

# 이산 웨이블릿 변환과 신경회로망을 이용한 FRTU의 고장판단 능력 개선에 관한 연구

論 文
56-7-2

## A Study for the Improvement of the Fault Decision Capability of FRTU using Discrete Wavelet Transform and Neural Network

洪大昇<sup>†</sup> · 高銳錫<sup>\*</sup> · 姜泰求<sup>\*\*</sup> · 朴學烈<sup>\*\*\*</sup> · 任化永<sup>§</sup>  
(Dae-Seung Hong · Yoon-Seok Ko · Tae-Ku Kang · Hak-Yeol Park · Hwa-Young Yim)

**Abstract** - This paper proposes the improved fault decision algorithm using DWT(Discrete Wavelet Transform) and ANNs for the FRTU(Feeder Remote Terminal Unit) on the feeder in the power distribution system. Generally, the FRTU has the fault decision scheme detecting the phase fault, the ground fault. Especially FRTU has the function for 2000ms. This function doesn't operate FI(Fault Indicator) for the Inrush current generated in switching time. But it has a defect making it impossible for the FI to be operated from the real fault current in inrush restraint time. In such a case, we can not find the fault zone from FI information. Accordingly, the improved fault recognition algorithm is needed to solve this problem. The DWT analysis gives the frequency and time-scale information. The neural network system as a fault recognition was trained to distinguish the inrush current from the fault status by a gradient descent method. In this paper, fault recognition algorithm is improved by using voltage monitoring system, DWT and neural network. All of the data were measured in actual 22.9kV power distribution system.

**Key Words** : FRTU(Feeder Remote Terminal Unit), Discrete Wavelet Transform, Neural network, Fault Indicator, Inrush current

### 1. 서 론

도시기능이 고도화되고 다양화됨에 따라 전력공급 신뢰도의 요구수준이 점점 높아지고 있다. 정전시간의 단축과 정전구간의 최소화, 사고파급방지 등의 중요한 문제들을 해결하기 위하여 전력사업자들은 배전계통을 다분할 다연계 구조로 설계, 운영하고 적극적으로 배전자동화 시스템을 적용하여 사용하고 있다. 배전자동화 시스템은 컴퓨터와 통신기술을 활용하여 원거리에 산재되어 있는 배전선로 운전용 단말장치(FRTU)를 사검소 배전사령실에서 감시제어 및 원격으로 설정할 수 있는 시스템이다. 그 기능은 전류, 전압 등 선로운전 정보를 실시간으로 계속 수집하고 고장시 자동으로 정전구간을 확인함으로써 원격제어를 통해 정전구간의 축소와 정전시간을 단축시키는 시스템이다.[1-3].

FRTU(Feeder Remote Terminal Unit)는 배전자동화 시스템에서 배전선로 자동화용 개폐기와 함께 선로에 설치되어 배전선로의 전압, 전류, 개폐기의 상태를 상시 감시하며, 선로의 고장전류를 경험하면 FI(Fault Indicator)가 동작되어 사고에 대한 정보를 주 장치로 전송하는 장치이다[4]. 그러나 현재 운용중인 FRTU는 고장선로의 고장을 처리하고 전

원을 투입하면 발생할 수 있는 돌입전류를 대비하기 위해 돌입억제시간(Inrush Time, 0.1~3s, Default 2s)을 설정하여 운영하고 있다. 만약 돌입억제시간에 고장전류가 발생하더라도 현 고장검출 알고리즘에서는 고장인식을 할 수 없는 단점이 있다. 따라서 배전계통의 고장검출 신뢰도를 향상 위하여 FRTU가 좀더 정확한 고장검출 및 돌입대비 기능이 요구되고 있다.

고장전류를 이용하여 고장을 판단하기 위한 기존의 연구에는 고조파 신호의 증가를 검출해 내는 방법, 3조파, 5조파, 7조파 성분의 증가를 검출해 내는 방법, 고장 전류를 FFT(Fast Fourier Transform)을 통해 얻어진 고조파를 이용하여 사고를 판단하는 방법에 관한 연구들이 있으나, 푸리에 변환을 이용한 신호해석 방법의 경우는 신호를 일정한 해석 윈도우의 크기만큼 주기적으로 가정된 고정 윈도우를 사용하기 때문에 돌입전류파형과 고장전류파형의 신호에 대하여 주파수에 대한 정보는 존재하지만 시간에 대한 정보를 얻을 수 없기 때문에 정확한 고장판단이 어려운 단점이 있다[11, 12]. 그러나 이산 웨이블릿변환(Discrete Wavelet Transform)은 주파수에 대한 정보 및 시간과 크기에 관한 정보가 동시에 제공되어 과도신호가 존재하는 신호해석에 적합하며 배전계통에서 고장전류파형의 정확한 해석 및 효과적인 고장판단방법으로 적용할 수 있다[5, 7]. DWT를 이용한 고장전류파형의 해석방법에서 분해 레벨(Decomposition level)에 따라서 입력 샘플개수는 감소하며 파형의 형태는 유지되는 특징이 있다. 또한 파형의 고장전류패턴을 신경회로망의 초기입력으로 설정하여 학습한 후 학습된 가중치와 바이어스를 이용하여 고장을 판단하는 연구도 많이 진행되고 있다[6-7].

