

# 최적 Type-2 퍼지신경회로망 설계와 응용

논문  
58-8-23

## The Design of Optimized Type-2 Fuzzy Neural Networks and Its Application

김 길 성\* · 안 인 석\*\* · 오 성 권†  
(Gil-Sung Kim · Ihn-Seok Ahn · Sung-Kwun Oh)

**Abstract** – In order to develop reliable on-site partial discharge (PD) pattern recognition algorithm, we introduce Type-2 Fuzzy Neural Networks (T2FNNs) optimized by means of Particle Swarm Optimization(PSO). T2FNNs exploit Type-2 fuzzy sets which have a characteristic of robustness in the diverse area of intelligence systems. Considering the on-site situation where it is not easy to obtain voltage phases to be used for PRPDA (Phase Resolved Partial Discharge Analysis), the PD data sets measured in the laboratory were artificially changed into data sets with shifted voltage phases and added noise in order to test the proposed algorithm. Also, the results obtained by the proposed algorithm were compared with that of conventional Neural Networks(NNs) as well as the existing Radial Basis Function Neural Networks (RBFNNs). The T2FNNs proposed in this study were appeared to have better performance when compared to conventional NNs and RBFNNs.

**Key Words** : Pattern Recognition, Partial Discharge, Dielectric Degradation, Type-2 Fuzzy Logic Systems, Type-2 Fuzzy Neural Networks, Particle Swarm Optimization, PRPDA

### 1. 서 론

최근 현장에서 부분방전을 측정하는 것은 전력설비 절연 열화의 가장 중요한 진단 기법으로 자리 잡고 있으며, 많은 측정이 이루어지고 있다. 이는 고주파 영역에서의 부분방전 측정을 포함하는 각종 H/W 및 S/W 기법으로 현장의 노이즈 제거가 어느 정도 가능해졌기 때문이다. 또한, 측정된 데이터에 대한 패턴인식을 통해 진성 부분방전을 구분해내는 많은 방법들이 제시되어 사용되고 있어[1-3], 현장 부분방전 측정의 효용성을 높이고 있다. 그러나 현장에서 발생하는 부분방전은 실험 환경이 우수한 실험실에서 모델을 통해 얻은 데이터와는 상당히 다를 뿐 아니라 측정 센서의 종류 및 센서의 위치 등에 따라 다른 결과를 얻게 된다. 이에 따라, 실험실 모델에 입각하여 학습시킨 부분방전 패턴인식 프로그램은 현장에서는 정확도가 저하되게 된다. 이러한 측면에서, 실험실에서 좋은 결과를 보이는 알고리즘인 뉴럴 네트워크(Neural Networks, NNs)[1-5]는 현장의 문제점을 고려하여 수정할 수 없다는 큰 단점을 갖고 있다[6-8].

현장 부분방전 측정의 또 다른 문제점은 실험실과는 달리 PRPDA(Phase Resolved Partial Discharge Analysis) 수행 시 전압 위상을 파악하기 어렵다는 것이다. 부분방전 패턴인식을 PRPDA에 입각하여 수행할 경우에는, 실험실에서 전압위상을 잘 아는 상태에서 얻은 데이터로 PRPDA를 수행하고, 이를 이용하여 패턴인식의 학습을 수행하게 된다. 그러나 현장에서 부분방전 측정과 동시에 정확한 전압 위상을

알기 어렵기 때문에 대부분 인위적으로 PRPDA를 수행하게 되므로, 정확한 분석이 되질 않는다. 특히 케이블의 접속함과 같이 종단과 멀리 떨어진 곳의 전압위상은 거의 측정이 불가능하다. 뿐만 아니라, 현장에서 부분 방전 발생 시 주위의 여러 가지 환경에 따라 노이즈가 침가 될 것은 자명하나 이에 대한 적절한 해결책이 제시 되지 못하고 있다. 따라서 기존의 NNs이나 Radical Basis Function Neural Networks (RBFNNs)과 같은 패턴인식에 일반 적으로 사용되는 분류기 모델은 이러한 전압 위상 문제점이나 노이즈 처리 측면에서는 더욱 그 성능을 보장 할 수 없다.

최근 NNs의 단점을 보완하기 위해 퍼지 논리 시스템과 뉴럴 네트워크의 결합인 뉴로-퍼지 기법의 적용에 대한 연구가 제시되어 좋은 결과를 보이고 있다[7,8]. 퍼지 논리는 그 자체로 PD(Partial Discharge) 패턴 분류에 직접 적용되어 왔으며 뉴럴네트워크만 사용하여 얻은 결과[10]와 거의 동등한 결과를 보이는 것으로 알려져 있다. 또한, 뉴로-퍼지 기법은 언어 및 사고에 관련된 애매함을 다루는 퍼지이론과 학습능력을 가진 신경회로망을 상호 결합한 지능형 모델로서 기존 모델보다 학습속도가 빠르고, 수렴특성이 우수하다고 알려져 있다[11]. 이러한 뉴로-퍼지 기법의 최신 이론은 Type-2 퍼지 논리 시스템이다[14]. Type-2 퍼지 논리 시스템은 제어, 패턴인식, 모델링 등의 여러 가지 분야에서 그 가치와 성능을 인정받고 있다. 특히 Type-2 집합 기반의 시스템들은 노이즈에 강인하고 예측 능력이 뛰어나 부분 방전 검출을 위한 패턴 인식 시스템에 알맞다.

