

웨이브렛 변환과 신경망 학습을 이용한 고저항 지락사고 검출에 관한 연구

홍대승*, 배영철**, 전상영*, 임화영*

*광운대학교 제어계측공학과, **여수대학교 전기공학과

A Study on the Detection of High Impedance Faults using Wavelet Transforms and Neural Network

*Dae-seung Hong, **Young-chul Bae, *Sang-young Jeon, *Wha-yeong Yim

*Kwangwoon University, **Nat'l Yosu University

E-mail : ycbae@yosu.ac.kr, hongds@shinbiro.com

Abstract

The analysis of distribution line faults is essential to the proper protection of power system. A high impedance fault(HIF) dose not make enough current to cause conventional protective device operating, so it is well known that undesirable operating conditions and certain types of faults on electric distribution feeders cannot be detected by using conventional protection system. In this paper, we prove that the nature of the high impedance faults is indeed a deterministic chaos, not a random motion. Algorithms for estimating Lyapunov spectrum and the largest Lyapunov exponent are applied to various fault currents detections in order to evaluate the orbital instability peculiar to deterministic chaos dynamically, and fractal dimensions of fault currents which represent geometrical self-similarity are calculated. Wavelet transform analysis is applied the time-scale information to fault signal. Time-scale representation of high impedance faults can detect easily and localize correctly the fault waveform.

1. 서 론

전력계통에서 고저항 고장(High Impedance Fault : HIF)은 고장 전류가 작은 아크성 특징 때문에 고장전류의 크기에 의존하는 기존의 계전 방식으로는 검출이 불가능하다. 특히, 3상 4선식 다중접지 방식인 우리 나라 배전 선로에서의 고저항 지락사고는 고장 전류와 부하 전류와의 구별이 어려운 문제점이 있으며, 이에 대한 많은 연구가 진행되고 있다.

고저항 고장전류는 일반적으로 아크를 수반하므로 화재의 우려 및 인체 감전이나 에너지 낭비 또한 정전 등의 사고를 발생할 수 있다. 고저항 고장을 검출하기 위한 기존의 연구에는 고조파 신호의 증가를 검출해 내는 방법, 3조파, 5조파, 7조파 성분의 증가를 검출해 내는 방법, 고저항 고장 신호를 FFT(Fast Fourier Transform)를 통해 얻어진 고조파를 이용하여 고저항 사고를 검출하는 연구등이 있으나, 현재까지 완벽한 해결책은 없는 실정이다. 특히 FFT를 이용한 고저항 지락사고 검출시에도 검출된 고조파가 고저항 사고에 의해 발생한 고조파인지, 비선형 부하에 의해 발생한 고조파인지 판단하기 어려운 문제점이 있다. 또한 혼돈 특성 추출에 관한 연구가 진행중이다.

본 논문에서는 1주기의 전류 파형을 이산 웨이브렛 변환(Discrete Wavelet Transform)을 이용하여 각 구간 고조파 전류의 계수 값을 추출하였고, 추출된 고조파 전류의 계수 값을 고장 검출의 변수로 사용하였다. 이 변수를 학습된 신경회로망의 입력으로 사용하여 사고판단을 하였고, 또한 변수를 이용하여 혼돈

특성의 추출을 위하여 시간 지연(Time delay)과 매립차원(Embedding Dimension)을 결정하여 위상공간 해석을 시도하였다. 위상 공간 해석한 결과를 정규화하여 신경망 입력으로 사용하여 고장 형태를 분류하였다. 또한 고저항 고장과 유사한 형태를 가진 일반 캐패시터 스위칭등의 일반부하와의 차이를 이용하여 고저항 고장의 특성을 확인하여 검출의 정확도를 높일 수 있는 가능성을 연구하였다.

2. 관계이론

2.1 이산 웨이브렛 변환

최근에는 전력계통의 사고 시 발생하는 비 주기적인 과도현상을 분석하고 검출하기 위한 새로운 방법으로 웨이브렛을 이용한 방법들이 제시되고 있다. 웨이브렛 변환은 전력계통의 고장과 스위칭에 관련된 과도현상에 주파수와 시간에 대한 정보를 제공함으로써 과도 신호 검출이나 사고 파형 검출에 더 효과적으로 적용할 수 있다.

