

웨이브렛 변환과 신경망 학습을 이용한 고저항 지락사고 검출에 관한 연구

論 文

50A-3-1

A Study on High Impedance Fault Detection using Wavelet Transform and Neural-Network

洪大昇* · 柳昌完** · 任化永***

(Hong Dae-Seung · Ryu Chang-Wan · Yim Wha-Yeong)

Abstract - The research presented in this paper focuses on a method for the detection of High Impedance Fault(HIF). The method will use the wavelet transform and neural network system. HIF on the multi-grounded three-phase four-wires primary distribution power system cannot be detected effectively by existing over current sensing devices. These paper describes the application of discrete wavelet transform to the various HIF data. These data were measured in actual 22.9kV distribution system. Wavelet transform analysis gives the frequency and time-scale information. The neural network system as a fault detector was trained to discriminate HIF from the normal status by a gradient descent method. The proposed method performed very well by proving the right state when it was applied staged fault data and normal load mimics HIF, such as arc-welder.

Key Words : High impedance fault, High impedance fault detector, Wavelet Transform, Backpropagation

1. 서 론

전력계통의 배전선로에서 발생하는 전력선이 지표면이나 나무 기타 시설물에 접촉되었 때 아크를 수반하는 미소한 고장전류가 흐르게 되는데 이를 고저항 고장(High Impedance Fault: HIF)이라 한다. 이 전류는 접촉면의 다양한 형태와 조건에 따라 다른 특성을 지닌 아크성 전류가 되므로 전류의 크기에 의존하는 기존의 계전 방식으로는 고장검출[1-5,7]이 힘들다.

또한 고저항 고장 특성은 배전선의 구조, 부하량, 날씨, 지락시 대지의 표면 절연상태에 따라 고장지락 시 대지의 표면 상태 등에 영향을 받아 고장전류의 크기가 매우 다양하게 나타나므로 EMTP등의 컴퓨터 시뮬레이션으로 정확히 모의하는 것은 매우 어려우며, 이를 토대로 한 검출 결과[7,8]로는 그 성능을 신뢰할 수 없다.

최근에는 국내외에서 웨이브렛 변환[6]을 이용하여 고저항 고장을 검출하려는 연구[8,9]도 있으나, 단지 고저항 고장에 적합한 마더 웨이브렛을 선정하여 계수 값들의 정량화 및 변화 수치만을 제시하는데 그치고 있다.

본 논문에서는 고저항 고장 전류를 이산 웨이브렛 변환[6]하여 고장을 정확하게 판별하도록 연구하였다. FFT 변환을 이용하는 경우 고주파 신호의 존재유무만을 알 수 있지만 웨

이브렛 변환은 신호의 주파수 성분과 그 발생 시간에 대한 정보를 동시에 얻을 수 있는 효과적인 방법이므로 전압 파형의 순시치와 그때 발생한 고장전류의 고주파 분포 특성을 추출하여 고장 검출에 적용하려는 것이다.

웨이브렛 변환을 효율적으로 수행하기 위하여 우수한 고장 판별 특성을 보이는 Daubechies의 D4 마더 웨이브렛을 선정하였으며 이를 적용한 웨이브렛 변환으로 얻어진 결과의 계수들을 신경망에 입력하여 다양한 형태의 고저항 고장 검출을 시도하였다. 웨이브렛 변환 계수 값을 이용해 고저항 고장을 효과적으로 판별하고 정량적으로 나타내기 위해 신경 회로망을 도입하였으며 신경 회로망의 파라미터 학습에는 최급 강하법(Gradient Descent Method)을 이용하여 고저항 고장 검출 성능 및 정확도를 향상시켰으며, FFT를 이용한 고저항 고장 검출법[7,10]과 비교하였다. 한국전력공사에서 실측한 22.9Kv 배전선로의 고저항 고장 데이터와 일반 아크부하의 사고검출을 비교하여 이산 웨이브렛과 신경 회로망을 이용한 고저항 고장 검출의 성능 및 정확도를 높이고 활용할 수 있는 가능성을 연구하였다.

