

Classification of High-Impedance Faults based on the Chaotic Attractor Patterns

辛承妍* · 公聖坤**
(Seung-Yeon Shin · Seong-Gon Kong)

Abstract - This paper presents a method of recognizing high impedance fault(HIF) of electrical power systems and classifying fault patterns based on chaos attractors. Two dimensional chaos attractors are reconstructed from neutral point current waveforms. Reliable features for HIF pattern classification are obtained from the chaos attractors. Radial basis function network, trained with 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 according to the features generated from the chaos attractors.

Key Words : 카오스 어트랙터, 패턴분류, 고저항 지락사고(HIF), RBFN 신경회로망

1. 서 론

고저항 지락사고(HIF: High Impedance Fault)란 전력시스템에서 송전선 또는 배전선의 도체가 저항이 큰 접지면에 접촉 또는 근접하였을 때 발생하는 고장으로 일반적인 보호계전기로는 검출이 어려운 저전류 고장을 말한다[1-3]. 일반적으로 전기공급 시스템은 고저항 사고시 발생하는 정도의 전류는 전달하도록 설계되어 있으므로, 고저항 사고에 의한 영향은 국부적이고 전체 시스템의 파괴를 유발시키지 않는다. 그러나 HIF 고장전류는 아크를 수반하므로 화재의 우려가 있으며, 인체 감전이나 에너지 낭비 등이 발생할 수 있다. 고저항 지락사고가 일반 시민이 거주하는 곳 근처에 발생한다면 인체의 감전사고가 일어날 우려가 있으며, 사고시 발생하는 아크로 인해 화재, 설비손상, 에너지 낭비 및 정전 등이 발생할 수 있다. 이러한 이유로 고저항 지락사고는 신속히 검출되어야 할 뿐 아니라 지락사고가 어느 곳에서 발생되었는지 알아내는 것이 중요하다. 지락사고시 발생하는 신호로부터 지락면의 종류를 알 수 있다면 쉽게 사고지점을 찾을 수 있다. 예를 들어 지락사고가 발생한 지락면이 아스팔트나 보도블록과 같은 경우에는 많은 사람이 다니는 곳에 해당되므로 좀더 신속한 조치가 취해져야 할 것이다. 이와 같이 고장전류에 의하여 지락면의 종류를 분류하는 것은 지락사고가 발생하였을 때 효과적으로 대응하는 데 도움을 준다.

HIF는 고장전류의 크기가 작아 고장검출이 쉽지 않고, 지락이 발생하는 접촉재질이 동일한 경우에도 고장전류의 파형과 크기는 장소에 따라 그리고 동일한 장소에서도 나 전선과 절연전선에 따라 달라지므로 특정한 검출 알고리즘을 적용하기 어렵다. HIF를 검출하기 위한 방법들로는 고저항 지락계전 방식, 고장전류 변분방식, 비율지락 보호계전 방식등이 있으며, 이 밖에도 P.T.I.방식과 우수파 검출 방식등도 있다[3]. 새롭게 시도되고 있는 고저항 검출 방법으로는 신경망을 통해 학습시키는 방법[4], 웨이블렛 변환을 이용하는 방법[3], 고저항시 나타나는 전류 신호에서 카오스 현상을 분석하여 고저항을 검출하는 방법[5] 등도 제안되고 있다. 고저항 지락사고의 유무 및 고장의 종류를 검출하기 위해서는 먼저 지락사고시 나타나는 신호의 특징을 추출하고 패턴을 분류하여야 한다. 특징 추출은 데이터의 형태분석을 쉽게 할 수 있도록 도와주며, 신경망 입력의 크기를 최소화한다.

본 논문에서는 카오스 특징추출 방법을 이용하였다. 카오스 어트랙터는 특유의 기하학적 구성으로 카오스 행동을 특징짓는다. 그래서 그 자체가 외부로부터 얻어진 정보를 함축, 가공하거나, 카오스 어트랙터간의 정보전달을 행하는 정보론적 기능을 가지고 있다. HIF로 인하여 발생하는 신호는 정상시 나타나는 주기신호와와는 달리 한 사이클로부터 다음 사이클까지 크게 변화될 수 있으며, 아크시 발생하는 열에 의해 도선 주변 흙의 성질이 변하여 전류파형의 일그러짐을 보이게 된다. 즉 HIF 전류는 비대칭성과 무작위성을 보이는데, HIF 신호가 카오스성을 가짐을 보여주는 연구들이 있다[5-6].

