

퍼지클러스터링 기법과 신경회로망을 이용한 고장표시기의 고장검출 능력 개선에 관한 연구

A Study on the Improvement of Fault Detection Capability for Fault Indicator using Fuzzy Clustering and Neural Network

홍대승* 임화영*

Dae-Seung Hong, Hwa-Young Yim

* 광운대학교 제어계측공학과

요 약

본 논문은 전력계통의 배전계통시스템에서 FRTU(Feeder remote terminal unit)의 고장검출 알고리즘의 개선에 관한 연구이다. FRTU는 상과 지락에 관한 고장검출을 할 수 있다. 특히 고장픽업 기능과 돌입억제기능은 일반적인 부하전류로부터 고장전류를 구별할 수 있다. FRTU는 돌입전류 또는 설정값을 초과한 고장전류가 발생하면 고장표시기(FI)로 고장을 발생한다. 짧은 시간 푸리에 변환(STFT) 분석은 주파수와 시간에 관한 정보를 제공하고, 퍼지 중심 평균 클러스터링(FCM) 알고리즘은 고조파의 특성을 추출한다. 고장 검출기의 신경회로망 시스템은 최급강하법을 이용하여 고장상태로부터 돌입전류를 구별하도록 학습된다. 본 논문에서는 FCM과 신경회로망을 이용하여 고장검출기법을 개선하였다. 검증에 사용된 데이터는 22.9KV 배전계통 시스템에서 실제 측정된 데이터이다.

키워드 : 퍼지클러스터링, 배전계통, 고장표시기, 신경회로망, FRTU

Abstract

This paper focuses on the improvement of fault detection algorithm in FRTU(feeder remote terminal unit) on the feeder of distribution power system. FRTU is applied to fault detection schemes for phase fault and ground fault. Especially, cold load pickup and inrush restraint functions distinguish the fault current from the normal load current. FRTU shows FI(Fault Indicator) when the fault current is over pickup value or inrush current. STFT(Short Time Fourier Transform) analysis provides the frequency and time information. FCM(Fuzzy C-Mean clustering) algorithm extracts characteristics of harmonics. The neural network system as a fault detector was trained to distinguish the inrush current from the fault status by a gradient descent method. In this paper, fault detection is improved by using FCM and neural network. The result data were measured in actual 22.9kV distribution power system.

Key Words : Fuzzy Clustering, Power distribution system, FI, Neural Network, FRTU

1. 서 론

배전자동화 시스템은 한전지점 중앙 제어실의 컴퓨터를 이용해 원격리에 산재돼 있는 배전선로용 개폐기의 상태 감시 및 제어를 수행하고, 건압, 전류 등을 계측할 수 있으며, 고장이 발생하면 자동으로 고장구간을 확인하여 배전선로 계통운전을 원격으로 수행하여 전력공급 신뢰도를 크게 개선하였다.[1-3]

배전 자동화시스템에서 FRTU(Feeder Remote Terminal Unit)는 배전선로용 개폐기와 함께 선로에 설치되어 상시 배전선로의 전압, 전류, 개폐기의 상태를 감시하고, 선로 사고발생시 사고에 대한 정보를 주 장치로 전송한다. 선로고장이 발생하여 각상의 측정된 전류값이 고장전류설정치보다 크고 보호기기가 동작하면 FI(Fault Indicator)가 발생한다. 그러나 운용 중인 FI 알고리즘에서는 돌입전류가 발생하여

도 고장전류로 판단하는 오동작이 발생할 수 있다. 또한 FI 알고리즘 중에는 전원 투입시 발생할 수 있는 돌입전류를 억제하기 위하여 돌입대비 시간을 2초동안 설정하여 돌입전류가 고장설정치보다 큰 값이 측정되어도 FI를 표시하지 않는다. 만약 돌입대비시간에 고장이 발생하여도 FI가 고장을 표시하지 못하여 사고가 확대될 수 있는 단점이 있다. 배전계통의 전력 공급 신뢰도를 향상을 위하여 FRTU가 좀 더 정확한 고장판단 및 고장표시가 요구되고 있는 실정이다.