위에서 설명한 일련의 이유로 본 연구에서는 Type-2 Fuzzy Neural Networks를 설계한다. T2FNNs을 설계 할 때, 패턴 분류기 모델의 형성에 큰 영향을 주는 몇 가지 파라미터 들이 있다. 신경회로망 기반 패턴 인식 시스템은 학습률, 모멘텀 계수 등의 네트워크 파라미터 들을 결정해야 하는데, 이와 같은 네트워크의 파라미터 선정 문제는 특별한 방법론이 정해지지 않은 어려운 문제이다.

\* 교신저자, 시니어회원 : 수원대학교 전기공학과 교수  
E-mail : ohsk@suwon.ac.kr

\* 준회원 : 수원대학교 전기공학과 공학석사

\*\* 정회원 : 위덕대학교 에너지전기공학부 교수

접수일자 : 2009년 3월 12일

최종완료 : 2009년 4월 28일

이상과 같은 관점에서 본 연구에서는 보다 신뢰성 있는 현장 부분방전 패턴인식 알고리즘을 개발하기 위해, T2FNNs을 설계하고 부분방전 패턴인식 실험을 하여 그 특성과 성능을 비교 분석하였다. 입력벡터로는 PRPDA의 왜도(skewness)나 첨쇄도(kurtosis)와 같은 통계적 파라미터를 사용하는 대신에, 통계적 파라미터가 주는 불확실성을 개선하기 위해 PRPD 데이터를 그대로 이용하는 방법을 사용하였다. 아울러, 기존 패턴 인식 시스템에서 많이 사용되는 NNs와 RBFNNs을 이용하여 제안된 T2FNNs 과의 부분 방전 성능을 비교 분석 하였다.

## 2. 부분방전 측정 및 데이터 구축

### 2.1 모델 결합 및 부분방전 측정 시스템

전력설비의 절연체에서 발생할 수 있는 부분방전 열화를 대상으로 하여, 다음과 같은 많이 발생하는 4 가지 모의 결합을 실험 대상으로 선정하였다. 우선, 절연체 결합의 내부 부분방전으로 보이드(void) 방전을 고려하였으며, 현장에서 절연체 내부 방전의 판단을 방해할 수 있는 종류의 방전으로 코로나(corona) 방전 및 표면방전(surface discharge)을 선정하였다. 아울러 현장 부분방전 측정에 영향을 미칠 수 있는 노이즈(noise) 결합에 대해서도 고려하였다.

부분방전 측정 데이터를 구축하기 위해 부분방전 측정에 많이 사용되는 대표적인 HFCT(High Frequency Current Transformer) 센서(200kHz~50MHz)를 이용하였다. 모의결합에 대해 고전압 전원을 인가하여 부분방전을 발생시킨 후, HFCT와 튜닝 앰프, 오실로스코프와 스펙트럼 어널라이저로 연동된 PC를 이용하여 측정 및 데이터 수집(LabVIEW 이용)을 하였다.

### 2.2 패턴인식 입력벡터

패턴인식의 전처리 단계로서 본 연구에서는 부분방전 해석에 가장 널리 사용되고 있는 PRPDA (Phase Resolved Partial Discharge Analysis)를 채택하였다. PRPDA는 발생되는 부분방전 펄스들을 인가전압의 위상에 맞추어 중첩시켜 분석하는 방법으로, 결합의 종류에 따라 다양한 형태의 패턴이 형성되기 때문에 측정된 부분방전의 원인 분석과 절연열화진단에 매우 유용한 분석방법이다. 패턴인식의 입력벡터로는 일반적인 PRPD의 왜도(skewness)나 첨쇄도(kurtosis)와 같은 통계적 파라미터를 이용하지 않고, 패턴인식 정확도의 향상을 위하여 PRPD 화면 전체를 입력하는 방법을 택하였다. PRPD 데이터 중에는 위상에 따른 부분방전 펄스 수( $\phi-n$ )와 평균 방전량( $\phi-q$ )을 이용하였다. 산출된 부분방전 펄스 수( $\phi-n$ )와 평균 방전량( $\phi-q$ ) 2 개의 요소는 하나의 조를 이루어 입력벡터로서 사용하였다. 이에 따른 입력벡터의 차원 수는 다음과 같다 :

