulski 교수가 부분방전 해석에 대해 BP(Back Propagation), SOM(Self Organizing Map) 및 LVQ(Learning Vector Quantization) 등 여러 가지 신경회로망 방법을 비교하였다[2]. 그는 여러 가지 모델 결함에서 발생하는 부분방전에 대해 PRPDA로 나타내고 각 결함에 대해 첨도와 왜도 및 정부극성 비교 값 등의 파라미터를 구한 후 3가지 신경회로망을 적용한 결과 BP의 인식율이 가장 높은 것으로 보고하였다. 이

후로 BP-NN(Back Propagation-Neural Network)을 이용한 부분방전 패턴인식기법은 가장 보편적인 인공지능기법으로서 자리잡고 있다.

부분방전의 PRPDA와 같은 패턴은 측정에 사용된 센서의 종류, 측정 주파수 대역, 측정시스템의 감도 등에 따라 약간씩 달라질 수 있으며, 특히 현장의 경우 동일한 결함일지라도 센서의 부착위치에 따라 패턴이 달라질 수 있다. 따라서, 부분방전 패턴인식 기법은 현장 데이터에 대한 수정이나 보완이 용이할 필요가 있다.

이러한 측면에서 BP를 이용한 패턴인식기법은 문제를 안고 있다. 즉, BP에서는 미리 실험실에서 확보된 데이터를 이용하여 학습하고 이를 현장에 적용시키는 알고리즘이므로, 현장에서 동일한 결함일지라도 약간 다른 특성의 데이터가 측정될 경우 이를 현장 수정을 통해 보완할 수 없으며, 보완하려면 다시 처음부터 학습하여야 하는 알고리즘이다. 또한, BP는 결함의 판별정도에 대한 수치적(%) 가능성만을 제시해 줄 뿐 새로운 패턴일 가능성에 대한 제시 및 실제적인 열화의 진단단계나 결함의 변화추이에 대한 확인이 용이하지 않다.

한편, SOM은 Gulski 교수의 연구[2]에서 BP에 비해 인식율은 떨어졌지만, 기 확보된 데이터로서 학습하여 패턴인식을 수행하다가 추가 데이터의 입력이 가능한 알고리즘이며 패턴의 변화 추이를 추적할 수 있는 알고리즘으로 알려져 있다[3]. 이러한 SOM의 특징은 현장에서의 부분방전 해석과 같은 경우 상당한 장점이라 생각할 수 있다.

따라서, 본 연구에서는 SOM의 Kohonen Map을 도입하여 부분방전 패턴인식에서 데이터 추가기능과 열화 진단 추이 추적 기능이 가능한지 시도하였다. 이를 위해 대표적인 전력

[†] 교신저자, 正會員 : 대전대 전기정보시스템공학과 부교수 · 공박
E-mail : jtkim@daejin.ac.kr

* 學生會員 : 대전대 전기정보시스템공학과 석사과정

** 學生會員 : 한양대 전기공학과 박사과정

*** 正會員 : 한양대 전기공학과 교수

接受日字 : 2004年 5月 28日

最終完了 : 2004年 8月 11日

설비인 GIS와 전력케이블을 대상으로 발생 가능한 대표적인 모델 결함에서의 부분방전 데이터를 토대로 SOM을 적용하여 분석하였다.

2. SOM 알고리즘 및 분석 방법

2.1 SOM 알고리즘

SOM은 무감독 학습 방법의 일종으로 스스로 n 차원의 입력 데이터들을 군집화하여 2차원으로 사상시켜 준다. SOM의 구조는 그림 1과 같다.




그림 1. SOM 알고리즘의 구조
Fig. 1. Structure of SOM algorithm

그림 1은 2-layer 신경망으로 n 차원의 입력 데이터를 표현하는 n 개의 입력 노드들과 k 개의 분류 영역(decision region)을 표현하기 위한 k 개의 출력 노드로 구성되어 있다. 모든 입력 노드들은 모든 출력 노드들과 연결되어 있고 연결가중치(weight)를 가진다. 초기 상태에서는 연결가중치들을 임의로 할당한다. 임의의 연결가중치를 할당한 후 입력 벡터와의 유사성을 측정하기 위해 보통 유클리드 거리를 이용한다. 입력 벡터와 k 개의 연결강도 벡터들 사이의 유클리드 거리를 구하여 가장 가까운 연결가중치 벡터가 승자가 된다. 승자 선택 후에는 연결가중치 벡터가 갱신되며, 승자 출력 노드의 연결가중치 벡터는 입력 벡터 쪽으로 약간 이동하게 된다. 이러한 움직임은 초기에는 산만하나 점차 안정되어 간다. 본 연구에서는 부분방전 해석에 대한 SOM 적용 가능성 판단을 위해 "Data Engine"이라는 범용 프로그램[4]을 사용하였다.

