

Lifting을 이용한 고저항고장 검출에 관한 연구

홍대승*, 임화영*
*광운대학교 제어계측공학과

A Study on High Impedance Fault Detection using Lifting Scheme

Hong D-S*, Yim, H-Y*
*Kwangwoon Univ

Abstract - The research presented in this paper focuses on a method for the detection of High Impedance Fault(HIF). The method will use the Lifting 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 lifting scheme 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.

1. 서 론

전력계통에서 전력선이 지표면이나 나무 기타 시설물에 접촉되었을 때 아크를 수반하는 미소한 고장전류가 흐르게 되는데 이를 고저항 고장(High Impedance Fault: HIF)이라 한다. 고저항 고장 시 흐르는 전류는 접촉면의 다양한 형태와 조건에 따라 다른 특성을 지닌 아크성 전류가 되므로 전류의 크기에 따라 고장 검출을 하는 기존의 계전방식으로는 고장검출이 힘들다.

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

최근에는 국내외에서 웨이블릿 변환을 이용하여 고저항 고장을 검출하려는 연구도 있으나, 단지 고저항 고장에 적합한 마더 웨이블릿을 선정하여 계수 값들의 정량화 및 변화 수치만을 제시하는데 그치고 있다.

본 논문에서는 2세대 웨이블릿 변환인 리프팅 기법을 이용하여 고저항 고장을 정확하게 판별하고, 변환에 필요한 계산속도를 감소시키는 연구를 하였다.

이산 웨이블릿 변환과 리프팅 기법의 계산속도를 판별하기 위하여 우수한 고장 판별 특성을 보이는 Daubechies의 D4 마더 웨이블릿을 선정하여 [5] 이를 적용한 웨이블릿 변환으로 얻어진 결과의 계수 값들이 얻어지는 시간을 측정하였으며, 이 결과를 신경망에 입력하여 다양한 형태의 고저항 고장 검출을 시도하였다. 고저항 고장을 효과적 판별하고 정량적으로 나타내기 위해 신경 회로망을 도입하였으며 신경 회로망의 파라미터 학습에는 최급 강하법(Gradient Descent Method)을 이용하여 고저항 고장 검출 성능 및 정확도를 향상시켰

으며, FFT를 이용한 고저항 고장 검출법과 비교하였다. 한국전력공사에서 실측한 22.9Kv 배전선로의 고저항 고장 데이터와 일반 아크부하의 사고검출을 비교하여 이산 웨이블릿과 신경 회로망을 이용한 고저항 고장 검출의 성능 및 정확도를 높이고 활용할 수 있는 가능성을 연구하였다.

2. 본 론

2.1 Lifting

전력계통의 사고 시 발생하는 외란 및 고장파급현상을 방지하기 위해서 신속하고 신뢰성있는 보호대책이 계속적으로 연구되고 있으며 최근 전력계통의 비주기적인 과도현상을 분석하기 위한 새로운 방법으로서 웨이블릿 변환은 전력계통의 고장과 스위칭에 관한 과도현상을 분석하기 위한 방법으로 사용되었다. 이 방법은 비주기성이거나 wide-band 신호일 경우에는 푸리에 변환보다 훨씬 적절한 방법이며 주파수 영역에서 균일하지 않은 분석영역을 제공한다. 특히 HIF(High Impedance Fault)와 같은 비주기성 신호 분석시 푸리에 변환이 가지고 있는 단점을 극복하기 위해서 STFT(Shot Time Fourier Transform)이 제시되었다. 그러나 STFT는 신호를 일정한 해석 원도의 크기만큼 주기적으로 가정하는 고정 윈도우를 사용하기 때문에 빠른 과도파형과 정현파형이 동시에 존재하는 신호에 대해서는 적합한 분석 방법이 되지 못한다. 그러나 웨이블릿 변환은 고주파수는 짧은 윈도우, 저주파수는 긴 윈도우를 사용함으로써 기본파 및 저차 고조파와 과도파형을 모두 가지고 있는 신호의 분석에 적합하다. 따라서 저주파수 정보를 정확하게 원하는 곳에서는 긴 윈도우를 사용하고 고주파수 정보를 원하는 곳에서는 짧은 시구간을 사용하여 신호를 정확하게 해석한다.