* 正 會 員 : 電子部品研究所 研究員

** 正 會 員 : 崇實大 電氣工學科 副教授 · 工博

接受日字 : 1999年 3月 18日

最終完了 : 1999年 11月 24日




그림 1 카오스 어트랙터를 이용한 패턴분류 과정
 Fig. 1 Procedure of pattern classification using the chaos attractor

그림 1은 고장전류 신호로부터 카오스 어트랙터를 재구성하고, 이로부터 특징을 추출하여 RBFN 신경망을 이용하여 분류하는 과정을 나타낸다. 고장전류 신호가 주어지면 어트랙터를 재구성하고, 재구성된 어트랙터가 존재하는 위상공간은 2차원이며, 어트랙터의 존재여부에 따라 1 또는 0의 값을 갖도록 특징벡터를 추출한다. 이렇게 해서 구해진 특징벡터가 Radial Basis Function Network(RBFN)의 입력으로 사용되며, RBFN의 출력을 통해 HIF의 발생 여부 및 지락면의 종류를 판별하게 된다.

2. 고저항 지락사고 신호의 특징추출

2.1 어트랙터 재구성

동역학 시스템에서는 시스템의 상태를 표현하는 유용한 도구로 위상궤적을 사용한다. 시스템의 안정상태가 유한하면, 시스템의 상태가 매 순간에 상태공간 위의 점으로 표현되며 특정한 형태를 갖게 된다. 안정된 시스템은 고정점을 향해 궤적을 그리며 고정점에서 안정하게 된다. 궤적의 모양은 시스템이 이러한 궤적을 그리도록 하는 어트랙터의 영향 때문이다. 어트랙터는 시스템이나 방정식을 최종상태로 이끌려는 경향 때문에 붙여진 이름이다. 평형점(equilibrium point), 한계사이클(limit cycle), 원환체(torus)등의 어트랙터는 예측 가능한 시스템이다. 전기신호의 경우 주기적 특성이 있으므로 폐곡선의 모양을 나타내게 된다.

어트랙터 재구성이란 시계열의 신호를 위상공간으로 임베딩하여 나타내는 것을 말한다. 따라서 어트랙터 재구성은 복잡한 현상에서 얻은 불규칙하며 잡음처럼 보이는 실험 데이터를 이해할 수 있게 도와준다. 신호가 단일 시계열 데이터이고 방정식이 주어지지 않은 경우는 위상공간으로 궤적을 표현할 수 없으나, Takens가 제안한 지연방법[7]을 이용하면 식 (1)과 같이 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 지락 사고 신호를 패턴 분류하는 것이 가능하다. 이 방법을 사용하기 위해서는 사전에 임베딩 차원과 시간지연을 설정해야하지만 본 논문에서는 임베딩 차원을 2로 정하였으므로 식 (1)을 식 (2)와 같이 표현할 수 있다.

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

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

2.2 카오스 어트랙터부터의 특징추출

HIF는 아크를 동반하는 것이 일반적이며, 따라서 아크의 특성을 살펴봄으로써 HIF시 나타나는 신호의 특징을 찾아볼 수 있다. HIF시 나타나는 $v-i$ 특성의 형상은 아크 기하학과 열 전달 조건에 따라 변화되며 두 요소들은 흙의 습기 함유량에 의해 영향을 받는다. 한 예로 건조한 흙에서 발생하는 고장의 전류파형은 일반적인 정현파 곡선에 비해 전류가 0에서 머무르는 간격이 넓다.

