

# 부분방전 패턴인식을 위해 EMC센서를 이용한 최적화된 RBFNNs 분류기 설계

## Design of Optimized Radial Basis Function Neural Networks Classifier Using EMC Sensor for Partial Discharge Pattern Recognition

정 병 진\* · 이 승 철\* · 오 성 권†

(Byeong-Jin Jeong · Seung-Cheol Lee · Sung-Kwun Oh)

**Abstract** - In this study, the design methodology of pattern classification is introduced for avoiding faults through partial discharge occurring in the power facilities and local sites. In order to classify some partial discharge types according to the characteristics of each feature, the model is constructed by using the Radial Basis Function Neural Networks(RBFNNs) and Particle Swarm Optimization(PSO). In the input layer of the RBFNNs, the feature vector is searched and the dimension is reduced through Principal Component Analysis(PCA) and PSO. In the hidden layer, the fuzzy coefficients of the fuzzy clustering method(FCM) are tuned using PSO. Raw datasets for partial discharge are obtained through the Motor Insulation Monitoring System(MIMS) instrument using an Epoxy Mica Coupling(EMC) sensor. The preprocessed datasets for partial discharge are acquired through the Phase Resolved Partial Discharge Analysis(PRPDA) preprocessing algorithm to obtain partial discharge types such as void, corona, surface, and slot discharges. Also, when the amplitude size is considered as two types of both the maximum value and the average value in the process for extracting the preprocessed datasets, two different kinds of feature datasets are produced. In this study, the classification ratio between the proposed RBFNNs model and other classifiers is shown by using the two different kinds of feature datasets, and also we demonstrate the proposed model shows superiority from the viewpoint of classification performance.

**Key Words** : RBFNNs, PSO Algorithm, FCM Clustering, Partial discharge, EMC sensor, PCA

### 1. 서 론

전력 수요가 대도시 집중화 현상과 대체 에너지의 중요성이 커짐에 따라 그 전력 수요가 증가하고 대응량 전력 설비 등 점점 그 양을 확충해야만 하는 상황이다. 하지만 우리나라는 국토 면적이 협소한 나라에 속하여 발전소, 송·변전 설비 및 전기 설비 등 입지의 어려움은 더욱 심화되고 있는 실정이다. 따라서 이의 대책 안으로 기존의 오래된 전력설비의 관리 및 유지와 지속적인 점검을 통하여 위에서 언급한 문제들 또한 예방하는 것이다. 사고를 미리 감지하기 위한 진단기법 연구가 필요한 시점이고 현재 Off-line 이나 On-line 접근 방식 등 여러 가지 절연 열화 진단을 통한 전기기기를 유지하는 많은 방안 중에서 근래 들어 각광 받고 있는 부분 방전(partial discharge) 진단기법을 소개하고 부분방전의 패턴 분류율을 높이기 위하여 최적화 알고리즘을 이용한 Fuzzy C-Means(FCM) 기반 Radial Basis

Function Neural Networks(RBFNNs) 모델을 설명한다. 먼저 부분방전은 전기장치나 절연 시스템에서 온도, 전기장, 운전 조건과 진동 등에 의거한 다양한 스트레스에서 오는 부분적인 방전 현상으로 전극 간을 완전하게 절연하지 않고 유전체의 일부분에서 발생하는 것을 말한다. 부분방전은 여러 가지 패턴과 특징으로 종류가 나누어진다. 어떤 스트레스로 인하여 절연체 내에 공극이 생기기 발생하는 보이드 방전, 국부만이 절연 파괴되어 발생하는 코로나 방전, 표면을 따라 불꽃을 발생하는 표면 방전, 회전기기의 슬롯에서 발생하는 슬롯 방전 등 이러한 부분방전의 특징들 외에도 방전의 크기, 발생 수, 모양 및 위치에 대한 정보를 가지고 분류할 수 있다. 본 실험에서는 센서 자체에서 전기적인 잡음을 잡아주는 Epoxy Mica Coupling(EMC)센서를 사용하여 실험했고, Motor Insulation Monitoring System(MIMS) 장비를 통하여 데이터를 획득한다. 이 데이터는 보이드 방전 250개, 코로나 방전 435개, 표면 방전 270개, 슬롯 방전이 245개 총 1200개이며, 데이터 하나당 차원수가 360개로 구성되었다. 또한 각각의 데이터는 진폭의 크기와 초당 펄스 수의 특징을 가진다. 여기서 진폭의 크기를 최댓값으로 설정할 것인지 아니면 평균값으로 하여 데이터를 취득할 것인지 그 추출하는 과정에서 따라 특징 데이터가 나누어진다.

본 논문에서 전처리 Phase Resolved Partial Discharge

† Corresponding Author : Dept. of Electrical Engineering, The University of Suwon, Korea  
E-mail: ohsk@suwon.ac.kr

\* Dept. of Electrical Engineering, The University of Suwon, Korea.

Received : January 9, 2017; Accepted : August 2, 2017

Analysis(PRPDA) 과정을 통하여 두 개의 특징데이터를 모두를 다루었고 본문에서 설명을 자세히 다루기로 한다. 그 밖에도 Principal Component Analysis(PCA)과 Particle Swarm Optimization(PSO)를 통한 제안된 모델의 구조 및 파라미터를 최적화 시켜 분류기 성능을 확인 및 그 결과와 고찰에 대해 서술하고 결론을 설명한다.

## 1.1 연구의 동기 및 구현방법

발전설비 사고로부터 사회적 재산 및 인명의 피해를 최소화하기 위해 현재까지 다양한 알고리즘을 이용하여 On-line 부분방전 진단 방법에 관한 논문들이 제안되었다. 하지만, 아직까지 제안된 방법은 파라미터와 같은 다양한 조건들이 만족되어야만 현장에 적용이 가능하다. 대표적으로 부분 방전 진단법에 사용된 모델로는 Neural Networks(NN)와 Support Vector Machine(SVM) 등이 있다. 신경회로망은 모멘텀 계수, 반복 수, 학습률, 노드 수 등 많은 파라미터 설정이 필요하고, 파라미터의 변화에 따라 성능이 크게 달라질 수 있다. 즉, 파라미터 변화에 민감하기 때문에 현장 적용에 있어서 제한적이다. 그리고 SVM은 비교적 우수한 성능을 나타내지만, 부분 방전을 진단하는 속도에 한계를 갖고 있기 때문에 현장 적용에 있어 어려움을 갖는다. 또한 실용적인 관점에서 볼 때, SVM의 가장 심각한 문제는 알고리즘이 복잡하고, 이에 따른 프로그래밍의 메모리가 광범위하게 요구된다는 것이다. 현장에서는 On-line으로 부분 방전을 진단하는 방법보다 Off-line 진단 방법을 중요시 하는데, 그 이유로는 Off-line 진단이 On-line 진단에 비해 진단 결과가 우수하기 때문이다. 그러나 Off-line 진단의 가장 큰 단점은 현장 설비에 대한 지식을 갖춘 전문가만이 진단할 수 있고, 가동 중인 발전설비들을 정지한 상태로 진단을 수행해야만하기 때문에 시간 및 재정적인 부분에서 경제적 손실이 크다. 반면에 On-line은 방법은 발전설비가 가동 중인 상황에서도 진단이 가능하기 때문에 경제적 손실을 줄일 수 있고, 전문가의 도움 없이도 컴퓨터가 이를 진단하고 판단하여 사고를 사전에 예측 및 방지할 수 있기 때문에 On-line 진단 방법의 개발 및 연구가 요구된다.

