

인공지능에 의한 부하전류파형의 인식으로 화재감지 시스템

이오걸*, 송호신**, 김태우#, 김민회##
 동의공업대학*, 부산정보대학**, 한국전력공사#, 영남이공대학##

Fire detection system by awareness of load current waveform by Neural Network

Lee O.K.*, Song H.S.**, Kim T.W.#, Kim M.H.##
 DongEui. I.T.*, Pusan I.T.**, Kepco#, Yeungnam I.T.##

ABSTRACT

In this paper, a method which can detect tracking caused by the insulation deterioration of conduct wiring, is proposed.

The computer which take experiment data is learned by neural network algorithm, which has recently been used for the load recognition.

The proposed method in our study can be applied to the development of several measuring equipments such as hot-line insulation tester, car earth tester for the detection of tracking under hot-line state.

1. 서 론

일반적으로 공장 전기배선에 사용하는 전선의 성질은 유기절연재료인 합성수지류로 만들어져 있으므로 전선피복이 주위 조건의 영향을 받아서 자연 열화 하거나, 습기나 수분의 영향을 받으면 전기절연성이 재질 본래의 것과는 달라지게 되어서 전선도체 상호간 또는 전선도체와 대지 사이에 전선피복재를 통하여 누설전류가 흐르면서 트래킹이 발생하여 결국 화재로 이어지게 된다.^{1~4)}

본 연구는 공장 배선의 선간 절연불량으로 발생하는 트래킹 현상을 검지하기 위해서 각 부하전류 파형과 무부하 및 부하시 트래킹 전류 파형의 고조파 성분을 FFT 분석하여 이들 데이터를 DB화하여, 최근 부하 인식에 많이 사용되고 있는 신경회로망을 이용하여 입력내용을 학습시켜서 부하의 종류와 트래킹 발생 유무를 식별할 수 있는 방법을 연구한다.

2. 트래킹 현상

2.1 트래킹의 생성과정.

유기절연재료의 표면이 자연열화하거나 먼지 및 습기

등의 원인에 의하여 누설전류가 흐르는 상태로 되어서 그 때 발생하는 미소한 아아크 방전(Scintillation)에 의하여 재질의 표면이 열화하여 탄화되어 가서 드디어는 탄화도전로가 형성되는 것을 트래킹 현상이라 하고, 탄화 도전로를 따라서 표면절연파괴를 일으키게 되며 화재 발생의 요인이 된다.¹⁾

2.2 공장배선의 트래킹 화재.

일반의 저전압 공장배선이나 전기기기용 배선등의 절연재료로서 종래에는 목면, 견, 쥘트 및 천연 고무 등 천연 절연 재료를 사용해 왔으나 최근에는 염화비닐(PVC) 수지가 널리 사용되고 있다. F케이블의 보급 이용에 수반해서 배선공사의 시공불량이나 쥐의 교상 등에 의해서 피복재에 손상부가 형성된다. 아래에 F-케이블의 절연 열화에 의한 발화과정을 나타내었다.




그림 1 F-케이블의 절연 열화에 의한 발화과정
 Fig. 1 Ignition process by insulation deterioration of F-cable

3. 신경 회로망의 학습

3.1 신경 회로망의 모델링

신경회로망은 불확실한 형태에 대한 판단기능과 비선형성을 가진 시스템에도 높은 적응력을 지니고 있다.

그림 2는 하나의 신경소자를 표현한 것으로 한 뉴런의 출력 Y 는 n 개의 입력, 즉, $X_1 \dots X_n$ 과 연결강도 W_i 와 곱의 합 즉, $\sum W_i X_i$ 를 출력함수 $f(X)$ 로 변환시킨 것이다. 여기서, 연결강도 W_i 는 수행하고자 하는 작업의 성능을 향상시키도록 학습시킨다.⁵⁻⁶⁾




그림 2 일반적인 뉴런의 모델
Fig. 2 Typical back-propagation processing element

n 개의 입력신호($X_1 \dots X_n$)는 모든 펄스의 크기를 나타내며, 그 강도는 0 또는 1 사이의 실수라고 한다.

3.2 역전파(Back-propagation) 학습 알고리즘

세개의 층으로 된 역전파 신경회로망에서, 입력층과 중간층의 입출력 관계는 식 (1) 및 (2)와 같다.

$$net_j = \sum w_{ji} out_i \quad (1)$$

$$out_j = f_j(net_j) \quad (2)$$

중간층과 출력층과의 관계는 식(3.3) 및 식(3.4)와 같다.

$$net_k = \sum w_{kj} out_j \quad (3)$$

$$out_k = f_k(net_k) \quad (4)$$

본 논문에서 사용한 중간층 출력함수는 그림 3에서 나타낸 것과 같은 일종의 시그모이드 함수로서, 출력 [0,1]의 범위내에서 미분 가능한 단조 증가의 Sigmoid 함수를 이용하였다.