† 교신저자, 正會員 : 남서울大學 電子工學科 兼任教授  
E-mail : hong\_ds@hanmail.net

\* 正會員 : 남서울大學 電子工學科 副教授 · 工博

\*\* 正會員 : 韓電KDN(주) 배전IT그룹장

\*\*\* 正會員 : 韓電KDN(주) 배전IT그룹 先任研究員

§ 正會員 : 光云大學 制御計測工學科 教授 · 工博

接受日字 : 2007年 4月 13日

最終完了 : 2007年 6月 7日

본 논문에서는 돌입전류파형을 억제하는 돌입대비시간동안 고장전류가 흘러도 고장을 인식할 수 있도록 하고 만약 돌입전류파형이 흘러도 FI를 동작시키지 않는 알고리즘을 제안한다. 제안된 알고리즘에서는 실측된 고장전류파형과 돌입전류파형에 대한 대표적인 패턴을 분류한다. 그 대표패턴들의 128샘플을 이산 웨이블릿 변환한다. 변환 후 파형의 특징은 유지되며 샘플개수는 줄어든 계수들을 신경회로망에 입력하여 돌입전류 및 고장전류로 분류할 수 있도록 최급강화법을 이용하여 학습한다. 고장인식의 정확도를 높이기 위해 출력오차가 작아지도록 학습된 가중치와 바이어스를 이용하여 고장인식의 정확도를 높인다. 종합적인 고장판단 알고리즘을 구성하면 배전계통의 3상 전압을 항시 감시하다가 전압의 불평형 및 크기가 감소하면 이상이 있는 상 정보를 고장판단 알고리즘에 전달하고 이산웨이블릿 변환과 신경회로망을 이용한 고장인식 알고리즘을 동시에 적용하여 고장판단의 정확도를 높일 수 있다. 본 논문에서 사용되는 데이터는 한국전력공사 배전계통에 설치된 FRTU에서 측정 및 저장된 실측 고장 및 돌입전류데이터이며, 계측된 데이터로부터 돌입 및 고장전류파형에 대한 분류는 현장 전문가와 고장관리 담당자들과 전문성을 토대로 판별하였다.

2. 고장표시기(Fault Indicator) 운영 알고리즘

현재 FRTU에서 운용중인 고장검출 알고리즘은 각 상의 전류 RMS 값을 감시하다가 설정값 이상의 전류가 흐르고, 보호기기가 동작하여 사선상태이면 고장을 발생시키는 보호기기에 의존적인 단순한 구조이다. 따라서 정상상태에서 발생될 수 있는 과도현상으로 돌입전류가 발생하고 그 크기가 설정값 이상이며 보호기기가 동작하면 FI를 동작시킬 수 있는 문제점이 있다. 또한 보호기기 동작에 의존적인 고장인식 알고리즘이기 때문에 정상상태(활선, 전류가 설정치 미만)로 운전 중에 고장전류를 경험하였다 하더라도 일정시간 동안 무전압(사선)이 되지 않은 경우(보호기기가 동작하지 않는 경우)에는 고장으로 판단하지 않는다. 다른 문제점은 FRTU는 Sequence 진행시 최초 고장경험한 상에 대해서는 돌입대비를 하지 않고, 고장경험하지 않은 상에 대해서는 돌입대비(돌입대비시간이 2초로 운영됨) 하기 때문에 최초 A상 고장에서 A, B상 선간단락으로 진전될 경우 B상에 대해서는 FI가 동작되지 않을 수 있다.

일반적으로 FI를 동작시키는 고장판단을 위한 기준이 표 1과 같이 기본값으로 설정될 경우 설정값보다 큰 전류가 흐르면 고장으로 판단하여 FI를 동작시키거나 해당 선로에 전원이 투입되면 처음 2000ms동안 돌입전류나 고장전류에 관계없이 FI를 발생시키지 않는다.

표 1 FRTU 선로운전 정보 예  
Table 1 Example of line information for FRTU

선로운전정보				
내용	Pick Up Current (Phase)	Pick Up Current (Ground)	Inrush Time (Phase)	Inrush Time (Ground)
설정값	120A~840A	30A~420A	100ms~3000ms	100ms~3000ms
기본값	400A	60A	2000ms	2000ms

표 1은 FRTU 운영프로그램에서 선로운전정보의 기본값은 초기 설정값이다. 고장발생을 위한 FRTU의 픽업전류(상, 지락)를 부하전류에 적합하게 설정하여 주어야 하나, 일반적으로 FRTU 공장출하시 설정된 상 돌입대비 시간(Inrush Time (Phase))과 지락 돌입대비 시간(Inrush Time(Ground))의 초기값은 2000ms로 설정을 바꾸지 않고 운영하는 경우가 많다. 또한 현재의 배전선로의 정격부하가 400A 정도이기 때문에 일반적으로 상간 고장전류 설정치(Pick Up Current (Phase))은 400A, 지락전류 설정치(Pick up Current(Ground))는 60A로서 거의 모든 FRTU에서 설정치를 해당 선로의 부하에 적합하게 변경하지 않고 사용하는 곳이 많다. 만약 돌입억제 시간인 2초동안에 사선에서 활선상태로 변화시 고장전류가 발생하여도 현재의 FI 알고리즘으로는 정상적인 고장인식이 불가능하다. 또한 부하단의 개폐기류 투입 용량 및 유도부하에 관련된 과도현상을 가진 돌입전류의 크기가 설정(pickup)값보다 크고 보호기기가 동작한다면 고장인식 알고리즘은 고장으로 오판하여 고장을 표시한다.