따라서 본 연구에서는 FCM과 RBFNNs를 이용하여 현장 적용에 적합한 부분방전 진단 모델을 제안한다. 제안된 모델의 장점은 NN과 SVM 알고리즘에 비해 구조가 복잡하지 않고, 많은 파라미터를 요구하지 않는다. 또한 외부요건의 변화에도 유연하게 대처할 수 있는 장점을 갖고 있다. 제안된 모델의 구조 및 파라미터 최적화를 위해 PSO를 이용하고, 부분 방전 데이터의 차원 축소를 위해 PCA를 사용한다.

## 2. 부분방전 모의실험 및 데이터 구성

본 장에서는 부분 방전을 분석하기 위해 시료를 통한 모의실험과 각 부분 방전의 특징 및 패턴에 대해 서술한다. 그리고 부분 방전을 분류하기 위한 패턴 분석 과정에 대해서 나열한다.

### 2.1 부분방전 모의실험

#### 가. 모의 결함 선정

본 실험에서는 고전압, 변압기, 전력기기 및 절연 시스템 등에서 온도에 의한 열적 스트레스, 전기장에 의한 전기적 스트레스, 운전 조건에 따른 열화 스트레스, 진동 등에 의한 기계적 스트레스로 발생할 수 있는 다양한 종류의 부분 방전 중에서 보이드, 코로나, 표면, 슬롯 방전을 선별하여 4가지 모의실험을 진행하였다[1].

##### 1) 보이드 방전(Void discharge)

여러 가지 스트레스로 인하여 절연체 내에서 또는 전극과 고체절연물 사이에서 공극이 존재하게 된다. 이것이 원인이 되어 전계의 세기가 커지고 절연내력이 작아지며 전리가 일어나 절연 파괴가 발생한다. 또는 고체 유전체가 열화 되어 절연물의 수명이 짧게 되는데 이것을 가리켜 보이드 방전이라 한다[2][3].

##### 2) 코로나 방전(Corona discharge)

공기 속 방전의 한 형태이고 기압을 낮추면 점점 불안정해진다. 한쪽 전극의 주변에만 전기장이 집중될 때 전위의 경도가 큰 주변에 전리가 일어난다. 이 결과 여기에 전류가 밀집되어 공간 전하 효과가 생기고 그 부분만 낮은 소리와 함께 발광하는 것을 말한다. 다시 말하면 한쪽 전극의 전기장이 강해져 국부만이 절연 파괴되어 발생하는 것이 코로나 방전이고 이것은 극 사이의 일부에서 일어나기 때문에 아크 방전과 구분된다.

##### 3) 표면 방전(Surface discharge)

일반적으로 절연체의 표면에서 일어나는 현상으로 절연물의 두 전극 간에 인가전압을 점진적으로 높아지면서 다량의 전하를 보유할 때 전극 사이의 절연물 표면을 따라서 불꽃이 발생하여 발광이 동반된 방전이 발생한다. 이것을 표면 방전 혹은 연면방전이라 한다.

##### 4) 슬롯 방전(Slot discharge)

슬롯은 철심, 웨지, 권선 절연 및 구리 등으로 이루어져 있으며 권선 슬롯을 단면으로 볼 때 위치에 따라서 다양한 원인들로 부분 방전이 발생할 수 있다. 열적 스트레스로 절연층간의 층간에 단락이 생기기고 전도체가 단락되거나 매우 높은 국부적인 전기장이 일어나 전기적 스트레스가 일어나고 장기간 열화 과정에서 트리밍(Treeing)이 생긴다. 결과적으로 결함 부위에서 부분방전이 발생하고 지속적인 방전으로 국부적인 손상도 초래한다.

### 2.2 모의실험을 통한 데이터 구성

#### 가. EMC(Epoxy Mica Coupling) 센서

EMC 센서는 개폐기, 모터, 발전기, 변압기와 다른 보조 고전압 장치와 같은 AC 고전압의 전기적 절연에 대한 부분 방전의

민감한 부분을 감지하기 위한 장치이다. 순수 운모(광물) 조각으로 구성되고 8kV, 18kV, 28kV 전압 레벨로 구분된다. 잡음을 감쇄시키기 위해서 설치위치도 중요한데 권선에 근접하여 설치하는 것이 좋으나 센서의 위치는 장비에 따라 달리 설치된다.

나. EMC 센서를 이용한 데이터 측정 및 시스템 구성

본 실험에서 현장 부분방전 측정에 사용되는 여러 센서 중 EMC 센서를 이용하여 부분 방전 측정 데이터를 취득하기 위한 실험 장치의 구성을 아래 그림 1에 나타내었다. 변압기를 이용한 고전압을 3.8kV~6.8kV 사이로 전압을 인가하고 측정하고자 하는 부분 방전의 모의실험을 설계한다. 이때 발생하는 부분 방전의 전기적 신호를 EMC 센서가 잡는다. 이 획득한 신호를 MIMS 장비를 통해 다듬어지지 않은 데이터를 구축하게 된다.




그림 1 EMC 센서를 이용한 부분방전 측정 시스템의 개념도  
 Fig. 1 Concept map of partial discharge measurement system using EMC sensor

다. 데이터 전처리 과정

PRPDA는 가장 널리 알려진 일반화된 전처리 방법이고 현재 공학 분야에서 많이 사용되고 있다. PRPDA는 MIMS장비를 통해 진폭의 크기(Amplitude : AMP)와 초당 진동수(Pulse Per Second : PPS) 정보만을 갖는 취득 데이터를 60Hz의 전압 위상에 중첩시킨다. 이 중첩된 부분 방전 신호는 대략 15초 이상 총을 쌓으면 900번 정도 신호가 겹치어져 정보의 신뢰도를 높인다. 이 부분 방전 신호에 대한 방전 크기 함수  $q(\Phi)$ 와 방전 수 함수  $n(\Phi)$ 로 나타내어 분석하는 방법이다. 아래 그림은 15초 동안의 부분 방전을 중첩한 그림 2이다.

라. 부분방전 데이터 구축

본 연구에서는 한 주기에 대한 신호 즉, 파형의 길이는 16.66ms인 부분방전 신호를 측정하고 중첩된 데이터를 통하여 데이터를 구축한다. 이때 한 데이터 당 위상이 360°인 신호를 2° 간격으로 쪼개어 180개 구역으로 분할합니다. 분할된 각 구역 당 AMP와 PPS 정보가 쌓인 데이터를 갖추고 있으며 그 차원의 수는 360개가 된다. 이에 대한 설명은 그림 3과 같다.