입력벡터의 차원 수 =

$$128(\text{방전 펄스 수}) + 128(\text{평균 방전량}) = 256 \quad (1)$$

즉, PRPDA의 ( $\phi-n$ ) 및 ( $\phi-q$ ) Map에서 인가전압의 위상  $360^\circ$ 을 128개의 원도우로 나누어, 1개의 원도우가 약  $2.8^\circ$ 의

위상각에 해당되도록 하였다. 이에 따라, 측정 시간 동안 층첩된 부분방전 펄스 수( $\phi-n$ )는 128개 원도우에 대한 펄스 수 데이터가 되도록 변환하였으며, 평균 방전량( $\phi-q$ )도 마찬가지로 128개 원도우에 대한 평균방전량 데이터가 되도록 하였다. 결국, 패턴인식 프로그램의 입력벡터의 수는 2 개 요소의 합인 256개가 된다.

### 2.3 현장 모의를 위한 전압위상 이동 및 노이즈 첨가

현장에서 부분방전을 측정할 경우 이와 매칭 되는 전압위상을 같이 측정하는 것은 거의 불가능하다. 따라서 현장에서 측정 분석된 PRPDA의 ( $\phi-n$ ) 및 ( $\phi-q$ ) Map은 실제 전압위상과 매칭 되었다고 보기 어려우며, 패턴인식 알고리즘은 이러한 문제점을 극복하여야 한다. 본 연구에서는 이러한 상황에서의 패턴인식 수행을 모의하기 위해 측정 분석된 ( $\phi-n$ ) 및 ( $\phi-q$ ) Map의 전압위상을 적절히 이동시켜 변형된 데이터를 구성하였다. 이 때, 현장에서 어느 정도의 위상 오차가 발생하는지를 알지 못하므로 본 연구에서는 임의로 5개 원도우( $14.1^\circ$ ) 및 10개 원도우( $28.2^\circ$ )의 전압 위상을 이동시켜 변형된 데이터를 구축하고 이를 활용하였다. 즉, 네트워크의 학습을 위한 학습 데이터는 위상 쉬프트가 없는 원래의 측정 데이터로서 수행하고, 테스트 데이터는 위상 쉬프트를 시킨 데이터를 이용하여 실험하여, 개발한 알고리즘이 이러한 현장 상황에 잘 적용될 수 있는지를 분석하였다. 본 연구에서는 위상 이동뿐만 아니라 현장 환경의 여러 가지 변화 요인으로 인한 데이터의 5, 10, 20% 범위의 노이즈를 예상하여 범위 내의 랜덤한 노이즈를 첨가하여 실험하는 등의 다양한 실험을 시행하였다.

## 3. 부분방전 패턴인식 시스템

본 연구에서는 부분방전 데이터의 패턴인식을 위해 3 가지 모델을 이용하여 그 성능을 비교하였다. 첫 번째 모델은 일반적으로 가장 많이 사용되는 BP-NN (Back Propagation-Neural Networks)이다. 두 번째로 선택된 모델은 Radial Basis Function Neural Networks (RBFNNs)이다. RBFNNs은 기존의 BP-NN보다 입력공간의 데이터 분포 특성을 잘 반영함으로써 빠른 학습 수렴과 성능 개선의 특징을 가진다[15]. 마지막 모델로서 본 연구에서 제안한 최신 뉴럴-퍼지 기법인 Type-2 Fuzzy Neural Networks (T2FNNs)이다. 본 장에서는 위의 3가지 모델에 대하여 설명하고 제안된 T2FNNs의 최적화에 사용된 Particle Swarm Optimization (PSO)에 대하여 설명한다.

### 3.1 BP-NN

BP-NN은 신경회로망을 기반으로 한 패턴 분류기의 모델 중 가장 많이 사용되는 모델이다. 일반적인 BP-NN는 입력층, 은닉층, 출력층의 3층 구조를 가지며 3층 구조를 가지며 오류 역전파 알고리즘(Back Propagation Algorithm)을 통하여 연결 가중치를 학습한다. BP-NN의 입력층은 입력벡터  $x = [x_1, \dots, x_n]^T$ 를 입력으로 받아 은닉층으로 전달한다. 은닉층과 출력층의 활성함수는 식 (2)의 시그모이드 함수를 사용하였다.

$$S(x) = \frac{1}{1+e^{-x}} \quad (2)$$

NN은 음성 및 화상 패턴인식 분야에서 매우 활용도가 높은 알고리즘으로 상대적으로 간단한 프로그램 구성과 탁월한 패턴인식 결과를 제공하는 것으로 알려져 있다.