전통적으로 전력계통의 동적인(dynamic) 과도상태 신호의 분석에 푸리에 변환이 사용되었다.[4] 그러나 신호를 주파수 영역으로 변환하는 과정에서 시간정보가 손실되는 단점으로 인하여 과도상태의 배전계통 신호를 분석하는데 매우 제한적이다. 고장패턴을 신경회로망의 초기입력으로 설정하여 학습한 후 최적화된 가중치와 바이어스를 이용하여 고장을 판단을 하는 연구도 많이 진행되고 있다.[5-6] 또한 기존의 많은 연구에서는 실측 고장 데이터를 취득하기 어려운 점이 있어서 고장을 모의한 데이터를 이용하여 많은 연구가 진행되었다. 그러나 모의 프로그램을 이용하여 작성된 고장모의

접수일자 : 2007년 5월 14일

완료일자 : 2007년 6월 10일

데이터는 실측된 고장 데이터의 여러 가지 특징을 정확하게 반영하기가 힘들어서 고장검출에 관한 특성 연구가 어려운 점이 있었다.[7-8]

본 논문에서는 실측된 고장전류 파형과 돌입전류 파형에 대하여 STFT(Short Time Fourier Transform)을 이용하여 고장전류와 돌입전류의 각 주기별 고조파를 추출하고, 추출된 고조파의 특성분류는 퍼지 평균 중심 클러스터링 기법을 이용하여 고조파의 분포도와 중심점을 추출하여 고장 및 돌입전류의 고조파 특징 추출에 관하여 연구하였다. 또한 고장전류파형과 돌입전류파형의 중심점이 유사한 데이터 및 각 클러스터를 대표할 수 있는 파형들을 대상으로 4주기동안 특정 고조파의 변화를 신경회로망에 입력하여 돌입 및 고장에 대해 학습한 후, 고장전류 판별에 최적화된 신경망의 가중치와 바이어스를 이용하여 고장판별의 정확도를 높이는 알고리즘을 제안한다.

2. 고장표시(FI) 운영 알고리즘

일반적으로 FI의 고장 판별을 위한 기준이 표 1과 같이 설정되어 있어서 해당 선로에 전원이 투입되면 처음 2초동안 돌입이나 고장 전류에 관계없이 FI를 나타내지 않게 된다.

표 1. FI 초기 설정값.

Table 1. Initial setting value of FI.

선로운전정보			
내용	고장전류 설정값 (상고장)	고장전류 설정값 (지락고장)	돌입대비 시간
설정값	400A	60A	2000ms

그러나 재폐로 개폐기(Recloser)의 재폐로 상황에 따른 돌입전류가 발생하여 고장전류의 설정치(pickup)보다 큰 값이 측정되면 잘못된 FI를 발생시키는 오동작을 할 수 있는 문제점을 가지고 있다.

그림 1은 2005년에 저장된 FRTU B의 돌입전류파형이다. 그러나 A, B, C, N상전류는 전형적인 고장전류 특성을 보이고 있다. 그림 2의 전압파형도 50샘플에서 150샘플까지 이상을 보이고 있어서 고장전류파형이 돌입파형으로 잘못 저장된 경우이다.




그림 1. FRTU B 돌입전류.
Fig. 1. FRTU B inrush current.




그림 2. FRTU B 전압.
Fig. 2. FRTU B voltage.

그림 3은 FRTU C의 고장전류를 보이고 있다. 약 10샘플에서 100샘플까지 약 3주기간 과도현상을 가진 돌입전류 파형형태이나, 약 100샘플에서 차단된 현상을 보이고 있다. 그림 4는 FRTU C의 전압을 보이고 있다. 그림 4의 전압정보와 그림 3의 과도현상을 보이고 있는 전류파형을 종합적으로 판단한 결과 과도현상을 가진 돌입전류파형에 대하여 표 1의 고장설정치보다 큰 C, N상 전류에 대하여 고장검출을 한 형태이다.




그림 3. FRTU C 고장전류.
Fig. 3. FRTU C Fault Currents.




그림 4. FRTU C 전압.
Fig. 4. FRTU C voltage.

