

카오스 어트랙터를 이용한 전력계통의 고저항 지락사고 패턴분류

신승연, 공성곤
송실대학교 전기공학과

Recognition of High Impedance Fault Patterns based on Chaotic Features

Seung Yeon Shin, Seong-Gon Kong
Soongsil University, Department of Electrical Engineering

Abstract - This paper presents recognition and classification of high impedance fault(HIF) patterns in the electrical power systems based on chaotic features. Chaotic features are obtained from two dimensional chaos attractors reconstructed from fault current waveform.

The RBFN is trained with the two types of HIF data generated by the electromagnetic transient program and measured from actual faults. The RBFN successfully classifies normal and the three types of fault patterns based on the binary chaotic features.

1. 서 론

고저항 지락사고(HIF: High Impedance Fault)는 전력시스템에서 송·배전선의 도체가 저항이 큰 접지 면에 접촉 또는 근접하였을 때 발생하는 고장으로 일반적인 보호계 전기로는 검출이 어려운 저전류 고장을 말한다[1-4]. 고저항 사고는 인체의 감전사고나 아크로 인해 화재, 설비손상, 에너지 낭비 및 정전 등을 발생시키므로 신속히 대처하여야 한다. 고장신호로부터 지락면의 종류를 알 수 있다면 사고 지점을 찾고 사고에 대한 대책을 세우는데 도움을 준다.

고저항 지락사고의 고장전류는 고장장소에 따라 다르며 접촉재질이 동일한 경우에도 고장전류의 파형과 크기는 나선과 절연전선에 따라 달라지므로 검출이 어렵다. 고저항 지락사고를 검출하기 위한 방법들로는 고저항 지락계전 방식, 고장전류 변분방식, 비율지락 보호계전 방식, P.T.I. 방식, 우수파 검출 방식 등이 있다[3]. 최근에는 신경망을 통해 학습시키는 방법[4], 웨이브렛 변환을 이용하는 방법[3] 등이 새롭게 시도되고 있다.

신경망을 통해 고저항 지락사고의 유무 및 고장의 종류를 검출하기 위해서는 먼저 지락사고시 나타나는 시계열 신호의 특징을 추출해야 한다. 특징 추출은 데이터의 형태 분석을 쉽게 할 수 있도록 도와주며, 신경망의 입력으로 사용될 데이터의 양을 최소화하는 역할을 한다. 본 논문에서는 카오스 특징추출 방법을 이용하여 특징을 추출하였다. 카오스 어트랙터는 특유의 기하학적 구조으로 카오스 운동을 특징 짓는다. 그래서 그 자체가 외부로부터 얻어진 정보를 함축, 가공하거나, 카오스 어트랙터 간의 정보전달을 행하는 정보론적 기능을 가지고 있다.

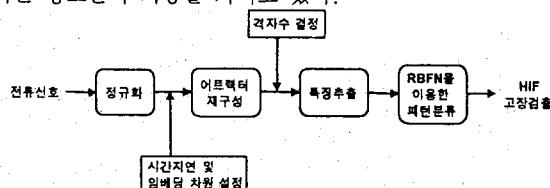


그림 1: 카오스 어트랙터를 이용한 패턴분류 흐름도

본 연구는 한국전력공사의 지원에 의하여 기초전력공학 공동연구소 주관으로 수행되었음.(관리번호:97-047)

그림 1은 이 논문에서 사용하고 있는 지락사고 패턴분류 과정을 나타낸다. 시계열 신호로 표현된 고장신호가 주어지면 어트랙터를 재구성하고, 위상공간에서 어트랙터의 유무에 따라 1 또는 0의 값을 갖는 특징벡터를 추출한다. 이렇게 해서 얻어진 값을 Radial Basis Function Network (RBFN)의 입력으로 하고 학습된 RBFN을 이용하여 고저항 지락사고의 발생 여부 및 지락표면의 종류를 판별한다.