### 3.2 Radial Basis Function Neural Networks

RBFNNs은 빠른 학습시간, 일반화(generality)능력, 단순화(simplicity)의 특징으로 인해 학습 데이터를 분류하는 작업과 비선형 시스템 모델링 등에 적용되고 있다[16]. RBFNNs의 구성은 입력데이터를 네트워크와 연결하는 입력층(input layer), 입력데이터를 RBF에 의해 고차원 공간으로 비선형 변환하는 은닉층(hidden layer), 은닉층의 결과를 선형 조합하여 네트워크의 최종 출력 값을 계산하는 출력층(output layer) 등의 세 개의 서로 다른 층으로 이루어져 있으며 그림 1와 같다.

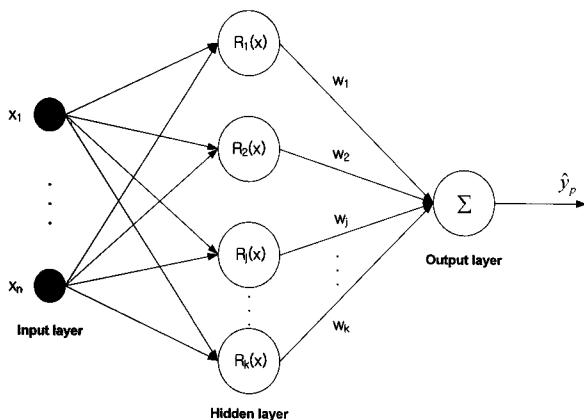


그림 1 일반적인 RBF 뉴럴네트워크

Fig. 1 General RBF Neural Network

방사형 기저 함수(Radial Basis Function)로는 가우시안(Gaussian) 함수, Thin plate spline 함수, 역 다항 2차(Inverse Multiquadratic) 함수, 다항 2차(Multiquadratic) 함수, 3차(Cubic) 함수, 및 선형(Linear) 함수 등이 사용될 수 있으며 주로 가우시안 형태가 사용된다. 은닉층 활성함수(RBF)의 중심과 폭은 뉴럴네트워크의 구조를 결정하게 되며, 입력 데이터 중에서 임의로 중심을 선택하는 방법, 네트워크의 입력 공간에서 임의로 중심을 추출하는 방법, 클러스터링(clustering) 기법을 이용한 중심 결정법 등이 사용된다. 본 연구에서는 클러스터링 기법중의 하나인 Fuzzy C-means(FCM)클러스터링 방법을 사용하여 방사형 기저 함수를 생성한다. 이러한 방법은 각각의 클래스에 따라서 적절한 소속 함수(membership function; MF)을 생성하여 RBF의 기능을 대신하여 그 성능을 향상 시킬 수 있다[12]. RBF의 중심과 폭이 결정된 후 네트워크의 연결자중치는 최소자승법(least square estimation) 또는 경사하강법(gradiant descent method) 등의 학습방법에 의해 결정된다.

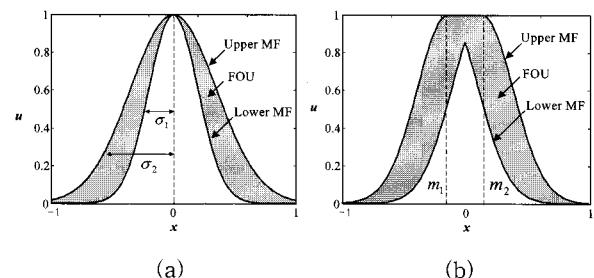
### 3.3 Type-2 Fuzzy Neural Networks

Type-2 퍼지 논리 시스템은 언어적인 불확실성을 다룰 수 있는 Type-1 퍼지 논리 시스템의 확장이다. Type-2 퍼지 집합은 General Type-2 퍼지 집합과 Interval Type-2 퍼지 집합으로 나눌 수 있다. General Type-2 퍼지 집합을 사용하여 퍼지 논리 시스템을 설계할 경우는 연산량이 매우 많아 실제 사용에 어려움이 있다[17]. 이와 같은 어려움들로 인하여 Interval Type-2 퍼지 집합을 이용한 Interval Type-2 퍼지 논리 시스템이 많이 연구되고 있다. 본 논문에서는 Interval Type-2 퍼지 집합을 기반으로 하여 Type-2 Fuzzy Neural Networks를 설계한다.

Interval Type-2 퍼지 집합  $\tilde{A}$ 은 FOU(Footprint Of Uncertainty)의 Upper Membership Function(MF)과 Lower MF으로 완전히 설명 될 수 있다. Upper MF은  $\overline{\mu}_{\tilde{A}}(x)$  으로, Lower MF은  $\underline{\mu}_{\tilde{A}}(x)$ 로 표기하며 아래의 식 (3)과 같이 FOU를 나타낼 수 있으며 그림으로 나타내면 그림 2와 같다.

$$\text{FOU}(\tilde{A}) = [\underline{\mu}_{\tilde{A}}, \overline{\mu}_{\tilde{A}}] \quad (3)$$

그림 2는 Gaussian 함수로 만들 수 있는 2가지 종류의 FOU를 보여준다. 그림 2(a)는 특정한 1개의 Gaussian 함수를 가지고 너비( $\sigma$ )를 변화시켜  $\sigma_1$ 에서  $\sigma_2$  까지 연속적으로 변화시키며 FOU를 구성한다. 이에 반해 그림 2(b)는 중심 특정한 1개의 Gaussian 함수의 중심을  $m_1$ 에서  $m_2$  까지 변화 시키며 FOU를 구성한 그림이다.