2차원 위상공간의 재구성된 어트랙터에서 특징을 추출하기 위해 어트랙터 평면을 $L \times L$ 의 격자로 나눈다. 격자내에 어트랙터가 존재하면 1의 값을, 그렇지 않은 경우에는 0의 값을 갖도록 입력패턴의 값을 이진값으로 바꾼다. 따라서 특징추출 후 입력패턴은 L^2 의 입력차원을 갖는다.




그림 2 어트랙터 재구성을 이용한 특징추출의 예
 Fig. 2 Example of feature extraction

그림 2는 특징추출의 한 예를 보여준다. 그림 2(a)는 정규화된 중성점 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, 흰부분은 '0'의 값을 갖는다. 격자내의 숫자는 인덱스 값을 나타낸다. 따라서, 신경망의 입력 데이터는 16차원 벡터로 식 (3)과 같이 나타난다.

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

신경망의 입력으로 식 (3)과 같이 나타나는 L^2 차원의 입력값 중에서 모든 입력 데이터에서 같은 값을 갖는 인덱스를 제거한다. 이렇게 함으로써 신경망의 구조를 단순화하며 연산을 줄인다.

3. 고저항 지락사고신호의 패턴인식

3.1 RBFN 신경망의 구조

HIF의 유무 및 지락면의 종류를 판별하기 위한 패턴분류기로 RBFN 신경망을 사용한다. RBFN은 MLP와 같은 전방향(feedforward) 신경망으로서 입력층, 중간층 그리고 출력층을 가진다.[8] 입력층과 중간층 사이의 가중치는 모두 1의 값이므로 어떠한 계산도 없다. 각각의 중간층은 방사함수를 가진다. 일반적으로 가우시안 함수를 사용하는데, 가우시안 함수를 사용하는 경우 중심값과 함수폭의 두 값을 설정하면 되기 때문이다. 중간층에서 중심값과 입력과의 거리 계산은 Euclidean Norm을 이용한다. 출력층에서는 하중합(weighted-sum)을 계산하며, 응용분야에 따라 출력값을 그냥 출력하기도 하고 다른 특정함수를 사용하기도 한다. RBFN의 응용분야로는 MLP와 마찬가지로 패턴의 구분이나 식별, 패턴인식 뿐만 아니라, 보간이나 예측, 시스템 모델링이나 신호처리 등의 다양한 분야에 적용되고 있다.[9-10] RBFN의 구조는 그림 3과 같이 나타낼 수 있다.




그림 3 RBFN의 구조
Fig. 3 Structure of RBFN

그림 3에서 \mathbf{x}_p 는 M 차원을 가진 입력이며, \mathbf{c}_n 는 입력과 같은 M 차원을 갖는 중심점 벡터이고, 그 개수는 중간층 노드수인 N 과 동일하다. g_n 는 스칼라(scalar)값을 갖는 방사함수의 응답이다. 즉, 하나의 입력 데이터에 대해 하나의 값을 출력한다. \mathbf{W} 는 중간층과 출력층을 연결하는 가중치(weight) 벡터이고, \mathbf{y}_p 는 출력으로 Q 차원 벡터이다. P 개의 입력 데이터가 주어진 경우, 가우시안 함수를 중간층의 활성화함수로 사용하는 중간층의 출력은 식 (4)와 같다.

$$\mathbf{G}^T = [\mathbf{g}_1 \ \mathbf{g}_2 \ \dots \ \mathbf{g}_P] \tag{4}$$

$$= \begin{bmatrix} 1 & 1 & \dots & 1 \\ g_1(\mathbf{x}_1) & g_1(\mathbf{x}_2) & \dots & g_1(\mathbf{x}_P) \\ \vdots & \vdots & \ddots & \vdots \\ g_N(\mathbf{x}_1) & g_N(\mathbf{x}_2) & \dots & g_N(\mathbf{x}_P) \end{bmatrix}$$

여기서 \mathbf{g}_p 는 p 번째 입력 데이터에 대한 중간층의 응답이고, 각 성분들은 식 (5)로 나타낼 수 있다.

$$g_n(\mathbf{x}_p) = \exp\left(-\frac{\|\mathbf{x}_p - \mathbf{c}_n\|^2}{2\sigma_n^2}\right) \tag{5}$$