표 2 조사된 일부 FRTU의 고장이력  
Table 2 fault record for a part of FRTU


순서	발생시간	구분	고장구분	고장발생상	A상 전류	B상 전류	C상 전류	N상 전류
1	2005/12/21 21:11:30:825	2/2	일시(P)	---N	124	53	55	78
2	2005/12/21 21:11:10:855	2	고장(F)	---N	124	53	55	78
3	2005/12/21 21:10:55:495	1	고장(F)	---N	84	21	64	79
4	2005/12/13 11:33:54:185	1/1	순간(T)	A--N	1476	219	115	1530
5	2005/12/13 11:33:50:290	1	고장(F)	A--N	1476	219	115	1530
6	2005/12/12 21:08:01:395	1/1	순간(T)	A--N	1522	214	115	1570
7	2005/12/12 21:07:57:510	1	고장(F)	A--N	1522	214	115	1570

표 2는 조사된 일부 FRTU 이력에 저장된 2005년 12월 12일부터 2005년 12월 21까지의 고장관련정보를 보이고 있다. 고장이력에 저장되는 데이터는 고장발생시간, 고장구분, 고장발생상, 그리고 고장발생시 각상의 전류값으로 구성되어 있다. 현 고장검출 알고리즘은 전류의 크기 요소와 활선/사선 정보만을 이용하므로 돌입전류 및 고장전류파형에 대한 정확한 판단을 하기 어려운 실정이다.

FRTU에 저장되는 하나의 고장파형은 1 주기에 24샘플링하여 10주기를 저장한다. 저장형태는 사고전류파형에서 사고전의 1주기(24샘플)와 사고지속 6주기(144샘플)까지 저장 후 사고에서 정상으로 복귀되는 2주기(48샘플)과 정상파형 1주기(24샘플)를 저장하는 구조로 구성되어 있다.

그림 1(a)는 2005년에 저장된 "FRTU A의 돌입파형"이다. 각 A, B, C, N상이 돌입전류가 발생하여 과도현상의 크기가 점차 줄어드는 전형적인 형태이다. 돌입전류파형이 점차 안정화되어 가는 형태이나 현 파형 저장 알고리즘으로는 10주기만 저장되어 안정화된 구간을 정확하게 알기 어려운

형태이다. 그림 1(b)는 리크로저 재폐로시 발생된 현상으로 "FRTU B 사고전류"의 A, B, C, N상이 돌입전류파형과 고장전류파형이 혼합된 경우이다. 1주기 무전류 상태에서 약 30샘플에서 투입 후의 돌입전류파형과 고장전류파형이 발생하여 6주기동안 고장이 진행된 파형을 보이고 있다.



(a) FRTU A inrush current (b) FRTU B fault current

그림 1 FRTU에 저장된 전류파형

Fig. 1 Currents waves saved FRTU

본 논문에서는 전국에 운영중인 일부 FRTU에서 2005년에 취득된 돌입파형 데이터 46개와 고장파형 데이터 161개를 대상으로 전압파형, 전류파형 및 고장이력에 대하여 분석한 결과 고장이력저장정보와 파형분석정보간에 차이점을 발견하였다. 돌입전류파형의 경우 고장전류파형이 저장된 것이 16기 데이터, 고장전류의 경우에 돌입전류파형이 저장된 경우 7-33개의 데이터로 현재 알고리즘으로 저장된 데이터에 대한 오류가 발견되었다. 본 논문에서는 FRTU에 저장된 실측데이터를 대상으로 발생한 고장오차를 줄이고 배전계통의 신뢰도를 향상시키고자 전류의 크기, 고장패턴, 전압의 크기요소를 이용하여 배전계통의 고장검출 능력을 향상시킬 수 있도록 연구하였다.

### 3. 웨이블릿 변환(Wavelet Transforms)

웨이블릿 변환은 전력계통의 고장과 스위칭에 관련된 과도현상을 분석하기 위한 방법으로서 비 주기성이거나 순간적으로 존재하는 과도신호등에 대해서는 주파수와 시간에 대한 정보를 제공함으로써 과도 신호 검출이나 사고 파형 검출에 더 효과적으로 적용할 수 있다. 특히, 실측된 고장전류파형과 돌입전류파형을 연구한 결과, 과도현상을 포함한 돌입전류의 경우 전류의 크기가 고장전류의 크기보다 작고 매우 불규칙하게 나타나는 특징을 이산 웨이블릿 변환을 사용하면 정확한 고장 판단을 할 수 있는 특징이 있다. 푸리에 변환의 경우는 신호를 일정한 해석 원도의 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 기본 파 및 저차 고조파와 과도 파형을 모두 가지고 있는 신호의 분석에 적합하다. 연속 웨이블릿 변환,  $\omega_{a,b}$ 는 식 (1)과 같이 표현된다.

$$\omega_{a,b}(t) = \int_{-\infty}^{\infty} s(t) \cdot \psi_{a,b}(t) dt \quad (1)$$

여기서  $s(t)$ 는 원 신호이며 변환함수  $\psi_{a,b}(t)$ 는 마더 웨이블릿(mother wavelet)을 나타낸다. 마더 웨이블릿은 유한한 값을 가지며 평균값이 0이고 양쪽 끝에서 급격히 감쇄하는 형태의 신호를 설정하여 이 변환신호로부터 원 신호를 변환하게 된다. 마더 웨이블릿은 식 (2)와 같이 나타낼 수 있다.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2)$$

이러한 마더 웨이블릿은 그 형태와 특성에 따라 Haar 웨이블릿(Haar), Daubechies 웨이블릿(db), Biorthogonal 웨이블릿(bior), Coiflets 웨이블릿(coif), Symlets 웨이블릿(sym) 등 여러 가지 형태로 구분되어 진다. 웨이블릿 변환의 수행 결과인 계수 값  $\omega_{a,b}(t)$ 는 원 신호의 한 부분과 마더 웨이블릿의 유사성을 나타내며  $a$ 는 크기요소로 마더 웨이블릿을 팽창시키거나 압축시키며,  $b$ 는 지연요소로 마더 웨이블릿을  $b$ 만큼 시간을 지연시키는데 이  $a, b$  값을 변화시키면서  $\omega_{a,b}(t)$ 를 계산한다.