본 논문에서는 그림 1과 같이 돌입억제시간에 발생할 수 있는 고장파형에 대한 정확한 검출과 그림 3의 돌입전류파형을 정확하게 판별하여 고장전류와 돌입전류로 정확하게 분류할 수 있는 알고리즘을 연구하였다.

본 논문에서는 전국에 운영중인 FRTU에서 2005년에 취득된 돌입파형 데이터 46개와 사고파형 데이터 161개를 대상으로 전압파형, 전류파형 및 고장이력에 대하여 현장 전문가와 고장관리 담당자들과 판별을 통하여 검증한 결과 FRTU프로그램에서 잘못 판단된 고장전류 값, 잘못 분류된 고장과 돌입파형, 고장상이 바뀐 경우 등 여러 가지 고장이력에 대한 오차를 발견하였다.

본 논문에서는 고장판단 오차를 줄이기 위하여 FRTU에 저장된 실측된 데이터 중에서 명확하게 돌입파형과 고장파형으로 구분된 데이터만을 대상으로 정확한 고장판단 알고리즘을 적용하여 FI의 고장판단 능력을 향상시킬 수 있도록 연구하였다.

3. 클러스터링(Clustering) 알고리즘

본 논문에서는 퍼지 중심 평균 클러스터링(Fuzzy Center-Means clustering) 알고리즘을 이용하여 고조파 분석을 연구하였다. 퍼지 중심평균 클러스터링 알고리즘은 소속도와 명기된 정보에 따라 각 정보 점을 클러스터로 구성하는 것으로 n개의 벡터 X_i 를 c개의 퍼지 집합으로 나누고 각 집합의 클러스터들의 중심을 찾는 것이다. 식 1은 정규화를 규정하기 위하여 소속도를 나타내며 소속도의 합은 항상 1이 된다.

$$\sum_{i=1}^c u_{ij} = 1, \forall j = 1, \dots, n. \quad (1)$$

여기서 u_{ij} 는 0과 1사이의 값으로서 소속도를 나타낸다. 중심값의 집합을 $G_i, i = 1, \dots, c$ 라고 할 때 n 개의 X_i 집합의 X_k 벡터와 클러스터 중심인 c_i 사이의 차이를 측정하는 유클리드 거리와 그 목표함수는 식 2와 같다.

$$J = \sum_{i=1}^c J_i = \sum_{i=1}^c \left(\sum_{k: x_k \in G_i} \|x_k - c_i\|^2 \right) \quad (2)$$

$$J(U, c_1, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (3)$$

여기서 $d_{ij} = \|c_i - x_j\|$ 는 j 번째 정보와 i 번째 클러스터 중심값 사이의 유클리드 거리이다. $m \in [1, \infty]$ 는 가중치이다. 식 3이 최소값이 되기 위한 필요조건은 식 4와 같다.

$$\begin{aligned} \bar{J}(U, c_1, \dots, c_c, \lambda_1, \dots, \lambda_n) &= J(U, c_1, \dots, c_c) + \sum_{j=1}^n \lambda_j \left(\sum_{i=1}^c u_{ij} - 1 \right) \\ &= \sum_{j=1}^n \sum_{i=1}^c u_{ij}^m d_{ij}^2 + \sum_{j=1}^n \lambda_j \left(\sum_{i=1}^c u_{ij} - 1 \right) \end{aligned} \quad (4)$$

여기서 λ_j 는 라그랑지 곱셈자(Lagrange multiplier)이다. 식 4에서 최소가 되기 위한 조건은 다음과 같다.

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{k=1}^i \left(\frac{d_{kj}}{d_{ij}} \right)^{2/(m-1)}} \quad (5)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{kj}}{d_{ij}} \right)^{2/(m-1)}} \quad (6)$$

퍼지 중심 평균 클러스터링 알고리즘은 식 5와 식 6의 조건이 만족하도록 계속 반복한다. 퍼지 중심 평균 클러스터링 알고리즘의 사용목적은 입력데이터들의 중심점을 계산하여 퍼지 소속 함수의 최적화된 위치를 결정하기 위하여 사용된다. 그러나 본 논문에서는 1고조파와 2고조파의 특성을 분석하고자 두 가지 고조파를 입력으로 평면을 구성하여 클러스터의 중심점을 찾는 알고리즘만을 퍼지 중심 평균 클러스터링 알고리즘을 이용하여 각 클러스터의 대표할 수 있는 중심점을 계산하였다. 클러스터의 개수는 7개로 정하였으며, 각 클러스터의 중심값에 가까운 돌입 전류파형과 고장 전류파형을 신경망 학습에 적용한다.

