

개선된 퍼지 C-Means 클러스터링을 이용한 고장전류판별에 관한 연구

論 文

57-11-33

A Study on the Fault Current Discrimination Using Enhanced Fuzzy C-Means Clustering

鄭鍾元* · 李浚柝†

(Jong-Won Jeong · Joon-Tark Lee)

Abstract - This paper demonstrates an enhanced FCM to identify the causes of ground faults in power distribution systems. The discrimination scheme which can automatically recognize the fault causes is proposed using Fuzzy RBF networks. By using the actual fault data, it is shown that the proposed method provides satisfactory results for identifying the fault causes.

Key Words : Fuzzy C-Means clustering, Fault Current, Fuzzy RBF Network, Fault Recorder, phase space

1. 서 론

급속한 산업발달과 경제성장으로 인하여 국내의 전기 에너지 수요가 급증함에 따라 전력설비의 용량이 증가하고 있다. 뿐만 아니라 대도시의 인구 집중 현상에 따른 전력 수요 밀도가 크게 증가하는 시점에서 전력계통의 안정적인 공급은 중요한 문제이다. 그러나 이러한 전력계통은 외부에 노출이 되어 있기 때문에 자연 재해나 여러 가지 원인에 의해서 고장이 발생하게 되며, 전력의 안정적인 공급이라는 측면에서 전력계통의 고장에 대한 해석, 복구, 계통 보호 및 사고 시에 그 원인을 규명하는 문제는 아주 중요한 관심사가 되어 진다.

고장의 원인을 규명하는 것은 사고로부터의 계통의 신속한 복구와 정전구역의 확대를 막기 위해 정확하고 신속하게 이루어져야 한다. 현재까지의 고장 진단 및 원인 규명은 주로 숙련된 전문가의 경험 및 보조 프로그램(ProTas, PSSE) 등에 의해 해결되어 왔으나, 전력계통이 점차 대형화되고 그에 따른 계통 보호 시스템이 복잡해짐에 따라 계통의 고장 유형이 점차 점점 복잡, 다양화(수목접촉, 외물접촉, 조류, 고층 건축물, 절연 열화, 산불, 기후, 도로굴착 등)되어 지고 있는 실정이다. 하지만 고도화된 첨단 산업 사회의 전력소비자들은 고품질의 전력 공급을 요구하고 있어 이를 위해서는 사고 시 고장 원인을 정확하게 빠른 시간 내에 판단하여 조치를 취하여 계통의 안정성 및 신뢰도를 확보하여야 한다. 본 논문에서는 이러한 선로의 고장에 있어 그 원인을 규명하기 위한 방법으로 선로에 취부 되어 있는 고장 기록 장치(Fault recorder)의 데이터와 개선된 퍼지 C-Means 클러스터링(Fuzzy C-Means Clustering; FCM) 기법을 이용

하여 판단하고자 하였다.

기존의 방법으로는 고장 원인의 특성을 파악하기 위하여 Fourier 변환이 사용되어왔다[1]. 그러나 이는 신호를 주파수 영역으로 변환하는 과정에서 시간정보가 손실되는 단점으로 인하여 계통의 신호를 분석하는데 매우 제한적이다. 또 다른 기법으로는 Wavelet 변환에 의하여 그 특성을 파악하기도 하였다[2]. Wavelet 변환은 고주파 성분에 대해서는 시간 분해능이 높고, 저주파 성분에 대해서는 주파수 분해능이 높아지므로, 주어진 신호에 대한 정확한 지식이 부족하더라도 시간-주파수 해석이 가능하고, 고주파 성분을 갖는 특이점의 검출에도 적합하게 된다. 하지만 계통에서의 고장전류의 경우는 시계열 데이터임과 그 형태의 유사성으로 인하여 어느 정도는 분류가 가능하지만 다양한 원인별 정확한 분류에는 어려움이 따른다. 그 외 원인의 판별을 위하여 고장패턴을 직접 신경회로망의 초기 입력으로 설정하여 학습한 후 최적화된 가중치와 바이어스를 이용하여 고장을 판단하는 연구도 진행되고 있었다[3].