2.2 해석 대상 및 전처리 과정

2.2.1 해석 대상

본 연구에서 고려한 분석 대상으로는 GIS와 XLPE 케이블 접속함 계면에서 주로 발생할 수 있는 결함을 모의하였다. 먼저 GIS에 대해서는 부유물(Floating Particle : "Float"), 스페이서에 붙은 이물(Particle on the Spacer : "MS"), 3중점에 위치한 이물(Particle on the Triple Point : "Triple"), 금속 이물(Moving Particle : "MG") 등 4 개의 결함을 선정하였으며, XLPE 케이블 접속함 계면에 대해서는 계면에 존재 가능한 보이드 결함을 선정하였다. GIS 모의 결함은 SOM을 이용한 분석 및 데이터 누적기능 확인을 위해 그리고 XLPE 케이블 접속함 계면 보이드 결함은 열화 진단 추적기능에 대한 확인을 위해 적용하였다.

2.2.1 전처리 과정

부분방전 패턴인식에 SOM 알고리즘을 적용하기 위해 측정된 부분방전 데이터에 대해 전처리를 수행하였다. PRPDA를 이용하여 측정 데이터의 인가전압 위상에 대한 최대 부분방전량($q-\Phi$)의 패턴 이미지를 얻은 후, 이를 120×20의 픽셀로 나누어 데이터 처리를 하였다. 즉, 위상인 가로축은 120(한 픽셀당 3°)으로 방전량인 세로축은 20(한 픽셀당 5%)으로 전체 이미지를 나누고, 각 픽셀 내에 들어가는 데이터의 수(방전수 n)를 이용하여 패턴인식을 수행하였다. 결국 SOM 적용시 입력 노드 수는 2,400개가 되었고, 출력 노드 수는 25×25 또는 40×40으로 수행하였다.




그림 2. SOM 신경회로망 학습 알고리즘
Fig. 2. Learning algorithm of SOM Neural Network

3. 분석 결과

3.1 알고리즘 학습 횟수에 따른 Kohonen-Map 형성 과정


GIS 모의 결함들을 대상으로 학습 횟수에 따른 Kohonen Map 형성 과정을 그림 3에 나타내었다. 이러한 학습 과정에 사용된 데이터는 "Float" 결함의 경우 11개의 PRPDA 데이터, "MS" 결함의 경우 8개, "Triple"의 경우 15개 및 "MG"의 경우 24개 PRPDA 데이터로서, 총 58개의 PRPDA 데이터였다. 각 PRPDA 데이터가 1,000개의 부분방전 펄스 수를 포함하고 있으므로, 총 58,000개의 부분방전 펄스 수가 기본 데이터라고 할 수 있다.

그림 3.(a)에서는 학습 초기인 19회 학습 후의 Kohonen Map을 보여주고 있다. 학습 곡선(Learning Curve : 그림 좌측하단의 그래프)을 통하여 Kohonen Map 형성 정도를 확인할 수 있으며, 19회 학습 후인 그림 3.(a)는 "Triple"과 "MG"


의 양상에서 보듯이 동일한 결함이 여러 영역으로 나누어져 있고 각 결함별 경계선이 불명확하며 아직 정확한 결함별 군집화를 이루지 못하여 추가적인 학습이 더 필요함을 보여주고 있다.

97회 학습 후인 그림 3.(b)에서는 Kohonen Map이 어느 정도 형성된 것을 보여주고 있다. 각 결함별 경계선상에서의 군집화 정도는 초기보다 진전된 모습을 보여주고 있으며, "Triple"과 "MG"에 대한 군집화 상태도 초기의 모습과 달리 어느 정도 완성된 상태에 있음을 확인할 수 있다.


그림 3(c)에서는 1,000회 학습 후의 Kohonen Map 모습을 보여주고 있으며, 상당히 안정된 학습 곡선에서 보듯이 충분히 신뢰 가능한 상태의 학습률을 보여주고 있다. 97회 학습 후인 그림 (b)와 거의 유사한 결과를 보여주고 있으며, 각 결함별 경계면상에서의 군집화 정도는 확실히 결함별 구분 가능한 모습을 보여 주고 있다.