4. STFT을 이용한 고조파 검출

전력계통의 사고 시 발생하는 비 주기적인 과도현상에 대하여 이를 분석하고 검출하기 위한 전통적인 방법으로 이산 푸리에 변환 기법을 이용한 고조파 분석 방법들이 있다. 고속 푸리에 변환은 이산 푸리에 변환을 고속으로 연산하기 위하여 제안된 알고리즘으로써 식 7과 같다.

$$X(k) = D[x(n)] = \sum_{n=0}^{N-1} x(n) e^{-j2\pi nk/N}, \quad (7)$$

$$k = 0, 1, 2, \dots, N-1$$

푸리에 변환의 대안으로 제시된 STFT은 전력계통의 고장과 스위칭에 관련된 과도현상을 분석하기 위한 방법으로서

설정된 윈도우의 고조파 분석을 위하여 제안된 기법이다. 이 기법은 시도한 연구자들 Garbor로써 시간에 따라 연속적으로 푸리에 변환을 이용하여 시간-주파수 표현을 시도하였다. STFT은 식 8와 같이 표현된다.

$$STFT(\tau, \omega) = \int y(t) g^*(t-\tau) e^{-j\omega t} dt \quad (8)$$

본 논문에서는 돌입파형과 고장파형의 특징을 추출하고자 STFT와 퍼지 클러스터링 기법을 이용한 고조파 검출을 시도하였으나 실측 고장파형과 돌입파형의 고조파가 유사한 형태를 보이고 있어서 특징을 분류하기가 어려웠다. 따라서 고장파형과 돌입파형의 주기별 윈도우를 설정하여 각 주기별 고조파의 변화를 보이는 1고조파와 2고조파의 5주기까지의 변화량을 신경회로망의 입력요소로 이용하여 학습에 사용토록 하였다.

5. 신경 회로망(Neural Network)

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 가능한 장점이 있다.

본 논문에서 구성된 고장 검출용 신경 회로망은 퍼지 클러스터링에서 선정된 고장 및 돌입전류의 4주기를 각 주기에 관하여 이산 푸리에 변환하여 1, 2고조파의 변화를 입력요소로 하여 총 10개의 입력요소와 32개의 가중치를 가지고 있는 2개의 은닉층과 1개의 출력층으로 구성하였다. 신경 회로망의 출력 활성화함수는 비선형요소를 포함하고 있고, ± 1 의 값을 갖는 hyperbolic tangent function을 이용하였으며 식 9와 같다.

$$f(x) = \tanh(x/2) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (9)$$

초기의 신경 회로망의 각 노드간의 연결강도인 가중치는 초기에 입력값의 크기들을 고려한 임의로 값으로 설정하였으며 최종 출력 오차를 이용한 가중치의 갱신은 식 10과 같은 방법을 사용하였으며 학습률과 모멘텀항을 추가하여 학습효율을 높이도록 하였다.

$$W(k+1) = W(k) + \Delta w(k+1) \quad (10)$$

$$\Delta w = -\eta \frac{\partial E}{\partial w} x_i, \quad \eta > 0 \quad (11)$$

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 적용적으로 변화시킨다는 것으로 오차의 경사 값을 이용하여 변동 학습률을 적용하였으며 학습률 η 는 식 12과 같이 정의하였다.

$$\eta(k+1) = \begin{cases} 1.022\eta(k) & \nabla E(k) > 1.01 \nabla E(k-1) \\ 0.55\eta(k) & \nabla E(k) < \nabla E(k-1) \\ \eta(k) & \text{그 외의 경우} \end{cases} \quad (12)$$

구성된 신경 회로망은 출력층이 고장전류와 돌입전류 파

형을 대상으로 고장일때 출력이 “-1”, 돌입일 때 출력이 “+1”이 되도록 학습 시켰으며 총 1200회 동안 패턴 반복으로 학습하여 고장검출 출력에 적합하게 학습된 가중치와 바이어스를 저장하여 비 학습된 고장파형을 대상으로 한 고장 검출 시 사용하였다.