2. 신경 회로망의 구성

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

* 正 會 員 : 光云大 制御計測工學科 博士修了

** 正 會 員 : (주)마이크로페이스 연구소장 · 工博

*** 正 會 員 : 光云大 制御計測工學科 教授 · 工博

接受日字 : 2000年 4月 28日

最終完了 : 2001年 2月 2日

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
Fig. 1 Neural network for detection of HIF

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

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

신경 회로망의 각 노드간의 연결강도인 가중치는 입력값의 크기를 고려하여 초기화 하였으며, 가중치의 갱신은 지역 최저치(local minimum)에 수렴하는 현상을 방지하기 위하여 식 (2)와 같이 학습율에 모멘텀 항을 추가하였다.

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

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

$$\Delta w(k+1) = \alpha \Delta w(k+1) + (1 - \alpha) \Delta w(k) \quad 1 \geq \alpha \geq 0 \quad (2)$$

여기서 η 는 학습률이고, x_i 는 입력 값이며 α 는 모멘텀 항 계수이다. 다양한 값으로 학습시켜 본 결과 모멘텀 계수 α 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 알고리즘[7]으로 변동 학습율을 적용하였다. 이 알고리즘의 특징은 현재와 과거의 오차 경사 값을 이용하여 학습율을 적응적으로 변화시키는 것으로 학습률 η 는 식 (3)과 같이 정의된다.

$$\eta(k+1) = \begin{cases} 1.04\eta(k) & \nabla E(k) > 1.04\nabla E(k-1) \\ 0.7\eta(k) & \nabla E(k) < \nabla E(k-1) \\ \eta(k) & \text{그 외의 경우} \end{cases} \quad (3)$$

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

난다.

3. 웨이브렛 변환

최근에는 전력계통의 사고 시 발생하는 비 주기적인 과도 현상을 분석하고 검출하기 위한 새로운 방법으로 웨이브렛을 이용한 방법[8,9]들이 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 정현파를 사용하여 신호를 분해하는 반면, 웨이브렛 변환은 유한한 값을 가지며 평균값이 0이고 양쪽 끝에서 급격히 감쇄하는 형태의 변환신호로 원 신호를 변환하게 된다.

3.1 이산 웨이브렛 변환

모든 임의의 신호는 식 (4)과 같은 급수의 형태로 표현될 수 있다.

$$f(t) = \sum a_l \varphi_l(t) \quad (4)$$

여기서 l 은 한계 혹은 무한계 합을 위한 정수 값이고, a_l 은 실수 계수이며 $\varphi_l(t)$ 는 실수값을 갖는 함수의 집합으로 이 급수가 유일하다면 이를 기저함수(basis function)라 한다.

웨이브렛 급수에서 식 (4)는 식 (5)와 같은 형태의 두 개의 매개변수를 갖는 형태로 표현될 수 있으며

$$f(t) = \sum_j \sum_k a_{j,k} \varphi_{j,k}(t) \quad (5)$$

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 (6)과 같은 확장성을 갖는다.

$$\varphi_{j,k}(t) = 2^{j/2} \varphi(2^j t - k) \quad j, k \in Z \quad (6)$$

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 $\varphi(2t-k)$ 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 계산하

는데 유용하게 사용할 수 있다.

어떤 부분 공간 ν_0 에 속해있는 $\varphi(t)$ 는 ν_1 공간에 있는 $\varphi(2t)$ 에 의해 식 (7)과 같이 표현될 수 있다.

$$\varphi(t) = \sum_n h(n)\sqrt{2}\varphi(2t-n), \quad n \in Z \quad (7)$$

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.

$$\psi(t) = \sum_n h_1(n)\sqrt{2}\varphi(2t-n), \quad n \in Z \quad (8)$$

여기서 $h_1(n)$ 은 정규 직교 특성에 의해 식 (9)를 만족한다.

$$h_1 = (-1)^n h(1-n) \quad (9)$$

따라서 식 (8)은 식 (10)과 같은 마더 웨이브렛을 갖는다.

