

카오스 특징 추출에 의한 고저항 지락사고의 패턴인식

Recognition of High Impedance Fault Patterns
according to the Chaotic Features

신승연, 공성곤

숭실대학교 전기공학과

Seung-Yeon Shin and Seong-Gon Kong

Department of Electrical Engineering

Soongsil University

e-mail : ssyeon@elecpwr.soongsil.ac.kr

ABSTRACT

This paper presents recognition of high impedance fault patterns based on chaotic features using the Radial Basis Function Network(RBFN). The chaos attractor is reconstructed from the fault current data for pattern recognition. The RBFN successfully classifies the three kinds of fault patterns and one normal pattern.

I. 서 론

고저항 지락사고는 송전선의 도체가 고저항(High Impedance)의 표면에 떨어지게 되었을 때 일어나는 고장을 말한다. 이 고저항 지락사고는 발생시 아크(arc)를 수반하므로 화재의 위험이 있으며, 지락면의 높은 저항으로 인해 기존의 과전류보호기기로는 검출할 수 없는 저전류가 흘러 인체 감전의 위험도 있다. 또, 지락면의 종류에 따라 고장파형의 형태도 다르게 나타나기 때문에 고장을 판단하기는 쉽지 않아서, 고장에 대한 대응도 늦어질 수밖에 없다. 이러한 문제점을 극복하기 위한 많은 방법들이 제시되었다. 고장전류의 주파수 성분을 이용하는 방법이 시도되었으며, 최근에는 신경회로망을 이용한 방법도 많이 제시되고 있다.[1-3].

신경망을 통해 고저항 지락 사고의 유무 및 고장의 종류를 검출하기 위해서는 먼저 지락사고시 나타나는 시계열 신호의 특징을 추출해야 한다. 특징 추출은 데이터의 형태분석을 쉽게 할 수 있도록 도와주

며, 신경망의 입력으로 사용될 데이터의 양을 최소화하는 역할을 한다. 비선형 특성이 강한 시계열 신호는 피크검출, 스펙트럼분석 또는 선형예측계수 등과 같은 일반적인 분석 방법으로는 신호 인식에 적합한 특징을 추출하기 어렵다. 본 논문에서는 카오스 특징 추출 방법을 이용하여 특징을 추출하였다.

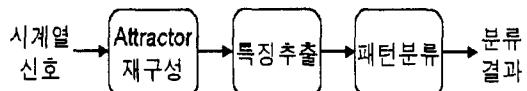


그림 1: 카오스 특징추출을 이용한 패턴분류

그림 1은 카오스 특징추출 방법을 이용한 패턴분류 과정을 나타낸다. 우선 주기성을 가진 시계열 신호가 주어지면 한 주기마다 어트랙터를 재구성한다. 재구성된 어트랙터를 패턴분류가 가능하도록 특징을 추출한다. 이렇게 해서 얻어진 값은 Radial Basis Function Network(RBFN)의 입력이며, RBFN의 출력을 통해 고저항 지락사고의 발생 여부 및 지락표면의 종류를 판별하게 된다.

II. 특징 추출

본 논문에서는 카오스 특징인 어트랙터 재구성을 이용하여 고저항 지락사고의 패턴분류에 적합한 특징을 얻는다.

2.1 어트랙터 재구성

어트랙터 재구성이란 시계열의 신호를 위상공간으로 임베딩하여 나타내는 것을 말하며, 위상공간에서 나타난 궤적을 어트랙터라 한다[6]. 단일 시계열 데이터가 주어진 경우에 Takens가 제안한 자연방법으로 어트랙터를 재구성하면, 식 (1)과 같이 나타낼 수 있다.

$$\hat{z}(i) = (z(i), z(i+\tau), \dots, z(i+(m-1)\tau)) \quad (1)$$

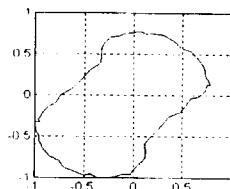
여기서, $z(i)$ 은 i 번째 시계열 신호이며, $\hat{z}(i)$ 은 m 차원 위상공간으로 임베딩된 i 번째 점이다. m 은 임베딩 차원이고 τ 는 시간지연이다. 이렇게 해서 구한 어트랙터가 주기성을 갖는 시계열 신호의 한주기에 대해서 다른 과정을 가지면 각기 다른 형태로 나타나므로 고저항 지락 사고 신호를 패턴분류하는 것이 가능하다. 이 방법을 사용하기 위해서는 사전에 임베딩 차원과 시간지연을 설정해야한다. 본 논문에서는 임베딩 차원을 2로 정하였는데, 2차만으로도 충분히 시계열 신호에 대해 구분할 수 있는 특징을 얻을 수 있기 때문이다. 임베딩 차원을 2로 고정하면 식 (1)은 식 (2)와 같이 표현할 수 있으며, 이러한 경우 시간지연만 설정하면 된다.

