

선형 예측 계수의 인식에 의한 고저항 지락사고 유형의 분류

이호섭⁰, 공성곤
숭실대학교 전기공학과

Classification of High Impedance Fault Patterns by Recognition of Linear Prediction coefficients

Ho-Seob Lee⁰, Seong-Gon Kong
Dept. of Electrical Engineering Soongsil University

Abstract

This paper presents classification of high impedance fault pattern using linear prediction coefficients. A feature of neutral phase current is extracted by the linear predictive coding. This feature is classified into faults by a multilayer perceptron neural network. Neural network successfully classifies test data into three faults and one normal state.

1. 서론

산업의 급속한 발달은 양질의 전력공급과 고도의 신뢰성을 전력계통에 요구하게 되었다. 전력계통의 신뢰성과 안정성을 향상시키기 위해 여러가지 고장을 사전에 방지하거나 고장 구간을 빠르게 차단하는 방법에 대한 연구가 진행되어 왔다[1]. 최근에는 시간지연신경망같은 지능형 고장 검출 시스템이 소개되고 있다[2]. 이런 방법은 모델링이 어려운 과정에 대해서도 원하는 결과를 얻을 수 있는 장점이 있다.

본 논문에서는, 고저항지락사고시 변화하는 중성점 전류 파형에서 선형예측계수를 추출하고 다층구조신경망(multilayer perceptron neural network)의 입력으로 사용하여 지락사고의 종류와 정상상태를 판별하였다.

선형예측계수를 학습데이터로 하여 다층구조신경망을 학습하였고 테스트파형에 대해 성공적으로 판별하였다.

2. 선형 예측계수의 추출

선형예측(linear prediction)이란 식(1)과 같이 과거의 신호의 선형결합 형태로 미래의 신호를 예측하는 것을 말한다.

$$\hat{x}[n] = a_1x[n-1] + a_2x[n-2] + \dots + a_Px[n-P] \quad (1)$$

$$= \sum_{k=1}^P a_k x[n-k]$$

여기서, a_k 는 k 번째 선형예측계수이고 P는 차수이다.

실제신호는 식(2)와 같이 예측한 결과와 오차와의 합이라 볼 수 있고, 이 오차가 최소가 되는 계수 a_k 를 선형 예측 계수(linear prediction coefficient) 계수라 한다.

$$x[n] = \hat{x}[n] + e[n] \quad (2)$$

여기서, $x[n], \hat{x}[n], e[n]$ 은 각각 실제신호, 예측신호, 예측오차이다.

선형예측계수들은 시스템의 전극모델(all pole model)의 계수인 선형예측계수들은 신호의 스펙트럼에 대한 정보를 가지고 있으므로, 음성분석과 인식, 합성에 유용하게 쓰인다.[3]

고저항지락사고의 전류파형은 전구간에서 비선형특성이 강하지만, 짧은 구간에 대해서는 선형성이 강하므로 선형화시킬 수 있다. 그러므로 선형예측계수를 이용하여 신호에 대한 특징을 추출하였다.

선형예측계수를 얻는 방법에는 자기상관계수법과 공분산계수법이 있다. 공분산계수법에 의한 계수는 자기상관법보다 신호를 잘 예측하나, 시스템의 안정성이 보다 큰 자기상관계수법을 주로 사용하므로 자기상관계수법을 이용하여 계수를 추출하였다.

정해진 N 구간동안 예측오차 $e_s[n]$ 의 제곱의 합 E_s 를 식(4)와 같이 정의한다. 여기서, 예측은 P 개의 차수로 하였으므로 실제로 오차의 제곱합은 N+P 구간에서 계산한다.

$$e_s[n] = x_s[n] - \hat{x}_s[n] \quad (3)$$

$$E_s = \sum_{n=0}^{N+P-1} e_s^2[n] \quad (4)$$

정의된 E_s 가 a_k 에 대하여 최소가 되는 $\partial E_s / \partial a_k = 0$, $k = 1, \dots, P$ 식에 의하여 식(5)을 얻는다.

$$\sum_{n=0}^{N+P-1} x_s[n-k]x_s[n] = \sum_{i=1}^P a_k \sum_{n=0}^{N+P-1} x_s[n-k]x_s[n-i] \quad (5)$$

여기서, $k = 1, \dots, P$ 이다.