2. 본 론

2.1 고저항지락사고 신호의 특징추출

2.1.1 어트랙터 재구성

동력학 시스템에서는 위상궤적을 사용하여 시스템의 상태를 표현한다. 시스템의 상태는 상태공간 위의 점으로 표현되며 안정된 시스템은 고정점에서 안정하게 된다. 전기신호의 경우 주기적 특성이 있으므로 폐곡선의 모양을 나타내게 된다.

어트랙터 재구성이란 시계열 신호를 위상공간으로 임베딩하여 나타내는 것을 말한다. 시계열 신호가 단일 시계열 데이터이고 방정식이 주어지지 않은 경우는 Takens의 지연방법[5]으로 어트랙터를 재구성할 수 있다.

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

여기서, $z(i)$ 은 i 번째 시계열 신호이며, $z(i)$ 은 m 차원 위상공간으로 임베딩된 i 번째 점이다. m 은 임베딩 차원이고 τ 는 시간지연이다. 이렇게 해서 구한 어트랙터는, 주기성을 가진 시계열 신호의 한 주기에 대해, 파형이 다른 경우 각기 다른 모양을 나타내므로 고저항 지락사고 신호를 패턴 분류하는 것이 가능하다. 본 논문에서는 임베딩 차원을 2로 고정하였다.

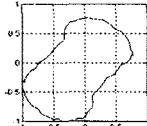
$$z(i) = (z(i), z(i+\tau)) \quad (2)$$

어트랙터 재구성을 이용한 패턴분류는 주기 신호의 한 주기 파형과 관계가 있다. 따라서 사용하는 시계열신호의 샘플링 주파수가 달라지더라도 동일한 패턴을 얻을 수 있다.

2.1.2 카오스 어트랙터부터의 특징추출

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

그림 2는 특징추출의 한 예를 보여준다. 그림 2(a)는 정규화된 증성점 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. 그림 2(b)에서 검은 부분은 '1'의 값을 가지며, 흰 부분은 '0'의 값을 갖는다. 격자내의 숫자는 인덱스 값을 나타낸다. 따라서, 신경망의 입력데이터는 16차원 벡터로 식 (3)과 같이 나타낼 수 있다.



(a) 재구성된 어트랙터

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

(b) 이진 이미지
그림 2: 어트랙터 재구성을 이용한 특징추출의 예

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

신경망의 입력은 같은 값을 갖는 인덱스를 제거하여 L^2 보다 차원을 줄인다.

2.2 고저항 지락사고신호의 패턴인식

고저항 지락사고의 유무 및 지락면의 종류를 판별하기 위한 패턴분류기로 Radial Basis Function Network (RBFN)을 사용한다. RBFN은 입력층, 중간층, 출력층으로 구성되는 전방향 신경망이다[6]. 입력층과 중간층 사이의 가중치는 모두 1이고 중간층 각 노드는 방사함수를 가진다. 가우시안 합수를 사용하면 중심점과 합수폭의 두 값을 설정하면 된다. 중간층에서 중심점과 입력과의 거리 계산은 Euclidean Norm을 이용한다. 출력층에서는 하중 합(Weighted-sum)을 계산하며, 응용분야에 따라 출력값을 그냥 출력하기도 하고 다른 특정함수를 사용하기도 한다. RBFN의 구조는 그림 3과 같이 나타낼 수 있다.

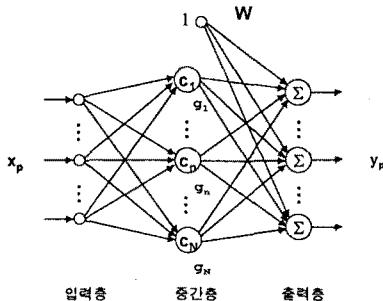


그림 3: RBFN의 구조

그림 3에서 x_p 는 M차원을 가진 입력이며, c_n 은 입력과 같은 M차원을 갖는 중심점 벡터(Center vector)이고, 그 개수는 중간층 노드수인 N과 동일하다. g_n 는 스칼라(scalar)값을 갖는 방사함수의 응답이다. 즉, 하나의 입력 데이터에 대해 하나의 값을 출력한다. W 는 중간층과 출력층을 연결하는 가중치(weight) 벡터이고, y_p 는 출력으로 Q차원 벡터이다.