6. 시뮬레이션

본 논문에서 제안한 알고리즘은 그림 5에 순서도로 보이고 있다. 고장 및 돌입파형을 STFT한 후 퍼지 클러스터링 알고리즘을 이용하여 대표성을 가진 파형들의 패턴을 7개 클러스터로 분류하였다.

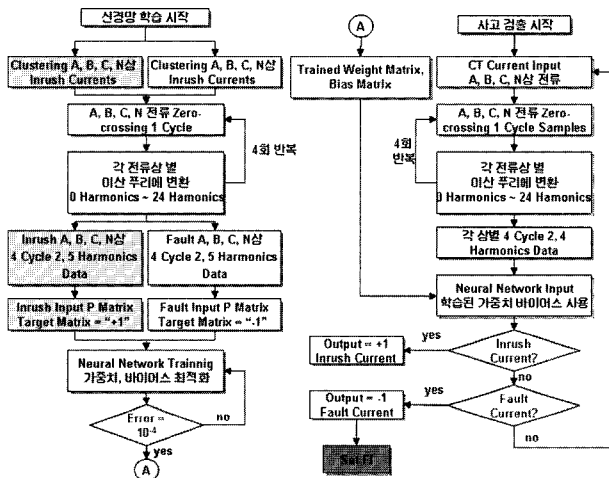


그림 5. 종합적인 고장검출 알고리즘 순서도.

Fig. 5. Complex fault detection algorithm flowchart.

그림 6은 고장파형의 1고조파와 2고조파를 좌표평면에 표현한 퍼지 클러스터링 결과이다. 분포도를 보기 위하여 각 고조파들의 조합에 대한 좌표평면 표현을 하였으나, 1고조파와 2고조파의 조합을 이용한 고조파 분석방법을 본 논문에서는 이용하였다.




그림 6. 고장전류들의 퍼지클러스터링.

Fig. 6. Fuzzy clustering of fault currents.

그림 7은 돌입파형의 1고조파와 2고조파에 대한 퍼지 클러스터링 분포도를 좌표평면에 보이고 있다.




그림 7. 돌입전류들의 퍼지 클러스터링.

Fig. 7. Fuzzy clustering of inrush currents.

그림 6은 고장전류의 고조파 중에서 클러스터 2, 4, 5에 많은 고장파형 데이터가 집중되어 있는 것을 알 수 있다. 또한 그림 7에서는 돌입파형의 1, 3, 6, 7 클러스터가 많은 돌입 파형 고조파특성을 가지고 있다. 표 3은 퍼지 클러스터링을 이용한 클러스터의 중심값을 나타내고 있다. 표 2에서 돌입전류의 클러스터 5의 경우와 고장전류의 클러스터 4인 경우 유사한 중심 값을 가지고 있어 고조파의 중심값으로 분류가 어렵다.

표 2. 퍼지 클러스터링 중심값.

Table 2. Fuzzy Clustering Center Value.

	돌입전류 중심값		고장전류 중심값	
	1고조파	2고조파	1고조파	2고조파
Cluster 1	16.39	3.37	1474.68	121.57
Cluster 2	26.80	12.30	442.36	25.52
Cluster 3	10.11	4.03	837.65	61.42
Cluster 4	39.30	17.39	20.17	2.81
Cluster 5	24.96	3.12	242.31	12.78
Cluster 6	6.04	1.83	1190.57	129.11
Cluster 7	17.02	7.71	103.63	14.00

본 논문에서는 신경망학습에 사용될 각 클러스터의 대표 값을 가진 데이터를 선정하였다. 학습에 사용될 데이터는 돌입전류와 고장전류파형 각각 15개의 대표 값들을 5주기의 전류파형을 분석하여 고조파의 변화를 신경회로망의 입력으로 사용하였다.