식 (5)은 p 번째 입력 데이터에 대한 n 번째 중간층의 출력을 의미한다. 그리고 q 번째 출력은 식 (6)으로 구할 수 있다.

$$\mathbf{y}_q = \mathbf{G} \mathbf{w}_q \tag{6}$$

가중치의 결정은 식 (7)와 같이 최소자승법에 의해 구할 수 있으며, 이러한 방법을 사용하는 경우 반복적인 계산 없이 최적의 해를 구할 수 있다.

$$\mathbf{w}_q = \mathbf{G}^+ \mathbf{d}_q \tag{7}$$

여기서 \mathbf{G}^+ 는 \mathbf{G} 의 의사역행렬이며, $N+1 \leq p$ 인 경우에 $\mathbf{G}^+ = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T$ 이고, $N+1 \geq p$ 인 경우 $\mathbf{G}^+ = \mathbf{G}^T (\mathbf{G} \mathbf{G}^T)^{-1}$ 이다.

3.2 중간층 파라미터의 결정

RBFN은 중간층 활성화함수로 가우시안 함수를 사용하는 경우 파라미터로 중심점과 함수폭을 가진다. 중심점을 결정할 때는 중심점의 수가 적으면서도 각각의 중심점이 각 클러스터를 대표할 수 있는 값으로 선택되었는지 고려해야 한다. 본 논문에서는 경쟁학습[11]을 통하여 중심점을 결정하였다. 식 (8)은 경쟁학습의 알고리즘을 수식으로 표현한 것이다.

$$\begin{cases} \mathbf{c}_p(k+1) = \mathbf{c}_p(k) + a(\mathbf{x} - \mathbf{c}_p(k)) \\ \mathbf{c}_i(k+1) = \mathbf{c}_i(k) \end{cases}, i \neq p \tag{8}$$

신경망의 출력 뉴런 중 가장 큰 값을 출력하는 뉴런의 연결도만을 학습시키는 과정을 반복적으로 수행하여 각 클러스터의 중심값을 얻는다. 이 때 입력데이터 \mathbf{x} 는 정규화되어야 한다. 정해진 횟수(epoch)동안 학습을 진행하며, 마지막 단계에서의 $\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_N$ 이 중심점이 된다.

함수폭의 값은 인접한 입력 데이터간의 거리보다는 크고, 입력 데이터간의 최대거리보다는 작은 값을 선택하는 것이 좋다. Lowe는 통계적인 실험을 통해서 적절한 함수값을 얻었다.

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

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

4. 시뮬레이션

HIF의 패턴분류를 위해 2가지 데이터를 이용하여 실험하였다. 실험에 사용한 데이터는 EMTP에 의해 얻은 데이터와 직접 고저항 사고를 모의하고 측정한 실험 데이터이다. 실험에서는 중성점 전류를 사용하였는데 이는 HIF 발생시 중성점 전류의 변화가 두드러지게 나타나기 때문이다.

4.1 실험 데이터

EMTP를 이용하여 HIF 신호를 얻기 위해 그림 4와 같은 배전계통을 생각하였다. 그림 4에서 지락사고는 a상 1상을 지락시킨 1상지락 사고이다. 여기서 HIF 모델은 Buchholz 모델[12]을 사용하였으며 부하모델로는 저항과 인덕터가 직렬로 연결된 1차 임피던스 모델을 사용하였다. 실험데이터로 중성점 전류를 사용하기 위해 3상 중 1상에 불평형부하를 걸어주며 따라서 정상상태에서도 중성점전류를 얻을 수 있다.




그림 4 EMTP 통해 데이터를 얻기 위한 계통도
Fig. 4 Power system model for EMTP

그림 4에서 사용하고 있는 각각의 파라미터는 표 1과 같이 나타낼 수 있다.