(a) 불확실한 너비를 갖는 Type-2 퍼지집합

(Type-2 fuzzy set with uncertain width)

(b) 불확실한 중심을 갖는 Type-2 퍼지집합

(Type-2 fuzzy set with uncertain center)

그림 2 FOU로 표현된 Interval Type-2 퍼지 집합 :

Fig. 2 Interval Type-2 fuzzy set with FOU

#### 3.2.1 Type-2 Fuzzy Neural Networks 구조

본 논문은 Type-2 Fuzzy Neural Networks(T2FNNs)을 제안한다. 제안된 T2FNNs 활성 함수로서 Type-2 퍼지집합을 사용하여 노이즈에 강인하고 위상의 이동에 덜 민감한 패턴 분류를 위한 네트워크를 설계한다. 제안된 T2FNNs은 4층 네트워크로서 Input Layer, Fuzzification layer, Inference layer, Defuzzification layer로 구성된다. 그림 3은 제안된 T2FNNs의 구조를 보여준다.

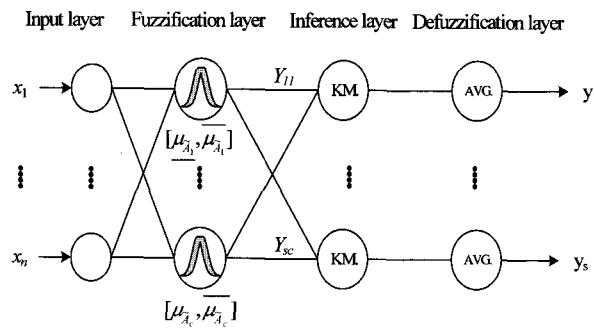


그림 3 네 개의 층을 갖는 T2FNNs의 구조  
Fig. 3 T2FNNs structure with four layers

여기서,  $\overline{\mu_{A_i}}(\mathbf{x})$ 과  $\underline{\mu_{A_i}}(\mathbf{x})$ 는 각각  $i (=1,...,c)$ 번째 클러스터(퍼지 규칙)의 Upper MF, Lower MF를 나타낸다.  $Y_{ji}(\mathbf{x})$ 는  $j (=1,...,s)$ 번째 출력 유닛과  $i$ 번째 클러스터 사이의 연결가중치이다. 기존의 은닉층에 해당하는 Fuzzification layer의 활성함수에 Type-2 FCM 클러스터링을 통해 생성된 Type-2 퍼지 집합을 사용한다. 제안된 네트워크는 Multi-output 구조로서 가중치는 Fuzzification layer와 Inference layer 사이에만 가중치가 존재하며 interval Type-1 퍼지집합을 가중치로 갖는다. 이를 수식으로 나타내면 다음과 같다.

$$Y_{ji}(\mathbf{x}) = C_{ji}, \quad C_{ji} = [c_{ji} - s_{ji}, c_{ji} + s_{ji}] \quad (4)$$

여기서,  $c_{ji}$ 는  $C_{ji}$ 의 중심을 나타내며,  $s_{ji}$ 는  $C_{ji}$ 의 너비의  $1/2$ 을 나타낸다.

### 3.2.2 Type-2 Fuzzy Clustering

본 절에서는 Fuzzy C-Means(FCM)을 설명하고 Type-2 Fuzzy C-Means(FCM)으로 확장하여 T2FNNs의 Fuzzification layer의 활성함수로 사용하는 방법론에 대하여 서술한다. T2FNNs은 FCM 클러스터링을 사용하여 학습 데이터(training data)의 특성 반영을 위해 입력 공간을  $c$ 개의 클러스터 수(퍼지 규칙 수)만큼의 로컬 영역으로 분리하고 각 로컬 영역의 소속정도를 퍼지 집합으로서 출력한다. FCM 클러스터 방법은 각 데이터와 특정 클러스터 중심과의 거리에 소속 정도를 부여하고 이 소속 정도에 따라 데이터를 분류하는 알고리즘이다. FCM 클러스터링은 목적함수인 식 (5)를 최소화함으로서 입력데이터의 각 클러스터에 대한 소속 값을 구한다.

$$Q = \sum_{i=1}^c \sum_{k=1}^N u_{ik}^m \| \mathbf{x}_k - \mathbf{v}_i \|^2 \quad (5)$$