그림 8은 FRTU D 돌입파형의 고조파 변화를 보이기 위하여 돌입파형의 첫 번째 주기부터 다섯 번째 주기까지 윈도우를 취하여 STFT한 각각의 고조파를 보이고 있다. 1주기 고조파에서는 1고조파와 2고조파와 3고조파가 5주기로 갈수록 점차 줄어드는 현상을 보이고 있다. 좀더 명확한 값을 추출하기 위하여 1고조파와 2고조파의 대표 값을 선출한다.

그림 9는 FRTU E 고장전류에 대한 사고시작점부터 5주기까지의 각 주기별로 고조파를 보이고 있다. 고장파형의 특성은 고장이 크기가 변화하지 않으므로 1고조파 및 2고조파는 거의 줄어들지 않는 특성을 보이고 있다. 사고전류의 크기가 거의 변화가 없어 기본파인 1고조파의 크기의 변화가 거의 없고, 2고조파의 크기도 기본파에 비하여 작은 값을 가지고 있다.

본 논문에서는 돌입과 고장파형의 차이점인 1주기부터 5주기까지의 고조파 중에서 1, 2고조파의 변화량의 차이점을 이용하여 신경망의 입력에 이용하여 가중치와 바이어스를 최적화할 수 있도록 학습한다.




그림 8. FRTU D 돌입전류와 고조파.
Fig. 8. Harmonics and FRTU inrush current.




그림 9. FRTU E 고장전류와 고조파.
Fig. 9. Harmonics and FRTU E fault current.

그림 10은 표 4의 돌입 및 고장 데이터를 이용하여 짐작된 1주기부터 5주기까지의 1, 2고조파를 신경회로망의 입력으로 사용하여 학습시킨 결과이다.




그림 10. 신경회로망 학습.
Fig. 10. Neural network training.

학습 오차에 대한 목표를 10^{-4} 으로 설정하여 학습시킨 결과가 10(a)이고, 돌입 및 고장파형 각각 15개에 대한 목표치와 학습된 결과를 보이고 있다.

본 논문에서는 학습된 신경망의 돌입 및 고장검출 능력을 평가하기 위한 학습에 사용되지 않은 돌입 데이터 18개와 고장 데이터 21개로써 총 39개의 실측 데이터 이용하였다.




그림 11. 비학습된 데이터에 대한 고장검출 결과.
Fig. 11. Fault detection for non-training data.

그림 11에서는 학습된 신경회로망을 이용한 비 학습 데이터에 대한 고장검출 결과를 보이고 있다. 돌입파형 18개 데이터와 고장파형 21개 데이터를 대상으로 한 고장검출 결과

이다. 돌입파형의 경우 FRTU F의 돌입파형 A상의 경우 신경회로망의 고장판단 결과 0.75 정도로 낮은 출력을 보이고 있지만 사고파형과의 경계값인 0.00 이상으로 출력되어 정확한 사고 검출을 보이고 있다. 또한 FRTU G의 사고파형은 신경회로망의 고장판단 출력이 -0.4로써 고장파형의 소속도가 낮지만 경계값 0.00 이상이므로 정확한 고장검출 결과를 보이고 있다.




그림 12. FRTU F 돌입전류의 사고검출.
Fig. 12. Fault detection for FRTU F inrush current.

그림 12는 FRTU F의 돌입전류파형과 신경회로망의 고장판단 결과를 보이고 있다. 고장판단 결과는 0.75로써 돌입파형을 나타내고 있다. 또한 1고조파와 2고조파의 변화를 보이고 있다. 학습시 점차 줄어드는 돌입특성과 다른 변화를 보이고 있으나 신경회로망에 학습시킨 변화특성으로 인하여 돌입에 가까운 결과판정을 보이고 있다.




그림 13. FRTU G 고장전류의 사고검출.
Fig. 13. Fault detection for FRTU G fault current.

그림 13은 FRTU G의 고장판단 결과를 보이고 있다. 고장판단 결과는 약 0.4정도를 보이고 있으나, 0.00 이상이므로 고장파형으로 판단할 수 있다. 하위의 2고조파의 변화가 점차 줄어드는 변화를 보이고 있으나, 고장으로 학습된 결과에 따라서 고장판단을 하는 결과를 보이고 있다.