그림 2 부분방전 데이터 중첩  
 Fig. 2 Superposition of partial discharge data set

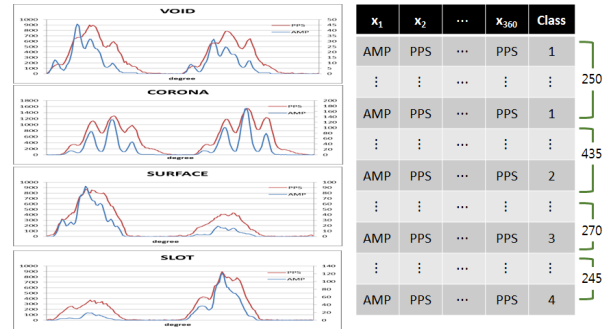


그림 3 EPRPDA 방법으로 구축된 부분방전 데이터 집합특징  
 Fig. 3 The partial discharge data set features built PRPDA method

3. PSO를 이용한 FCM기반 RBFNNs 패턴분류기 설계

3.1 PSO(Particle Swarm Optimization)

입자군집 최적화 알고리즘은 새와 물고기 떼와 같은 사회적 행동양식을 바탕으로 한 최적화 알고리즘이다. 이론이 간결하고 구현이 용이하며 단순한 수학 연산자를 사용하여 다른 확률적 방법보다 안정적으로 수렴한다. 또한 병렬처리가 가능하여 최적의 해를 빠른 시간 안에 생성할 수 있다. 본 논문에서는 PSO를 사용해 실험 파라미터를 최적화 시킨다[8].

3.2 PCA(Principle Component Analysis)

주성분 분석법은 대표적인 선형변환 특징추출 방법으로 공분산 행렬을 이용하여 구한 특징데이터를 입력데이터의 차원보다 작은 차원을 사용한다. 이때 실제 입력 값보다 작은 양의 특징을 가지고서 이용한다. 즉, 고차원의 입력데이터에서 저차원으로 축소되는 방법이기 때문에 축소 전 고차원의 실제 데이터 정보를 최대한 유지하면서 축소하는 것이 가장 중요하다. 차원을 축소하는 이유는 계산상의 부하 감소 및 노이즈 제거 효과도 기대할 수 있다. 현재 보유하고 있는 부분방전 데이터는 보이드 250개, 코로나 435개, 표면 270개, 슬롯 방전 245개로 구성되어 총 1,200개의 데이터를 가지고 있다. 각 데이터는 360 차원으로 이루어져 있다. 360 차원의 입력변수를 주성분 분석법을 통해 실험

하게 될 경우 사용하지 않았을 때보다 좀 더 효율적으로 실험을 진행할 수 있다. 본 실험에서는 입력변수 즉 차원수를 임의로 선정하여 실험하기도 하고 최적화 알고리즘을 통하여 찾은 파라미터로 패턴율과 성능을 구해보았는데 이 부분에 대한 설명은 뒤에 실험 및 고찰에서 자세하게 다루기로 한다[9].

### 3.3 제안된 RBFNNs 패턴분류기의 구조

신경회로망은 패턴학습을 반복하여 스스로 지식을 습득할 뿐만 아니라 규칙을 알 수 없는 상황에서의 특징과 패턴을 찾아가기 위해 많은 양의 데이터를 분석할 수 있는 능력을 가진다. 입력층, 은닉층, 출력층으로 신경회로망이 구성되어 있으며 각층을 구성하는 가장 중요하고 기본적인 요소는 크게 두 가지로 정의할 수 있는데, 인공 신경세포인 뉴런과 연결이다. 제안된 RBFNNs 패턴분류기는 신경회로망 기반으로 구성되어 있고, 기능적 모듈로서 조건부, 결론부, 추론부로 나누어 동작한다. 조건부에 각 규칙들은 가우시안과 같은 방사형 기저 함수를 활성화함수로 갖는데 본 논문에서는 FCM을 사용하여 데이터를 특징별로 나누어 중심값을 찾아가며 진행했고 조건부에서 변환된 활성화함수로 각 규칙마다의 적합도는 연결가중치 값과 곱해서 무게중심법을 통해 추론부에서는 최종 출력으로 나오게 되며, 이때 연결가중치의 값은 상수항과 같은 간략추론 말고도 1차식, 2차식과 같은 선형추론과 이것을 변형한 선형추론을 사용한다[7].

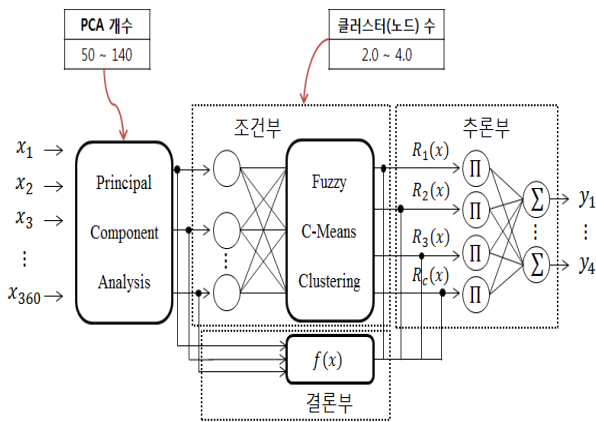


그림 4 PSO를 이용한 FCM 기반 RBFNNs 알고리즘  
 Fig. 4 FCM-based RBFNNs algorithm using PSO

본 논문에서는 PSO를 이용한 FCM 기반 RBFNNs 모델을 사용하고, 전처리 부분의 주성분 분석법을 통해서 부분 방전의 특징을 추출하여 데이터의 360차원에서 데이터의 정보 및 특징을 잃지 않은 범위내로 축소된 데이터를 생성한다. 생성된 특징데이터가 입력층에 입력되고, 은닉층으로 들어온 특징데이터는 FCM을 통하여 소속행렬의 소속정도를 계산한다. 이때 은닉층의 노드수는 클러스터 개수만큼 나오게 되고 소속정도는 기존의 조건부의 가우시안 함수를 통한 활성화함수의 적합도 개념과 동일하게 사용한다. FCM을 통해 계산된 적합도와 연결가중치를 이용하여 각

클래스 별로 출력을 계산한다. 사용되는 연결가중치는 1차 선형 추론(Linear), 2차 선형 추론(Quadratic), 변형된 2차 선형 추론(Modified Quadratic)이 있으며 본 논문에서는 1차식을 사용하였다[10]. 다항식 형태의 연결가중치를 사용함으로써 아래 식의 퍼지 규칙 표현과 같은 언어적 관점에서의 해석이 가능하다.

$$IF x_{ji} \text{ is } A_{ji} \text{ and } \dots \text{ and } x_{jk} \text{ is } A_{jk} \text{ then } f_{ji}(x_1, \dots, x_k) \quad (1)$$

여기서  $x_{ji}$ 는 입력벡터,  $A_{ji}$ 는 FCM에 의한  $i(i=1, \dots, c)$ 번째 그룹의 소속 함수,  $f_{ji}(x)$ 는  $i(i=1, \dots, s)$ 번째 출력에 대한  $j$ 번째 퍼지 규칙의 다항식이다. FCM을 사용함으로써 네트워크 측면에서는 활성화 함수를 언어적 측면에서는 소속 함수의 기능을 수행한다. 식 (1)의 'then' 이후 결론부의 다항식은 네트워크 연결가중치로, 퍼지 규칙의 로컬 모델로 동작된다. 추론부에서 네트워크의 최종출력은 퍼지 규칙의 추론 결과로서 구해진다. 이와 같이 개선된 RBFNNs 구조는 퍼지 규칙을 기반으로 한 네트워크 구조를 가지며, 조건부, 결론부, 추론부와 같이 세 가지 기능적 모듈로 분리되어 동작한다.