#### 3-1. 이산 웨이블릿 변환(Discrete Wavelet Transforms)

배전계통에서 실측된 A, B, C상 전압 및 A, B, C, N상 전류는 각각 10주기 240개의 이산샘플로 저장된 데이터이다. 이러한 이산 데이터는 이산 웨이블릿 변환을 이용하여 파형의 특성을 추출할 수 있다. 이산웨이블릿은 식 (3)과 같이 표현된다.

$$W(j, K) = \sum_j \sum_K x(k) 2^{-j/2} \phi(2^{-2}n - k) \quad (3)$$

여기서  $\phi(t)$ 는 마더 웨이블릿이다. 이산웨이블릿은 다중 필터뱅크에 관련된 피라미드 알고리즘을 적용하여 빠른 계산이 가능하다. 이산 웨이블릿 변환은 신호를 고주파요소와 저주파요소로 식 (4), (5)와 같이 분해할 수 있다.

$$y_{high}[K] = \sum_n x[n]g[2k - n] \quad (4)$$

$$y_{low}[K] = \sum_n x[n]h[2k - n] \quad (5)$$

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 가지고 있는 3 level 근사계수를 신경회로망을 이용한 고장검출에서 패턴특징 분류 및 분석에 적용하기 위하여 입력으로 선정하였다.

#### 3-2. 고장인식에 적합한 마더 웨이블릿 선정

돌입전류에 발생하는 과도현상과 가장 유사한 형태의 마더 웨이블릿을 선택하여 DWT한 결과 계수 값이 커지므로 고장과 돌입관별을 위한 명확한 기준으로 사용될 수 있다. 그러므로 배전계통에서 발생하는 고장전류 신호의 특성을 최적화 하는 방법은 고장 전류 파형과 돌입상태의 전류 파형에 대해 유사한 마더 웨이블릿을 적용하여 고장상태와 돌입상태의 웨이블릿 계수 값 즉 마더 웨이블릿과의 유사성이

가장 큰 마더 웨이블릿을 선정하는 것이다. 따라서 마더 웨이블릿의 정확한 선택은 고장과 돌입전류의 파형분석 시 매우 중요한 부분을 차지한다.

최적의 마더 웨이블릿을 선정하기 위해 본 논문에서는 표 3의 각 마더 웨이블릿을 이용하여 이산 웨이블릿 변환의 분해과정을 1 level에서 3 level까지 선택하여 DWT 결과를 신경 회로망에 학습시켰다. 이때 신경 회로망의 학습에 대한 목표치와 출력치의 오차율을 비교하여 그 오차를 최소로 하는 최적의 마더 웨이블릿을 선정하였다.

표 3 파형 분석에 사용된 마더 웨이블릿  
Table 3 Mother wavelet used signal analysis

Mother Wavelet	db			bior		coif		sym		
	1	2	4	1.1	2.2	2	3	2	3	4
종 류	6	8	10	3.1	4.4	4	5	5	6	7
Level	1, 2, 3			1, 2, 3		1, 2, 3		1, 2, 3		

학습에 사용된 고장상태 및 돌입상태의 데이터와 학습 후 신경 회로망의 검출성능을 판단하기 위한 데이터는 고장전류파형 161개의 각 상별 644개 데이터에서 71개의 대표성을 가진 데이터와, 돌입전류파형 46개의 각상별 데이터 개수 184개에서 총 53개의 데이터를 대표성을 가진 데이터를 대상으로 마더 웨이블릿 선정에 사용하였다.

표 3의 각 마더 웨이블릿을 이용하여 학습대상 전류 파형을 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 인식에 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 계산 양이 적어 실시간적인 처리가 가능하다.

본 논문에서 구성한 고장인식용 신경 회로망은 전류를 웨이블릿 변환하여 얻어진 계수들을 입력요소로 하여 2개의 은닉층과 1개의 출력층으로 구성하였다. 신경 회로망의 출력 활성화함수는 비선형이며 ±1의 값을 갖는 hyperbolic tangent 함수를 이용하였으며 식 (6)과 같다.

$$f(x) = \tanh(x/2) = \frac{1 - e^{-x}}{1 + e^{-x}} \tag{6}$$

초기의 신경 회로망의 각 노드간의 연결강도인 가중치는 초기에 입력 값의 크기들을 고려한 임의의 값으로 설정하였으며 최종 출력 오차를 이용한 가중치의 갱신은 식 (7)과 같은 방법을 사용하였다. 또 학습률과 모멘텀항을 추가하여

학습효율을 높이도록 하였다.

$$W(k+1) = W(k) + \Delta w(k+1) \tag{7}$$

$$\Delta w = -\eta \frac{\partial E}{\partial w} x_i, \quad \eta > 0 \tag{8}$$

여기서  $\eta$ 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 경사값의 변화를 이용하여 학습률을 변화시킨다. 오차의 경사값을 이용하여 변동 학습률을 적용하였으며 학습률  $\eta$ 는 식 (9)와 같이 정의하였다.

$$\eta(k+1) = \begin{cases} 1.02\eta(k) & \nabla E(k) > 1.02\nabla E(k-1) \\ 0.6\eta(k) & \nabla E(k) < \nabla E(k-1) \\ \eta(k) & \text{그 외의 경우} \end{cases} \tag{9}$$

구성된 신경 회로망은 입력층 1개와 은닉층 2개를 가지며 이를 주어진 학습대상 고장전류와 돌입전류 파형을 대상으로 고장일때 출력이 “-1”, 돌입일 때 출력이 “+1”이 되도록 학습 하며, 총 50000회 동안 패턴을 반복 학습하여 최적화된 가중치와 바이어스를 저장함으로써 비 학습된 고장전류파형을 대상으로 한 고장인식에 사용하였다.

