

신경회로망과 DWT를 이용한 고장표시기의 고장검출 개선에 관한 연구

홍 대승, 임 화영
광운대학교

A Study for the Improvement of Fault Detection on Fault Indicator using DWT and Neural Network

Dae-Seung Hong, Hwa-Young Yim
Kwang Woon University

Abstract - This paper presents research about improvement of fault detection algorithm in FRTU on the feeder of distribution system. FRTU(Feeder Remote Terminal Unit) is applied to fault detection schemes for phase fault, ground fault, and cold load pickup and Inrush restraint functions distinguish the fault current and the normal load current. FRTU is occurred FI(Fault Indicator) when current is over pick-up value also inrush current is occurred FRTU indicate FI. Discrete wavelet transform(DWT) analysis gives the frequency and time-scale information. The neural network system as a fault detector was trained to discriminate inrush current from the fault status by a gradient descent method. In this paper, fault detection is improved using voltage monitoring system with DWT and neural network. These data were measured in actual 22.9kV distribution system.

1. 서 론

도시화 과밀화에 따른 수요의 고밀도화가 도시기능의 고도화 및 다양화에 수반하여 전력공급 신뢰도 향상의 필요성은 나날이 고조되고 있다. 전력사업자들은 사고과급효과를 최소화하기 위해 배전계통을 다분할 다연계 구조로 설계, 운영하고 있으며, 배전자동화 시스템을 도입하여 전력공급 신뢰도를 크게 개선하고 있다[1-3]. FRTU(Feeder Remote Terminal Unit)는 배전선로용 개폐기와 함께 배전선로에 설치되어 상시 배전선로의 전압, 전류, 개폐기의 상태를 감시하고, 선로 사고발생시 사고에 대한 정보를 주장치로 전송하여 고장점을 판단한 후, 주장치로부터의 제어명령을 통해 배전선로의 고장구간을 최소화하기 위한 설비이다.[4] 현재 사용중인 FRTU의 고장표시 알고리즘으로는 고장발생시 개폐기의 재폐로 상태에 따라서 유도 및 용량부하 특성으로 발생되는 과도전류가 고장표시기의 고장설정(Pick up)값 이상으로 흐르면 고장전류가 발생하지 않아도 선로상태를 고장으로 표시하는 오동작이 발생할 수 있다. 또한 고장표시기 알고리즘에는 사고를 경험하지 않고 사선상태에서 환선상태로 계통의 변화가 발생하면 돌입전류에 대비하여 2초간 돌입전류가 흘러도 고장표시를 하지 않도록 설정되어 있다. 만약 돌입억제시간에 고장전류가 발생하여도 고장발생(FI)을 하지 못하여 큰 사고로 발전할 수도 있는 단점이 있다.

본 논문에서는 주파수에 대한 정보 및 시간 정보(time-scale)가 제공되어 과도신호가 존재하는 신호해석에 적합하고, 배전계통의 고장과 돌입파형의 정확한 해석 및 검출방법으로 더욱 효과적으로 적용할 수 있는 이산 웨이블릿 변환(Discrete Wavelet Transform)을 이용하여 고장전류 파형과 돌입전류 파형에 대한 각각의 특성을 추출하였다.[5] 이산 웨이블릿 변환 결과를 신경회

로망에 입력하여 돌입 및 고장을 대상으로 학습시켜 고장전류파형을 최대한 정확하게 판별하여 신뢰도를 향상시켰다.[6-7] 기존에 고장표시기에 적용된 고장검출 알고리즘에 새로운 알고리즘인 전압감시시스템과 이산 웨이블릿변환기법 그리고 신경회로망을 이용한 고장검출기법을 접목시켜 배전계통의 고장 검출 성능을 향상시켰다.

2. 고장표시기

FRTU의 고장표시기는 고장발생을 위한 FRTU의 픽업전류(상, 지락)를 부하에 맞게 설정하여 주어야 한다. 현장에서는 일반적으로 상간 고장전류 설정값은 400A, 지락전류 설정값은 60A로 운용되고 있다. 또한 돌입전류에 관련된 돌입억제 시간도 설정된 2초로 적용 운영되고 있어서 돌입억제 시간인 2초내에 사고전류가 흘러도 현재의 FI 알고리즘으로는 고장검출이 불가능한 실정이다. 또한 개폐기의 재폐로시 용량 및 유도부하에 관련된 돌입전류의 크기가 설정(pickup)값보다 크면 고장검출 알고리즘은 고장으로 오판하는 실정이다.