### 3.4 전반부 구조 동정 및 후반부 파라미터 동정

본 절의 전반부 구조 동정은 주어진 데이터의 입력변수의 선택과 멤버십 함수 형태(삼각형 또는 가우시안 함수 등)를 결정한다. 본 논문의 제안하는 RBFNNs는 기존 가우시안 함수 대신 FCM을 사용하였다. FCM은 비슷한 패턴, 속성, 형태 등의 기준을 통해 데이터를 분류하는 알고리즘으로, 데이터와 각 클러스터와의 거리를 기준으로 소속정도를 측정하여 데이터를 분류한다. 이는 활성화 함수의 적합도 개념과 동일해 다항식 기반 RBFNNs 모델의 은닉층 활성화함수 형태를 표현할 수 있다. 아래 단계를 통해 FCM 전반부 동정은 수행된다[5][6]. 후반부 다항식의 파라미터 계수는 Least Square Estimator(LSE) 학습방법을 사용하여 모델을 설계한다. LSE는 오차제곱의 합이 최소가 되도록 계수를 추정하며 후반부 다항식들의 계수를 한 번에 구하기 때문에 전역 모델의 학습에 수행 가능하다.

## 4. 시뮬레이션 및 결과 고찰

### 4.1 실험 개요 및 절차

본 연구에서 제안된 FCM기반 RBFNNs를 통해 패턴 분류 실험에 적용하였다. 부분방전 특징 중 AMP를 최댓값으로 주고 데이터를 획득한 것과 평균값으로 계산하여 획득한 데이터의 패턴 및 성능과 분류율을 비교하고 최적화 알고리즘을 사용하여 파라미터를 탐색하여 나온 값과 임의로 파라미터를 설정하여 패턴 분류율을 확인한다. 또한 패턴 분류기의 구체적인 성능을 평가하고 통계적 신뢰도를 높이기 위해서 전체데이터를 아래 표 1의 5-Fold Cross Validation을 사용하여 학습과 검증을 분할하여 실험을 진행하였다.

**표 1** 5-Fold Cross Validation을 이용한 평균 분류기

**Table 1** Average classifier using 5-Fold Cross Validation

학습	검증				테스트			
1	■	■	■	■	■	■	■	■
2	■	■	■	■	■	■	■	■
3	■	■	■	■	■	■	■	■
4	■	■	■	■	■	■	■	■
5	■	■	■	■	■	■	■	■

5-Fold Cross Validation는 데이터를 학습하는 과정에서 순차적으로 하나의 데이터만을 분류하지 않고 검증에 사용하여 각 분류기에서 얻는 패턴 분류율 및 성능을 평균 내어서 하나의 값으로 나타낸 분류기를 설계하고 학습과 검증에 사용하지 않은 테스트 데이터를 입력하여 인식률을 산출한다. 분류 과정은 아래의 단계와 같다.

**[Step 1]** 부분방전 시료를 통하여 모의실험 진행

슬롯에서 부분방전 발생이 잦은 시료를 가지고 모의실험을 한다. 이때 시료가 더 이상 실험으로 사용될 수 없을 때까지 각각의 부분방전의 특징 데이터를 축적시킨다.

**[Step 2]** 데이터 전처리

MIMS장비를 통해 축적된 데이터를 널리 알려진 PRPDA기법을 이용하여 방전의 크기와 방전 수로 데이터를 전처리하게 된다. 이때 AMP를 최댓값으로 할 것인지 평균값으로 할 것인지를 정한다.

**[Step 3]** 구축 과정

360°의 위상, 이를 2° 간격으로 쪼개어 180개 구역으로 분할한다. 이 쪼개진 구역 당 AMP와 PPS를 교차로 중첩한 데이터를 갖추게 된다. (입력변수 360개)

**[Step 4]** 최종적인 부분방전 분류

최종적으로 부분 방전을 분류하는 단계이고, 획득한 데이터 1200개, 입력변수가 360개를 제한된 RBFNNs에 입력하여 분류하게 된다. 이때 최적화 알고리즘을 통해 패턴 분류율을 높였고, 주 성분 분석법을 통하여 높은 차원의 데이터 공간에서 저차원으로 데이터 공간으로 줄여주면서 짧은 시간에 더 효과적인 분석이 가능하게 된다.

**4.2 파라미터 설정**

RBFNNs 패턴분류기를 구현하기 위해서 신경망의 입력으로는 360개의 입력변수를 최적화알고리즘을 통하여 [40 80] 차원 영역을 탐색 및 축소해가며 특징데이터를 사용하였다. 또한 은닉층 노드의 개수와 FCM의 퍼지화 계수도 최적화 알고리즘을 통해 각각 [2 4], [1.1 3.0] 값 중 가장 좋은 성능을 탐색한다. 각 출력 클래스 당 데이터를 50%는 학습하였고, 30%는 검증, 나머지 20%는 테스트 데이터로 사용하였다. 데이터의 개수가 적기 때문

에 후반부 다항식은 Type 1인 Linear으로 고정시켰고, 그 밖의 효율적인 학습을 위한 파라미터의 탐색 범위 및 최적화 파라미터는 아래 표 2와 같이 설정하였다[11].


**표 2** PSO를 이용한 RBFNNs 모델 구축을 위한 파라미터

**Table 2** Parameters for building of RBFNNs model using PSO

PSO관련 파라미터	
No. of Generations	100
Swarm Size	50
$V_{max}$	20%
$[W_{min} W_{Max}]$	[0.4 0.9]
$C_1, C_2$	2.0
후반부 다항식 차수	Type 1 (Linear)
탐색 범위	
No. of Dimensions	[40 80]
No. of Rules	[2 4]
Fuzzification coefficient	[1.1 3.0]

**4.3 최댓값 데이터와 평균값 데이터의 부분방전 패턴 비교**

데이터를 전처리하는 과정에서 진폭의 크기를 최대로 하여 뽑았을 때와 평균을 내어 추출할 때의 총 2개의 특징데이터가 나오게 된다. 이 두 개의 특징데이터가 어떻게 각 부분방전마다 다른 특징을 보이는지 그림을 통하여 비교 확인해 본다. 먼저 보이드 방전의 특징은 Negative(0°에서 90°)와 Positive(180°에서 270°)부근에 AMP 및 PPS가 밀집된 분포도의 패턴특징을 보인다. 최댓값의 특징 데이터 그림 (a)와 평균값의 특징 데이터 그림 (b)가 비슷한 양상을 보인다[4].