5. 전압 감시정보를 이용한 고장검출 알고리즘

현재 FRTU에서 운용중인 고장검출 알고리즘의 첫 번째 문제점은 전류파형 각 상의 RMS 값을 감시하다가 설정값 이상의 전류가 흐르고 보호기기 동작으로 사전상태일때 돌입전류가 발생하여도 그 크기가 설정값 이상이고 보호기기가 동작한다면 FI를 동작시킬 수 있다. 두 번째 문제점은 고장처리 후 후비측 보호기기 투입 시 발생할 수 있는 돌입전류를 억제하기 위한 돌입전류억제시간이 공장출하 초기값인 2초로 설정되어 있다면 현재의 FI 알고리즘에서 돌입전류억제 시간에 돌입전류가 아닌 고장전류가 흘러도 FI를 동작시킬 수 없는 단점이 있다.

본 논문에서는 돌입전류억제 시간에서 발생할 수 있는 고장과 전류의 크기에 의존하고 있는 기존의 고장판단 단점을 해소하고자 새로운 고장판단 규칙을 제안하였다.

규칙 1) 전압파형의 급격한 크기의 변화가 발생하고, 동상 전류의 크기가 설정값보다 크고, DWT+신경망의 출력이 고장이면 FI동작.(일반적인 고장)

규칙 2) 전압파형의 급격한 크기의 변화는 발생하지 않고, 2 또는 3개상의 위상차이가 없으며, N상 전류의 크기가 설정값 보다 크면 FI동작(3상 단락 고장).

규칙 3) 전압파형의 크기의 변화가 발생하지 않고, 전류의 크기가 설정값보다 크고, DWT+신경망의 출력이 돌입이면 돌입전류로 판단.

규칙 4) 전압파형의 크기의 변화가 발생하지 않고, 전류치가 설정값보다 크고, DWT+신경망의 출력이 고장이면 FI동작.(거의 불평형 N상 고장)

규칙 5) 전압파형의 크기의 변화가 없고, 전류치가 설정값 보다 작고, DWT+신경망의 출력이 정상이면 정상파형

규칙 6) 전압파형의 크기의 변화가 발생하고, 전류치가 설정값 보다 크고, DWT+신경망의 출력이 돌입이면 최종 판단은 고장발생.(돌입파형과 사고파형이 혼합된 형태)

새로운 고장인식 알고리즘은 3상 전압파형을 감시하여 전압의 크기가 감소하거나 위상의 변화가 발생하였을 때 고장상의 전류치를 고장인식 설정값과 비교하여 설정값보다 크면 FI를 동작시키고, 만약 전압이 정상이라도 전류의 크기를 검토하고, 이산 웨이블릿 변환결과와 신경망 고장판단 결과를 이용하여 고장전류파형과 돌입전류파형의 패턴을 분리한다. 전압상태가 정상일 때 발생할 수 있는 N상의 고장전류 및 돌입전류를 검출할 수 있는 능력을 높일 수 있는 장점이 있다. 그림 2는 고장전압, 고장전류, 고장전류의 이산웨이블릿변환과 신경망을 이용한 종합적인 고장 및 돌입전류파형 판단 알고리즘을 순서도로 표시하였다.

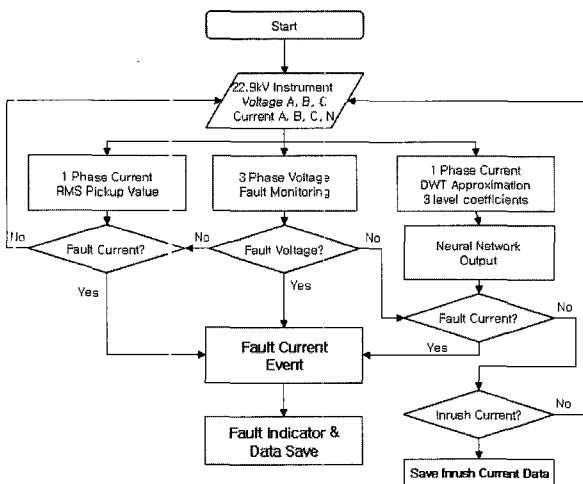


그림 2 고장판단 알고리즘의 순서도  
Fig. 2 Flowchart of Fault Decision Algorithm

일반적인 고장의 지락 고장 및 상고장의 경우 고장 전류가 크게 흐르며, 고장상의 전압도 크게 변동된다. 그러나 전압파형의 상 불평형으로 발생할 수 있는 N상 고장 및 돌입파형의 경우는 전압변동률이 작거나, 전압의 변화가 거의 없는 형태이다. 그래서 정상적인 전압파형의 경우도 고장유무를 확인하기 위하여 정상인 선간전압과 계측된 선간전압의 차이가 많이 발생하는 경우, 연속적으로 4주기동안 측정하여 지속적으로 진행하여 전압 실효값의 차이가 많이 발생하는 경우와 적게 발생하는 경우, 또한 3상 단락고장으로 인한 전압의 크기는 같고 위상이 같아지는 고장의 경우등에 대하여 고장의 등급을 결정하여 전류값을 고장 설정값과 비교하여 고장으로 판명된 경우 FI를 동작시킨다. 또한 전압파형이 고장이 아닌 경우에도 전류의 크기 비교와 전류파형에 대한 이산웨이블릿 변환 결과와 신경망 출력을 이용하여 고장전류파형, 돌입전류파형, 정상전류파형으로 분류하게 된다.