표 1에서 Z_0 , Z_1 , Z_2 는 각각 영상분, 정상분 그리고 역상분 임피던스이다. 그리고 부하 임피던스에서 a상의 임피던스 값은 각각 $50 \leq R_0 \leq 130$, $25 \leq X_0 \leq 65$ 의 범위를 갖는 값이다. 따라서 부하에는 불평형 부하가 걸리며, 정상상태에서도 중성점에 전류가 흐르게 된다.

그림 5에 나타난 Buchholz의 고저항 지락사고 모델을 기반으로 하여 실험에 사용할 3가지 고장을 정의하였다. 우선 고장 1은 Buchholz[12]에서 사용하고 있는 HIF 모델 파라미터를 그대로 사용한 것이고, 고장 2와 고장 3을 얻기 위하여 원 모델에서 사용된 파라미터의 값을 임의로 변화시켰다. 표 2는 이와같이 정의한 세 종류의 고장에 대한 파라미터를 나타낸 것이다. EMTP에 의해 만들어진 각 데이터는 260 $[\mu s]$ 로 샘플링 되었으며, 따라서 한 주기는 64개의 샘플을

표 1 시스템 모델 구성요소의 파라미터
Table 1 Parameters of system model

전원 분기 임피던스 Z_0	Z_0 [%]	0.257 + j1.336
	Z_1, Z_2 [%]	0.072 + j0.757
발전원	E_s [kV]	154
	용량[MVA]	45/60
	정격전압[kV]	154/23
	결선방식	$\Delta - Y$
선로 임피던스 Z_{line}	Z_0 [%/km]	11.99 + j29.26
	Z_1, Z_2 [%/km]	3.47 + j7.46
가공선로	선로길이[km]	10
부하	크기[MVA]	6
	역률	0.9
부하 임피던스	a상[Ω]	$R_0 + j X_0$
	b,c상[Ω]	78.66 + j38.07




그림 5 Buchholz HIF 모델
Fig. 5 Buchholz HIF model

표 2 EMTP에 의한 데이터에서 고장의 정의
Table 2 Definition of fault patterns by the EMTP

구분	V_P [V]	V_N [V]	$R + jX$ [Ω]
고장 1	1000	2500	123.4 + j12.3
고장 2	800	2000	100 + j9
고장 3	1200	3000	140 + j15

가진다. 실측실험 데이터는 1986년 정주 변전소 관할 정읍 D/L에서 a상의 전력선을 다양한 접지 면에 떨어뜨림으로써 얻은 실제 지락사고 데이터이다[1]. 데이터는 정상 및 3종류 고장 데이터이며, 고장은 지락면의 종류에 따라 구분하였다. EMTP에 의한 데이터와 실측실험 데이터 모두 분류할 패턴은 정상 및 3가지 종류의 고장으로 4종류이며, 입력 데이터는 각 신호에 대해서 특징추출 과정을 통해 얻었다. 전체

표 3 실험 데이터

Table 3 Experimental input data

	EMTP데이터에 의한 입력 데이터수			실측실험 데이터에 의한 입력 데이터수		
	학습	테스트	전체	학습	테스트	전체
	정상	38	7	45	124	24
고장 1	225	45	270	161	33	194
고장 2	225	45	270	119	23	142
고장 3	225	45	270	118	24	142
합계	713	142	855	522	104	626

입력 데이터 중 약 85%는 학습에 이용하였으며, 나머지는 테스트에 이용하였다. 표 3에 실험에 사용한 입력 데이터를 나타내었다.

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 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 값의 설정이 τ 와 무관하지 않으므로 두 값의 변화를 쌍으로 하여 실험을 하였다. 두 값의 선택하는데 있어서 우선 고려되어야 할 사항은 서로 다른 클래스에 속하는 입력 데이터를 같은 데이터로 인식하지 말아야 한다는 것이며, 두 번째로 고려되어야 할 사항은 입력 데이터의 값을 가능한 한 작은 값으로 만들어야 한다는 것이다. 입력 데이터의 차원을 작은 값으로 선택하는 가장 큰 이유는 입력의 값이 작을수록 설계되는 신경망의 구조가 간단해지기 때문이다. 그림 6과 그림 7은 각각 EMTP에 의한 데이터와 실측실험 데이터의 재구성된 어트랙터 패턴을 나타낸다.