**그림 5** 보이드 데이터 최댓값과 평균값 특징 비교

**Fig 5** Pattern feature comparison of void discharge data of maximum and average value

코로나 방전의 특징은 전압 위상 90°와 270°를 중심으로 양 옆으로 고르게 AMP 및 PPS가 밀집된 분포도의 패턴특징을 나타낸다. 최댓값의 특징 데이터 그림 (a)와 평균값의 특징 데이터 그림 (b)가 비슷한 양상을 보이지만 그림 (b)의 경우 기준이 되는 90°와 270°의 우측으로 AMP와 PPS의 분포도가 쏠리는 특징을 보인다.




그림 6 코로나 데이터 최댓값과 평균값 특징 비교

Fig 6 Pattern feature comparison of corona discharge data of maximum and average value

표면 방전의 특징은 Positive(180°에서 270°)보다 Negative (0°에서 90°)쪽에 AMP 및 PPS가 밀집된 분포도의 패턴특징을 나타낸다. 하지만 최댓값의 특징 데이터 그림 (a)는 명확하게 그 기준을 보이지만 평균값의 특징 데이터 그림 (b)는 Positive와 Negative부근의 분포도가 비슷하여 표면 방전의 특징을 나타내기가 모호하며 표면상으로는 보이드 방전의 특징과 비슷하게 보여 진다.




그림 7 표면 방전 데이터 최댓값과 평균값 특징 비교

Fig 7 Pattern feature comparison of surface discharge data of maximum and average value

슬롯 방전의 특징은 앞에서 설명한 표면 방전과 반대로 Negative(0°에서 90°)보다 Positive(180°에서 270°)쪽에 AMP 및 PPS가 밀집된 분포도의 패턴특징을 나타낸다. 하지만 표면 방전과 마찬가지로 최댓값의 특징 데이터 그림 (a)는 명확하게 그 기준을 보이지만 평균값의 특징 데이터 그림 (b)는 Positive와 Negative 부근의 분포도가 비슷하여 표면 방전의 특징을 나타내기가 모호하며 표면상으로는 보이드 방전과 표면방전의 특징과 비슷하게 보여진다.




그림 8 슬롯 방전 데이터 최댓값과 평균값 특징 비교

Fig 8 Pattern feature comparison of slot discharge data of maximum and average value

#### 4.4 실험을 통한 성능 평가

최적화를 사용했을 때와 하지 않았을 때를 비교한다. 최적화를 사용하지 않았을 경우, 은닉층의 노드 수 [2 4] 영역에서 퍼지화 계수 2.0일 때, 입력벡터(차원수)는 PCA를 사용하여 임의로 선정 해주었다. PCA를 사용하지 않았을 경우도 나머지 모든 파라미터 조건을 동일하게 하여 실험하여 비교한다. 제안된 RBFNNs 패턴 분류기 뿐만 아니라 신경회로망과 SVM 분류기도 실험하여 패턴 분류율을 비교하였다. 그리고 데이터를 부분방전 AMP의 최댓값 데이터와 평균값 데이터 두 가지로 나누어서도 비교해 보았다.

표 3 제안된 RBFNNs를 이용한 평균 데이터의 실험 결과

Table 3 Results of experiment of average data using proposed RBFNNs

Opt	NR	Di	PCA	TR_CR	TE_CR		
without Opt	2	360	with PCA	40	95.62±0.48	94.00±1.33	
				50	96.50±0.30	93.91±0.86	
				60	97.16±0.31	93.91±0.86	
				70	97.52±0.26	93.16±1.43	
	without PCA				100.00±0.0	85.75±1.75	
	3		with PCA	40	96.81±0.66	95.16±1.40	
				50	97.62±0.48	94.25±1.07	
				60	98.31±0.17	94.50±0.90	
				70	98.70±0.11	95.16±0.75	
	4		with PCA	40	98.20±0.20	96.00±0.69	
				50	98.56±0.20	95.58±1.08	
				60	99.00±0.28	95.66±1.12	
70		99.37±0.12		95.58±1.33			
with Opt	3	2.757	60	99.20±0.29	96.31±1.87		

Optimization(Opt), Number of rules(NR), Fuzzification coefficient(FC), Number of dimensions(Di), Number of reduced dimensions using PCA(PCA), Training data for classification rate(TR\_CR), Test data for classification rate(TE\_CR)

먼저 표 3을 통해 최적화 알고리즘을 이용한 제안된 방사형 기저함수 신경회로망의 출력과 최적화 알고리즘을 사용하지 않은 방사형 기저함수 신경회로망의 출력을 비교 확인했다. PSO를 사용하지 않았을 때 파라미터 값을 규칙 수는 [2 4]로 퍼지화 계수는 2로 고정시켰고 PCA를 통해서 차원수를 [40 70] 사이 10씩 차이를 두어 실험했고 마지막으로 PCA를 사용하지 않았을 때와 비교해보았다. 그 결과 규칙 수 4, PCA를 이용한 차원 수가 40일 때 학습 성능이 98% 이상의 패턴 분류율을 보여주고 테스트 성능도 96% 이상의 패턴 분류율을 보여준다. 또한 전체적으로 주성분 분석법을 사용했을 때와 사용하지 않았을 때를 살펴볼 때, 주성분 분석법을 통한 특징들을 추출하여 분류기를 이용할 때 더 좋은 패턴 분류율과 시간단축 효과를 나타낸다. 마지막으로 PSO를 통하여 최적의 파라미터 값을 탐색하여 나온 패턴 분류율이 PSO를 사용하지 않았을 때보다 미세하지만 더 나은 성능을 나타내고 있다.

표 4 BP-NN를 이용한 부분방전 패턴인식 결과(평균값 데이터)

Table 4 Results of partial discharge pattern recognition using BP-NN(Average data)

NH	LR	MC	NI	TR_CR	TE_CR
15	0.005	0.15	300	86.71±6.55	83.17±5.87
25	0.005	0.15	300	88.56±3.55	84.75±4.19
35	0.005	0.15	300	85.52±16.5	81.58±14.0
45	0.005	0.15	300	65.04±20.0	63.58±18.6

Number of Hidden Nodes(NH), Learning Rate(LR), Momentum Coefficient(MC), Number of Iteration(NI)

위 표 4는 기존의 다른 Back Propagation-Neural Networks (BP-NN) 모델을 부분방전 데이터를 넣어서 학습률을 0.005, 모멘텀 계수를 0.15, 세대수를 300으로 고정시키고 은닉층의 노드수를 [15 45] 영역에서 10단위씩 노드수 변화를 주면서 학습과 테스트를 비교한다. 그 결과 은닉층의 노드수 25일 때, 학습 성능이 88%, 테스트 성능이 84% 패턴 분류율이 가장 높은 성능을 보여주고 있다. 하지만 제안된 RBFNNs 분류기보다는 떨어지는 성능을 나타내고 있다.