(a) 19회 학습 후 형성 모습
(a) after 19 learning steps



(b) 97회 학습 후 형성 모습
(b) after 97 learning steps



(c) 1,000회 학습 후 형성 모습
(c) after 1,000 learning steps

그림 3. 학습횟수에 따른 Kohonen Map 형성 양상

Fig. 3 Shapes of Kohonen Map according to number of learning steps


한편, SOM의 문제점은 패턴을 인식할 때 단순히 패턴을 100%의 값으로 결정하는 점에 있다고 볼 수 있다. 즉, BP 알

고리즘에서는 % 값의 수치적으로 결함을 인식하여 예를 들어 A 결함 70%, B 결함 30%와 같이 인식하는데 반해, SOM에서는 무조건 A 결함으로 인식한다. 따라서, A 결함 51%, B 결함 49%의 경우라도 SOM에서는 A 결함으로 판단하기 때문에 약간의 변동성을 두지 않아 완벽한 오판을 할 수 있는 단점을 안고 있다. 따라서, 유사한 패턴양상을 갖고 있는 결함들에 대해 SOM을 적용할 경우에는 기본적으로 오판의 위험성을 안고 있다. 따라서, 이러한 SOM의 단점을 보완할 방안이 모색될 필요가 있다.


이상의 Kohonen Map 형성과정에 대한 학습 횟수별 분석을 통하여 결함 종류별로 각각의 클러스터들이 형성되어 가는 모습을 확인하였으며, 약간의 오판 가능성은 존재하지만 Kohonen Map을 통한 결함들 간의 패턴분류가 충분히 가능하다고 판단된다.

3.2 임의 데이터에 대한 판별

Kohonen Map 형성 후 임의의 부분방전 데이터가 측정되었을 때 이를 판단하는 기능에 대해 확인하고자, 기 구성된 Kohonen Map에 임의의 데이터를 입력하여 어떠한 결함인지를 분석해 나가는 과정에 대해 그림 4와 같이 나타내었다. 이 때, 사용한 PRPDA 데이터는 그림 3에서 사용한 데이터와 동일한 것이다.



(a) 각 결함 데이터에 따라 기 구성된 Kohonen Map
(a) Kohonen Map composed based on data from various defects



(b) 임의의 데이터 입력 및 분석 후의 Kohonen Map
(b) Kohonen Map after the analysis for unknown data

그림 4. 임의의 데이터에 대한 분석 및 판별 과정

Fig. 4. The process of analysis and decision for the unknown data

먼저 그림 4(a)에서는 전술한 바와 같이 4개의 GIS 모의 결함에서의 부분방전 측정 데이터를 이용하여 Kohonen Map

을 구성하였다. 측정 데이터에 대해 140회 정도의 학습을 시킨 결과 학습 곡선에서도 알 수 있듯이 잘 정착된 Kohonen Map을 확인할 수 있다.

그림 4(b)는 임의의 데이터를 기 구축된 Kohonen Map에 적용하여 데이터 사상(Data Mapping)을 수행한 후의 모습을 나타내고 있다. 여기서 추가된 임의 데이터가 금속이물 결합인 "MG" 위에 정확하게 사상되어진 모습을 확인할 수 있다. 또한, 학습 곡선에서의 임의 데이터에 대한 추가적인 사상 수행과정이 약 140~150회에 걸쳐 발생하였음을 확인할 수 있다. 즉, Kohonen Map을 이용하여 임의 데이터에 대한 결합의 종류 판별이 가능함을 보여주었다.

한편, 상기한 그림 3 및 그림 4와 후술하는 그림 5 및 그림 7의 경우는 데이터가 동일하지만 Kohonen Map의 구성은 다르게 나타난다. 이것은 SOM 알고리즘의 특징으로 입력층 데이터의 배열 순서 또는 방법에 따라 동일한 데이터들이라 할지라도 출력층에 사상되는 위치가 다를 수 있기 때문이다. SOM은 입력층과 출력층간의 연결가중치 벡터가 유클리드 거리를 이용하여 거리가 가까운 쪽으로 이동하게 되는데, 초기에 입력된 입력층에서 데이터의 위치가 바뀐다면 출력층의 구성도 다르게 되기 때문이다. 따라서, 입력층의 데이터를 어떻게 입력시켰는지에 따라 결과인 Kohonen Map은 다르게 구성될 수 있다. 하지만, 학습 후 현장 적용시에 어떤 결합에 해당되는 데이터가 입력되어 분석될 경우에는 결국 학습된 Kohonen Map에 따라 사상될 것이므로 아무런 문제가 없다.