P개의 입력데이터가 주어진 경우, 가우시안 합수를 중간층의 활성함수로 사용하는 중간층의 출력은 식 (4)와 같다.

$$\begin{aligned} G^T &= [g_1 \ g_2 \ \cdots \ g_p] \quad (4) \\ &= \begin{bmatrix} 1 & 1 & \cdots & 1 \\ g_1(x_1) & g_1(x_2) & \cdots & g_1(x_p) \\ \vdots & \vdots & \ddots & \vdots \\ g_N(x_1) & g_N(x_2) & \cdots & g_N(x_p) \end{bmatrix} \end{aligned}$$

여기서 g_p 는 p번째 입력데이터에 대한 중간층의 응답이고, 각 성분들은 식 (5)로 나타낼 수 있다.

$$g_n(x_p) = \exp\left(-\frac{\|x_p - c_n\|^2}{2\sigma_n^2}\right) \quad (5)$$

식 (5)는 p번째 입력데이터에 대한 n번째 중간층의 출력을 의미한다. 그리고 q번째 출력은 다음과 같다.

$$y_q = G \ w_q \quad (6)$$

가중치의 결정은 식 (7)과 같이 최소자승법에 의해 구할

수 있으며, 이러한 방법을 사용하는 경우 반복적인 계산 없이 최적의 해를 구할 수 있다.

$$w_q = G^+ d_q \quad (7)$$

여기서 $G^+ = (G^T G)^{-1} G^T$ 는 G 의 의사 역행렬이다.

2.2.1 중간층 파라미터의 결정

중간층 함수로 가우시안 합수를 사용하는 경우 중심점과 합수폭을 설정하여야 한다. 중심점은 그 수는 적으면서 각 클러스터를 대표할 수 있는 값으로 선택하여야 한다. 본 논문에서는 경쟁학습[7]을 통하여 중심점을 결정하였다.

$$\begin{cases} c_p(k+1) = c_p(k) + \alpha (x - c_p(k)) \\ c_i(k+1) = c_i(k) \end{cases}, i \neq p \quad (8)$$

식 (8)은 경쟁학습의 알고리즘을 나타내는 식으로, 신경망의 출력 뉴런 중 가장 큰 값을 출력하는 뉴런의 연결강도만을 학습시키는 과정을 반복적으로 수행하여 각 클러스터의 중심값을 얻는다.

합수폭의 값은 인접한 입력데이터간의 거리보다는 크고, 입력데이터간의 최대거리보다는 작은 값을 선택하는 것이 좋다. Lowe는 통계적인 실험을 통해서 적절한 합수값을 얻었으며 그 값은 식 (9)로 결정한다.

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

식 (9)에서 N은 중간층의 노드 수이고, d_n 는 n번째 중심점, 즉 c_n 에서 가장 먼 중심점까지의 거리이다.

2.3 시뮬레이션

고저항 지락사고의 패턴분류를 위해, EMTP에 의해 얻은 데이터와 직접 고저항 사고를 모의하고 측정한 실험 데이터이다. 실험에서는 중심점 전류를 사용하였는데 이는 고저항 지락사고 발생시 중심점 전류의 변화가 두드러지기 때문이다.

2.3.1 실험데이터

EMTP를 이용하여 고저항 지락사고 신호를 얻기 위해 그림과 같은 배전계통을 생각하였다. 그림에서 HIF 모델은 Buchholz의 의해 1996년 발표된 모델이다[8].