본 논문에서는 실시간 사고 파형분석을 위해 변환에 필요한 계산속도 단축을 위해 2세대 웨이블릿인 리프팅을 적용하였다.

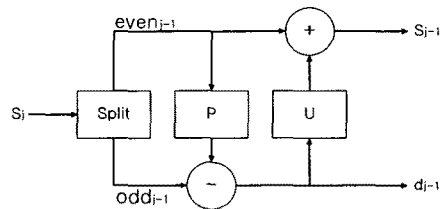


그림 1 Lifting Scheme, forward transform

그림 1은 Lifting 이론의 구조를 보이고 있다. 여기서 P는 선형 예측이며, U는 업데이트이다. 표 1에서 Daubechies D4 웨이블릿을 사용할 경우 최대 56%까지의 계산속도 향상으로 실시간 적용의 가능성을 더욱

높았다.

표 1 웨이블릿 변환과 리프팅의 계산속도 비교

Wavelet	Standard	Lifting	Speedup
Haar	3	3	0%
D4	14	9	56%
D6	22	14	57%

2.2 최적의 마더 웨이블릿 선정

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

표 2 파형 분석에 사용된 마더 웨이블릿의 종류

Mother Wavelet	Daubechies	Biorthogonal	Coiflets	Symlets
종류	1 2 4 6 8 10	1.1 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

2.3 신경회로망

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 웨이블릿을 이용한 고속 웨이블릿 변환을 level 5 까지 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 2는 본 논문에서 사용한 신경회로망의 구조를 나타냈다.

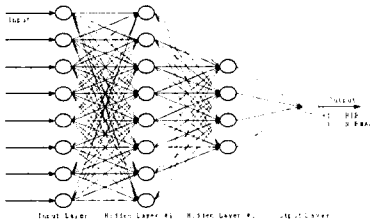


그림 2 고저항 고장검출을 위한 신경회로망

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 입력 값의 크기를 고려하여 초기화 하였으며, 가중치의 갱신은 지역 최저치(local minimum)에 수렴하는 현상을 방지하기 위하여 식 (2)와 같이 학습에 모멘텀 항을 추가하였다.

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

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

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

여기서 η 는 학습률이고, x_i 는 입력 값이며 a 는 모멘텀 계수이다.

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

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. 비학습된 고장 파형은 제시한 고장 검출법의 성능을 검증하기 위한 예비 데이터로 남겨 두었으며, 다른 고장 파형 및 부하 전류에 대해서도 동일한 방법으로 적용하였다. 표 3은 신경 회로망의 학습 및 검증에 사용된 파형을 정리한 것이다.

표 3 신경 회로망 학습에 사용된 데이터

	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 웨이블릿을 적용하여도 변환 level에 따라 학습 오차가 다르며, 동일한 level에서도 다른 종류의 마더 웨이블릿을 사용할 경우에도 많은 차이를 나타냈다.

그림 3은 입력층에 72개, 은닉층에 36개, 출력층에 5개의 가중치 파라미터를 갖는 신경회로망을 이용해 고장전류 및 아크 부하전류(표 2)를 입력시켜 정상일 때 출력이 -1, 고장일 때 +1이 되도록 학습 시켰다. 총 500회 동안 반복하여 학습시켰을 때의 학습오차와 최종 출력이다.

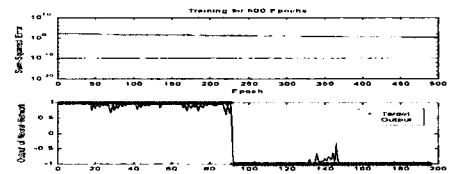


그림 3 신경 회로망의 학습 오차(위)와 최종 출력(아래)

2.4 적용사례

배전선로를 자갈과 모래가 혼재한 지면에 인위적으로 지락시켰을 때 실측한 고장전과 고장후의 전압 및 전류 파형을 그림 4에 나타냈다. 그림 6은 Lifting과 FFT 결과값을 이용한 고장판단 출력을 표현하였다.