본 논문에서는 선로에 취부되어 있는 고장 기록 장치(Fault Recorder)로부터 얻어진 트립(trip) 신호와 고장 시 발생하는 중성선 전류를 위상평면으로의 전처리를 수행하였다. 전처리 후 위상평면에서의 데이터의 수와 전체에 대한 밀도를 구하여 퍼지 RBF 네트워크의 학습백터로 사용하여 그 원인별을 판별하였다. 퍼지 RBF 네트워크의 사용은 기존의 RBF 네트워크의 문제인 학습되지 않은 데이터의 입력 시 학습된 분류로 구분하는 문제를 해결하기 위해 새로운 고장 데이터의 입력 시 중간층에서 새로운 뉴런을 생성시킴으로써 학습된 유사한 패턴으로 분류되는 오류를 피하기 위함이다. 그리고 효율적이고 정확성이 높은 중간층을 구성하기 위하여 기존의 이분법이 아닌 2개 이상의 원인에 소속이 가능한 퍼지 분류가 가능하고 군집간의 거리에 따른 변화와 군집 중심의 위치, 그리고 군집형태에 따라 영향을 덜 받는 개선된 FCM 클러스터링 알고리즘을 사용하였다. 이를 통하여 중간층 뉴런의 과도한 생성을 막고 좀 더 효율적이고 정

* 學生會員 : 東亞大 工大 電氣工學科 博士課程

† 교신저자, 正會員 : 東亞大 工大 電氣工學科 教授 · 工博

E-mail : jtlee@dau.ac.kr

接受日字 : 2008年 8月 26日

最終完了 : 2008年 10月 2日

확한 중간층의 구성이 가능하도록 하고자 하였다. 이상의 과정을 그림 1로 나타내었다.

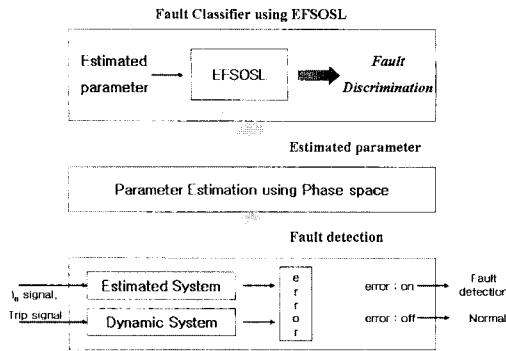


그림 1 제안하는 방법에 의한 고장판별
Fig. 1 Fault Classifier Using EFSOSL

2. Radial Basis Function(RBF) Network

2.1 RBF Network

RBF 네트워크는 빠른 학습 속도, 일반화, 단순화의 특징으로 데이터 분류, 비선형 시스템 모델링 등에 많이 적용되고 있다. 신경망의 관점에서 RBF네트워크는 3개의 층으로 구성된 전방향 신경망 형태를 갖추고 있다. 이런 구조적 형태의 특징으로 각 계층이 개별적인 순서를 결정하기 때문에 학습 속도가 다층 퍼셉트론 보다 빠른 특징을 가지고 있다.

전형적인 RBF 네트워크의 구조는 그림 2와 같다.




그림 2 RBF 네트워크
Fig. 2 RBF Network

여기서 입력층과 중간층간에는 클러스터링하는 역할을 수행하게 된다. 중간층에 있는 노드는 그 자신의 중심을 가지고, 입력 $X = \{x_1, x_2, x_3, \dots, x_n\}$ 에 대하여 자신과의 중심간의 거리벡터를 구한다. 이 노드의 출력은 거리 벡터에 대한 일정 형태의 비선형 함수로 얻어진다. 입력이 노드의 중심에 가까울수록 그 출력값은 커지게 된다. 중간층을 구하는 것은 식(1)과 같다.

$$\rho_k = \exp\left(\frac{-\|X - C_k\|^2}{\sigma_k^2}\right) \quad (1)$$

여기서 c_i 는 각 클러스터의 중심값이고 σ 는 중심에 대한 넓이 값이 된다. 중간층과 출력층간에는 일반적인 학습과

정을 수행한다. RBF 네트워크의 출력노드는 각 중간층 노드의 출력값에 학습과정 중 가변인 연결가중치를 곱한 후 이들을 더한 값을 그 출력값으로 갖는다. 그리고 식(2)와 같이 지도학습과 동일한 형태로서 목표값과 출력값 간의 오차값을 최소화하는 방향으로 학습한다.