어트랙터가 존재하는 위상공간을 9×9 의 격자로 나누어 어트랙터가 존재하는 격자에 1의 값을 어트랙터가 존재하지 않는 격자에 0의 값을 주어 이진값을 갖는 입력 데이터를 얻었으며, 모든 데이터에 대해서 같은 값을 갖는 인덱스를 제거함으로써 패턴분류기의 입력차원을 줄였다. 결정된 패턴분류기의 입력차원은 58이다.

4.3 고저항 지락사고 데이터의 패턴분류 결과

HIF 데이터를 패턴분류하기 위한 RBFN의 구조는 다음과 같다. 입력노드의 수는 각 입력 데이터의 차원으로 58이며, 중간노드의 수는 중심점의 수로 27이다. 출력층에 'hard-limit' 함수를 사용하였으며, 4종류의 신호를 분류하므로 2개의 노드만 있으면 된다. 표 4는 실험결과를 인식률로 나타낸 것이다.

표 4에서 인식률의 계산은 식 (10)과 같다.

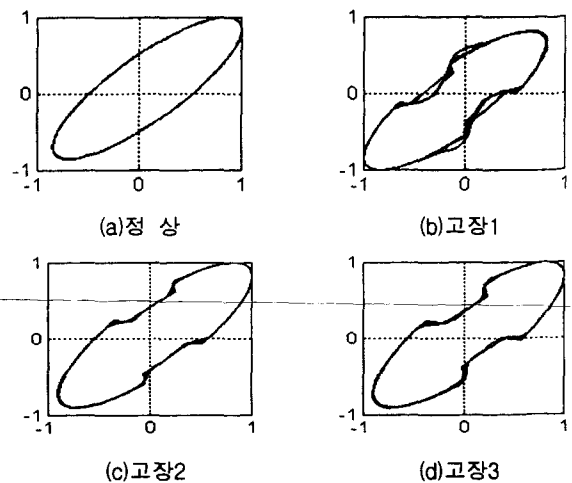


그림 6 EMTP에 의한 데이터의 재구성된 어트랙터
Fig. 6 Reconstructed attractors from EMTP data

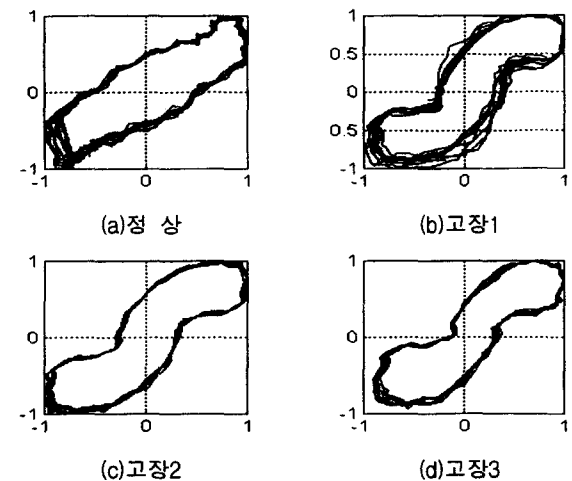


그림 7 실측 실험 데이터의 재구성된 어트랙터
Fig. 7 Reconstructed attractors from actual data

표 4 패턴분류 결과

Table 4 Pattern classification results

		정상	고장1	고장2	고장3	전체인식률
EMTP 데이터	학습시	100	83.97	98.09	94.27	89.62
	테스트시	100	80	88.9	86.7	85.92
실측실험 데이터	학습시	100	94.4	95.8	98.3	96.93
	테스트시	100	90.9	86.96	100	94.23

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

오인식이 발생하는 경우를 살펴보면 표 5와 같다. 표 5에서 목표 데이터는 원하는 데이터이며, 출력데이터는 실제

표 5 오인식 결과의 종류

Table 5 Types of misclassification results

목표데이터→출력데이터	EMTP 데이터		실측실험 데이터	
	학습	테스트	학습	테스트
정상 → 고장2	1	0	0	0
고장1 → 고장2	4	0	2	2
고장1 → 고장3	15	6	3	1
고장2 → 고장1	17	6	3	3
고장3 → 고장1	25	7	0	0
오인식 데이터수의 합계	62/825	19/165	8/510	6/101