7. 결 론

본 연구에서는 자동화된 배전계통에 설치 운용되고 있는 FRTU에서 고장검출 알고리즘의 오동작을 개선할 수 있도록 실측된 돌입파형과 고장파형에 대한 고장검출 능력의 개선에 관하여 연구하였다. 현 고장검출 알고리즘에서는 돌입억제시간에 고장전류가 발생하여도 고장검출을 할 수 없어 큰 문제가 발생할 수 있다. 또한 돌입전류파형이 고장검출 설정치보다 큰 값이 흐르면 고장으로 판단하여 고장차단을 할 수 있어 배전계통의 신뢰도에 나쁜 영향을 줄 수 있다.

본 논문에서는 실측된 고장전류와 돌입전류의 특성을 추출하기 위하여 STFT를 이용한 고조파를 추출하였고, 신경회로망의 학습에 사용할 대표적인 고조파 성분을 선별하기 위하여 퍼지 중심 평균 클러스터링 기법을 이용하여 클러스터의 중심값에 유사한 대표적인 데이터를 선정하였다. 또한

돌입 및 고장전류의 고조파를 변화를 이용하기 위하여 고장 파형의 5주기동안 고조파의 변화에 대하여 신경망 학습을 하였다. 신경망 학습은 클러스터링을 이용하여 검출된 총 고장 전류 15개와 돌입전류 15개 파형에 대하여 학습이 진행되었다. 학습된 가중치와 바이어스를 이용하여 비학습 실측 고장 전류파형과 돌입전류파형을 대상으로 학습결과를 검증하였다. 고조파의 변화를 이용하여 돌입역제시간에 고장파형이 발생할 수 있는 상황에 대하여 정확한 고장검출을 할 수 있고, 돌입파형에 대한 고장검출 후 차단을 억제할 수 있어 FRTU의 신뢰도를 향상시킬 수 있다. 또한 배전계통의 정확한 특성을 포함한 고장 및 돌입전류파형을 이용하여 신경망의 학습과 고장검출의 유효성이 검증됨으로써 향후 FRTU 고장검출 알고리즘 적용에 있어서 향상된 고장검출을 기대할 수 있다. 따라서 배전자동화시스템의 안정된 운영을 기대할 수 있다.

[6] Martin T. Haugan "Neural Network Design" PWS Publishing Company, 1996
 [7] Youssef, O.A.S., "A wavelet-based technique for discrimination between faults and magnetizing in-rush currents in transformers" Power Delivery, IEEE Trans. on Volume 18, Issue 1, pp.170 - 176, Jan 2003,
 [8] Xusheng Chen, Venkata, S.S.A., "three-phase three-winding core-type transformer model for low-frequency transient studies" Power Delivery, IEEE Trans. on Vol.12, Issue 2, pp.775 - 782, April 1997

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] 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
 [3] 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.
 [4] Aucoin B.M., Russell B.D., "Distribution High Impedance Fault Detection Utilizing High Frequency Current Components", IEEE Trans. on Power Apparatus and Systems Vol.PAS-101, No. 6, pp.1596-1606, June 1982
 [5] 도경훈, 험기호, "역전과 신경회로망을이용한 고임피던스고장 검출", Trans. KIEE, Vol. 45, No. 11, pp.1534-1541, Nov. 1996,

저 자 소 개



홍대승(Dae-Seung Hong)

1969년 11월 20일생. 1992년 광운대 공대 제어계측공학과 졸업. 1994년 동 대학원 제어계측공학과 졸업(석사). 1994년-1997년 기아정보시스템. 2000년 광운대 대학원 제어계측공학과 박사과정 수료. 현 남서울대학교 전자공학과 겸임교수

Phone : 02-940-5152
 Fax : 02-914-6039
 E-mail : hong_ds@hanmail.net



임화영(Hwa-Young Yim)

1946년 3월 17일생. 1973년 한양대 공대 전기과 졸업. 1976년 동 대학원 전기공학과 졸업(석사). 1984년 동 대학원 전기공학과 졸업(공학박사). 1982년~1988년 광운대학교 전기공학과 교수. 현재 광운대학교 정보제어공학과 교수

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