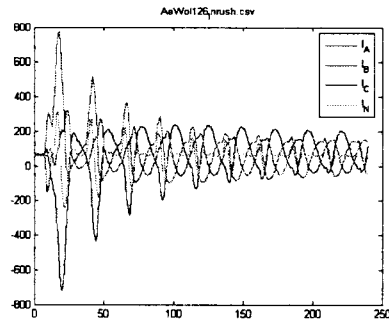


그림 1. 제주/애월126 돌입전류파형

그림 1은 2005년에 저장된 “제주지사/애월126”의 A, B, C, N상의 돌입전류파형이다. 전형적인 돌입파형으로서 과도현상이 점차 줄어드는 경우를 보이고 있다.

3. 이산 웨이블릿 변환

전력계통의 사고 시 발생하는 비 주기적인 과도현상에 대하여 이를 분석하고 검출하기 위한 새로운 방법으로 웨이블릿 변환 기법을 이용한 방법들이 제시되고 있다. 웨이블릿 변환은 전력계통의 고장과 스위칭에 관련된 과도현상을 분석하기 위한 방법으로서 비 주기성이거나 순간적으로 존재하는 과도신호등에 대해서는 주파수와 시간에 대한 정보를 제공함으로써 과도 신호 검출이나 사

고 파형 검출에 더 효과적으로 적용할 수 있다. 특히 과도현상을 포함한 돌입전류의 경우 그 사고 전류의 크기가 일반적으로 작고 매우 불규칙하게 나타나기 때문에 이러한 특징을 가진 웨이블릿 변환을 사용하여 보다 더 정확한 사고 검출을 할 수 있다. 푸리에 변환의 경우는 신호를 일정한 해석 윈도우의 크기만큼 주기적으로 가정된 고정 윈도우를 사용하기 때문에 빠른 과도 파형과 정현 파형이 동시에 존재하는 신호에 대해서는 적합한 분석방법이 되지 못한다. 그러나 웨이블릿 변환은 고주파수는 짧은 윈도우, 저주파수는 긴 윈도우를 사용함으로써 기본파 및 저차 고조파와 과도 파형을 모두 가지고 있는 신호의 분석에 적합하다. 따라서 저주파수 정보를 정확하게 원하는 곳에서는 긴 윈도우를 사용하고 고주파수 정보를 원하는 곳에서는 짧은 시구간 윈도우를 이용하여 신호를 해석할 수 있다. 배전계통에서 계측된 전압 및 전류파형은 10주기 240 샘플을 가진 이산 데이터이다. 이산 데이터에 대하여 웨이블릿 변환을 적용하려면 이산 웨이블릿 변환을 이용하여야 한다. 이산웨이블릿은 식 1과 같이 표현된다.

$$W(j, K) = \sum_j \sum_K x(k) 2^{-j/2} \phi(2^{-j}n - k) \quad (1)$$

여기서 $\phi(t)$ 마더 웨이블릿이다. 이산웨이블릿은 다중 필터뱅크에 관련된 피라미드 알고리즘을 적용하여 빠른 계산이 가능하다. 이산 웨이블릿 변환은 신호를 고주파 요소와 저주파요소로 식 (2), (3)와 같이 분해할 수 있다.

$$y_{high}[K] = \sum_n x[n]g[2k - n] \quad (2)$$

$$y_{low}[K] = \sum_n x[n]h[2k - n] \quad (3)$$

여기서 $y_{high}[k]$ 는 고주파수 필터(g)의 출력이며, $y_{low}[k]$ 는 저주파수 필터(h)의 출력이다. 본 논문에서는 $y_{low}[k]$ 의 특징을 이용하여 고장검출에 관한 특징분류에 적용하였다.

3.1 최적의 마더 웨이블릿 선정

배전계통에서 발생되는 고장전류 신호의 특성을 최적화하는 방법은 고장상태와 돌입상태의 웨이블릿 계수 값 즉 마더 웨이블릿과의 유사성이 가장 큰 것을 선정하는 것이다. 돌입전류에 발생하는 과도현상과 가장 유사한 형태의 마더 웨이블릿을 선택하여 이산 웨이블릿 변환한 결과 계수 값이 커지므로 고장과 돌입판별을 위한 명확한 기준으로서 사용될 수 있다. 그러므로 마더 웨이블릿의 정확한 선택은 고장과 돌입파형 분석 시 매우 중요한 부분을 차지한다. 최적의 마더 웨이블릿을 선정하기 위해 본 논문에서는 표 1의 각 마더 웨이블릿을 이용하여 이산 웨이블릿 변환의 분해과정을 1 level에서 3 level까지 정하여 이산 웨이블릿 변환 결과를 신경 회로망에 학습시켰다. 이때 신경 회로망의 학습에 대한 목표치와 출력치의 오차율을 비교하여 그 오차를 최소로 하는 최적의 마더 웨이블릿을 선정하였다.