3.3 추가 데이터 누적기능 및 새로운 패턴 제시 기능


SOM 알고리즘의 장점중 하나인 데이터 누적기능에 대해 연구하고자 GIS의 4가지 모델결합들 중 3 가지 결합들만으로 Kohonen Map을 구성하고 이후에 추가로 다른 종류의 결합에 대한 데이터를 추가할 경우의 누적기능 확인과 새로운 결합에 대한 Kohonen Map 상에서의 영역 구성이 가능한지에 대해 조사하였다. 먼저 그림 5(a)에 나타난 바와 같이 부유물인 "Float"와 3 중점의 금속성 이물인 "Triple", 금속 이물인 "MG" 등 3가지 종류의 결합에 대한 부분방전 데이터를 이용하여 Kohonen Map을 구성하였다. 여기에 새로운 부분방전 데이터로서 스페이서에서 발생한 금속성 이물 결합 즉, "ADD(MS)"를 추가한 후 계속적으로 사상을 수행한 경우를 그림 5(b)에 나타내었다.

그림 5(b)에서 알 수 있듯이 추가 누적 데이터가 우측 하단 금속 이물의 영역 한 귀퉁이에 새로 자리 잡으면서 영역을 확보하는 것으로 나타났다. 여기에 소요되는 학습 횟수는 학습 곡선에서 알 수 있는 바와 같이 약 150~200회 정도인 것으로 확인되었다.


이러한 결과를 통해 새로운 추가 데이터 누적 시 초기부터 재학습시켜야하는 번거로움이 있는 BP 알고리즘 적용 방법과는 달리 이미 학습되어진 상태에서 추가적인 데이터에 대한 추가학습이 가능하다는 SOM의 장점을 확인할 수 있었으며, 이것은 현장 부분방전 진단에 매우 효과적인 기능이 될 수 있다. 즉, 서론에서 언급한 바와 같이 부분방전 패턴은 측정에서 사용된 부분방전 측정 시스템 및 센서 설치 위치와 현장 조건 등에 따라 동일한 결합일지라도 달라질 수 있기 때

문에, 정확한 패턴인식 뿐 아니라 부분방전 측정시스템이 장착된 바로 그 현장에서 측정된 데이터를 측정 시스템에 누적하여 패턴인식 프로그램을 수정할 필요가 있다. 현재 많이 적용하고 있는 BP 알고리즘의 경우 데이터 누적을 위해서는 기존 데이터와 함께 추가 데이터를 새로 학습시켜야 하지만, SOM의 경우에는 누적기능을 이용하여 현장에서 쉽게 수정이나 보완이 용이하므로 SOM이 BP에 비해 현장 적용성이 뛰어난 알고리즘이라 할 수 있다.

또한, 그림 5에 나타난 바와 같이 추가되어 누적된 데이터는 Kohonen Map 상의 한 곳에 자리 잡으면서 한 영역을 확보하고 있는데, 이것은 새로 누적된 데이터가 새로운 패턴일 가능성을 말해주는 결과라 할 수 있다. 만일, 추가된 데이터가 기존의 패턴에 해당된다면 기존 패턴의 영역에서 분산되면서 사상될 것이지만, 새로운 패턴이기 때문에 추가된 데이터가 군집을 이루면서 새 영역을 자리 잡게 된 것이다. 이러한 SOM의 기능은 부분방전 패턴인식의 현장 적용에 매우 유용한 기능이라 할 수 있다. 전술한 바와 같이 부분방전 측정 시스템 및 현장 여건 등에 따라 부분방전 패턴이 약간씩 달라질 수 있게 되는데, 기존에 적용되고 있는 BP 알고리즘이라면 수치적으로 100% 패턴인식은 아니고 어느 정도의 오차를 보일 것이다. 그러나, SOM에서는 상기한 바와 같이 새로운 패턴일 가능성을 제시하고 있어, 측정자로 하여금 그 현장의 특징을 감안한 패턴인 것으로 판단할 수 있게 한다. 나아가 입력 데이터가 만일 별도의 결합에 의한 것이건 특정한 노이즈에 의한 것이건 Kohonen Map에서 한 영역을 자리 잡게 된다면, 이 역시 측정자로 하여금 새로운 패턴의 가능성을 인지하게 할 수 있으므로 별도의 조치가 가능해진다. 하지만, BP 알고리즘에서는 새로운 패턴이라 할지라도 기존에 인식하고 있는 패턴에만 맞추기 때문에 기존 패턴으로만 분석하게 되는 문제가 있다. 예를 들어, 새로운 패턴이지만 BP에서 A 패턴 확률 60%, B 패턴확률 30%, C 패턴확률 10%로 도출된다면 거의 A 패턴으로 인식할 것이기 때문이며 새로운 패턴일 가능성을 제시하지는 않게 된다. 이에 반해 SOM에서는 BP에서와 같이 A 패턴으로 오판한다 해도 Kohonen Map 상에서 데이터가 군집되어 새로운 패턴일 가능성을 제시하게 되므로 측정자가 추가적인 조치를 할 수 있게 된다. 이와 같이 SOM의 데이터 누적기능은 새로운 패턴의 가능성을 제시해줄 수 있는 현장 적용에 매우 뛰어난 알고리즘이라 할 수 있다.