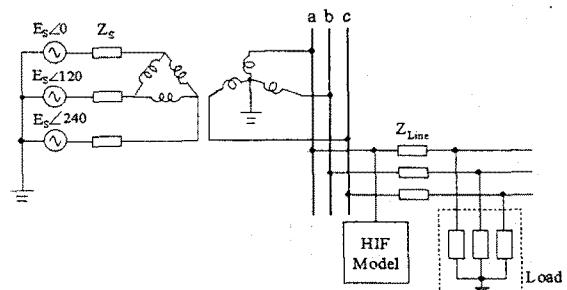


그림 4: 전력 계통도

지락사는 a상을 지락시킨 1상지락 사고이다. 부하 모델은 1차 임피던스 모델로서 저항과 인덕터가 직렬로 연결된 모델이며, 정상상태에서도 중심점에 전류가 흐를 수 있도록 1상에 불평형부하를 걸어주었다.

실측실험데이터는 1986년 정주 변전소 관할 정읍 D/L에서 a상의 전력선을 다양한 접지 면에 떨어뜨림으로써 얻은 실제 지락사고 데이터이다[1].

EMTP에 의한 데이터와 실측실험데이터 모두 분류할 때는 정상 및 3가지 종류의 고장으로 4종류이며, 입력데이터는 각 신호에 대해서 특징추출 과정을 통해 얻었다. 전체 입력데이터 중 약 85%는 학습에 이용하였으며, 나머지는

테스트에 이용하였다. 표 1에 실험에 사용한 입력데이터를 나타내었다.

표 1: 실험데이터

	EMTP데이터에 의한 입력데이터수			실측실험데이터에 의한 입력데이터수		
	학습	테스트	전체	학습	테스트	전체
정상	38	7	45	124	24	148
고장1	225	45	270	161	33	194
고장2	225	45	270	119	23	142
고장3	225	45	270	118	24	142
합계	713	142	855	522	104	626

2.3.2 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 한 주기가 입력되면 평균을 제거하고, 그 신호의 최대 또는 최소 값이 1 또는 -1의 값을 갖도록 정규화한다. 이는 어트랙터 재구성 과정이 시계열 신호의 크기와 무관하고, 한 주기 신호의 파형과 관계 있기 때문이다.

통계적인 실험에 의해 시간지연 τ 는 6으로, 격자수 L 은 9로 정하였다. L 의 설정과 τ 와 무관하지 않으므로 두 값의 변화를 쌍으로하여 실험을 하였다. 두 값의 선택하는데 있어서 우선 고려되어야 할 사항은 서로 다른 클래스에 속하는 입력데이터를 같은 데이터로 인식하지 말아야 한다는 것이며, 두 번째로 고려되어야 할 사항은 신경망의 구조를 간단하게 하기 위하여 입력데이터의 값을 가능한 한 작은 값으로 만들어야 한다. 그림 5와 그림 6은 각각 EMTP에 의한 데이터와 실측실험 데이터의 재구성된 어트랙터이다.

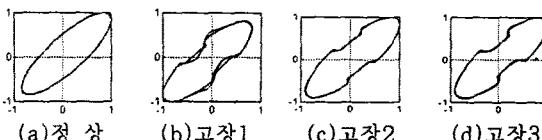


그림 5: EMTP에 의한 데이터의 재구성된 어트랙터

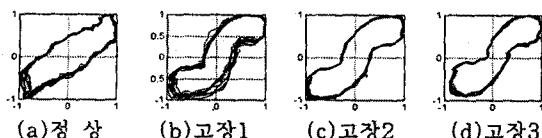


그림 6: 실측 실험 데이터의 재구성된 어트랙터

어트랙터가 존재하는 위상공간을 9×9 의 격자로 나누어 어트랙터가 존재하는 격자에 1의 값을 어트랙터가 존재하지 않는 격자에 0의 값을 주어 이진값을 갖는 입력데이터를 얻었으며, 모든 데이터에 대해서 같은 값을 갖는 인덱스를 제거함으로써 패턴분류기의 입력차원을 줄였3 다.