표 1. 파형 분석에 사용된 마더 웨이블릿의 종류

Mother Wavelet	db					bior			
	1	2	4	6	10	1.1	2.2	3.1	4.4
종류	1	2	4	6	10	1.1	2.2	3.1	4.4
Level	1-3 level					1-3 level			

표 1의 각 마더 웨이블릿을 이용하여 학습대상 전류 파

형을 1 level에서 3 level까지의 각 level에 대하여 웨이블릿 변환하여 이를 돌입 전류 파형 데이터와 고장전류 데이터를 대상으로 신경 회로망에 학습시킨 후 각 마더 웨이블릿에 대하여 최소의 학습오차를 나타내는 level과 그 오차의 크기를 계산하여 오차가 가장 적은 마더 웨이블릿을 고장전류 검출에 적용하였다.

4. 신경 회로망(Neural Network)

신경 회로망은 물리적 신경망을 모델로 비선형적인 문제를 풀기 위해 제안된 방법 중에 하나이다. 신경 회로망은 그 구조가 간단하고 비선형적인 특성이 우수하며 학습 능력을 가지고 있어서 다양한 비선형 최적화 문제에 적용되고 있으며, 한번 학습된 신경 회로망은 계산량이 적어 실시간적인 처리가 가능하다. 본 논문에서 구성된 고장 검출용 신경 회로망은 전류를 웨이블릿 변환한 계수를 입력요소를 갖고 2개의 은닉층과 1개의 출력층으로 구성하였다. 신경 회로망의 출력 활성화함수는 비선형이며 ± 1 의 값을 갖는 hyperbolic tangent function을 이용하였으며 다음 식 4와 같다.

$$f(x) = \tanh(x/2) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (4)$$

초기의 신경 회로망의 각 노드간의 연결강도인 가중치는 초기에 입력값의 크기들을 고려한 임의로 값으로 설정하였으며 최종 출력 오차를 이용한 가중치의 갱신은 식 6와 같은 방법을 사용하였으며 학습률과 모멘텀항을 추가하여 학습효율을 높이도록 하였다.

$$W(k+1) = W(k) + \Delta w(k+1) \quad (5)$$

$$\Delta w = -\eta \frac{\partial E}{\partial w} x_i, \quad \eta > 0 \quad (6)$$

여기서 η 는 학습률이고, x_i 는 입력 값이다. 오차 역전파 학습 알고리즘의 경우 입력 패턴이 복잡한 경우 지역 최소값으로 수렴하여 학습이 더 이상 진행되지 않는 경우가 발생할 수 있으므로 이러한 문제를 해결하기 위해서 Jacobs에 의해 변동 학습률을 적용한 delta-bar-delta 알고리즘을 적용하였다. 이 알고리즘의 특징은 현재와 과거의 오차의 경사 값을 이용하여 학습률을 적응적으로 변화시킨다는 것으로 오차의 경사 값을 이용하여 변동 학습률을 적용하였으며 학습률 η 는 식 7과 같이 정의하였다.

$$\eta(k+1) = \begin{cases} 1.02\eta(k) & \nabla E(k) > 1.02\nabla E(k-1) \\ 0.6\eta(k) & \nabla E(k) < \nabla E(k-1) \\ \eta(k) & \text{그 외의 경우} \end{cases} \quad (7)$$

구성된 신경 회로망은 입력층 1개와 은닉층 2개를 가지며 이를 주어진 학습대상 고장전류와 돌입전류 파형을 대상으로 고장일때 출력이 -1, 돌입일 때 출력이 +1이 되도록 학습시켰으며 총 30000회 동안 패턴 반복으로 학습하여 최적화된 가중치와 바이어스를 저장하여 고장 검출시 사용하였다. 그림 2는 학습결과를 보이고 있다.




그림 2. 신경망 학습 오차와 학습된 계수들

5. 고장검출 알고리즘

본 논문에서는 돌입억제 시간에서 발생할 수 있는 고장과 돌입전류의 크기에 의한 고장검출 오차를 줄이고자 새로운 고장검출 알고리즘을 제안하였다. 새로운 고장검출 알고리즘은 3상 전압파형을 감시하여 전압의 크기가 감소하거나 위상의 변화가 발생하였을 때 고장상의 전류 크기값을 고장검출 설정값과 비교하여 설정값이상이면 고장표시기에 고장을 발생시키고, 만약 전압은 정상이라도 전류의 크기를 검토하고, 이산 웨이블릿 변환결과와 신경망 고장판단 결과를 이용하여 고장파형과 돌입파형의 패턴을 분리한다. 전압상태가 정상일 때 발생할 수 있는 N상의 고장전류 및 돌입전류를 검출할 수 있는 능력을 높일 수 있는 장점이 있다.

그림 3은 고장전압, 고장전류, 고장전류의 이산웨이블릿 변환과 신경망을 이용한 종합적인 고장 및 돌입파형 검출 알고리즘을 순서도로 표시하였다.