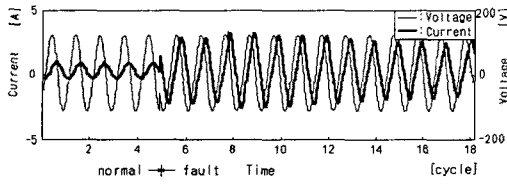


그림 4 자갈 모래 지락시 고장상의 전압, 전류 파형

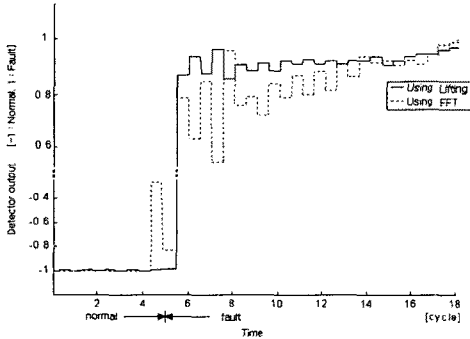


그림 5 자갈 모래 지락시 고장상의 고장 판단 출력

그림 4에서 실선으로 표시한 것은 전압이고 굵은 선은 전류 파형으로, PT와 CT 2차측의 크기로 표시했으며 주기당 64 샘플로 양자화 되었다.

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.

검출기의 결과 출력에서 Lifting을 사용한 고장판단 출력은 실선, FFT를 사용한 출력은 점선으로 나타냈으며 +1인 경우가 고장이며 -1인 경우가 정상상태이다.

두 경우 모두가 고장 발생 직후 정확하게 고장판단을 하고 있지만 웨이브렛 변환을 사용한 경우가 더 정확하게 고장을 검출하는 것을 볼 수 있으며, 특히 7[cycle] 시점에서 FFT 결과의 판단은 출력에 큰 변동을 보이며 정상상태에 가깝게 판단을 하고 있지만 웨이브렛의 경우는 정확히 고장임을 출력하고 있다.

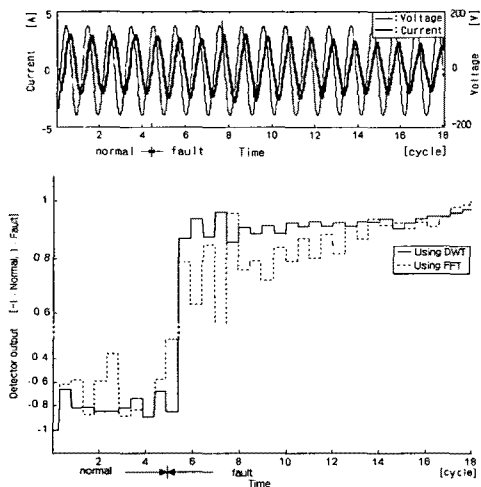


그림 5 자갈 모래 지락시 고장상의 전압, 전류 파형(위)과 고장판단 출력(아래)

그림 6은 그림 4의 자갈 모래 지락시의 전류를 대상으로 하여 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 리프팅 변화과 FFT 적용시 5 [cycle]에서 +1로 모두 사고검출을 하고 있으나, 웨이브렛 변환 적용시 더욱 정확하고 빠른 검출 성능을 보이고 있다.

이는 제안한 알고리즘이 고저항 고장 전류의 특성을 추출하여 정상상태 전류 크기를 사고 파형과 같게 하여도 그 크기와 상관없이 고저항 고장을 검출하는 우수한 성능을 나타낸 것이다.

3. 결 론

고저항 고장 전류는 아크현상을 수반하고 이때 포함된 고주파 성분을 전압의 위상에 따라 실시간으로 추출하기 위하여 리프팅 변환을 도입하여 계산속도를 증가시켰다.

고저항 고장 검출에 적합한 마더 웨이브렛을 선정하기 위해 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 현상이 직접 실용화가 가능하고 검출 신뢰도를 높일 수 있었다. 향후, 여러 고장 조건에서 발생한 더 많은 고장 데이터를 적용함으로써 고장 검출 성능을 향상시킬 수 있을 것으로 기대된다.

(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] 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
- [3] I. Daubechies, "Ten Lectures on Wavelet", SIAM, Philadelphia, Pennsylvania, 1992.
- [4] W.Sweldens, "The lifting scheme", Appl. Compt. Haon. Anal., 3(2):186-200, 1996
- [5] 홍대승, 유창완, 임화영, "웨이브렛 변환과 신경망 학습을 이용한 고저항 지락사고 검출에 관한 연구" 대한 전기학회논문지 제50A권 3호, pp.105-111, 2001.3