그림 3 시그모이드 함수
Fig. 3 Sigmoid function

델타법에 의한 연결강도 갱신은 식 (5)와 같다.

$$\Delta w_{ji}(n) = -\eta \frac{\partial J}{\partial w_{ji}} + \alpha \Delta w_{ji}(n-1) \quad (5)$$

4. 파형 측정 실험

4.1 파형 측정 장치 구성

공장에서 주로 많이 사용하는 모터를 부하로 선택하여 공장배선에 트래킹 현상이 발생하였을 때의 파형을 측정하였으며, 측정 시스템은 그림 4와 같다.




그림 4 시스템 구성도
Fig. 4 Configuration of system

신경회로망에 각 부하의 특성을 인식시키기 위하여 파형을 변류기와 변압기를 사용하여 컴퓨터에 장착된 A/D, D/A 콘버터의 데이터 획득 보드인 DT 2820 보드에 입력하고, A/D 콘버터에 의해 디지털량으로 변환한 후 컴퓨터의 Memory에 읽어 들여진다. 이를 소프트웨어에 의해 각 부하의 고조파를 계산한다.

4.2 실험

그림 5에 각 전류파형과 고조파 FFT시킨 파형을 나타내었다. 이때 파형의 샘플링 시간은 0.8333[ms]로 1주기의 전류 파형을 200구간으로 샘플링 하였다. 컴퓨터에 읽어 들여진 데이터는 FFT 분석에 의해 전류의 스펙트럼을 1 - 9차 고조파까지 분석하였다. 매 부하별로 100회씩 실험을 반복하여 데이터를 구성하였다.




그림 5 트랙킹시 모터의 전류 파형 및 고조파 스펙트럼 진폭
Fig. 5 Current waveform and harmonic spectrum amplitude of motor at tracking

5. 시뮬레이션 및 결과고찰

5.1 학습 데이터 구성방법

모터를 100회의 측정결과를 FFT에 의해서 고조파 분석을 하여 각 고조파 중에서 기수차의 고조파 만을 선택하였다. 이렇게 하여 구성된 각 부하별 기본파의 진폭 및 제 3고조파에서 제 9고조파의 진폭을 모두 합한후 이 전체에 대한 각 기본파 및 고조파의 비율이 몇 퍼센트인지를 계산하였다.

이를 신경회로망을 사용하여 각 부하별로 트랙킹 현상 학습에 중간층을 가변시키면서 파형인식에 가장 정확도가 높은가를 고찰하였다.

표 1의 테스트 데이터는 각 부하별로 1개만 취하여 트랙킹 상태를 테스트하는데 이용하였다.

출력의 데이터 bit는 실험하는 부하의 종류가 10개 이상 여러 개 있을 경우 이를 2진수로 표시하기 위해서는 4bit가 되어야 하므로 bit수를 4개로 출력을 표시하였다.

표 1 테스트 데이터
Table 1 Test data

부하	INPUT HARMONIC(입력)					출력
	1	3	5	7	9	
NO	0.334213	0.433451	0.172923	0.069621	0.015907	0000
MO	0.651331	0.136253	0.050110	0.165286	0.066615	1000
NOT	0.244356	0.293496	0.269580	0.173264	0.063410	0001
MOT	0.685466	0.035654	0.083586	0.234902	0.053452	1100

기호는 다음과 같다.

MO : motor

NO : No Load

MOT: motor Tracking

NOT: No Load Tracking

학습할 때 오차 J가 1[%] 이하일 때 혹은 학습회수가 50,000회에 도달하면 학습을 종료한다.

정확도 A가 0에 가까울수록 상대적으로 우수한 구조이고 1[%]이내에 포함된다면 만족스러운 구조이다.

뉴런간의 Weight 초기값은 -1~+1 사이의 난수를 이용한다. 그 중에서 가장 적절한 -0.1 ~ +0.1을 선택하였다. 학습률 η 와 모멘트 계수는

$$\eta=0.5 \quad \alpha = 0.9$$

로 선택하였다.

5.3 결과 고찰

입력층을 5개에 각 고조파의 진폭을 입력하고, 정확성이 가장 좋은 중간층을 찾기 위하여 중간층을 5개에서 20개까지 가변하면서 학습하였다.

그림 6에 중간층이 15개 일때 신경회로망 구성의 학습한 결과를 Recall한 것이다.

이때 각각 학습 횟수는 200회와 15,000회, 30,000회, 50,000회 학습하였을 때 출력층의 오차크기는 약 30,000회 학습시에 거의 1[%]이하로 만족한 학습과정을 볼 수 있다.




그림 6 중간층이 15개일때의 학습 신경회로망
Fig. 6 Neural network of hidden layer no=15

학습률 η 와 모멘트 계수 α 를 각각 0.1에서 0.9로 가변시키면서 학습해본 결과 학습계수가 0.5이고 모멘텀항이 0.9일때 가장 빨리 학습하면서도 정확성이 가장 양호하였다.

학습결과 중간층의 수가 많을수록 적을 때 보다 수렴속도가 빠르게 되었지만 너무 많아도 오히려 수렴속도가 떨어졌다.