(a) 추가 결합 데이터 누적 전 Kohonen Map
(b) Kohonen Map before accumulating the additional data



(b) 추가 결합 데이터 누적 후 형성된 Kohonen Map
(b) Kohonen Map after accumulating the additional data

그림 5. 새로운 결합 데이터에 대한 추가 누적 과정
Fig. 5. The process of accumulating additional data

3.4 시간에 따른 입력데이터 추적 분석

시간에 따라 입력되는 데이터에 대해 단순히 패턴인식을 수행하는 것 보다 데이터의 패턴변화를 시간적으로 추적할 수 있다면 열화 판단 및 이에 따른 보수 점검 등의 적절한 조치에 큰 도움이 될 수 있다. 본 연구에서는 SOM 알고리즘 중 또 하나의 장점인 데이터 추적기능에 대해 파악하기 위해 다음과 같이 2 가지 모델 결합에 대해 연구하였다.

3.4.1 GIS의 금속이물 결합에 대한 분석

시간에 따른 패턴의 변화 추이 추적에 대해 조사하려면 부분방전 측정 데이터가 시간에 따라 변화하는 것이라야 그 효과가 있게 된다. 따라서, 본 연구의 GIS 모델 결합 중에서는 금속 이물의 경우가 시간에 따라 약간 변화하는 양상을 나타내어 이를 분석 대상으로 삼았다. 그림 6은 시간에 따라 변화하는 GIS 금속이물 결합의 PRPDA 패턴이다.

그림 6에 나타난 바와 같이 1차에서 4차까지 시간 순서에 따른 금속이물에 대한 PRPDA 패턴은 약간 달라 보이지만 큰 차이는 없었으며 다만 발생 위상에서 시간이 갈수록 차이를 보이고 있다.

그림 7은 그림 6에 나타난 테스트 데이터를 분석하기 위하여 사전에 여러 가지 결합에 대해 미리 구성된 Kohonen Map이다. 본 연구에서 다루고 있는 4 가지 GIS 모델 결합이 영역별로 잘 구성되어 있는 것을 볼 수 있다.

그림 8에 그림 6.(a)의 1차 테스트 데이터에 대해 그림 8의 Kohonen Map에 사상 한 결과를 나타내었으며, 학습 곡선에 1차 테스트 데이터에 대한 학습과정 구간이 나타나고 있음을 확인할 수 있다. 약 80회의 추가적인 반복 학습을 통해 사상이 거의 완성됨을 알 수 있다. 아울러, Kohonen Map에 사상 결과로서 1차 테스트 데이터가 금속이물인 “MG” 영역 위에 정확히 사상되어있는 것을 볼 수 있다. 1차 테스트 데이터의 누적으로 인해 전체적인 Kohonen Map 구성의 큰 변화는 없었다.

이러한 방법으로 그림 6.(b) ~ (d)의 2차 ~ 4차 테스트 데

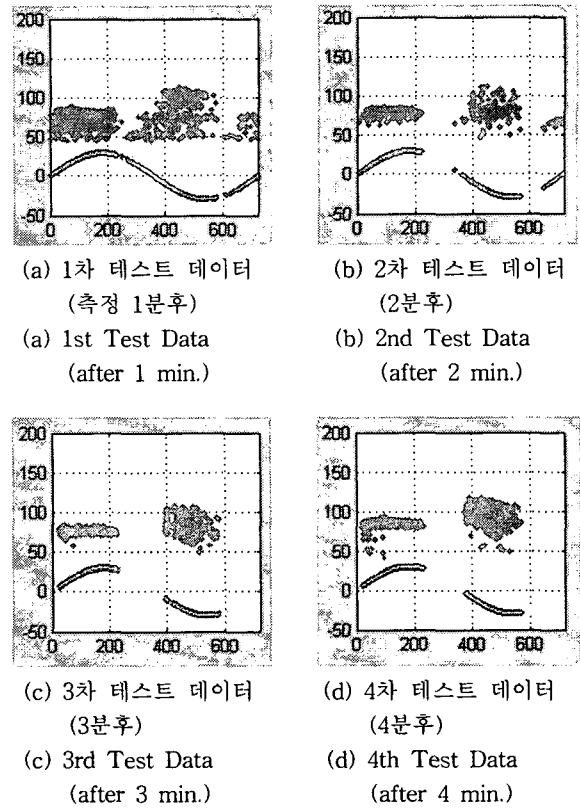


그림 6. GIS 금속이물 결합에 대한 시간에 따른 PRPDA 데이터
Fig. 6. PRPDA data according to the time evolution for the moving metal particle in GIS

이터를 순차적으로 Kohonen Map에 사상하여 테스트 데이터들의 변화 추이를 그림 9에 나타내었다. 3차 및 4차 테스트 데이터는 PRPDA 양상이 부유물인 “Float”와 유사하기 때문에 “MG” 및 “Float”의 경계부분에 사상되었지만, 1차 ~ 4차 테스트 데이터 모두 “MG” 영역 위에 올바르게 사상되고 있으며 시간적으로 순차적인 데이터의 변화 추이가 어떻게 나타나는지를 잘 보여주고 있다.