$$\psi_{j,k}(t) = 2^{j/2}\psi(2^j t - k) \quad j, k \in Z \quad (10)$$

그러므로 L_2 에서 임의의 함수 $g(t) \in L_2(R)$ 에 대하여 식 (6)의 스케일 함수 $\varphi(t)$ 와 식 (10)의 웨이브렛 함수 $\psi(t)$ 을 사용해 다음 식 (11)과 같이 표현할 수 있다.

$$g(t) = \sum_{k=-\infty}^{\infty} c_n 2^{j/2} \varphi(2^j t - k) + \sum_k \sum_{j_0}^{\infty} d_j(k) 2^{j/2} \psi(2^j t - k) \quad (11)$$

각각의 계수는 식 (12), 식 (13)과 같고

$$c_j(n) = \sum_{k=0}^{N-1} h(k-2n)c_{j+1}(k) \quad (12)$$

$$d_j(n) = \sum_{k=0}^{N-1} g(k-2n)c_{j+1}(k) \quad (13)$$

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.

4. 최적의 마더 웨이브렛 선정

FFT와는 달리 이산 웨이브렛 변환은 다양한 변환함수가 존재하며, 그 형태와 특성이 다르므로 고저항 고장 검출에 이산 웨이브렛 변환을 적용하기 위해서는 변환 함수인 마더 웨

이브렛을 선정하는 것이 매우 중요하며 선행되어야 할 과제이다. 마더 웨이브렛 $\psi_{j,k}(t)$ 는 형태와 특성에 따라 Haar 웨이브렛, Daubechies 웨이브렛, Biorthogonal 웨이브렛, Coiflets 웨이브렛, Symlets 웨이브렛 등의 여러 가지 종류가 있다.

여러 문헌등에 발표된 마더 웨이브렛의 종류는 많으나, 전력계통의 해석 시 고장전류 파형과 형태가 유사한 마더 웨이브렛을 이용한 분석이 정확한 결과를 얻을 수 있다.

본 논문에서는 실측된 고저항 고장 전류 파형을 표 1에 제시한 마더 웨이브렛들을 대상으로 level 1에서 level 7까지 이산 웨이브렛 변환(총 140가지 경우)한 후 신경 회로망에 학습시켰으며, 이 때 최소의 학습오차를 갖는 것을 최적 마더 웨이브렛으로 선정하였다.

표 1 파형 분석에 사용된 마더 웨이브렛의 종류
Table 1 The type of mother wavelet for signal analysis

Mother Wavelet	Daubechies					Biorthogonal				Coiflets					Symlets						
	1	2	4	6	8	1.1	1.2	2.2	3.1	4.4	2	3	4	5	2	3	4	5	6	7	
종 류	1	2	4	6	8	1.1	1.2	2.2	3.1	4.4	2	3	4	5	2	3	4	5	6	7	
Level	1~7 level					1~7 level				1~7 level					1~7 level						

고저항 고장 전류 파형과 가장 유사한 형태의 마더 웨이브렛을 선택하면, 고저항 고장의 경우에는 계수 값이 크게 나타나므로 고장 판별을 위한 명확한 기준으로 사용될 수 있다.

정확한 고저항 고장 검출을 위해 고저항 고장 전류뿐 아니라 정상적인 아크 부하 전류 및 건전 선로의 정상 전류 파형도 신경 회로망의 학습에 적용하였으며, 일부 파형은 학습에는 사용하지 않고 학습 결과를 판단하기 위한 평가 파형으로만 사용하였다. 배전 선로가 보도 블록에 지락한 보도 블록1과 보도 블록2의 고장 파형 중 보도 블록 1의 고장 파형만 신경 회로망의 학습에 적용하였다. 비학습된 고장 파형은 제시한 고장 검출법의 성능을 검증하기 위한 예비 데이터로 남겨 두었으며, 다른 고장 파형 및 부하 전류에 대해서도 동일한 방법으로 적용하였다. 표 2는 신경 회로망의 학습 및 검증에 사용된 파형을 정리한 것이다.