그리고, 학습의 정확도는 중간층의 수가 입력층의 수보다 약 3배일때 가장 학습 정확도가 양호했으며, 중간층의 수가 많을수록 정확도가 더 양호하게 되나 너무 많으면 정확도가 오히려 떨어짐을 알 수 있었다.




그림 7 트래킹이 없는 경우의 정확도(%) (부하:모터)
 Fig. 7 Accuracy of neural network without tracking (Load=Motor)(A=5,000회, B=15,000회, C=30,000회, D=50,000회)

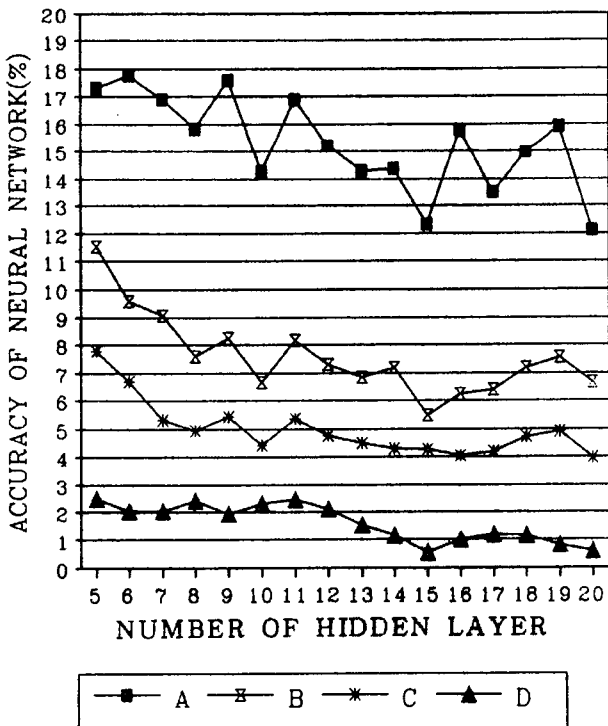


그림 8 트래킹이 있는 경우의 정확도(%) (부하:모터)
 Fig. 8 Accuracy of neural network with tracking (Load=Motor) (A=5,000회, B=15,000회, C=30,000회, D=50,000회)

각각 중간층을 5개에서 20개까지 가변시키면서 학습회수가 5,000회, 15,000회, 30,000회, 50,000회의 경우 출력층의 오차가 1[%] 이내까지 수렴 할 때의 정확도를 그림 7과 그림 8에 나타내었다.

무부하인 경우는 트래킹 현상이 발생했을 때 보다는 수렴속도도 빠르고 정확성도 좋게 나타났다.

학습 횟수를 약 30,000회이상 많이 하였을 때는 무부하나 트래킹 현상이 있는 부하에 관계없이 거의 같은 학습 특성을 보였다.

이상에서와 같이 중간층의 뉴런수가 입력층의 뉴런수의 약 3배 정도일 때가 가장 정확성의 면에서 우수한 인식능을 발휘하는 것을 알 수 있다.

중간층의 뉴런수가 입력층의 뉴런 수보다 약 3배 이상이 되면 인식이 거의 비슷한 결과를 가졌다.

이는 본 연구에서 구축한 신경회로망이 모든 트래킹 현상을 인식할 수 있는 아주 우수한 신경 회로망이 됨을 확인 할 수 있었다.

6. 결 론

본 연구에서 사용한 부하는 공장에 시설된 전선을 비롯하여 수 많은 전기설비 중에서 특히 사용 빈도가 높은 무부하시와 모터를 대상으로 실험을 하였다. 본 연구의 결과 부하시 트래킹 인식이 완벽한 장점을 이용하여 현재 공장 전기설비의 과부하 및 단락 보호장치인 배선용 차단기나 퓨우즈가 검출하지 못하는 트래킹 현상을 활선 상태에서 검출할 수 있는 활선 절연측정기 및 차량 누전 측정기 등 측정장치 개발의 기초 연구자료로 활용하는데 도움이 될 것이며, 배선용차단기와 퓨우즈의 대체품으로 사용할 수 있는 등 그 활용 범위가 넓은 것으로 생각된다.

참 고 문 헌

- [1] 青池晃, "トラッキング現象とその問題点について," 火災, 30권 3호(126), pp. 15~26, 昭和55年.
- [2] 松浦正博, "低圧用電線の火災時の被熱による絶縁破壊について," 生産と電気, pp. 16~19, 昭和58年 10月.
- [3] 西田眞外, "配電用絶縁電線の耐トラッキング性を決定するための加速試験と破壊現象," 電気學會論文誌, 104卷, 7號, pp. 25~32, 昭和59, 7.
- [4] Beland, B. "Examination of Electrical Conductors Following a Fire," Fire Technology, Vol. 16, No. 4, pp. 252~258, November 1980.
- [5] C. Klimasauskas, J. Guiver, G. Pelton, "Neural Works Professional and Neural Works Explorer, Vol. II, Neural Computing", Neural Ware, Inc., 1989.
- [6] Robert Hecht-Nielsen, "Theory of the Backpropagation Neural Network", IJCNN Conference No. 1, pp. 593~605, 1989, 6.