이상과 같이 GIS 모의 결합에 대한 테스트 데이터의 시간적인 변화 추이를 SOM 알고리즘을 이용하여 추적가능하다는 것을 확인할 수 있었다. 이것은 SOM을 이용하여 열화의 시간적인 진전(변화)을 추적할 수 있다는 것을 의미하고 있다.




그림 7. 4 가지결합에 대한 Kohonen Map 구성 모습
Fig. 7. Kohonen Map for the data from 4 kinds of defects




그림 8. 1차 테스트 데이터 사상 결과
Fig. 8. The result of 1st test data mapping




그림 9. 1차 ~ 4차 입력데이터의 사상 및 순차적 변화 추이
Fig. 9. 1st ~ 4th test data mapping and the trend in time evolution of the data

3.4.2 XLPE 케이블 접속함 내 결함에 대한 분석


XLPE 케이블 접속함의 대표적인 결함중 하나인 보이드 결함을 분석 대상으로 선정하였으며, SOM을 이용하여 이에 대한 열화 진전단계별 변화 추이 분석을 시도하였다. 일반적으로 XLPE 케이블 접속함 계면에 존재하는 보이드에서 나타나는 부분방전은 초기에는 전형적인 보이드 방전의 패턴을 나타내다가 점차적으로 계면을 따라 진전되는 계면 전기트리가 개시되면서부터 계면 전기트리의 패턴을 나타내게 된다.[5] 본 연구에서 분석한 계면 보이드 결함에서의 부분방전 패턴의 예를 그림 10에 나타내었다. 측정된 데이터의 양을 기준으로 순차적으로 PRPDA 패턴을 구성하였으며 총 60개의 PRPDA 데이터로 구분하였다.(하나의 PRPDA 데이터당 부분방전수는 약 1,000개 정도임) 편의상 60개의 PRPDA 데이터를 20개씩 구분하여 초기(1번 데이터 ~ 19번 데이터 : "start"로 표기), 중기(20번 데이터 ~ 39번 데이터 : "middle"로 표기), 계면 전기트리 발생 및 진전(40번 데이터 ~ 60번 데이터 : "tree"로 표기) 단계로 나타내었다.

상기 60개 PRPDA 데이터에 대해 Kohonen Map을 구성한 결과를 그림 11에 나타내었다. 이 때, Kohonen Map 구성은 출력 노드수를 25×25로 구성하여 GIS에서 사용한 40×40의 경우와 비교를 겸하였다.


그림 11에서 나타난 바와 같이 분석 결과 3개 영역으로 구성된 Kohonen Map을 확인할 수 있다. 즉, "start"는 계면 보이드 결함 초기 부분방전을, "middle"은 계면 보이드 결함 중기 부분방전을, "tree"는 보이드에서 계면 전기트리가 개시 및 진전되고 있는 절연파괴 바로 전 단계를 각각 의미하고 있다. 각 영역이 서로 분산되지 않고 군집화를 잘 이룬 것은



(a) 보이드 결함 초기 "start" 단계
(a) "start" stage ; beginning stage in void



(b) 보이드 결함 중기 "middle" 단계
(b) "middle" stage ; middle stage in void



(c) 계면전기트리 발생 및 진전 "tree" 단계
(c) "tree" stage ; initiation and propagation stage of interfacial electrical tree from void

그림 10. 계면보이드 결함에 대한 단계별 PRPDA 데이터 예
Fig. 10. Examples of PRPDA data for the interfacial void with the degradation stages




그림 11. 계면 보이드 결함의 부분방전 데이터에 대한 Kohonen Map

Fig. 11. Kohonen Map for the PD data of the interfacial void

부분방전의 시간에 따른 패턴 변화가 순차적으로 변화가 지속적으로 이루어졌음을 의미한다. 한편, 상기 Kohonen Map은 25×25의 총 625개 출력 뉴런을 격자점하여 구성된 것으로 학습 곡선에서 볼 수 있듯이 총 200회의 반복 학습으로 거의 안정된 Kohonen Map임을 알 수 있다. GIS에서 사용한 40×40 출력 뉴런과 비교할 때 군집 형성 과정이나 데이터의 사상 과정에 큰 차이가 나타나지는 않았으나, 25×25 구성으로 인해 45×45 구성의 Kohonen Map 보다 거칠게 나타나고 있는 것을 볼 수 있다.