$$y_i = \sum_{k=1}^M \rho_k w_{kj} \quad (2)$$

2.2 RBF Network의 문제점

RBF 네트워크는 학습이 완료된 상태 즉, 연결강도가 특정 값으로 고정된 상태에서 새로운 패턴을 학습시키게 되면 이미 설정된 모든 연결 강도에 영향을 주므로 RBF 네트워크를 다시 학습시키는데 상당한 시간이 소요되는 단점과 RBF 네트워크에 학습되지 않은 전혀 새로운 형태의 패턴이 들어오는 경우 이전에 학습된 유사한 패턴으로 분류해버리는 단점이 있다[4].

3. 개선된 FCM 알고리즘을 이용한 퍼지 RBF Network

3.1 클러스터링 알고리즘

퍼지 RBF 네트워크에서 제안하는 중간층의 클러스터링 방법은 기존의 이분법과는 달리 퍼지 분류인 1개의 데이터가 2가지 이상의 클러스터에 속하는 것을 허용한다[5]. 퍼지 논리의 특징을 이용하여 이분법에 의한 ART1 알고리즘을 적용한 방법보다 효율적이고 정확성이 높은 중간층을 구성하기 위하여 본 논문에서는 기존의 FCM 알고리즘을 개선한 개선된 퍼지 RBF 네트워크를 제안하였다.

3.2 FCM(Fuzzy C-Means Clustering) 알고리즘

기존의 FCM 알고리즘은 다음과 같다. FCM 알고리즘은 소속도와 명기된 정보에 따라 각 데이터를 클러스터로 구성하는 것으로 n 개의 벡터 X_i 를 c 개의 퍼지 집합으로 나누고 각 집합의 클러스터들의 중심을 찾는 것이다. 식 (3)은 정규화를 규정하기 위하여 소속도를 나타내며 소속도의 합은 항상 1이 된다.

$$\sum_{i=1}^c u_{ij} = 1, \quad \forall j = 1, \dots, n. \quad (3)$$

여기서 u_{ij} 는 0과 1사이의 값으로 소속도를 나타낸다.

$$J = \sum_{i=1}^c J_i = \sum_{i=1}^c \left(\sum_{k, x_k \in G_i} \|x_k - c_i\|^2 \right) \quad (4)$$

$G_i, i = 1, \dots, c$ 라고 할 때, n 개의 X_i 집합의 X_k 벡터와 클러스터의 중심인 c_i 사이의 차이를 측정하는 유클리드 거리와 그 목표함수는 위 식 (4)와 같다.

$$J(U, c_1, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_j^n u_{ij}^m d_{ij}^2 \quad (5)$$

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 (5)가 최소값이 되기 위한 필요조건은 식 (6)과 같다.

$$\begin{aligned} \bar{J}(U, c_1, \dots, c_c, \lambda_1, \dots, \lambda_n) &= J(U, c_1, \dots, c_c) + \sum_{i=1}^n \lambda_i (\sum_{j=1}^c u_{ij} - 1) \quad (6) \\ &= \sum_{i=1}^c \sum_j^n u_{ij}^m d_{ij}^2 + \sum_{i=1}^n \lambda_i (\sum_{j=1}^c u_{ij} - 1) \end{aligned}$$

여기서 λ_i 는 라그랑지 곱셈자(Lagrange multiplier)이다. 식 (6)에서 최소가 되기 위한 조건은 다음과 같다.

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{k=1}^n (\frac{d_{ij}}{d_{kj}})^{2/(m-1)}} \quad (7)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c (\frac{d_{ij}}{d_{kj}})^{2/(m-1)}} \quad (8)$$

FCM 알고리즘은 식 (7), 식 (8)의 조건이 만족하도록 계속 반복한다.