$$\hat{z}(i) = (z(i), z(i+\tau)) \quad (2)$$

2.2 고저항 지락사고 패턴분류를 위한 특징추출

어트랙터를 재구성한 후에는 주어진 어트랙터 평면을 $L \times L$ 의 격자로 나눈다. 격자내에 어트랙터가 존재하면 1의 값을, 그렇지 않은 경우에는 0의 값을도록 입력패턴의 값을 이진값으로 바꾼다. 따라서 특징추출 후 입력패턴은 L^2 의 입력차원을 갖는다.

그림 2는 특징추출의 한 예를 보여준다. 그림 2(a)는 정규화된 중심점 전류 신호 한 주기를 식 (2)에 의해 어트랙터 재구성한 것이다. 그림 2(b)에는 특징추출 결과로서 신경망의 입력패턴을 4×4 의 이진 이미지로 나타내었다.



1	2	3	4
5	6	7	8
9	10	11	12
13	14	15	16

(a) 재구성된 어트랙터

(b) 이진 이미지

그림 2: 어트랙터 재구성을 이용한 특징추출의 예

그림 2(b)에서 검은 부분은 '1'의 값을 가지며, 흰 부분은 '0'의 값을 갖는다. 격자내의 숫자는 인덱스 값을 나타낸다. 따라서, 신경망의 입력패턴은 16차원 벡터로 식 (3)과 같이 나타낼 수 있다.

$$\mathbf{x} = [0 1 1 1 1 1 0 1 1 0 1 1 1 1 1 0] \quad (3)$$

III. 고장신호의 패턴분류

3.1 Radial Basis Function Network

RBFN은 복잡한 입력패턴이 주어졌을 때 중간층의 수를 늘려 입력패턴의 차원을 높이고, 입력패턴과 가장 잘 맞는 다차원 공간상의 평면을 찾음으로써 패턴을 분류하는 신경망의 한 종류이다[4].

그림 3은 RBFN의 구조를 나타낸다. RBFN은 중간층에 해당하는 Radial basis 층과 출력층에 해당하는 선형층으로 이루어져 있으며, 중간층에서는 활성함수로 중심점에 대칭인 비선형 함수를 사용한다. 가우시안 함수를 중간층의 활성함수로 사용하는 경우 입력벡터에 의한 RBFN의 중간층의 출력은 식 (4)와 같다.

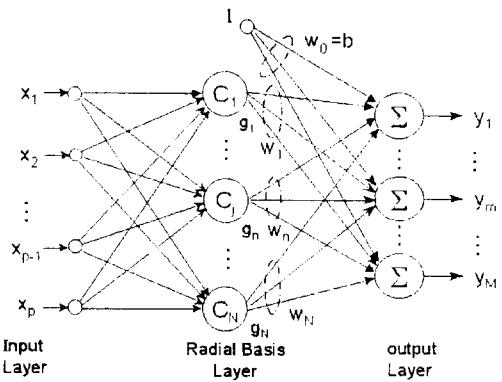


그림 3: RBFN의 구조

$$g_n(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_n\|^2}{2\sigma_n^2}\right) \quad (4)$$

\mathbf{x} 는 입력벡터이고, \mathbf{c}_n 는 n 번째 중간노드의 중심점(center)으로 입력과 같은 차원을 갖는다. σ_n 는 n 번째 중간노드의 가우시안 함수의 폭을 나타내는 값이다. m 번째 출력노드의 출력 \mathbf{y} 은 식 (5)이다.

$$\mathbf{y} = \sum_{m=1}^M \mathbf{g}^T \mathbf{w}_m \quad (5)$$

여기서, M 은 출력층의 노드수이다. 그리고 $\mathbf{g} = [g_1, \dots, g_N, 1]$ 이며, 중간층과 m 번째 출력노드 사이의 가중치는 $\mathbf{w}_m = [w_{1m}, \dots, w_{Nm}, b]$ 이다. 학습이 잘 된 경우 출력벡터 \mathbf{y} 는 목표벡터 \mathbf{d} 와 같으므로 \mathbf{W} 에 관하여 풀면 식 (6)과 같다.