열화진전의 변화추이 추적을 위해 이와 함께 테스트 데이터 선정을 위해 계면 보이드의 부분방전 열화 진행 단계 순으로 총 60개의 새로운 테스트용 데이터를 추가로 확보하였으며, 이 중 아래와 같이 5개의 데이터만을 선정하여 테스트 데이터로 사용하였다.

- 1차 테스트 데이터 : 4번째 (초기 단계)
- 2차 테스트 데이터 : 20번째 (초·중기 단계)

- 3차 테스트 데이터 : 28번째 (중기 단계)
- 4차 테스트 데이터 : 40번째 (중기·tree 단계)
- 5차 테스트 데이터 : 60번째 (tree 단계)

그림 12에 초기 단계인 1차 테스트 데이터를 그림 11의 기형성된 Kohonen Map에 새로 사상시킨 결과를 나타내었다. 그림 12의 학습 곡선을 보면 열화 초기 단계 데이터의 사상을 위해 추가적으로 필요한 학습 횟수가 어느 정도인지를 알 수 있다. 또한 그림 12의 Kohonen Map에서 보듯이 초기 단계인 1차 테스트 입력 데이터(s_4)가 초기결함영역 위에 정확히 사상되어, SOM 알고리즘이 초기결함 테스트 입력 데이터(s_4)를 초기 결함으로 올바르게 판단하고 있음을 알 수 있다.




그림 12. 1차 테스트 데이터(초기 단계)에 대한 사상 결과
Fig. 12. The result of 1st test data("start" stage) mapping

1차 테스트 데이터와 유사하게 순서대로 2차 ~ 5차 테스트 데이터를 입력하여 분석한 결과 그림 13과 같은 열화 진전의 추이 분석이 가능함을 알 수 있었다. 2차 테스트 데이터는 초·중기 단계에 해당하는 20번째 데이터로서 계면 보이드 결함 중기 부분방전인 "middle" 영역에 속하지만 초기 부분방전 영역인 "start"와의 경계 부분에 위치하여 초·중기 단계라는 것을 잘 나타내고 있다. 3차 테스트 데이터는 중기 단계에 해당하는 28번째 데이터로서 Kohonen Map 상의 "middle" 영역에 잘 위치하고 있다. 4차 테스트 데이터는 40번째 데이터로서 중기·tree 단계 즉 보이드 방전에서 계면 전기트리 방전으로 넘어가는 시점 부근이며 실제로 Map 상에서 "tree" 영역에 속하지만 "middle"과의 경계 가까이에 위치하는 것을 알 수 있다. 마지막으로 5차 테스트 데이터인 60번째 데이터는 완벽히 "tree" 영역에 사상되고 있다.




그림 13. 계면 보이드 결함에 대한 열화진전 추이 추적 양상
Fig. 13. Trend of the degradation stages for the interfacial void

이상 언급한 바와 같이 계면 보이드 결함에서 열화 진전에 따라 보이드 방전으로부터 계면 전기트리 방전으로 변화되어 가는 것을 SOM의 Kohonen Map을 이용하여 정확히 추적할 수 있다는 것을 확인할 수 있었다. 이것은 SOM 알고리즘이 열화진전을 직접적으로 추적 가능하다는 측면에서 열화진행 정도의 정확한 판단 및 예측과 보수 및 교체 시점 판단에 매우 효과적인 부분방전 해석 알고리즘이라는 것을 입증하는 결과이다.

4. 결론

부분방전 패턴인식 방법으로 SOM(Self Organizing Map) 신경회로망 알고리즘의 적용가능성을 파악하기 위해 GIS 및 XLPE 케이블 접속함 모의 결함에서의 부분방전 데이터를 이용하여 분석을 수행하여 다음과 같은 결론을 얻었다.

SOM의 Kohonen Map을 이용하여 여러 가지 모의 결함에서 얻어진 부분방전 데이터에 대한 패턴인식이 잘 이루어짐을 알 수 있었다. 다만, 백분율을 이용하여 수치적으로 인식율을 나타내는 BP 알고리즘과는 달리 SOM은 단순히 하나의 결함 패턴으로 지정하여 그에 해당하는지의 여부만을 판별하기 때문에 잘못된 인식을 보일 경우 완벽한 오판을 할 수 있는 단점을 안고 있다.