푸리에 변환은 신호 해석에 고정된 크기의 윈도우를 사용하기 때문에 빠른 과도 파형과 정현 파형이 동시에 존재하는 신호에 대해서는 적합한 분석방법이 되지 못한다. 그러나, 웨이브렛 변환은 고주파수는 짧은 윈도우, 저주파수는 긴 윈도우를 사용함으로써 기본파 및 저차 고조파와 과도 파형을 모두 가지고 있는 신호의 분석에 적합하다. 또한 푸리에 변환은 sin과 cos의

정형파를 사용하여 신호를 분해하는 반면, 웨이브렛 변환은 유한한 값을 가지며 평균값이 0이고 양쪽 끝에서 급격히 감쇠하는 형태의 변환신호로 원 신호를 변환하게 된다.
모든 임의의 신호는 식 (1)과 같은 급수의 형태로 표현될 수 있다.

$$f(t) = \sum_j a_j \varphi(t) \quad (1)$$

여기서 t 은 한계 혹은 무한계 합을 위한 정수 값이고, a_j 은 실수 계수이며 $\varphi(t)$ 는 실수값을 갖는 함수의 집합으로 이 급수가 유일하다면 이를 기저함수(basis function)라 한다. 웨이브렛 급수에서 식 (1)은 식 (2)와 같은 형태의 두 개의 매개변수를 갖는 형태로 표현될 수 있으며

$$f(t) = \sum_j \sum_k a_{j,k} \varphi_{j,k}(t) \quad (2)$$

여기서 $\varphi_{j,k}(t)$ 는 웨이브렛 급수함수(또는 기저함수)이고, 계수들의 집합인 $a_{j,k}$ 를 $f(t)$ 의 이산 웨이브렛 변환이라 하며 식 (3)과 같은 확장성을 갖는다.

$$\varphi_{j,k}(t) = 2^{j/2} \varphi(2^j t - k) \quad j, k \in Z \quad (3)$$

여기서, k 는 시간 혹은 공간적 위치에 대한 정보를 가지고 있고, j 는 주파수에 대한 정보를 가지게 된다. 또한 모든 웨이브렛 확장은 다해상도(multiresolution) 조건을 만족시킨다. 어떤 신호들의 집합이 $\varphi(t-k)$ 의 합으로 표현된다면 그 신호를 포함하는 집합은 $\varphi(2^j t - k)$ 의 선형 결합으로 표현할 수 있다. 즉 기본 확장 신호는 더 큰 집합의 신호들을 근사화 할 수 있다.

즉 저해상도의 계수는 고해상도의 계수들로부터 계산할 수 있다는 것을 의미하며, 이는 확장한 신호들의 계수를 계산하는데 유용하게 사용할 수 있다. 어떤 부분 공간 ν_0 에 속해있는 $\varphi(t)$ 는 ν_1 공간에 있는 $\varphi(2t)$ 에 의해 식 (4)과 같이 표현될 수 있다.

$$\varphi(t) = \sum_n h(n) \sqrt{2} \varphi(2t - n), \quad n \in Z \quad (4)$$

여기서 $h(n)$ 은 스케일 함수(scaling function)에 대한 계수값들이다. 그리고 ν_1 공간의 w_0 공간은 식 (8)과 같이 표현될 수 있다.

$$\psi(t) = \sum_n h_1(n) \sqrt{2} \varphi(2t - n), \quad n \in Z \quad (5)$$

여기서 $h_1(n)$ 은 정규 직교 특성에 의해 식 (6)를 만족한다.

$$h_1 = (-1)^n h(1-n) \quad (6)$$

따라서 식 (5)은 식 (7)과 같은 마더 웨이브렛을 갖는다.

$$\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k) \quad j, k \in Z \quad (7)$$

그러므로 L_2 에서 임의의 함수 $g(t) \in L_2(R)$ 에 대

하여 식 (3)의 스케일 함수 $\varphi(t)$ 와 식 (7)의 웨이브렛 함수 $\psi(t)$ 를 사용해 다음 식 (8)과 같이 표현할 수 있다.