여기서,  $c$ 는 클러스터의 개수(퍼지 규칙 수),  $N$ 은 입력 패턴 수,  $m$ 은 퍼지화 계수이고  $m$ 은 1.0보다 크다.  $\mathbf{x}_k$ 는  $k$ 번째 입력 벡터이고  $\mathbf{v}_i$ 는  $i$ 번째 클러스터의 중심이다.  $u_{ik}$ 는  $k$ 번째 데이터가  $i$ 번째 클러스터에 속하는 소속정도를 나타내는 0과 1사이의 실수로 식(6)과 식(7)의 조건을 만족한다.

$$\sum_{i=1}^c u_{ik} = 1, \quad 1 \leq k \leq N \quad (6)$$

$$0 < \sum_{k=1}^N u_{ik} < N, \quad 1 \leq i \leq c \quad (7)$$

식(5)의  $\| \cdot \|$ 는 아래의 식(8)로 표현되는 가중 유클리디안 거리(weighted Euclidean distance)를 사용한다[12].

$$\| \mathbf{x}_k - \mathbf{v}_i \|^2 = \sum_{j=1}^n \frac{(x_{kj} - v_{ij})^2}{\sigma_j^2} \quad (8)$$

여기서,  $\sigma_j$ 는 입력 패턴들의  $j$ 번째 입력 차원의 표준편차이다. 가중 유클리디안 거리는 데이터 크기 분포에 크게 영향을 받지 않는 알맞은 거리 정보를 제공하므로 많이 사용되고 있다.  $n$ 차원 유클리드 공간상의  $N$ 개의 패턴으로 구성된 입력 벡터 집합  $X=\{x_1, x_2, \dots, x_N\}$ ,  $x_k \in R^n$ ,  $1 \leq k \leq N$ 과 클러스터 중심  $v=\{v_1, v_2, \dots, v_c\}$ ,  $v_i \in R^n$ ,  $1 \leq i \leq c$ 에 대한 소속정도를 소속행렬로 표현하면  $U=[u_{ik}]$ 로 표현되고  $u_{ik}$ 와  $v_i$ 는 식(9)과 식(10)에 의해 각각 계산된다.

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left( \frac{\| \mathbf{x}_k - \mathbf{v}_i \|^2}{\| \mathbf{x}_k - \mathbf{v}_j \|^2} \right)^{\frac{2}{m-1}}} \quad (9)$$

여기서,  $1 \leq k \leq N$ ,  $1 \leq i \leq c$

$$\mathbf{v}_i = \frac{\sum_{k=1}^N u_{ik}^m \mathbf{x}_k}{\sum_{k=1}^N u_{ik}^m}, \quad 1 \leq i \leq c \quad (10)$$

FCM 클러스터링은 식(9)과 식(10)을 반복적으로 수행하면서 소속행렬  $U$ 와 각 클러스터의 중심  $v_i (i=1, \dots, c)$ 를 수정하며 식(5)의 목적함수  $Q(U, v_1, v_2, \dots, v_c)$ 를 특정 값으로 수렴시킨다.

퍼지화 계수 “ $m$ ”은 각 클러스터의 소속 함수의 형태를 결정하는 매우 중요한 요소이다. 일반적으로 2.0을 사용하며 2.0을 기준으로 작을 경우 각 클러스터 영역간의 중첩되는 영역이 감소되어 1과 0부근의 소속정도를 갖는 영역이 늘어나고 퍼지 집합이 아닌 크리스프 집합(crisp set)의 특성을 나타내는 영역이 증가한다. 2.0보다 클 경우 클러스터 중심점이 뾰족한 모양의 퍼지 집합이 생성되어 서로의 클러스터에 대한 소속 값의 차이가 적어지는 특징이 있다. 본 연구에서는 PSO 알고리즘으로 입력 데이터 집합과 규칙 수에 따른 최적화된 퍼지화 계수를 동조한다.

퍼지화 상수 ‘ $m$ ’에 서로 다른 값을 할당하여 Type-2 Fuzzy 클러스터링을 수행하는 방법이 제안되었다[9]. 하지만 어떤 ‘ $m$ ’ 값을 사용할 것인가에 대한 해답은 제시되지 않았다. 특정 데이터에 알맞은 Type-2 퍼지 집합을 결정하는 것은 명확한 해답이 존재하지 않는 문제이기 때문이다. 본 연구에서는 결정하기 힘든 ‘ $m$ ’ 값에 대하여 주어진 데이터에 알맞은 최적의 ‘ $m$ ’ 값을 PSO를 통하여 탐색한다. 아래의 그림 4은 퍼지화 상수에 따라 결정되는 Type-2 퍼지 집합의 예를 보여준다.