$$\mathbf{W} = \mathbf{g}^+ \mathbf{d} \quad (6)$$

여기서 \mathbf{W} 은 식 (7)로 나타나는 $M \times N$ 행렬이다.

$$\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_M] \quad (7)$$

\mathbf{g}^+ 는 식 (8)과 같다.

$$\mathbf{g}^+ = (\mathbf{g}^T \mathbf{g})^{-1} \mathbf{g}^T \quad (8)$$

3.2 패턴분류를 위한 RBFN

패턴분류를 위한 RBFN를 설계하기 위해서는 우선 중간층 활성함수인 가우시안 함수 내의 중심점과 분산을 결정해야한다.

중심점을 선택함에 있어서 가장 분명한 방법은 중심점을 입력패턴과 일치하는 값으로 결정하는 것이다. 입력패턴의 수가 많은 경우 이 방법을 실제로 적용하는 데는 무리가 있다. RBFN의 중심점을 선택하는 문제에 관해 많은 연구가 이루어져 왔으며, 경쟁학습은 그 중 하나이다. 본 논문에서는 경쟁학습[5]을 통하여 중심점을 결정하였다.

RBFN의 성능을 결정짓는 요소 중 분산은 인접한 입력간의 거리값보다는 크고, 전체 입력간의 거리보다는 작은 값으로 선택하는 것이 좋다. Lowe는 통계적인 실험에 통해 적절한 분산값을 보장하는 식 (9)을 얻었다[4].

$$\sigma_n = \frac{d_n}{\sqrt{2N}} \quad i=1, \dots, N \quad (9)$$

마찬가지로, N 은 중간층의 노드수이고, d_n 는 n 번

째 중심점에서 가장 먼 중심점까지의 거리이다. 따라서 하나의 클러스터에 하나의 분산값을 갖게 된다.

IV. 실험 및 결과

4.1 실험데이터

본 실험에서 사용한 데이터는 1986년 12월 3일 정주 변전소 관할 정읍 D/L에서 나전선인 A상의 전력선을 다양한 접지면에 떨어뜨림으로써 얻은 실제 지락사고시 과형이다. 이 데이터는 정상상태시 과형과 지락사고시 과형을 포함하며, 지락사고시 데이터는 접지면의 종류에 따라 보도블럭, 모래, 자갈·모래의 3가지를 갖는다. 지락사고 시에는 중심점 전류파형의 변화가 가장 심하기 때문에 이 실험에서는 중심점 전류만을 실험데이터로 사용하였다. 그럼 4에 실험에 사용한 데이터를 종류별로 일부분만 나타내었다. 가로축은 샘플수를 나타내며, 세로축은 전류의 크기를 나타낸다. 각 데이터의 한 주기는 64샘플이다.

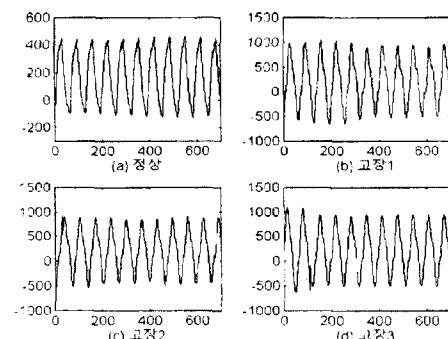


그림 4: 정상 및 3종류의 지락사고 과형

표 1에서는 실험에 사용한 모든 데이터를 보여준다. 분류할 패턴은 모두 4종류이며, 입력패턴수는 각각의 4가지 종류의 데이터에서 특징추출 과정을 통해 얻은 입력패턴의 수를 말한다. 전체 패턴수의 85%를 학습에 사용하고 나머지를 테스트에 사용한다.

표 1: 실험데이터

접지면의종류	구분	학습시	테스트시	입력
		입력패턴수	입력패턴수	패턴수
정상	정상	124	24	148
보도블럭	고장1	158	32	190
모래	고장2	109	22	131
자갈·모래	고장3	119	23	142
합계		510	101	611

4.2 고저항 지락사고 데이터의 특징추출

어트랙터 재구성은 전기신호와 같이 주기성을 갖는 신호에 대해서는 각 주기마다 유사한 모양을 가지므로 시계열 신호의 분석구간은 한 주기 동안이 된다. 먼저 한주기가 입력되면 평균을 제거하고, 그 신호의 최대 또는 최소값이 1 또는 -1의 값을 갖도록 정규화한다. 이는 어트랙터 재구성이 시계열 신호의 크기와는 무관하며, 단지 한주기 신호의 파형과 관계 있기 때문이다.