$$g(t) = \sum_{k=-\infty}^{\infty} c_k 2^{j/2} \varphi(2^j t - k) + \sum_j \sum_{k=j_0}^{\infty} d_j(k) 2^{j/2} \psi(2^j t - k) \quad (8)$$

각각의 계수는 식 (9), 식 (10)과 같고

$$c_j(n) = \sum_{k=0}^{N-1} h(k-2n) c_{j+1}(k) \quad (9)$$

$$d_j(n) = \sum_{k=0}^{N-1} g(k-2n) c_{j+1}(k) \quad (10)$$

여기서 $h(k)$ 와 $g(k)$ 는 이산 웨이브렛 변환함수의 계수값이다.

고저항 고장(HIF)의 경우 고장 전류의 크기가 매우 작고, 불규칙한 비선형 특성을 보이므로, 이산 웨이브렛 변환하면 그 특성을 웨이브렛 계수 값으로 효율적인 정량화가 가능하다. 이 웨이브렛 계수 값들을 학습된 신경망의 입력요소로 사용하여 고장판단을 하였다.

2.2 신경 회로망

신경 회로망은 물리적 신경망을 모델로 비선형 최적화 문제를 풀기 위해 제안된 방법 중 하나이다. 신경 회로망은 구조가 간단하고, 비선형 특성이 우수하며 학습 능력을 가지고 있을 뿐 아니라, 한번 학습되면 계산 양이 적어 실시간 처리가 가능한 장점이 있다.

본 논문에서 제시한 고저항 고장 검출용 신경 회로망은 1개의 입력층과 2개의 은닉층, 1개의 출력층으로 구성되었다. 전류 파형을 한 주기마다 Daubechies D4 마더 웨이브렛을 이용한 이산 웨이브렛 변환을 level 5까지 계산된 계수 값 중 근사계수(approximation coefficients)를 입력할 수 있도록 8개의 입력을 받을 수 있는 입력층을 구성하였으며, 각각의 은닉층은 8개, 4개의 노드를 갖도록 하였다. 그림 1은 본 논문에서 사용한 신경회로망의 구조를 나타냈다.




그림 1 고저항 고장검출을 위한 신경회로망

신경 회로망의 출력 활성화함수는 비선형이며, ± 1 의 값을 갖는 쌍곡 탄젠트(hyperbolic tangent)함수로 식 (11)과 같다.

$$f(x) = \tanh(x/2) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (11)$$

신경 회로망의 각 노드간의 연결강도인 가중치는 입

력값의 크기를 고려하여 초기화 하였으며, 가중치의 갱신은 지역 최저치(local minimum)에 수렴하는 현상을 방지하기 위하여 식 (12)와 같이 학습율에 모멘텀 항을 추가하였다.

$$W(k+1) = W(k) + \Delta w(k+1)$$

$$\Delta w = -\eta \frac{\partial E}{\partial W} x_i, \quad \eta > 0$$

$$\Delta w(k+1) = a\Delta w(k+1) + (1-a)\Delta w(k) \quad 1 \geq a \geq 0 \quad (12)$$

여기서 η 는 학습률이고, x_i 는 입력 값이며 a 는 모멘텀 계수이다. 다양한 값으로 학습시켜 본 결과 모멘텀 계수 a 는 0.9가 적합하였다.

오차 역전파 학습 알고리즘의 경우 입력 패턴이 복잡한 경우 지역 최소 값으로 수렴하여 학습이 더 이상 진행되지 않는 경우가 발생할 수 있으므로, 본 논문에서는 generalized delta rule 알고리즘으로 변동 학습율을 적용하였다. 이 알고리즘의 특징은 현재와 과거의 오차 경사 값을 이용하여 학습률을 적응적으로 변화시키는 것으로 학습률 η 는 식 (13)과 같이 정의된다.

$$\eta(k+1) = \begin{cases} 1.04\eta(k) & \nabla E(k) > 1.04\nabla E(k-1) \\ 0.7\eta(k) & \nabla E(k) < \nabla E(k-1) \\ \eta(k) & \text{그 외의 경우} \end{cases} \quad (13)$$

학습된 신경망은 전류파형을 이산웨이브렛 변환한 근사계수를 신경망에 입력하면 출력층의 목표값(Desired value)은 정상상태일 경우는 -1, 고저항 고장상태일 경우는 +1로 나타난다.