### 6. 시뮬레이션 결과

본 논문에서 고장 및 돌입전류파형의 대표성을 가진 파형들의 패턴을 선정하고, 선정된 대표적인 파형 패턴에 대해 이산 웨이블릿 변환을 하여 그 결과를 신경회로망의 학습에

적용하였다. 실측파형의 고장 및 돌입전류파형의 특징을 분류하기 위하여 고장이후 128샘플에 대하여 이산웨이블릿 변환 결과를 사용하였다. 128샘플의 경우 약 5주기 정도의 전류파형을 분석하여 돌입전류파형의 특징인 과도현상이 줄어드는 형태와 고장전류파형의 패턴을 구분할 수 있도록 하였다. 1주기(24샘플)을 대상으로 진행된 기존의 연구에서는 이산웨이블릿 변환 결과가 고장전류파형 패턴과 돌입전류파형 패턴의 특징을 분류하기 어려운 단점이 발생했다. 128샘플을 대상으로 고장 인식을 위한 이산웨이블릿 변환과 신경망을 이용한 고장판단의 경우 개폐기의 차단 알고리즘보다 시간을 많이 소요하나, FI에서 정확한 고장판단을 목적으로 하므로 많은 샘플을 대상으로 고장검출을 시도하였다.

또한 이산웨이블릿 변환을 위하여 가장 중요한 마더 웨이블릿 선정을 위하여 여러 가지 마더 웨이블릿 변환 결과를 신경망에 입력하여 학습시킨 후 학습에서 제외된 돌입 및 고장파형을 대상으로 오차를 계산하였다. 표 4는 학습오차를 이용한 마더 웨이블릿을 비교하기 위하여 신경망 학습을 50000회씩 동일하게 진행하여 얻어진 결과이다. 신경망 학습 목표값에 대한 도달오차 및 다른 고장파일에 대한 검증 오차가 적은 마더 웨이블릿은 db4, db10, bior3.1, sym5이다. 그중에서 신경망 학습에 대한 학습오차는 sym5가 가장 적으나, 비학습 데이터에 대한 고장출력 오차는 db4가 가장 작다. 본 논문에서는 종합적인 오차가 가장 작은 db4를 마더 웨이블릿으로 선정하였다. db4를 마더웨이블릿으로 선정하여 신경회로망의 학습오차를  $10^{-4}$ 으로 설정한 후, 설정된 학습오차에 도달되도록 신경회로망을 재학습한다.

표 4 학습오차를 이용한 Mother wavelet 비교  
Table 4 Compare of mother wavelet using learning error

	Mother Wavelet	Decomposition Level	신경망 목표값( $10^{-4}$ )에 대한 학습오차	비학습 데이터에 대한 출력오차
1	db1	3	0.298772/1e-04	27.31 %
2	db2	3	0.196551/1e-04	19.54 %
3	db4	3	0.021145/1e-04	10.92 %
4	db6	3	0.158670/1e-04	20.46 %
5	db8	3	0.095396/1e-04	16.33 %
6	db10	3	0.028418/1e-04	12.71 %
7	bior1.1	3	0.485673/1e-04	19.67 %
8	bior2.2	3	0.318441/1e-04	25.84 %
9	bior3.1	3	0.039752/1e-04	14.92 %
10	bior4.4	3	0.518413/1e-04	30.65 %
11	sym2	3	0.113671/1e-04	18.40 %
12	sym5	3	0.020415/1e-04	12.14 %
13	sym8	3	0.091430/1e-04	18.29 %
14	coif2	3	0.511326/1e-04	35.32 %
15	coif4	3	0.872172/1e-04	31.07 %

그림 3(a)는 FRTU A의 돌입전류파형이다. 그림 3(b)는 db4를 마더웨이블릿으로 이산웨이블릿을 3단계 분해한 근사 계수이다. 그림 3(c)는 db10, 그림 3(d)는 bior3.1 마더웨이블릿을 이용한 DWT 결과이다.

그림 3(b)와 그림 3(d)의 경우 원 신호의 특징을 거의 정확하게 표현하고 있다. 이산웨이블릿 결과는 신호의 특성은 크게 나타나고 계수의 값은 줄어들어 계산량을 줄일 수 있는 장점이 있다. 신경망은 입력층 18개 은닉층 32개로 구성

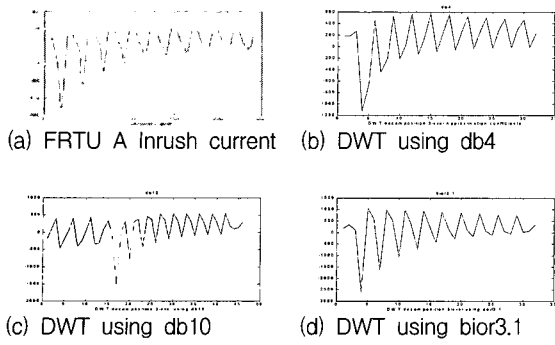


그림 3 마더웨이블릿을 이용한 DWT 결과  
Fig. 3 DWT output using Mother Wavelets

된 2개층과 출력층 1개의 구조로 구성되었다. 총 83개의 가중치와 바이어스에 대한 학습을 하였다. 그림 4(a)는 신경망 학습에 대한 오차를 보이고 있다. 학습오차 목표는  $10^{-4}$ 이고 총 82354회의 학습으로 오차 목표값에 도달하였다.