3.3 개선된 FCM 알고리즘

전술되어진 바와 같이 기존의 FCM 알고리즘은 입력벡터들과 각 군집의 중심과의 거리를 이용하여 측정된 유사도에 기초한 목적 함수의 최적화 방식을 사용한다[6]. 그러나 측정된 패턴과 군집 중심과의 거리만을 이용하여 군집화 하는 알고리즘이기 때문에 군집공간상의 패턴들의 분포에 따라 바람직하지 못한 군집화 결과를 보일 수 있다[7].

예를 들면 군집공간상에 분포된 패턴들이 타원의 경계를 가지는 경우이거나 패턴의 분포가 군집 경계면에 존재하고 그 기본형이 서로 교차하는 경우를 들 수 있다. 이러한 경우에는 기본형의 중심으로부터 패턴간의 거리를 측정하는 유클리드 거리법 적용 시 올바르게 못한 군집화 결과의 원인이 될 수 있다. 따라서 본 논문에서는 대칭적 성질을 이용하는 대칭성 측도에 퍼지 이론을 적용하여 군집간의 거리에 따른 변화와 군집 중심의 위치, 그리고 군집형태에 따라 영향을 덜 받는 개선된 FCM 클러스터링 알고리즘을 적용한다. 개선된 FCM 알고리즘에서 적용하는 대칭성 측도는 다음 식 (9)와 같다.

식 (9)에서 $\text{deg}(x_i, x_j, c)$ 는 점 c 를 중심으로 점 x_i 와 점 x_j 의 각도를 의미하며, $\text{ratio}_d(x_i, x_j, c)$ 는 다음의 식 (10)과 같고, α 는 퍼지 이론을 이용한 가중치이다. 가중치 계산은 다음 식 (11)과 같다.

$$\begin{aligned} &\text{Symmetric}(x_i, c) \\ &= \max_{j \in \text{are} \setminus \text{pattern}, i \neq j} \left((1 - \alpha) \left(1 - \frac{\text{deg}(x_i, x_j, c)}{180} \right) - (\alpha * \text{ratio}_d(x_i, x_j, c)) \right) \quad (9) \end{aligned}$$

$$\text{ratio}_d(x_i, x_j, c) = \begin{cases} \frac{d(x_j, c)}{d(x_i, c)} & \text{if}(d_i > d_j) \\ \frac{d(x_i, c)}{d(x_j, c)} & \text{if}(d_i < d_j) \end{cases} \quad (10)$$

여기서 $d(x_j, c)$ 는 유클리드 거리를 의미한다.

$$\alpha = \frac{d(c_i, c_j)}{\sqrt{D_m}} \quad (11)$$

식 (9)를 이용하여 대칭성 측도를 구한 상수값을 $\mu(x)$ 라고 정의한 후, 군집의 중심값을 계산한다. 군집의 중심값 계산은 다음 식 (12)와 같다.

$$c^{(p)} = \frac{\sum_{k=1}^n (\mu_{ik})^m x_k}{\sum_{k=1}^n (\mu_{ik})^m} \quad (12)$$

개선된 FCM 알고리즘으로 군집화된 각 군집들의 중심값과 현재 패턴 사이의 유사도 U를 식 (13)을 이용하여 계산한다.

$$U = \sqrt{\sum_{i=0}^{k-1} (x_i - c_i)^2} \quad (13)$$

개선된 FCM 알고리즘의 학습과정은 그림 3과 같다.

3.4 개선된 FCM 알고리즘을 이용한 퍼지 RBF Network

FCM을 통하여 클러스터링 된 중간층의 클러스터들은 출력층의 입력 벡터로 사용하게 된다. 중간층과 출력층의 출력 벡터는 식 (14)와 같이 계산한다.

$$O_k = \frac{1}{1 + e^{-\left(\sum_{i=0}^{N-1} w_{kj} O_{ij} + \theta_k\right)}} \quad (14)$$

출력 벡터와 목표 벡터를 비교하여 식 (15)를 사용하여 오차신호를 구하고 식 (16), 식 (17)을 적용하여 연결강도와 바이어스를 조정한다.

$$\delta_k = (T_k - O_k) O_k (1 - O_k) \quad (15)$$

$$w_{kj}(t+1) = w_{kj}(t) + \alpha \delta_k z_j \quad (16)$$

$$\theta_k(t+1) = \theta_k(t) + \beta_k \delta_k \quad (17)$$

여기서 T값은 목표 벡터이고 w와 θ 은 연결강도와 바이어스이다. 제안된 개선된 FCM을 이용한 퍼지 RBF Network의 알고리즘은 그림 4와 같다.