2.3 위상공간 해석

불규칙하고 유계된(bounded) 카오스 신호의 성질이 아크성 고장전류에도 포함되어 있음을 규명하려면 카오스 현상의 판별 기준인 시계열 데이터, 위상공간, 포엔카레맵, 리아프노프 지수, 프랙탈 차원으로 판별해야 하나, 수학적 모델없는 1차원의 시계열 데이터로는 그 구별이 매우 어렵다.

본 연구에서는 고저항 지락 사고시의 실측 데이터에 카오스적인 성질이 있음을 매립(embedding) 이론에 의한 상태 공간의 재구성 및 기하학적인 카오스의 성질을 나타내는 프랙탈 차원으로 증명하여 새로운 고장 검출 인자로 제시하였다.

본 논문에서는 재구성시 false neighbour기법을 적용하여 최적의 재구성 차원을 선정하였다. 주어진 고장 전류 $s(k)$ 로부터 d 차원의 벡터 $y(k)$ 를 재구성하면

$$y(k) = \{s(k), s(k+r), \dots, s(k+(d-1)r)\} \quad (14)$$

여기서, d 는 재구성 차원이고, r 는 시간지연이다. 본 논문에서 재구성 차원은 3, 자기상관함수로 계산한 시간 지연은 42로 하여 식 (14)을 식 (15)와 같이 표현할 수 있다.

$$y(k) = \{s(k), s(k+r), s(k+2r)\} \quad (15)$$

표1은 실측 고저항 고장 파형을 이용하여 자기상관함수로 계산한 시간지연들의 결과이다. 평균 시간지연은 약 42로 결정되었고, 이 시간 지연을 이용하여 카오스 어트랙터로 재구성하였다.

실측한 고저항 고장파형을 웨이브렛 변환하여 고장파

형의 특성을 분류한 후 계수들을 이용하여 카오스 어트랙터를 구성하였다. 그림 2는 건전상 전류의 위상공간이다.




그림 2 (a)수목에 접촉시 건전 A상전류의 위상 공간
(b) 보통토사에 지락시 건전 B상전류의 위상 공간

정상 부하시 전류의 위상 공간은 단일 폐곡선을 나타내는 1주기 신호에 가깝고 변화의 폭 및 불규칙한 특성이 크게 나타나지는 않았다.

고저항 고장시의 위상 공간을 그림 3에 고장 유형별로 나타내었다.




그림 3 (a) 모래에 지락시 고장 전류의 위상 공간
(b) 보도블럭 지락 시 고장전류 위상공간
(c) 보도블럭(습기)에 지락시 고장 전류의 위상 공간
(d) 수목에 접촉시 고장 전류의 위상 공간

고장 전류의 위상 공간은 지락 매체에 따라 그 모양이 구분된 특성을 나타내며, 아크의 발생과 소멸에 따라 특정한 형태로는 변하지는 않지만 위상 공간내의 일부분을 벗어나지 않으며, 마치 수많은 끌개(attractor)가 얽히고 중첩된 기이하면서도 모양이 있는 구조체를 형성한다. 이러한 구조체를 이상한 끌개(strange attractor)라 하며, 고장 전류는 카오스 성질을 강하게 나타낸다고 할 수 있다.


위상공간을 64등분하여 각각 격자에 어트랙터가 존재하면 1 존재하지 않으면 0로 신경망의 입력을 받아 사고 유형을 판별하였다.

즉 고저항 고장 파형을 웨이브렛 변환과 신경회로망을 이용하여 실시간 고장 판별을 한 후 이 고장 파형을 위상공간 해석과 신경회로망을 이용하여 사고 유형을 판별한다.