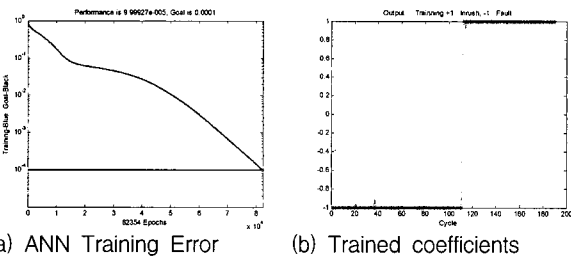


그림 4 신경회로망 학습  
Fig. 4 Neural Network Training

그림 4(b)는 돌입과형의 목표값인 +1과 고장과형의 목표값인 -1에 대한 입력값의 수렴정도를 보이고 있다. 신경망의 가중치와 바이어스는 수렴정도가 높아서 좋은 학습 결과 값을 가지고 있다.




그림 5 FRTU C 고장판단  
Fig. 5 Fault Decision of FRTU C

그림 5는 FRTU C에서 N상의 고장전류과형이다. 학습된 신경망 출력은 "-1"로써 고장으로 인식되었고, 전압감시 부분에서 A상의 큰 변화를 보이고 있어 "규칙 1"에 해당하는 고장이다. 그림 6은 FRTU D에서 N상의 고장전류과형에 대한 고장판단 결과이다. 학습된 신경망 출력은 "-1"로써 사고를 나타내고, 전압은 A, B, C상 모두 정상과형과 많은 차이를 보이고 있으나, 3상 위상감시에 대한 고장판단 결과 3상 단락사고에 대한 결과를 보이고 있으므로 "규칙 2"에 해당

하는 고장전류과형이다. 그림 7은 FRTU E에서 C, N상의 고장전류과형 중 C상의 고장전류에 대한 고장판단 결과이다. 신경망 출력은 "-1"로써 고장이고, 전압감시의 경우 C상이 고장으로 판명되어 "규칙 1"에 해당하는 고장인식을 하고 있다.




그림 6 FRTU D 고장판단  
Fig. 6 Fault Decision of FRTU D

그림 8의 경우는 FRTU F에서의 A, N상 고장전류과형에 대한 결과를 보이고 있다. 전압감시의 경우 정확하게 A상의 고장을 판단하고 B상 C상도 약간의 변화에 대한 오차를 보이고 있다(규칙 1).




그림 7 FRTU E의 (C,N상) 고장판단  
Fig. 7 Fault Decision of FRTU E




그림 8 FRTU F의(A,N상) 고장판단  
Fig. 8 Fault Recognition of FRTU F

그림 9는 FRTU G에서 고장전류과형의 경우 "고장이력"에는 N상의 고장으로 저장되어 있으나, 학습된 신경망 출력으로 "+1" 값을 가지므로 돌입전류이며, 전압감시 오차에 대한 결과도 정상이므로 돌입전류과형을 고장으로 판단한 오류이다.(규칙 3) 이러한 돌입전류과형을 기존의 FI 알고리즘에서는 고장으로 전류의 크기와 사전정보를 이용하여 잘못된 판단을 하였으나, 본 연구에서는 개선된 효과를 보이고 있다. 그림 10은 FRTU H에서 돌입전류과형은 "고장이력"에는 돌입전류과형으로 저장되어 있다. 그러나 A상전류에 대한 고장판단의 결과는 신경망출력이 "-1"로 고장전류과형

으로 판단되었고, 전압감시 또한 A상 전압이 이상으로 나타났다. 종합적인 결과 돌입전류파형이 아닌 고장전류파형으로 판단되었다.(규칙 1)




그림 9 FRTU G 고장판단  
Fig. 9 Fault Decision of FRTU G




그림 10 FRTU H 돌입파형 고장인식  
Fig. 10 Fault Decision of FRTU H

이 경우에는 돌입억제 시간에 저장된 파형으로써 고장전류파형이 돌입억제 시간에 발생되어 위험한 사고로 발전될 가능성이 있다. 이러한 개선된 효과를 FRTU 프로그램에 적용하여 고장검출 신뢰도를 향상시킬 수 있다. 그림 11은 FRTU J의 사고 전압을 나타내고 있다. 전압파형의 경우 C상의 전압이 작게 나타나며 B상과 C상도 이상현상을 보이고 있다.




그림 11 FRTU J의 전압파형  
Fig. 11 FRTU J Voltage wave




그림 12 FRTU J의 (B상) 고장판단  
Fig. 12 Fault Detection of FRTU J

“고장이력”은 전류의 크기를 이용하여 고장파형으로 저장이 되었으나, 그림 12의 경우 신경망출력결과는 과도현상이 들어드는 전형적인 돌입전류파형의 패턴을 보이고 있다. 따라서 고장전류파형이 아닌 돌입전류파형으로 잘못된 출력을 보이고 있으나 전압감시 알고리즘과 기존 전류의 크기를 이용한 고장 판단 알고리즘을 이용하여 보완된 결과로 적용하면 고장으로 판단 가능하다.(규칙 6)

본 논문에서는 이산 웨이블릿 변환과 신경망을 이용한 고장판단방법을 제시하였고, 그림 12와 같은 신경망출력이 학습된 고장 패턴으로 잘못된 고장판단을 하는 경우에도 전압감시 알고리즘과 기존의 FRTU 알고리즘의 결과를 종합적으로 판단하여 고장판단의 정확도를 높였다.