SOM 알고리즘의 장점중 하나인 데이터 누적가능성은 부분방전 데이터에 대해서도 잘 적용되었으며, 현장에서 바로 데이터를 누적하여 수정 및 보완할 수 있다는 측면에서 BP 알고리즘에 비해 현장 적용성이 뛰어나다고 할 수 있다.

또한, 새로운 누적 데이터가 Kohonen Map 상에서 군집하여 하나의 새로운 영역을 구축할 경우 기존과는 다른 새로운 패턴일 가능성을 제시하는 것으로 그 현장의 특성에 따라 달라진 패턴 또는 새로운 결함의 패턴일 것이라는 것을 의미하므로, 이러한 새로운 패턴가능성 제시 기능은 SOM이 매우 뛰어난 현장 적용성을 갖고 있음을 보여주는 것이다.

아울러, 결함에서 열화가 진행될 경우에 SOM의 Kohonen Map을 이용하여 정확한 추적이 가능하였으며, 열화진행 정도의 정확한 판단 및 예측과 보수 및 교체 시점 판단에 매우 효과적인 부분방전 해석 알고리즘이라는 것을 알 수 있었다.

이상 언급한 바와 같이 SOM은 부분방전 패턴인식의 현장 적용 측면에서 매우 우수한 방법이지만 앞으로 실제 적용을 위해서는 오판의 위험성을 줄일 수 있는 방안이 강구되어야 할 것으로 판단된다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초전력연구원 (R-2003-B-063) 주관으로 수행된 과제임.

참고 문헌

- [1] Cigre Working Group 21.03 Recognition of Discharges, Electra, Vol. 11, pp. 61-98, 1969.
- [2] E. Gulski, A. Krivda, "Neural Network as a Tool for Recognition of Partial Discharges", IEEE Trans. on

Elect. Insul., Vol. 28 No. 6, pp. 984-1001, 1993.

[3] T. Kohonen, "The Self-Organizing Map", Proc. of the IEEE, Vol. 78, No. 9, pp. 1464-1480, 1990.

[4] MIT Gmbh, DataEngine Overview and User Manual, 1999.

[5] Jeon-Seon Lee and Ja-Yoon Koo, "An Analysis of the Partial Discharge Pattern Related to the Artificial Defects Introduced at the Interface in an XLPE Cable Joint using a Laboratory Model", KIEE International Transactions on Electrophysics and Applications, Vol. 2-C, No. 5, pp. 239-245, 2002.

저 자 소 개



김 정 태 (金正泰)

1960년 1월 1일생. 1982년 한양대 공대 전기공학과 졸업(학사). 1987년 한양대 공대 전기공학과 졸업(석사). 1992년 한양대 공대 전기공학과 졸업(공학박사). 현재 대전대 공대 전기정보시스템공학과 부교수.

Tel : (031)539-1914 Fax : (031)535-3579
E-mail : jtkim@daejin.ac.kr



김 지 홍 (金智鴻)

1973년 8월 13일생. 2000년 대전대 공대 전기공학과 졸업(학사). 2002년 한양대 공대 전기전자제어계측공학과 졸업(석사), 2004년 한양대 공대 전기전자제어계측공학과 박사과정 수료, 현재 한양대 공대 전기전자제어계측공학과 연구과정.

Tel : (031)400-4041 Fax : (031)417-0533
E-mail : 100@ihanyang.ac.kr



이 호 근 (李鎭根)

1977년 6월 8일생. 2003년 대전대 공대 전기공학과 졸업(학사). 현재 대전대 공대 전기공학과 석사과정.

Tel : (031)539-1910 Fax : (031)535-3579
E-mail : neo2000p@empal.com



구 자 윤 (具滋允)

1951년 2월 7일생. 1975년 서울대 공대 전기공학과 졸업(학사). 1980년 프랑스 ENSEEIHT 졸업(석사). 1980년~1984년 프랑스 ENSIEG 졸업(공학박사). 현재 한양대 공대 전기공학과 교수. 한양대 전자재료부품연구센터(EM&C) 소장, 한양대 퓨전전기기술응용연구센터(FET) 소장

Tel : (031)400-5163 Fax : (031)407-9873
E-mail : koojy@hanyang.ac.kr



임 윤 석 (林鈞錫)

1973년 1월 3일생. 1998년 호서대 공대 전기공학과 졸업(학사). 2000년 광운대 공대 전기공학과 졸업(석사), 2002년 한양대 공대 전기전자제어계측공학과 박사과정 수료, 현재 한양대 공대 전기전자제어계측공학과 연구과정.

Tel : (031)400-4041 Fax : (031)417-0533
E-mail : seog29@ihanyang.ac.kr