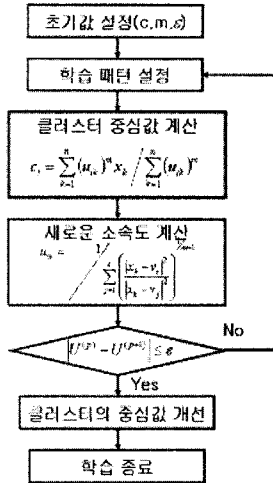


그림 3 개선된 FCM 알고리즘
Fig. 3 Enhanced FCM Algorithm

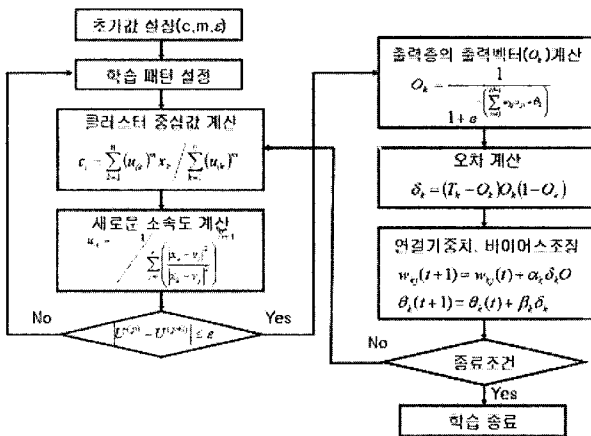


그림 4 개선된 FCM을 이용한 퍼지 RBF Network
Fig. 4 Fuzzy RBF Network Based on Enhanced FCM

4. 자료 취득 장치(Fault Recorder; F/R)

계통의 고장 전류 자료 취득 장치는 그림 5와 그림 6과 같다. F/R(Fault Recorder)은 전력설비에 취부되어 있는 PT(전압-변성기)와 CT(전류-변류기)의 2차 출력 값(전압 : 63.5/ 115V/ 190V, 전류 : 5A)으로 고장 발생 시 각상의 전압과 전류의 데이터 그리고 중성선의 데이터를 취득하여 저장 및 출력하여 주는 장치로서 샘플링 타임은 0.520833[ms]이고 전압전류 파형 AC Channel 16/32, DC Channel(on-off 접점) 32/64로 구성 되어 있다.




그림 5 자료 취득 장치 구성도
Fig. 5 Block Diagram of Fault Recorder




그림 6 고장기록장치(TR-2132)
Fig. 6 Fault Recorder(TR-2132)





그림 7 고장기록장치와 통신망
Fig. 7 Fault Recorder & Communication Network



(a) 시간 영역 (a) Time region
(b) 주파수 영역 (b) frequency region

그림 8 프로타스를 이용한 고장 데이터
Fig. 8 Fault Data Using ProTas

또한 그림 7에서 보여 지는 것과 같이 네트워크를 통하여 원거리에서도 자료를 취득하여 분석 할 수 있다. 이러한 일련의 과정을 통해 고장이 발생한 경우 현재는 그림 8의 (a), (b)에서와 같이 사고 시의 순시 전압, 전류의 파형과 주파수를 통해 고장의 발생을 파악하고 그 원인을 규명하기 위하여 ProTas, PSSE 등과 같은 보조 프로그램과 당시의 기후

등 여러 가지 조건들을 이용하여 원인을 유추하고 있으나 판단자의 경험에 의존하는 부분이 많으며 선로 순시원들 등에 의해 직접적으로 고장의 원인을 찾는 방법이 사용되어지고 있지만 시간적인 면에서 상당히 지연된 후의 상황이 되어지므로 정확한 원인 규명에는 어려움이 따른다. 그림 8의 (a), (b)는 ProTas를 이용한 사고시의 순시전압, 전류와 주파수이다.