2.3.2 고저항 지락사고 데이터의 패턴분류 결과

고저항 지락사고 데이터를 패턴분류하기 위한 RBFN의 구조는 다음과 같다. 입력노드의 수는 각 입력데이터의 차원으로 58이며, 중간노드의 수는 중심점의 수로 27이다. 출력층에 'hard-limit' 함수를 사용하였으며, 4종류의 신호를 분류하므로 2개의 노드만 있으면 된다.

표 2는 실험결과를 나타내며, 표 2에서 인식률의 계산은식 (10)과 같다.

$$\text{인식률} [\%] = \frac{\text{전체데이터수} - \text{오인식데이터수}}{\text{전체데이터수}} \times 100 \quad (10)$$

표 2: 패턴분류 결과

	정상	고장1	고장2	고장3	전체인식률
EMTP 데이터	학습시	100	82.76	89.78	94.22
	테스트시	100	80	86.67	93.33
실측실험 데이터	학습시	100	95.65	93.28	99.15
	테스트시	100	90.9	86.96	100
					94.23

표 3: 오인식 데이터의 종류

목표데이터→출력데이터	EMTP 데이터		실측실험 데이터	
	학습	테스트	학습	테스트
정상 → 고장2	8	2	0	0
고장1 → 고장2	15	4	8	3
고장1 → 고장3	12	3	1	0
고장2 → 고장1	11	4	5	3
고장2 → 고장3	1	0	0	0
고장3 → 고장1	28	5	2	0
오인식 데이터수의 합계	75/713	18/142	16/522	6/104

오인식이 발생하는 경우를 살펴보면 표 3과 같다. 표 3에서 목표데이터는 원하는 데이터이며, 출력데이터는 실제 RBFN의 출력으로 나온 데이터를 말한다. 오인식 데이터 수는 목표데이터와 출력데이터가 일치하지 않은 데이터의 수로 학습 시와 테스트 시로 나누어 나타내었다. 표 3을 통해 학습과 테스트데이터에서 발생한 오인식 데이터 중에서 고장 패형을 정상 패형으로 오인식 하는 경우는 발생하지 않음을 알 수 있다.

3. 결 론

본 연구에서는 고저항 지락사고의 패턴분류를 위해 중성 점 전류의 카오스 어트랙터를 구하였으며, 어트랙터가 나타나는 위상공간을 격자로 나눠 이진 특징벡터로 변환하였다. 이 값은 패턴분류기로 사용되는 RBFN의 입력으로 사용되며 RBFN의 출력으로 지락사고의 유무 및 지락면의 종류를 알 수 있다.

EMTP를 이용한 지락사고 데이터와 실제 지락사고를 모의하여 측정한 데이터 각각에 대해서 인식률은 87.32[%]와 94.23[%]로 나타났다. 카오스 특징 추출에 의한 시계열신호의 패턴분류에 이용되는 RBFN은 고저항 지락사고의 발생 여부 및 고장의 종류를 인식하는 데 높은 인식률을 보였으며, 오인식의 가장 위험한 경우인 고장신호를 정상신호로 인식하는 오류는 발생하지 않았다.

(참 고 문 헌)

- [1] 한국전력공사 기술연구원, 다중접지 배전선로 보호계전방식 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] 전력 연구원, 직접접지계통 송전선로 고저항 지락사고대책 연구, 1997.
- [4] 이화석, 한중길, 박준호, "배전계통에서 신경회로망을 이용한 고저항 지락사고 검출기법에 관한 연구," 전기학회 논문지, Vol. 45, No. 11, pp.1534-1541, Nov. 1996.
- [5] F. Takens, Lecture Notes in Mathematics, edited by D. A. Rand and L. S. Young, Springer-Verlag, Vol. 898, pp.266, 1981.
- [6] S. Haykin, Neural Networks, Macmillan College Pub., pp.236-284, 1994.
- [7] J. M. Zurada, Introduction to Artificial Neural Systems, West Pub., pp.401-405, 1992.
- [8] V. L. Buchholz, et al., "High Impedance Fault Detection Device Tester," IEEE Trans. on Power Delivery, Vol. 11, No. 1, pp. 184-190, Jan. 1996.