표 2 신경 회로망 학습에 사용된 데이터
Table 2 Used data for learning of neural network

	학습에 사용된 데이터		학습 후 검증에 사용된 데이터
	건전구간	사고구간	사용 여부
보도블록 1	45 cycle	20 cycle	×
보도블록 2	-	-	○
자갈, 모래 1	20 cycle	35 cycle	×
자갈, 모래 2	-	-	○
모래 1	-	40 cycle	×
모래 2	-	-	○
나무	-	-	○
순간아크부하	45 cycle	-	○
지속아크부하	-	-	○

신경회로망의 학습시 같은 고장 전류 파형에 동일한 웨이브렛을 적용하여도 변환 level에 따라 학습 오차율이 다르게 나타났으며, 동일한 level에서도 마더 웨이브렛이 다를 경우에는 그 차이가 심하게 나타났다.

학습 오차율은 Daubechies D10 웨이브렛을 이용한 level 4가 6.33, Daubechies D4 웨이브렛을 이용한 level 5에서 8.71, Daubechies D8 웨이브렛을 이용한 level 3의 오차율은 13.26, Biorthogonal 3.1 웨이브렛을 이용한 level 5는 9.50의 결과를 얻었다. 그러나 학습에 포함되지 않은 데이터에 대한 출력 오차율이 상대적으로 가장 작게 나타난 Daubechies D4가 여러 가지 고저항 고장 전류의 특성을 잘 구별하는 특성을 보였다. 본 논문에서는 학습 오차 및 비학습 데이터에 대한 출력 오차가 가장 작게 나타난 Daubechies D4를 마더 웨이브렛으로 선정하였다.

그림 2는 입력층에 72개, 은닉층에 36개, 출력층에 5개의 가중치 파라미터를 갖는 신경회로망을 이용해 고장전류 및 아크 부하전류(표 2)를 입력시켜 정상일때 출력이 -1, 고장일때 +1이 되도록 학습 시켰다. 총 500회 동안 반복하여 학습시켰을 때의 학습오차와 최종 출력이다.




그림 2 신경 회로망의 학습 오차(위)와 최종 출력(아래)
Fig. 2 Learning error(top) & output(bottom) of the neural network

5. 적용사례

배전선로를 자갈과 모래가 혼재한 지면에 인위적으로 지락(한국전력공사 시행)시켰을 때 실측한 고장전과 고장후의 전압 및 전류 파형을 그림 3에 나타냈다.




그림 3 자갈 모래 지락시 고장상의 전압, 전류 파형
Fig. 3 Voltage and current waveform when the conductor is grounded on mixing gravel and sand

그림 3에서 실선으로 표시한 것은 전압이고 굵은 선은 전류 파형으로, PT와 CT 2차측의 크기로 표시했으며 주기당 64 샘플로 양자화 되었다. 시작점으로부터 약 5 [cycle]에서 사고 상태가 발생하여 지속되는 경우로, 전류 파형을

Daubechies D4를 사용하여 level 5 까지 이산 웨이브렛 변환한 계수값을 그림 4에 나타냈다.




그림 4 자갈 모래 지락 고장상의 이산 웨이브렛 변환계수
Fig. 4 The coefficient of the wavelet transform when the conductor is grounded on mixing gravel and sand

웨이브렛 계수값은 그 값 자체가 파형의 크기를 나타내는 것은 아니며 마더 웨이브렛과의 상관관계 정도를 나타내는 값으로 이 값들을 사용해 재구성하면 원 신호인 전류 파형을 얻어낼 수 있다.

웨이브렛 변환 계수값은 고장 전후에 크기가 다르게 나타나지만 계수값의 크기만을 고려해 고장을 판단하지 않고 이를 신경 회로망의 입력으로 사용하여 고장을 판별하도록 하였다. 신경 회로망에서는 입력된 계수값들의 크기와 분포를 고장과 정상 각각의 경우에 대하여 학습하고 이를 근거로 입력되는 전류에 대하여 고장 여부를 판별하게 된다.