5. 실험결과 및 결론

본 논문에서는 전술되어진 바와 같이 F/R로부터 얻어진 데이터 중 중성선의 전류를 가공하여 전처리 한 후 개선된 FCM을 이용한 RBF Network를 이용하여 고장 원인을 규명하고자 하였다. 데이터는 부산 경남 울산 소재의 F/R로부터 얻어진 고장 데이터를 사용하였으며 2001년부터 2006년까지의 데이터를 이용하였다.

5.1 고장 전류의 특성 벡터

우선 제안한 알고리즘의 구현을 위하여 고장전류 데이터를 FCM의 입력을 위한 하나의 데이터로 특징 지워야 하는데 시계열 데이터임을 감안하여 고장 전류가 나타나는 사이클 동안의 고장 전류 데이터를 전처리를 하여 사용하였다.




그림 9 섬락에 의한 애자 파손(원신호)
Fig. 9 Insulator breakdown by flashover(Original signal)




그림 10 섬락에 의한 애자 파손(FFT)
Fig. 10 Insulator breakdown by flashover(FFT)




그림 11 섬락에 의한 애자 파손(위상계적)
Fig. 11 Insulator breakdown by flashover(Phase space)

이를 위하여 고장 전류분과 고장전류의 변화분에 관해 위상 평면을 구성하여 이를 2X8의 벡터로 구성하여 실험의 입력으로 하여 이를 각각 구현하였다. 그림 9는 2001년 8월

5일 xx 지역의 섬락에 의한 애자파손의 데이터로 고장 전류이고 그림 10은 이의 FFT 결과이다. 그림 11은 제안한 위상계적에 의한 결과이다. 그림 12는 위상계적에 의해 추출된 데이터를 학습데이터로 만든 것이고 그림 13은 그 방법을 보인다.




그림 12 섬락에 의한 애자 파손(학습데이터)
Fig. 12 Insulator breakdown by flashover(Training Data)




그림 13 학습데이터 추출
Fig. 13 Extraction of Training Data

5.2 실험 결과 및 고찰

전술한 바와 같은 절차에 의해 고장 전류의 데이터를 이용하여 고장 원인을 판별하고자 하였다. 실험은 기존의 FCM과 개선된 FCM을 이용한 방법을 비교 고찰 하였다.

먼저 자연재해와 이물접촉, 설비고장, 인적실수, 정정불량의 5개 유형으로 나누어진 각종 사고에 의한 데이터를 입력하여 판별정도를 실험하고, 두 번째는 기존의 방법으로 판별이 힘든 자연재해와 이물접촉의 세부원인에 대하여 판별율을 조사하였다.[8]

실험 결과는 다음과 같다. 표 1은 자연재해와 이물접촉, 설비고장, 인적실수, 정정불량의 5개 유형으로 나누어진 각종 사고에 의한 데이터에 대한 판별율에 대한 결과로 기존의 FCM에 의한 방법에서는 총 50개 중 49개를 판별하였고, 개선된 FCM에 의한 방법으로는 50개 모두를 인식하였다. 표 2는 기존의 FCM 방법으로 판별이 힘들다고 결과가 나온 자연재해와 이물접촉의 세부원인에 대한 판별율의 결과이다. 자연재해는 낙뢰, 폭설, 폭우, 산불 등의 원인에 대한 결과이고, 이물접촉은 조수류 접촉, 크레인접촉, 비닐 및 은박지 등의 비례물 접촉 등의 원인에 대한 판별 정도를 나타낸다. 물론 낙뢰에 의한 고장 역시 지락고장과 애자파손 등으로 나누어지나 본 논문에서는 제외하였다. 결과에서 보이는 바와 같이 기존의 방법에 의해서는 총 20개의 유형 중 15개를 판별하였고, 제안한 방법에 의해서는 19개를 판별할 수 있었다.