이 식의 아래와 같이 풀면 선형예측계수 a_k 를 구할 수 있다.

$$R_s[k] = \sum_{m=0}^{N-1+k} x_s[n]x_s[m+k] \quad (6)$$

$$\begin{bmatrix} R_s[0] & R_s[1] & R_s[2] & \cdots & R_s[p-1] \\ R_s[1] & R_s[0] & R_s[1] & \cdots & R_s[p-2] \\ R_s[2] & R_s[1] & R_s[0] & \cdots & R_s[p-3] \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ R_s[p-1] & R_s[p-2] & R_s[p-3] & \cdots & R_s[0] \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ a_3 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} R_s[1] \\ R_s[2] \\ R_s[3] \\ \vdots \\ R_s[P] \end{bmatrix} \quad (7)$$

이런 방법으로 계산된 선형예측계수는 고저항지락사고의 종류를 판별하는 다중구조신경망의 입력으로 사용된다.

3. 실험

3-1. 실험 데이터

실험에 사용된 데이터는 1985~1987년 동안 한국전력의 정주와 구미 변전소에서 한상의 전력선을 다양한 접지면에 떨어뜨려 봄으로서, 실제 지락사고시 파형을 측정한 것이다. 이 데이터는 정상상태시 파형과 지락사고시 파형을 포함한다. 지락사고시 데이터는 보도블록, 모래, 자갈모래, 나무 접지면의 나눠지며, 각 데이터는 3상 전압, 전류와 중성점 전압 전류파형이 들어있다.

이들 중 정상 파형과 접지면이 보도블록, 보통땅, 자갈모래 경우 고장시 중성점 전류파형을 실험에 사용하였다. 실험에 사용된 파형들은 신호의 형태만으로 판별하기 위해 크기를 모두 -1과 1 사이로 정규화시켰다. 그림 1은 각 경우에 해당하는 -1과 1로 정규화시킨 중성점 전류 파형이다.

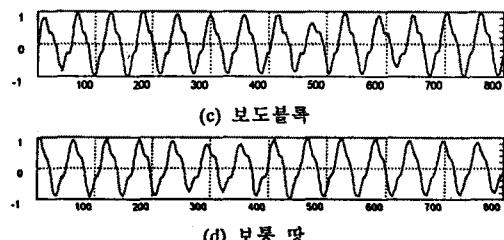
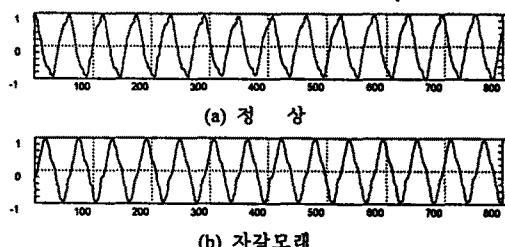


그림 1 정상상태와 접지면의 종류에 따라 -1에서 1 까지 정규화 시킨 중성점 전류 파형

3-2. 실험 방법

3 가지의 접지면에 따른 고장과 정상상태의 중성점 전류 파형의 선형예측계수들로 다중신경망을 학습시키고, 임의의 테스트 입력에 대해 고장의 종류를 판별할 수 있는지를 실험했다. 학습을 위한 선형예측계수들은 표 1과 같이 정상상태와 고장시 접지면의 종류에 따라 2 가지를 선택했고, 테스트 데이터에 대해서는 1 가지를 택했다. 음주기에서 양주기로 변하는 영교차점(zero-crossing point)부터 다음 음주기에서 양주기로 변하는 영교차점까지를 찾는 방법으로 한 주기를 검출하였으며 한주기는 약 65 개의 신호데이터였다. 선형예측계수들은 영교차점에서 시작하여 8 주기 단위로 추출하고, 한 주기를 이동시킨 뒤 다시 같은방법으로 추출하였다. 여기서 선형예측계수들은 4 차, 7 차, 9 차로 하면서 파형당 8 주기로 하여 15 개씩 구하였다.

표 1 실험데이터

학습데이터	테스트 데이터	분류영역
보도블록 1,2	보도블록 3	class1
보통 땅 1,2	보통 땅 3	class2
자갈모래 1,2	자갈모래 3	class3
정상 1,2	정상 1,2	class4

다중구조신경망은 그림 2 와 같이 2 층의 구조이고 입력의 노드 수는 선형예측계수의 차수와 같고 출력노드는 4 개로 분류하므로 2 비트수로 하였다. 은닉층 뉴런 수는 입력에 따라 실험적으로 정했다.