고장 발생 순간인 5 [cycle] 시점에서 사고 전후에 계수값의 크기가 크게 변화하는 특성을 나타내고 있다. 고장 직후에 계수값들이 작게 나타나고 고장이 진행됨에 따라 다시 조금씩 커져 가는 모습을 볼 수 있다.

고저항 고장 검출용 신경 회로망의 고장 판단 출력을 그림 5에 보였다. 검출기의 결과 출력에서 웨이브렛 변환을 사용한 고장판단 출력은 실선, FFT를 사용한 출력은 점선으로 나타냈으며 +1인 경우가 고장이며 -1인 경우가 정상상태이다.





그림 5 자갈 모래 지락시 고장상의 고장 판단 출력
Fig. 5 Output of a fault detector when the conductor is grounded on mixing gravel and sand of a fault detector

두 경우 모두가 고장 발생 직후 정확하게 고장판단을 하고 있지만 웨이브렛 변환을 사용한 경우가 더 정확하게 고장을 검출하는 것을 볼 수 있으며, FFT를 사용한 경우는 출력의 변동이 나타나고 있다.


특히 7 [cycle] 시점에서 FFT 결과의 판단은 출력에 큰 변동을 보이며 정상상태에 가깝게 판단을 하고 있지만 웨이브렛의 경우는 정확히 고장임을 출력하고 있다.

그림 6부터 8은 배전선로가 모래, 나무, 자갈·모래, 보도블록등 다양한 매체에 지락시 전압과 전류 파형과 고장 검출 성능을 보인 것으로 신경 회로망의 학습에 사용되지 않은 데이터이다.

그림 6(a)는 나무 지락시의 전압, 전류 파형이며 전구간이 고장이다. 그림 6(b)에서 웨이브렛 변환 적용시에는 일관된 출력으로 신뢰성 있는 검출 성능을 나타내었다.



(a) 전압, 전류 파형



(b) 고장판단 출력


그림 6 나무 지락시 고장상의 (a) 전압, 전류 파형, (b) 고장판단 출력

Fig. 6 Fault phase when the grounded on trees (a) Voltage & Current waveform, (b) Output of a fault detector


그림 7(a)는 앞에서 사용한 그림 2의 자갈 모래 지락시의 전류를 대상으로 고장 이전의 전류 크기를 고장 이후의 크기와 동일하게 하여 사고 검출을 시도하였다. 고저항 지락 고장의 특징인 사고시 전류의 증분이 거의 없도록 하여 검출 성능을 확인하기 위해 사고 전후의 전류 증분이 없도록 한 것으로 배전선로가 5 [cycle] 시점에 자갈모래에 지락 되어 사고가 진행되는 파형이다. 이 경우의 고장 판단 출력은 웨이브렛 변환과 FFT 적용시 5 [cycle]에서 +1로 모두 사고검출을 하고 있으나, 웨이브렛 변환 적용시 더욱 정확하고 빠른 검출 성능을 보이고 있다.

이는 제한한 알고리즘이 고저항 고장 전류의 특성을 추출하여 정상상태 전류 크기를 사고 파형과 같게 하여도 그 크

기와 상관없이 고저항 고장을 검출하는 우수한 성능을 나타낸 것이다.



(a) 전압, 전류 파형



(b) 고장판단 출력


그림 7 자갈 모래 지락시 고장상의 (a) 전압, 전류 파형, (b) 고장판단 출력

Fig. 7 Fault phase when the grounded on gravel & sand (a) Voltage & Current waveform, (b) Output of a fault detector


이산 웨이브렛 변환을 이용한 경우와 FFT를 이용한 경우 모두 정확한 사고를 검출하고 있으나 FFT결과를 이용한 고장 판단의 경우 사고 전에 큰 진폭을 보이고 있으며, 웨이브렛을 변환을 사용한 경우가 진동 없이 더 정확한 검출을 하고 있다. 이 결과로 고장을 검출하는 요소가 전류의 크기가 아닌 전류 파형에 포함된 특징을 추출함을 알 수 있다. 또한 사고가 진행되는 동안에도 FFT를 사용한 경우는 출력의 진동이 심하지만 이산 웨이브렛 변환을 이용한 경우는 매우 안정적인 출력을 내고 있다.