표 1 FCM과 개선된 FCM에 의한 고장 전류 판별결과1
Table 1 Result of Fault Current Discrimination by FCM & EFCM 1

	FCM	개선된 FCM
반복횟수	214	182
생성된 중간층 노드수	16	9
판별 정도	49/50	50/50

표 2 FCM과 개선된 FCM에 의한 고장 전류 판별결과2
Table 2 Result of Fault Current Discrimination by FCM & EFCM 2

	FCM	개선된 FCM
반복횟수	352	211
생성된 중간층 노드수	9	8
판별 정도	15/20	19/20

전술되어진 바와 같이 계통은 외부에 노출이 되어 있기 때문에 항상 자연 재해나 여러 가지 원인에 의한 고장이 발생할 수 있다. 하지만 고장의 원인을 규명하는 것은 사고로부터의 계통의 신속한 복구와 정전구역의 확대를 막기 위해 정확하고 신속하게 이루어져야 한다. 현재까지의 고장 진단 및 원인 규명은 주로 숙련된 전문가의 경험 및 보조 프로그램(protas, PSSE) 등에 의해 해결되어 왔지만 긴 시간과 많은 노동력을 필요로 하기에 많은 인적·물적 비용이 요구되어 지므로 사고 시 고장 원인을 정확하게 빠른 시간 내에 판단하여 조치를 취하여 계통의 안정성 및 신뢰도를 확보함에 어려움이 따르는 것이 사실이다. 이에 본 논문에서는 제안한 방법에 의하여 고장 기록장치의 데이터를 통하여 고장의 원인을 판별하는 것이 가능하리라 사료되어 지므로 이전에 비해 작은 비용으로, 사고 원인에 따른 빠른 대응도 가능하여 질 것이라 생각된다.

향후, 본 논문의 결론에 대한 지속적인 검증과 본 논문에서 제시되어진 고장 유형 이외에 또 다른 유형의 사고 원인에 대한 정보를 확충하고 지속적인 연구를 진행, 다양한 사고 패턴 인식에 적용하고 그 학습 성능을 분석하여 더욱더 판별 성능을 높이고자 한다.

감사의 글

이 논문은 동아대학교 학술연구비 지원에 의하여 연구되었음

참 고 문 헌

[1] Aucoin B.M., Russell B.D., "Dustribution High Impedance Fault Detection Utilizing High Frequency Current Components", IEEE Trans. on Power Appartus and Systems Vol. Pas-101, NO. 6, pp. 1596 1606, June 1982.

[2] 이준탁, 정종원, "웨이블릿 변환을 이용한 전력시스템 고장전류의 판별", 조명·설비학회 논문지, 제21권 3호, pp.75-81, 2007, 3월.

[3] Martin T. Haugan, "Neural Network Design", PWS Publishing Company, 1996.

[4] M. L. Kothari, S. Madnari and R. Segal, "Othogonal Least Square Learning Algorithm Based Radial Basis Function Network Adaptive Power System Stabilizer", Proceedings of IEEE SMC, Vol. 1, pp. 542-547, 1997.

[5] R.L. Cannon, J.V. Dave, and J.C. Bezdk, "Efficient Implementation of Fuzzy C Means Clustering Algorithm," IEEE Trans. Pattern Anal. & Machine Int., Vol. PAMI-8, No.2, pp248-255, 1986.

[6] Arun D.K., Computer Vision and Fuzzy - Neural Systems, Prentice Hall PTR, 2001.

[7] J. bezdek, "A convergence theorem for the Fuzzy ISODATA clustering algorithm",IEEE Trans. Pattern Anal. Machine Intell., Vol. PAMI-2, No. 1, pp.1-8, 1980.

[8] 2006 보호계전기 동작상태 분석 보고서, 한국전력공사 송변전처 변전운영팀, 2006.

저 자 소 개



정 종 원 (鄭 鍾 元)

1998년 동아대 전기공학과 졸업. 2001년 부산대 메카트로닉스과 졸업(석사). 현재 동아대 대학원 전기공학과 박사과정
Tel : 051-200-6951
Fax : 051-200-7743
E-mail : jongwonj@hanmail.net



이 준 탁 (李 浚 柝)

1979년 동아대 전기공학과 졸업. 1981년 동 대학원 전기공학과 졸업(석사). 1988년 중앙대 대학원 전기공학과 졸업(공학박사). 1997년 日本 Tsukuba大學 客員教授. 2008년 현재 동아대 전기공학과 교수
Tel : 051-200-7740
Fax : 051-200-7743
E-mail : jtlee@dau.ac.kr