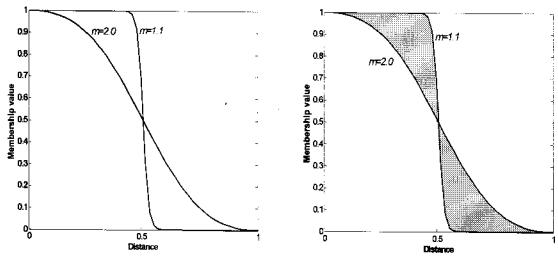


그림 4 Type-2 FCM을 이용하여 interval Type-2 퍼지 집합을 구성하는 방법의 예

Fig. 4 Example of construction method of interval Type-2 using Type-2 FCM

그림 4와 같이 Type-2 집합으로 활성 함수를 구성하고 Fuzzification layer의 각 유닛은 Upper MF은  $\bar{\mu}(x)$  으로, Lower MF은  $\underline{\mu}(x)$  을 출력한다. 이를 식으로 나타내면 아래와 같다.

$$\bar{\mu}_i(x_k) = \frac{1}{\sum_{j=1}^c (d_{ik}/d_{jk})^{2/(m_1-1)}} \text{ if } \frac{1}{\sum_{j=1}^c (d_{ik}/d_{jk})^{2/(m_1-1)}} > \frac{1}{\sum_{j=1}^c (d_{ik}/d_{jk})^{2/(m_2-1)}} \\ \text{otherwise } \frac{1}{\sum_{j=1}^c (d_{ik}/d_{jk})^{2/(m_2-1)}} \quad (11)$$

$$\underline{\mu}_i(x_k) = \frac{1}{\sum_{j=1}^c (d_{ik}/d_{jk})^{2/(m_1-1)}} \text{ if } \frac{1}{\sum_{j=1}^c (d_{ik}/d_{jk})^{2/(m_1-1)}} \leq \frac{1}{\sum_{j=1}^c (d_{ik}/d_{jk})^{2/(m_2-1)}} \\ \text{otherwise } \frac{1}{\sum_{j=1}^c (d_{ik}/d_{jk})^{2/(m_2-1)}} \quad (12)$$

식 (11)과 (12)의  $d_{ik}$ 는 식 (8)로 표현되는 i번째 클러스터 중심과 k번째 입력 벡터  $x_k$ 와의 유clidean 거리이다. 위의 식 (11)과 (12)를 이용하여 Fuzzification layer 의 출력이 결정된다. FCM을 이용하는 특성 때문에 일반적으로 퍼지 논리 시스템에 사용되는 전반부 meet연산(minimum t-norm등의)은 T2FNNs에서는 존재하지 않는다. 이러한 이유로 i번째 Type-2 퍼지 집합은 아래의 식 (13)로 표현 가능하다.

$$F^i(x) = [\underline{\mu}_i, \bar{\mu}_i] = [\underline{f}^i(x), \bar{f}^i(x)] \equiv [\underline{f}^i, \bar{f}^i] \quad (13)$$

### 3.2.3 Type Reducer

T2FNNs의 구조는 아래의 퍼지 규칙으로 표현된다.

$$R_i : \text{If } x \text{ is } \tilde{A}_i \text{ then } Y_{ji}(x) = C_{ji} \quad (14)$$

여기서,  $R_i$ 는  $i(=1, \dots, c)$ 번째 퍼지 규칙을 나타낸다. 식(13)

에 의해  $\tilde{A}_i$ 가 Type-2 퍼지 집합 이므로  $[\underline{f}^i, \bar{f}^i]$ 로 표현할 수 있고, 이는 각각 i번째 클러스터(퍼지 규칙)의 Upper MF, Lower MF을 나타낸다.  $Y_{ji}(x)$ 는  $j(=1, \dots, s)$ 번째 출력에 대한 i 번째 퍼지 규칙의 후반부 interval Type-1 퍼지 집합이며 네트워크 구조상으로는 연결가중치이다. 또한  $Y_{ji}(x)$  은 interval set이기 때문에 식 (4)에 의해 다음의 식과 같이 표현 할 수 있다.

$$Y_{ji}(x) = [y_{ji}^l, y_{ji}^r] = [c_{ji} - s_{ji}, c_{ji} + s_{ji}] \quad (15)$$

위에서 정의 한 일련의 식들을 사용하여 Inference layer 의 j번째 출력  $Y_j(x)$ 은 아래의 식으로 계산된다.

$$Y_j(x) = [y_j^l, y_j^r] = \int_{y_1 \in [y_1^l, y_1^r]} \cdots \int_{y_c \in [y_c^l, y_c^r]} \int_{f_1 \in [f_1^l, f_1^r]} \cdots \int_{f_c \in [f_c^l, f_c^r]} \frac{\sum_{i=1}^c f_i y_i}{\sum_{i=1}^c f_i} \quad (16)$$