순간적으로 정상적인 아크 부하전류가 흐르는 경우의 전류 파형을 전압 파형과 함께 그림 8(a)에 보였다.

아크부하가 연속적으로 계속 흐르지 않고 순간적으로 잠시 동안만 흐르는 경우로, 아크부하의 순간에는 미세한 출력 변동이 있으나 고저항 고장과는 명확하게 구별되는 특성을 나타내고 있다. 아크 부하 전류가 흐르고 있는 10 [cycle] 시점부터 18 [cycle] 시점까지의 구간에서 FFT를 이용한 결과 출력은 초기에 하반의 진동을 보이고 있으나 웨이브렛 변환을 이용한 경우는 정상전류로 판단하고 있음을 보이면서 계속해서 진동하는 모습을 보이고 있어서 아크성 부하 전류에도 아크성 고장전류에 포함된 특징이 어느 정도는 포함되어 있음을 알 수 있다.



(a) 전압, 전류 파형



(b) 고장판단 출력

그림 8 순간 아크 부하시 (a) 전압, 전류 파형, (b) 고장판단 출력

Fig. 8 Instantaneous welding arc load (a) Voltage and Current waveform, (b) Output of a fault detector

위와 같은 다양한 유형의 고저항 지락고장을 대상으로 FFT와 웨이브렛 변환을 적용해 고장검출을 시도하여 비교한 결과 비슷한 검출 성능을 보이고 있으나 웨이브렛 변환을 이용한 검출 방법이 더 빠르고 정확한 검출성능으로 나타나 신뢰도가 높은 것으로 평가된다.

6. 결 론

본 논문은 전력계통에서 발생하는 고장 중에서 선로의 전력선이 지표면이나 기타 시설물 등에 접촉하였을 때 발생하는 고저항 고장의 검출에 대하여 연구하였다.

고저항 고장 전류는 아크현상을 수반하고 이때 포함된 고주파 성분을 전압의 위상에 따라 추출하기 위하여 이산 웨이브렛 변환을 도입하여 적용하였다. 이산 웨이브렛 변환은 신호에 포함된 주파수 성분을 그 발생 시간에 대한 정보와 같이 얻어낼 수 있는 방법이며 푸리에 변환을 적용할 경우 데이터 윈도우를 전압의 위상에 따라 정확히 위치시켜야 하는 어려움이 있다.

고저항 고장 검출에 적합한 마더 웨이브렛을 선정하기 위해 전력계통 해석에 일반적으로 적용되는 Daubechies 웨이브렛, Symlets 웨이브렛등을 신경회로망에 학습시켜 학습오차를 최소로 하는 Daubechies 웨이브렛을 최적의 마더 웨이브렛으로 선정하였다.

신경 회로망의 학습 방법에는 역전파 알고리즘을 적용하였고, generalized delta rule 알고리즘으로 지역 최소치로 수렴하는 것을 방지하였으며, 다양한 형태의 고저항 고장에 대해

복잡한 수식적 해석이 없어도 검출이 가능하도록 하였다.

고저항 고장의 특징인 사고 후 지락전류의 증분이 없는 경우를 고려하여 정상상태 전류 크기를 고장 전류와 크기를 같게 하여 고장 검출을 시도하여 고장 전류의 크기와 상관없이 정확하게 판별하는 우수한 성능을 보였다. 고저항 고장 검출용 신경 회로망은 학습시키지 않은 새로운 유형의 고저항 고장도 정확도가 높게 검출했으며, 아크 고장 전류와 유사한 아크 부하 전류도 구분하여 검출함을 확인하였다.

본 논문에서는 한국 전력공사에서 실측한 고저항 고장 데이터를 적용함으로써 현장에 직접 실용화가 가능하고 검출 신뢰도를 높일 수 있었다. 향후, 여러 고장 조건에서 발생한다 더 많은 고장 데이터를 적용함으로써 고장 검출 성능을 향상시킬 수 있을 것으로 기대된다.