### 7. 결 론

본 연구에서는 자동화된 배전계통에 설치 운용되고 있는 FRTU의 고장검출 알고리즘 신뢰도를 향상시킬 수 있도록 전압감시 알고리즘과 이산웨이블릿 변환을 이용한 신경망 학습의 결과를 이용하여 종합적인 고장판단을 하는 새로운 알고리즘을 제안하였다. 주파수에 대한 정보 및 시간 정보가 제공되어 과도신호가 존재하는 신호해석에 적합하고, 배전계통의 고장과 돌입전류파형의 정확한 해석 및 판단방법으로 더욱 효과적으로 적용할 수 있는 이산 웨이블릿 변환을 이용하여 고장전류파형과 돌입전류파형에 대한 각각의 특성을 추출하였다. 이산 웨이블릿 변환 결과를 신경회로망에 입력하여 돌입 및 고장의 목표값을 대상으로 학습시켜 고장전류파형을 최대한 정확하게 고장을 판별하도록 하였고 약 90% 정도로 FRTU 고장판단 알고리즘의 신뢰도를 향상시켰다. 기존의 저장된 고장이력의 고장전류파형을 이산 웨이블릿 변환과 신경회로망을 이용한 고장판단기법으로 향상된 결과를 얻을 수 있었다. 또한 전류의 패턴만을 이용한 신경망 고장판단기법의 오류를 발생할 수 있는 고장파형들에 대하여 새로운 전압감시 알고리즘과 기존의 전류 설정값을 이용한 고장판단 알고리즘을 종합적으로 이용하는 고장판단 알고리즘으로 고장판단 오류를 줄이도록 연구하였고, 제안된 방법은 신경회로망 학습에 사용되지 않은 실측파형들을 대상으로 한 유효성을 검증함으로써 향후 FRTU의 고장검출 알고리즘에 적용한다면 향상된 고장판단 능력을 기대할 수 있다. 본 알고리즘은 MATLAB 프로그램을 이용하여 검증되었다.

### 감사의 글

본 연구는 산업자원부의 전력IT 국가과제인 배전지능화시스템 개발[지능형 다기능 단말장치 및 데이터처리장치 개발] 과제사업의 지원으로 수행되었음

### 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. PAS-99, pp.549-557 March/April 1980.

[2] 고윤석, 홍대승, 송완석, 박학열. "멀티에이전트 개념에 기반한 배전계통의 분산 자율적 고장구간 분리기법" 대한전기학회 논문지 제55A권 6호, pp.227-235 2006.

[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. "웨이브렛 변환과 신경망 학습을 이용한 고저항 지락사고 검출에 관한 연구" 대한전기학회논문지 제50A권 3호, pp.105-111 2001.3

[8] T. M. Lai, L. A. Snider, D. Sutanto, "High-Impedance Fault Detection Using Discrete Wavelet Transform and Frequency Range and RMS Conversion" IEEE Trans. on Power Delivery, Vol. 20, No. 1, pp.397-407 JAN, 2005

[9] Yong Sheng, Steven M., "Decision Tree-Based Methodology for High Impedance Fault Detection" IEEE Trans. on Power Delivery, VOL. 19, NO. 2, pp.533 - 536 APRIL 2004

[10] D. C. Yu and S. H. Khan, "An adaptive high and low impedance fault detection method," IEEE Trans. Power Delivery, vol. 9, pp. 1812-1818, Oct. 1994.

[11] 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

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

저 자 소 개



**홍대승 (洪大昇)**  
 1969년 11월 20일 생. 1992년 광운대 공대 제어계측공학과 졸업. 1994년 동 대학원 제어계측공학과 졸업(석사). 1994년~1997년 기아정보시스템. 2000년 광운대 대학원 제어계측공학과 박사과정 수료. 현재 남서울대학교 전자공학과 겸임교수.  
 전화 : 02-940-5152  
 FAX : 02-914-6039



**고 윤 석 (高 鈞 錫)**  
 1984년 2월 광운대 공대 전기공학과 졸업. 1986년 2월 광운대 대학원 전기공학과 졸업(석사). 1996년 2월 광운대 대학원 전기공학과 졸업(박사). 1986년 3월~1996년 3월 한국전기연구소 선임연구원. 1996년 4월 1997년 2월 포스코 경영연구소 연구위원. 1997년 3월~현재 남서울대학교 전자공학과 부교수.  
 전화 : 041-580-2115  
 FAX : 041-580-2110  
 E-mail : ysko@nsu.ac.kr



**강 태 구 (姜 泰 求)**  
 1953년 1월 13일 생. 1980년 2월 한양대학교 전자공학과 졸업. 1979년 11월~1992년 4월 한전 계측제어업무. 1992년 4월~현재 계측제어 및 연구개발업무 수행. 2007년 현재 한전KDN(주) 배전IT연구그룹장.  
 전화 : 032-420-0790  
 FAX : 032-420-0749  
 E-mail : saram@kdn.com



**박 학 열 (朴 學 烈)**  
 1969년 5월 17일 생. 1996년 2월 한양대 전기공학과 졸업. 1995년 10월~현재 배전 자동화시스템 개발 및 구축업무 수행. 2007년 현재 한전KDN(주) 전력IT연구원 배전IT연구그룹 선임연구원/기술사.  
 전화 : 032-420-0790  
 FAX : 032-420-0749  
 E-mail : saram@kdn.com



**임 화 영 (任 化 永)**  
 1946년 3월 18일 생. 1973년 한양대 공대 전기과 졸업. 1976년 동 대학원 전기공학과 졸업(석사). 1984년 동 대학원 전기공학과 졸업(공박). 1982년~1988년 광운대 공대 전기공학과 교수. 현재 광운대 공대 제어계측공학과 교수  
 전화 : 02-940-5152  
 FAX : 02-914-6039  
 E-mail : yimhy@daisy.kwangwoon.ac.kr