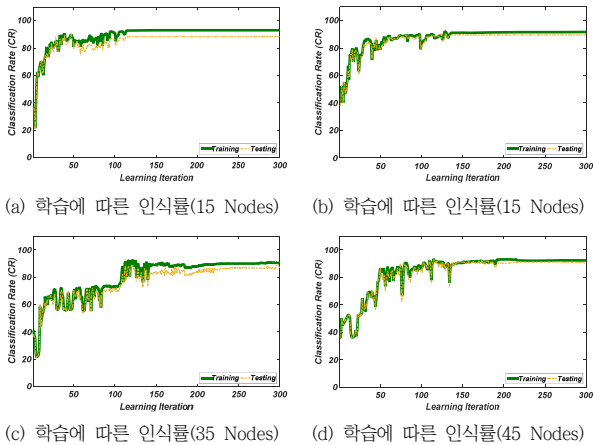


그림 9 BP-NN 의한 패턴인식률(평균값 데이터)

Fig 9 Pattern recognition for BP-NN (Average data)

오류 역전과 알고리즘은 오늘날 가장 유명한 신경회로망 학습 규칙 중의 하나인 알고리즘으로 다층 신경망 학습은 입력층의 입력 값과 기술기에 의한 탐색하는 과정에서 기대되는 출력층 노드에서 원하는 목표값을 가지고 오차함수를 최소화시켜 연결강도를 최적화하는 방법이다[11]. 이때 오차를 바로 아래층뿐만 아니라, 그것에 달린 더 아래층 뉴런까지 전달함으로써 연결가중치를 조절해 준다. 이러한 특징으로 최적 매개변수로서의 탐색방향을 결정하는 강하방법의 알고리즘이다. 그림 9는 신경회로망의 오류 역전과 알고리즘을 통해 더 나은 성능을 찾아가는 모습을 그래프로 나타낸 것이다.

표 5 SVM를 이용한 부분방전 패턴인식 결과(평균값 데이터)

Table 5 Partial discharge pattern recognition using SVM (Average data)

Type	Di	PCA	TR_CR	TE_CR	
l	360	with PCA	40	96.47±0.55	92.75±1.54
			50	97.16±0.37	92.50±1.74
			60	97.77±0.15	93.75±0.65
		without PCA	70	97.75±0.27	93.00±0.99
q	360	with PCA	40	100.00±0.0	88.83±0.90
			50	100.00±0.0	89.58±1.21
			60	100.00±0.0	88.50±2.40
		without PCA	70	100.00±0.0	87.75±0.95
p	360	with PCA	40	99.97±0.04	88.16±1.92
			50	99.97±0.04	87.50±2.30
			60	99.97±0.04	86.25±2.31
		without PCA	70	99.89±0.10	82.91±2.48
r	360	with PCA	40	100.00±0.0	57.16±1.36
			50	100.00±0.0	48.33±3.04
			60	100.00±0.0	41.83±1.27
		without PCA	70	100.00±0.0	37.50±0.65
		without PCA	100.00±0.0	36.25±0.00	

linear(l), quadratic(q), polynomial function(p), rbf function(r)

표 5는 SVM 모델을 다항식 유형별 linear, quadratic, polynomial, rbf와 주성분 분석법을 통하여 차원수를 임의로 선정하고, 변화시켜가면서 성능을 나타냈다. 또한, 주성분 분석법을 사용하지 않았을 때의 값도 비교 정리하였다. 실험 결과 4개의 다항식 유형 중 linear를 선택하고 PCA를 통한 차원수를 60이 될 때, 학습 성능이 97%, 테스트 성능이 93% 이상의 패턴 분류율이 가장 좋은 성능을 보여줬다. quadratic이 유일하게 PCA를 사용하지 않고서 차원수를 그대로 입력했을 때 PCA를 사용했을 때보다 나은 패턴 분류율을 보여줬고 나머지 다항식에서는 PCA를 하는 것이 패턴 분류율이 좋았지만 제안된 RBFNNs 분류기보다는 떨어지는 성능을 보여주었다. 부분방전의 데이터 추출을 AMP의 평균값을 선택하여 특징데이터를 뽑아 제안된 RBFNNs 모델과 최적화 알고리즘도 불여가면서 비교해보았고 뿐만 아니라 기존의 모델을 신경회로망과 SVM도 함께 돌려가면서 패턴 분류율을 비교했다. 아래는 데이터 추출을 진폭의 값을 평균값이 아닌 최댓값을 이용하여 특징데이터를 사용하여 각 모델을 비교 정리해 보았다.

표 6은 제안된 모델에서 최적화 알고리즘을 사용하지 않은 것과 사용한 것을 나누어서 정리했고, PSO를 사용하지 않은 모델에서는 규칙수를 [2 4] 영역으로 퍼지화 계수는 2.0으로 고정시켰고 차원수는 주성분 분석법을 통하여 임의로 선정하여 패턴 분류율을 나타냈다. 마지막으로 주성분 분석법을 사용한 것과 사용하지 않았을 때의 성능도 확인해보았는데 PCA를 사용했을 때 빠른 분류율과 성능도 좋게 나왔을 확인했다. 노드수가 4개이고 차원수가 50일 때 학습 성능이 99%, 테스트 성능이 98%로 가장 좋은 패턴 분류율을 보여줬다. 하지만 임의로 선정한 노드수에

다른 변화는 큰 차이가 없는 것으로 확인했고, PSO를 이용한 제안된 모델이 좀 더 나은 패턴 분류율을 나타냈다.

표 6 제안된 RBFNNs를 이용한 최대 데이터의 실험 결과

Table 6 Results of experiment of maximum data using proposed RBFNNs

Opt	NR	Di	PCA	TR_CR	TE_CR	
without Opt	2	360	with PCA	40	98.00±0.29	97.41±1.15
				50	98.20±0.23	97.66±0.91
				60	98.45±0.13	97.66±0.95
				70	98.79±0.11	97.66±0.75
			without PCA	100.00±0.0	85.50±1.87	
			3	with PCA	40	98.68±0.09
	50				99.00±0.11	98.16±0.95
	60				99.37±0.12	97.83±0.95
	70				99.50±0.28	98.25±1.03
	without PCA			100.00±0.0	85.50±1.87	
	4			with PCA	40	99.27±0.16
			50		99.50±0.13	98.91±0.75
60		99.68±0.07	98.41±1.19			
70		99.75±0.05	98.66±1.36			
without PCA		100.00±0.0	85.50±1.87			
with Opt		3	2.468	75	99.86±0.07	98.95±0.88

표 7 BP-NN를 이용한 부분방전 패턴인식 결과(최댓값 데이터)

Table 7 Results of partial discharge pattern recognition using BP-NN(Maximum data)

NH	LR	MC	NI	TR_CR	TE_CR
100	0.0013	0.005	300	89.85±3.85	89.67±4.41
110	0.0013	0.005	300	95.23±1.62	93.33±1.72
120	0.0013	0.005	300	89.83±8.84	87.83±7.27
130	0.0013	0.005	300	86.73±12.8	85.67±13.0