감사의 글

본 연구는 2001년도 광운대학교 연구지원에 의하여 이루어진 연구로서, 관계부처에 감사드립니다.

참 고 문 헌

- [1] B. Mike Aucoin and B. Don Russell, "Distribution High Impedance Fault Detection Utilizing High Frequency Current Components", IEEE Transactions on Power Apparatus and Systems, Vol. 101, No. 6, pp. 1596-1606, Jun. 1982
- [2] "High Impedance Fault Detection Using Third Harmonic Current", Electric Power Research Institute Report EL-2430, Prepared by Hughes Aircraft Co., Jun. 1982
- [3] B. Mike Aucoin and B. Don Russell, "Detection of Distribution High Impedance Faults Using Burst Noise Signals Near 60Hz", IEEE Transactions on Power Delivery, Vol. PWRD-2, No.2, pp.342-348, Apr. 1987
- [4] 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.
- [5] Kwon, W. H., Lee, G. W., Park, Y. M. " A Study for the improvement of the protection relay scheme on multi grounded distribution system", KEPCO Project Final Report, KRC-85A-JO5, 1987.
- [6] I. Daubechies, "Ten Lectures on Wavelet", SIAM, Philadelphia, Pennsylvania, 1992.
- [7] 도경훈, 현기호, 변영복, 조기윤, 하영호, "역전파 신경회로망을 이용한 고임피던스 고장 검출", 대한전기학회 논문지, 제43권, 11호, 1994. 11.
- [8] 남순일, 강용철, 김성수, 손진만, 박종근, 장성일, 김광호, 김일동, "Wavelet 변환을 이용한 배전 계통의 고저항 사고 검출 알고리즘", 대한전기학회 하계학술대회 논문집(C) pp.975-978 1997. 7.
- [9] 신정훈, 김태원, 박성택, "웨이브렛 변환을 이용한

전력계통의 고장검출”, 대한전기학회 전력계통연구회
춘계학술발표논문집 pp.61-63 1997. 5.

- [10] 임화영, 유창완, 고재호, “전력계통의 고임피던스 고장
검출 기법에 관한 연구”, 대한 전기학회논문지, 제48A권,
1호, pp.15-21 1999. 1.
- [11] 윤만철, 권옥현, “다중접지 배전선로 보호계전 방식

개선에 관한 연구”, 한국전력공사 기술 연구원
최종보고서, KRC-85A-505, 1987. 9.

- [12] 최인혁, 추진부, 백영기, 이종범, “직접 접지계통
송전선로 고저항 지락 보호대책 연구” 한국전력공사
전력 연구원 최종보고서, TR.95YJ25.97.57-1, 1997. 7.

저 자 소 개



홍대승 (洪大昇)

1969년 11월 20일 생. 1992년 광운대 공대
제어계측공학과 졸업. 1994년 동 대학원 제
어계측공학과 졸업(석사). 1994년~1997년
기아정보시스템. 현재 광운대 대학원 제어
계측공학과 박사과정 수료

Tel : 02-940-5152, Fax : 02-914-6039
E-mail : hongds@shinbiro.com



임화영 (任化永)

1946년 3월 18일 생. 1973년 한양대 공대
전기과 졸업. 1976년 동 대학원 전기공학과
졸업(석사). 1984년 동 대학원 전기공학과
졸업(공학박). 1982년~1988년 광운대 공대
전기공학과 교수. 현재 광운대 공대 제어계

측공학과 교수
Tel : 02-940-5152. Fax : 02-914-6039
E-mail : yimhy@daisy.kwangwoon.ac.kr



유창완 (柳昌完)

1969년 5월 12일 생. 1992년 광운대 공대
제어계측공학과 졸업. 1994년 동 대학원 제
어계측공학과 졸업(석사). 2000년 동 대학
원 제어계측공학과 졸업(공학박). 현재 (주)
마이크로페이스 연구소장.

Tel : 02-913-4406
E-mail : cwryu@mface.com