통계적인 실험에 의해 시간지연 τ 는 6으로, L은 9로 정하였다.

식 (3)과 같이 입력패턴을 나타내면 모든 데이터에 대해 같은 값을 갖는 인덱스가 존재하게 되고, 이러한 인덱스를 제거하면 입력패턴의 차원도 줄어들게 된다. 이렇게 함으로서 결정된 신경망의 입력차원은 58이다.

4.3 고저항 지락사고 데이터의 패턴분류 결과

고저항 지락사고 데이터를 패턴분류하기 위한 RBFN의 구조는 입력노드의 수가 58개, 중간노드의 수가 8개, 출력노드의 수가 2개이다. 출력값이 0 또는 1의 값을 갖도록 출력층에서 ‘hardlimit’ 함수를 사용한다.

표 2: 패턴분류 결과 [단위:%]

	정상	고장1	고장2	고장3	평균
인식률	학습 데이터	99.2	94.9	92.7	98.3
	테스트데이터	100	93.8	91.3	100
		96.27			96.27

표 2는 실험결과를 나타낸다. 정상신호와 3종류의 고장신호의 학습데이터와 테스트데이터의 인식률을 각각 나타내었고, 전체 신호에 대한 인식률도 평균란에 나타내었다.

표 2에서 학습률 및 테스트율의 계산은 식 (10)과 같다.

$$\text{인식률} = \frac{\text{전체 패턴수} - \text{오차 패턴수}}{\text{전체 패턴수}} \times 100 \quad (10)$$

표 1에 의해 전체 패턴수는 학습시에는 510이며, 테스트시에는 101개이다.

오인식이 발생하는 경우를 살펴보면 표 3과 같다. 표 3에서 목표패턴은 원하는 패턴이며, 출력패턴은 실제 RBFN의 출력값이다. 오인식 패턴수는 실제 오인식한 패턴의 수로 학습과 테스트를 나누어 나타내

표 3: 오인식 패턴의 종류

목표 패턴 → 출력 패턴	오인식 패턴 수	
	학습	테스트
정상 → 고장1	1	0
고장1 → 고장2	7	2
고장1 → 고장3	1	0
고장2 → 고장1	8	2
고장3 → 고장1	2	0
오인식 패턴 수의 합계	19/510	4/101

었다.

표 3을 통해 학습과 테스트데이터에서 발생한 오인식 패턴 중에서 고장파형을 정상파형으로 오인식하는 경우는 발생하지 않음을 알 수 있다.

V. 결 론

본 연구에서는 카오스 어트랙터를 이용하여 고저항 지락사고 신호의 특징을 추출하고 RBFN을 이용하여 패턴을 인식하는 방법을 연구하였다. RBFN은 고저항 지락사고의 발생 여부 및 고장의 종류를 인식하는 데 높은 인식률을 보였으며, 가장 위험한 경우인 고장신호를 정상신호로 인식하는 오류는 발생하지 않았다.

VI. 참고문헌

- [1] 한국전력공사 기술연구원, 다중접지 배전선로 보호계 전방식 개선에 관한 연구, 1987.
- [2] W. H. Kwon, et al., "High Impedance Fault Detection Utilizing Incremental Variance of Normalized Even Order Harmonic Power," 전기학회 논문지, Vol. 6, No. 2, pp. 557-564, Apr. 1991..
- [3] 이화석, 한중길, 박준호, "배전계통에서 신경회로망을 이용한 고저항 지락사고 검출기법에 관한 연구," 전기학회 논문지, Vol. 45, No. 11, pp. 1534-1541, Nov. 1996.
- [4] Simon Haykin, Neural Networks, Macmillan College Pub., pp. 236-284, 1994.
- [5] Jacek M. Zurada, Introduction to Artificial Neural Systems, West Pub., pp. 401-405, 1992.
- [6] 이호성, 카오스 특징추출에 의한 시계열 신호의 패턴인식, 숭실대학교 석사학위 논문, 1996. 12.