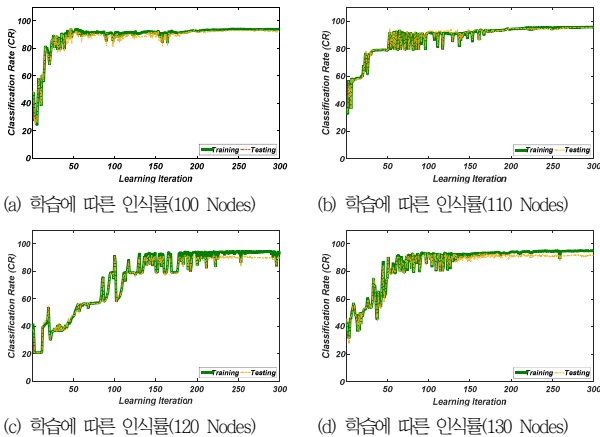


그림 10 BP-NN 의한 패턴인식률(최댓값 데이터)

Fig 10 Pattern recognition for BP-NN (Maximum data)

표 7은 기존의 신경회로망의 최댓값 특징데이터를 넣어서 돌렸을 때의 성능을 표로 정리했고 학습률을 0.0013, 모멘텀 계수

를 0.005, 반복수는 300으로 고정시켰으며 노드수 100에서 130까지 10단위씩 은닉층의 노드수 변화를 주어가며 그에 따른 성능 비교했다. 비교 결과, 노드수가 110일 때 패턴 분류율 학습 성능이 95%, 테스트 성능이 93%로 가장 우수하다. 그림 10은 BP-NN 과정을 통해서 부분방전 최댓값 데이터가 좋은 성능을 찾아가는 과정을 각 노드마다 그래프로 나타내었다.

표 8 SVM를 이용한 부분방전 패턴인식 결과(최댓값 데이터)

Table 8 Partial discharge pattern recognition using SVM (Maximum data)

Type	Di	PCA	TR_CR	TE_CR		
l	360	with PCA	40	97.79±0.23	96.00±0.47	
			50	97.87±0.37	96.08±0.63	
			60	98.10±0.25	95.25±1.54	
			70	97.87±0.36	94.50±0.45	
		without PCA	100.00±0.0	90.41±2.22		
		q	with PCA	40	100.00±0.0	96.25±1.06
				50	100.00±0.0	94.25±0.54
				60	100.00±0.0	93.16±1.46
				70	100.00±0.0	92.16±2.25
			without PCA	100.00±0.0	90.00±1.25	
			p	with PCA	40	100.00±0.0
		50			100.00±0.0	92.25±0.81
60	99.95±0.05	89.83±0.86				
70	99.93±0.05	89.00±0.22				
without PCA	81.97±0.38	50.75±3.49				
r	with PCA	40		100.00±0.0	52.25±3.56	
		50	100.00±0.0	39.91±1.70		
		60	100.00±0.0	36.91±0.22		
		70	100.00±0.0	36.50±0.37		
	without PCA	100.00±0.0	36.25±0.00			

표 8은 기존의 다른 모델 SVM에 최댓값 데이터를 넣어서 각 다항식 유형 Linear, Quadratic, Polynomial, RBF 마다 기존의 차원수 360을 주성분 분석법을 통하여 일정 패턴으로 변화를 주어 실험하였고, 또한 주성분 분석법을 사용하지 않았을 때와 얼마나 차이가 있는지도 비교 실험해보았다. 다항식 유형이 Quadratic 이면서 주성분 분석법을 통한 차원수가 40일 때, 학습 성능이 100%, 테스트 성능이 96%로 가장 좋은 성능을 보여주고 있다.

표 9는 PSO를 이용한 RBFNNs 모델과 기존의 다른 모델 신경회로망과 SVM 모델 출력의 패턴 분류율 중에서도 각 모델별로 잘 나온 성능을 뽑아서 한 표에다가 정리한 것이다. 노드 수, 다항식, 차원수의 변화를 주어 성능을 뽑았고, 주성분 분석법을 사용했을 때의 성능과 사용하지 않았을 때를 비교했을 때 주성분 분석법을 사용하여 분류했을 때 더 좋은 성능을 보여주었다. 또한 데이터를 추출하는 과정에서 진폭의 크기를 평균값과 최댓값 두 개의 특징으로 뽑은 특징데이터를 구분하여서 비교 나타내었다.

먼저 진폭을 최댓값으로 선택하여 뽑은 특징 데이터가 각 부분방전의 특징들을 뚜렷하게 나타냈고 평균값으로 추출했을 때는 데이터의 특징이 최댓값으로 뽑았을 때보다 모호하여 분류기에 두 데이터를 넣어 성능을 비교해본 결과 미세하지만 진폭을 최댓값으로 뽑은 데이터의 패턴 분류율이 더 나은 패턴 패턴율을 보



여겼다. 최종적으로 최적화를 통하여 최적의 파라미터를 탐색하여 뽑은 성능이 큰 차이는 없지만 학습 성능이 99%, 테스트 성능이 96%로 우세한 결과 값을 나타낸다.

**표 9** 각 데이터별 모델의 유형에 따른 선별된 패턴 분류율 비교  
**Table 9** Comparison of pattern classification rate selected according to types of Models for each dataset

Types of Models		NR	T	De	PCA	TR_CR	TE_CR
NN[11]	110	c	m	X		95.23±1.62	93.33±1.72
	25					a	88.56±3.55
SVM[12]	N/A	q	m	O	40	100.00±0.0	96.25±1.02
		l	a	O	60	97.77±0.15	93.75±0.65
Pro	without PSO	4	m	O	50	99.50±0.13	98.91±0.75
		4				a	O
	with PSO	3	m	O	75	<b>99.86±0.07</b>	<b>98.95±0.88</b>
		3				a	O

Type(T), Data extraction method(De), constant(c), maximum data(m), average data(a), Proposed model(Pro)

### 5. 결 론

본 논문에서는 현장에서 일어날 수 있는 여러 가지 변수들로부터 우수한 성능으로 진단하여 실용화할 수 있도록 최적화 알고리즘을 통한 Fuzzy C-Means기반 RBFNNs 패턴분류기를 설계하였다. 최적화 알고리즘을 통해 최적의 위치 정보를 탐색하여 주 성분 분석법을 75개로 입력변수를 선택 및 은닉층의 규칙수가 3개이고 퍼지화 계수가 2.468일 때가 테스트 데이터의 목적함수 패턴 분류율이 98.95%로 가장 우수함을 확인하였다. 이는 부분방전 데이터를 추출하는 과정에서 AMP를 최댓값으로 선정하여 데이터를 취득한 경우의 파라미터 값과 패턴 분류율이고 AMP를 평균값으로 데이터를 취득했을 때는 차원수가 60, 은닉층의 규칙수가 3 그리고 퍼지화 계수가 2.757로 PSO를 통하여 탐색한 파라미터 값이다. 이때 패턴 분류율(목적함수) 96.31%로 가장 뛰어난 성능을 보여주는 것을 확인하였다. 이것으로 평균값을 통한 데이터 추출보다는 최댓값으로 데이터를 축적하는 것이 뚜렷한 패턴 특징을 보여준다. 이뿐만 아니라 다른 분류기에서도 평균값 데이터보다 최댓값의 특징 데이터로 분류하는데 더 뛰어난 것을 보여줬는데 이는 최댓값의 특징 데이터가 뚜렷한 특징을 나타내어 상대적으로 그 특징들이 모호한 평균값 데이터보다 더 나은 패턴 분류율을 나타내고 있는 것으로 확인된다.