3. 사례 연구

그림 4는 모래 지락시의 사고파형을 웨이브렛 변환

파 학습된 신경망을 이용하여 사고판별을 한 그림이다.




(a) 전압, 전류 파형




(b) 고장판단 출력

그림 4. 모래 지락시 고장상의 (a) 전압, 전류 파형, (b) 고장판단 출력

그림 5(a)는 나무 지락시의 전압, 전류 파형이며 약 5 cycle에서부터 사고이다. 정상전류 파형을 사고파형의 크기와 동일하게 하여 사고검출을 한 그림이다. 그림 5(b)는 정확한 사고검출을 보이고 있다. 그림 5는 FFT와 웨이블릿 변환을 이용한 검출을 비교하고 있다. FFT 변환보다 웨이블릿 변환이 더욱 정확하게 사고검출을 하고 있음을 보이고 있다.




(a) 전압, 전류 파형




(b) 고장판단 출력

그림 5. 자갈 모래 지락시 고장상의 (a) 전압, 전류 파형, (b) 고장판단 출력

순간적으로 아크 부하전류가 흐르는 경우의 전류 파형을 전압 파형과 함께 그림 6(a)에 보였다.



(a) 전압, 전류 파형



(b) 고장판단 출력

그림 6 순간 아크 부하시 (a) 전압, 전류 파형, (b) 고장판단 출력

그림 6에서 아크부하가 연속적으로 계속 흐르지 않고 순간적으로 잠시 동안만 흐르는 경우로, 아크부하의 순간에는 미세한 출력 변동이 있으나 고저항 고장과는 명확하게 구별되는 특성으로 나타나고 있다.

4. 결론

본 논문에서는 사고 파형중 전류 파형 1주기를 웨이블릿 변환을 이용하여 고주파 및 저주파 성분으로 분류하여 각 구간의 전류의 분포 특성 변화를 고장 검출 변수로 적용하였다. 고저항 고장파형을 직접 시계열 데이터로 사용하여 어트랙터를 구성한 결과보다 웨이블릿 변환된 검출인자를 매립차원의 시계열 데이터로 사용하여 어트랙터를 구성시 각 사고별로 그 모양이 구분된 특성을 나타내었다. 또한 웨이블릿 변환한 계수를 이용하여 카오스 어트랙터를 구성하여 각 고장파형의 특성을 재구성하여 다양한 형태의 고저항 고장에 대해 복잡한 수식적 해석이 없이도 고장패턴을 분류할 수 있으며 고장의 검출 성능 및 정확도를 높일 수 있었다.

웨이블릿 변환과 위상공간으로 재구성한 결과를 신경 회로망에 적용하여 어트랙터 구성에 따른 정확하고 신속한 고장판별과 그 알고리즘을 마이크로 프로세서에 적용하여 실측 데이터를 이용한 실험과정이 추후과제로 남는다.

[참고 문헌]

[1] "High Impedance Fault Detection Using Third Harmonic Current", Electric Power Research Institute Report EL-2430, Prepared by Hughes Aircraft Co., Jun. 1982

[2] Russel, B. D., Chinchali, R. P. "A digital signal processing algorithm for detecting arcing faults on power distribution feeders", IEEE Trans. on Power Delivery, Vol.4, No.1, Jan, 1989.

[3] I. Daubechies, "Ten Lectures on Wavelet", SIAM, Philadelphia, Pennsylvania, 1992.

[4] 도경훈, 현기호, 변영복, 조기윤, 하영호, "역전파 신경회로망을 이용한 고임피던스 고장 검출", 대한전기학회 논문지 43권 11호, 1994년 11월

[5] 남순일, 강용철, 김성수, 손진만, 박종근, 장성일, 김광호, 김일동, "Wavelet 변환을 이용한 배전 계통의 고저항 사고 검출 알고리즘", 대한전기학회 하계학술대회 논문집(C) pp.975-978 1997년 7월

[6] 임화영, 유창완, 고재호, "전력계통의 고임피던스 고장 검출 기법에 관한 연구", 대한전기학회 논문지 48A권 1호, pp.15-21 1999년 1월