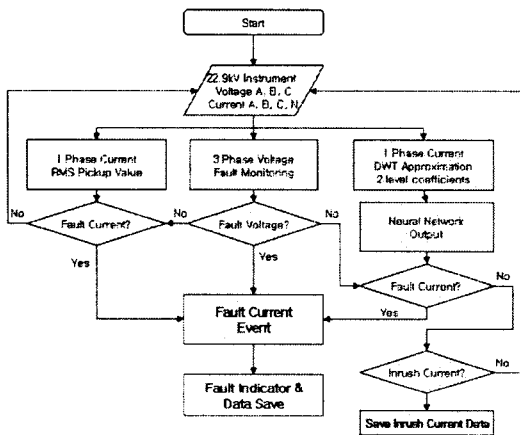


그림 3 제안된 고장검출 알고리즘의 순서도

6. 시뮬레이션 및 결과고찰

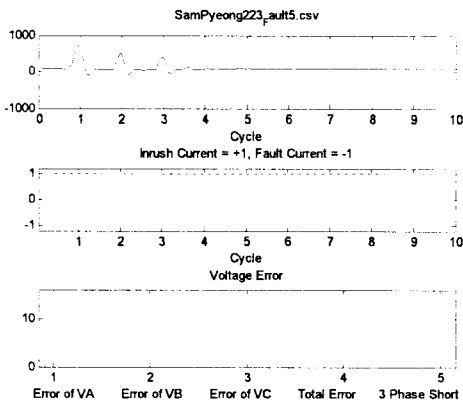


그림 4 삼평223 사고 5는 고장전류 고장판단

그림 4은 삼평223 사고 5는 고장이력에는 N상 고장으로 저장되어 있으나 학습된 신경망 출력으로 +1 값을 가지므로 돌입전류이며, 전압감시 오차에 대한 결과도 정상(0)이므로 돌입파형을 고장으로 잘못 저장한 경우이다.

이러한 돌입파형을 기존의 FI 알고리즘에서는 고장으로 전류의 크기만을 이용하여 잘못된 판단을 하였으나, 본 연구에서는 개선된 효과를 보이고 있다.

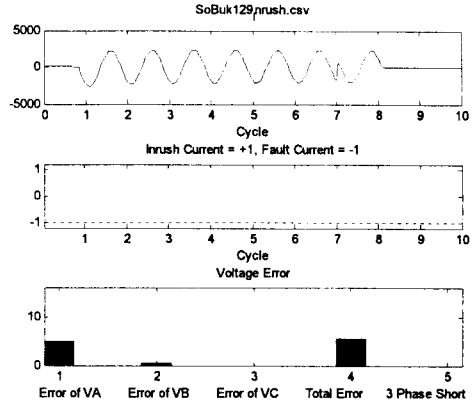


그림 5 서북129 돌입파형 A상전류 고장판단

그림 5은 서북129 돌입파형은 고장이력상 돌입파형으로 저장되어 있다. 그러나 A상 전류에 대한 고장판단한 결과 신경망 출력의 경우 -1로 고장파형으로 판단되었고, 전압감시 또한 A상 전압이 이상(5)으로 나타났다. 종합적인 결과 돌입파형이 아닌 고장파형으로 판단되었다. 이 경우에는 돌입억제 기간(2초)에 저장된 파형으로써 고장파형이 돌입억제 기간에 발생되어 위험한 사고로 발전될 가능성이 있다. 이러한 개선된 효과를 이용하여 계통의 신뢰도를 향상시킬 수 있다.

[참 고 문 헌]

- [1] Castro, C. H., J. B. Bunch, and T. M. Topka, "General Algorithms for Distribution Feeder Deployment and Sectionalizing," IEEE Trans. on Power Apparatus and Systems, Vol. P AS-99, No. pp.549-557 March/April 1980.
- [2] 고윤석, 홍대승, 송완석, 박학열. "멀티에이전트 개념에 기반한 배전시스템의 분산 자율적 고장구간 분리기법" 대한전기학회논문지 제55A권 6호, pp.227-235 2006. 6.
- [3] J. J. Rico, E. Acha., M. Madrigal. "The Study of Inrush Current Phenomenon Using Operational Matrices" IEEE Trans. on Power Delivery, Vol. 16, No.2, April, 2001
- [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] I. Daubechies, "Ten Lectures on Wavelet", SIAM, Philadelphia, Pennsylvania, 1992.
- [6] Martin T. Haugan "Neural Network Design" PWS Publishing Company, 1996
- [7] 홍대승, 유창완, 임화영. "웨이블릿 변환과 신경망 학습을 이용한 고저항 지락사고 검출에 관한 연구" 대한 전기학회논문지 제50A권 3호, pp.105-111 2001.3