향후 연구방향으로는 부분방전 감지 센서 2개 이상을 사용하여 데이터를 취득하여 부분방전을 분류하고 현장에는 노이즈와 같은 데이터를 축적하는데 많은 방해요소가 존재하는데 이와 같은 경우의 대안으로 효과적인 분류를 위한 노이즈 제거 방법을 연구하고 노이즈 데이터를 취득하여 기존 부분방전 외에도 노이즈를 분류할 계획이다. 본 실험에서는 AMP를 최댓값과 평균값으로 축적된 특징 데이터를 사용했지만 향후에 중간값을 통한 특징

데이터를 사용하고 제안된 분류기에 적용시켜 설계 및 패턴분류에 의한 해석을 진행할 예정이다.

### 감사의 글

This search was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Science, ICT & Future Planning (NRF-2015R1A2A1A15055365) and by the Ministry of Education (NRF-2017R1D1A1B03032333)

### Reference

- [1] Keon-Jun Park, Gil-Sung Kim, J-Y Back, Won Choi, W-J Kim, Jeong-Tae Kim, Sung-Kwun Oh, "A Study on Partial Discharge Pattern Recognition Using Neuro-Fuzzy Techniques", The transactions of The Korean Institute of Electrical Engineers 57, 2313-2321, 2008.12
- [2] Lianwei Bao, Jian Li, Jing Zhang, Tianyan Jiang, "Partial Discharge Process and Characteristics of Oil-Paper Insulation under Pulsating DC Voltage", Journal of Electrical Engineering & Technology 11, 437-445, 2016. 03
- [3] S. M. Hassan Hosseini, S. M. Hosseini Bafghi, "Comparison of High Frequency Detailed Generator Models for Partial Discharge Localization", Journal of Electrical Engineering & Technology 10, 1752-1758, 2015. 7
- [4] Aulia, Mohd Hafizi Ahmad, Zulkurnain Abdul-Malek, Yanuar Z. Arief, Kwan Yiew Lau, Novizon, "Partial Discharge Characteristics in LLDPE-Natural Rubber Blends - Correlating Electrical Quantities with Surface Degradation", Journal of Electrical Engineering & Technology, 699-706, 2016.5
- [5] Wook-Dong Kim Sung-Kwun Oh, Hyun-Ki Kim, "Structural Design of FCM-based Fuzzy Inference System : A Comparative Study of WLSE and LSE", The transactions of The Korean Institute of Electrical Engineers 59, 981-989, 2010.5
- [6] Jeong-Hwan Lee, "A Setting of Initial Cluster Centers and Color Image Segmentation Using Superpixels and Fuzzy C-means(FCM) Algorithm", Journal of Korea Multimedia Society 15, 761-769, 2012.06
- [7] Min-Seok Kang, Seong-Hyeon Lee, Sang-Hong Park, Seung-Yong Shin, Eunjung Yang, Kyung-Tae Kim, "Inter-Pulse Motion Compensation of an ISAR Image Generated by Stepped Chirp Waveform Using Improved

Particle Swarm Optimization", The Journal of Korean Institute of Electromagnetic Engineering and Science 26, 218-225, 2015.2

- [8] Chookiat Kiree, Danupon Kumpanya, Satean Tunyasrirut, Deacha Puangdownreong, "PSO-Based Optimal PI(D) Controller Design for Brushless DC Motor Speed Control with Back EMF Detection" Journal of Electrical Engineering & Technology 11, 715-723, 2016.5
- [9] Joonhyuck Lee, Gabjo Kim, Sangsung Park, Dongsik Jang, "Generating Firm's Performance Indicators by Applying PCA", Journal of Korean Institute of Intelligent Systems 25, 191-196, 2015.04
- [10] Mingwen Zheng, Yanping Zhang, "An Algorithm to Determine RBFNN's Center Based on the Improved Density Method", Open Journal of Applied Sciences, 1-5, 2014.04
- [11] Kim, Joong-Hyo, Kwon, Sung-Dae, Hong, Jeong-Pyo, Ha, Tae-Jun, "Development of Optimum Traffic Safety Evaluation Model Using the Back-Propagation Algorithm", JOURNAL OF THE KOREAN SOCIETY OF CIVIL ENGINEERS 35(4), 2015.6, 679-690
- [12] Jinju Hong, Sehan Kim, Jeawon Park, Jaehyun Choi, "A Malicious Comments Detection Technique on the Internet using Sentiment Analysis and SVM", Journal of the Korea Institute of Information and Communication Engineering 20, 260-267, 2016.2



**이 승 철 (Seung-Cheol Lee)**

2014년 : 수원대학교 전기공학과 졸업  
 2016년 : 수원대학교 전기공학과 공학석사  
 2016년 6월~현재 (주)파워피디  
 관심분야 : 뉴럴 네트워크, 퍼지 추론 시스템, 패턴 분류  
 Phone : +82-31-222-6544  
 E-mail : lsc225@suwon.ac.kr



**오 성 권 (Sung-Kwun Oh)**

1981년 : 연세대학교 전기공학과 공학사  
 1983년~1989년 : 금성산전연구소(선임연구원)  
 1993년 : 연세대학교 전기공학과 공학박사  
 1996년~1997년 : 캐나다 Manitoba 대학 전기 및 컴퓨터 공학과 Post-Doc  
 1993년~2004년 : 원광대학교 전기전자 및 정보공학부 교수  
 2005년~현재 : 수원대학교 전기공학과 교수  
 2002년~현재 : 대한전기학회, 퍼지 및 지능시스템학회 편집위원  
 2013년~현재 : Information Sciences 편집위원  
 관심분야 : 퍼지 시스템, 퍼지-뉴럴 네트워크, 자동화 시스템, 고급 Computational Intelligence, 지능제어 등.  
 Phone : +82-31-229-8162  
 E-mail : ohsk@suwon.ac.kr

저 자 소 개



**정 병 진 (Byeong-Jin Jeong)**

2016년 : 수원대학교 전기공학과 졸업  
 2016년~현재 : 동 대학원 석사과정  
 관심분야 : 퍼지 이론, 컴퓨터 지능 및 지능 제어, 뉴럴 네트워크, 패턴 분류 등.  
 Phone : +82-31-222-6544  
 Fax : +82-31-220-2667  
 E-mail : qudwls2@suwon.ac.kr