RBFN의 출력으로 나온 데이터를 말한다. 오인식 데이터 수는 목표 데이터와 출력 데이터가 일치하지 않은 데이터의 수로 학습 시와 테스트 시로 나누어 나타내었다. 표 4를 통해 학습과 테스트 데이터에서 발생한 오인식 데이터 중에서 고장 파형을 정상 파형으로 오인식 하는 경우는 발생하지 않음을 알 수 있다.

5. 결 론

본 연구에서는 카오스 어트랙터를 이용하여 HIF 신호의 특징을 추출하고 RBFN을 이용하여 패턴을 인식하는 방법을 연구하였다. HIF의 패턴분류를 위해 중성점 전류의 카오스 어트랙터를 구하였으며, 이진 특징 벡터로 변환하여 신경망의 입력으로 사용하여 패턴분류 하였다.

EMTP를 이용한 지락사고 데이터와 실제 지락사고를 모의하여 측정된 데이터 각각에 대해서 인식률은 88.48[%]와 94.23[%]로 나타났다. 카오스 특징 추출에 의한 시계열신호의 패턴인식에 이용되는 RBFN은 HIF의 발생 여부 및 고장의 종류를 인식하는 데 높은 인식률을 보였으며, 가장 위험한 경우인 고장신호를 정상신호로 인식하는 오류는 발생하지 않았다.

감사의 글

이 연구는 1997년도 한국전력공사의 지원으로 수행되었습니다. (과제번호: 97-047)

참 고 문 헌

[1] 한국전력공사 기술연구원, 다중접지 배전선로 보호계전 방식 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 지락사고 대책 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] 유창완, 심재철, 고재호, 배영철, 임화영, "신경망과 카오스 현상을 이용한 고저항 지락 사고 검출 기법에 관한 연구," 1997 대한전기학회 하계학술대회 논문집, pp. 897-899, 1997.
 [6] 이호섭, 카오스 특징 추출에 의한 시계열 신호의 패턴 인식, 숭실대학교 대학원 석사학위 논문, 1996.
 [7] F. Takens, Lecture Notes in Mathematics, edited by D. A. Rand and L. S. Young, Springer, Vol. 898, p. 266, 1981.
 [8] Simon Haykin, Neural Networks, Macmillan College Pub., pp. 236-284, 1994.
 [9] S. Chen, B. Mulgrew and P. M. Grant, "A Clustering Technique for Digital Communications Channel Equalization Using Radial Basis Function Networks," IEEE Trans. on Neural Networks, Vol. 4, No. 4, pp. 570-578, July 1993.
 [10] K. B. Cho and B. H. Wang, "Hierarchical Intelligent Prediction System using RBF based AFS," Proc. of Int. Conf. Neural Networks(ICNN'95), Vol. 4, pp. 1839-1844, 1995.
 [11] J. M. Zurada, Introduction to Artificial Neural Systems, West Pub., pp. 401-405, 1992.
 [12] 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.

저 자 소 개



신승연 (辛承妍)

1974년 3월 21일 생. 1996년 호서대 전자공학과 졸업.(학사) 1998년 숭실대 대학원 전기공학과 졸업.(석사) 1999년~현재 전자부품연구원 위촉연구원.

Tel : (0333) 610-4375

E-mail:ssyeon@netsgo.com



공성곤(公聖坤)

1959년 11월 26일생. 1982년 서울대학교 공대 전기공학과 졸업.(학사) 1987년 서울대 대학원 전기공학과 졸업.(석사) 1991년 미국 University of Southern California 전기공학과 졸업.(공학박) 1992년 3월~현재 숭실대 전기공학과 부교수, 학과장. 1998년~현재 당 학회 컴퓨터 및 인공지능 연구회 간사장, 편집위원.

Tel : 820-0648

E-mail : skong@ee.ssu.ac.kr