입력은 차수마다 0 과 1 사이로 정규화 과정을 거쳤으며, 신경망을 학습시키는 알고리즘은 역전파(back-propagation) 알고리즘을 사용하였고, 활성함수는 모두 시그모이드(sigmoid)함수를 사용하였다. 학습상수(learning rate)는 0.01로 하였다. 출력은 0 과 1 의 디지털 값이 출력되어야 하므로 0.5 를 기준으로 이상은 1, 그 이하는 0 으로 출력하도록 하였다.

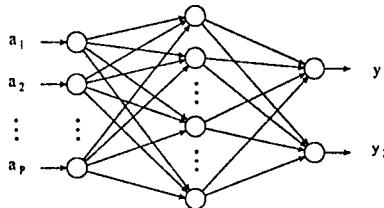


그림 2 다층구조 신경망

4. 결과

4-1. 학습

학습 데이터는 표 1에 나타낸 데이터를 사용했으며, 3 가지 차수에 따라 각각 다른 신경망을 사용했다. 학습은 반복회수가 6000 번 이상 되거나, 제곱오차합(SSE-Sum Squared Error)가 0.01 이하로 하였을 때 학습을 마치도록 하였다. 제곱오차합은 식(8)과 같다

$$SSE = \sum_{i=1}^I \sum_{j=1}^J (y_{ij} - t_{ij})^2 \quad (8)$$

여기서, I는 전체 학습패턴의 갯수, J는 출력노드의 갯수이며 y_{ij} 와 t_{ij} 는 i 번째 패턴에 대한 j 번째 출력 뉴런의 원하는 출력값과 실제 출력값이다. ($I=8\times15, J=2$)

표 2 신경망 분류기의 학습결과

	선형예측계수의 차수		
	4 차	7 차	9 차
데이터의 학습 결과	100%	100%	100%
제곱오차합	0.8	0.01	0.01
온닉층 뉴론수	80	80	70

표 2에서와 같이 다층구조신경망의 학습은 선형예측계수가 4 차일 때 제곱오차합은 0.8 이지만 7 차와 9 차에서는 제곱오차합 0.01 까지 충분히 충분히 떨어졌다. 학습 후 회상(recall) 결과는 학습데이터에 대해서 완벽하게 학습했다. 온닉층 뉴론수는 충분히 학습될 때까지 수를 늘려 가면서 정한 것이다.

4-2. 테스트 데이터의 판별

학습된 다층구조신경망은 테스트 데이터에 대한 판별의 결과는 표 3과 같다.

표 3 테스트 데이터에 대한 다층구조신경망의 출력

	고장종류	선형예측계수의 차수		
		4 차	7 차	9 차
판별률	보도불복 3	33.3 %	60 %	73.3 %
	보통 땅 3	0 %	93.3 %	93.3 %
	자갈모래 3	76.6 %	100 %	100 %
	정상 3	40 %	100 %	100 %

선형예측계수의 차수가 높은 다층구조신경망이 차수가 낮은 다층구조신경망보다 좀 더 정확한 결과를 냈다. 선형예측계수가 9 차일 경우 정상파형과 자갈모래파형은 100% 구별했으며, 보통 땅에 대해서는 93.3%, 보도불복에 대해서는 73.3%를 구별했다.

5. 결론

정상과 고장 파형에 대해 추출한 선형예측계수로 차수에 따라 각각 다층구조신경망을 구성하고, 성능을 평가하였으며, 선형예측계수로 고장한 지락사고의 패턴을 분류할 수 있는 가능성을 보였다.

실험에 있어 실험데이터의 패턴은 모두 성공적으로 학습, 테스트 되었지만, 다양한 종류의 파형들과 많은 파형들을 가지고 분류를 해 봄으로서 선형예측계수의 특징 추출방법에 대한 신뢰성을 검증해야 할 것이다. 또한, 향후 과제는 보다 적은 주기를 가지고 보다 정확한 판단을 할 수 있는 특징추출법과 알고리즘을 연구하는 것이다.

참고문헌

- [1] W. H. Kwon, G. W. Lee, Y. M. Park, and M. C. Yoo, "High impedance fault detection utilizing incremental variance of normalized even order harmonic power," *IEEE Trans, Power Delivery*, Vol. 6, No. 2, p557-563, April 1991.
- [2] 최진원, 이종호, 김춘우, "시간지연 신경망을 이용한 고장지락사고 검출," 대한 전기학회 추계 학술대회 논문집, pp405-407, 1994. 11.
- [3] L. R. Rabiner and R. W. Schafer, *Digital processing of speech signals*, prentice-hall, 1978.