따라서  $Y_j(x)$ 의 양끝 2개의 점을 계산하면 되고 이 과정은 Karnik-Mendel이 제안한 반복적인 방법(KM algorithm)으로 계산 할 수 있다. 네트워크의 최종 출력을 구하기 위한 KM algorithm[17]은 아래와 같다(출력에 대한 첨자 j 생략). 이와 같은 KM algorithm은 최대 c번의 반복 횟수 이하에서 수렴하는 것으로 증명되었다[17]. 본 연구에서는 KM알고리즘을 이용하여 Inference layer에서의 출력을 얻는다. 식 (16)의 Inference layer의 j번째 유닛의 출력  $Y_j = [y_j^l, y_j^r]$ 은 interval Type-1 퍼지 집합이므로 j번째 출력의 최종 출력  $\hat{y}_j$  을 얻기 위해 Defuzzification layer에서는 비 퍼지화를 위해 평균을 취한다. 이는 아래의 식 (17)로 표현된다.

$$\hat{y}_j = \frac{y_j^l + y_j^r}{2} \quad (17)$$

### 3.2.4 Type-2 Fuzzy Neural Networks의 학습

본 연구에서 제안된 T2FNNs은 interval Type-1 퍼지 집합인 연결가중치를 Gradient Descent Method를 이용하여 학습한다. 본 장에서는 편의를 위해 아래의 모든 학습식 유도는 출력에 대한 첨자를 생략하고 서술한다. i번째 규칙의 후반부 Type-2 집합의 중심을 의미하는 interval set은 아래의 식으로 표현된다.

$$Y_i(x) = C_i = [y_i^l, y_i^r] = [c_i - s_i, c_i + s_i] \quad (18)$$

학습식은 아래의 오차식을 최소로 하도록 학습이 이루어진다.

$$E_q = \frac{1}{2} (t_q - \hat{y}_q)^2, q=1, \dots, N \quad (19)$$

여기서 q는 패턴에 대한 첨자이다. 이하 첨자 q를 생략한다. T2FNNs의 학습은 식 (18)의 i번째 퍼지 규칙의 후반부 집합의 표현인  $c_i$ 와  $s_i$ 을 학습 하므로 이루어진다. 먼저 interval set의 너비에 해당하는  $s_i$ 에 대한 학습식은 아래의 수식으로 표현된다.

$$\frac{\partial E}{\partial s_i} = \frac{\partial E}{\partial \hat{y}} \cdot \left( \frac{\partial \hat{y}}{\partial y^l} \cdot \frac{\partial y^l}{\partial y_i^l} \cdot \frac{\partial y_i^l}{\partial s_i} + \frac{\partial \hat{y}}{\partial y^r} \cdot \frac{\partial y^r}{\partial y_i^r} \cdot \frac{\partial y_i^r}{\partial s_i} \right) \quad (20)$$

각 항을 미분하여 정리하면 출력 오차에 대한 너비  $s_i$ 의 변화 분  $\Delta s_i$ 은 아래의 식(21)과 같고 모멘텀까지 고려한 최종 식은 식(22)과 같다. 여기서  $\eta$ 는 학습률,  $\alpha$ 는 모멘텀 계수,  $p+1$ 은 새로운 값,  $p$ 는 현재 값,  $p-1$ 은 이전 값을 나타낸다.

$$\Delta s_i = -\eta \frac{\partial E}{\partial s_i} = 0.5\eta(t - \hat{y})(dl - dr) \quad (21)$$

$$s_i(p+1) = s_i(p) + 0.5\eta(t - \hat{y})(dl - dr) + \alpha(s_i(p) - s_i(p-1)) \quad (22)$$

$dl$ 과  $dr$ 은 KM 알고리즘 내에서  $y^l$ 과  $y^r$ 을 계산하는데 영향을 준  $\underline{f}_i^l$ 과  $\underline{f}_i^r$ 에 대하여 i번째 룰에 대한 출력을 미분한 항을 나타내며 수식으로 나타내면 각각 아래와 같다.

$$dl = \frac{\partial \left( \frac{\sum_{i=1}^c \underline{f}_i^l y_i^l}{\sum_{i=1}^c \underline{f}_i^l} \right)}{\partial y_i^l}, \quad dr = \frac{\partial \left( \frac{\sum_{i=1}^c \underline{f}_i^r y_i^r}{\sum_{i=1}^c \underline{f}_i^r} \right)}{\partial y_i^r} \quad (23)$$

식 (23)에서  $\underline{f}_i^l$ 은 KM 알고리즘 내에서 출력을 구하는 데 사용된  $\underline{f}_i^l$  또는  $\underline{f}_i^r$  중 1개를 나타낸다. 너비  $s_i$ 와 마찬가지로 중심  $c_i$ 의 변화분  $\Delta c_i$ 는 식 (24)으로 표현 되고 모멘텀까지 고려한 최종 식은 식(25)과 같다.

$$\Delta c_i = -\eta \frac{\partial E}{\partial c_i} = 0.5\eta(t - \hat{y})(dl + dr) \quad (24)$$

$$c_i(p+1) = c_i(p) + 0.5\eta(t - \hat{y})(dl + dr) + \alpha(c_i(p) - c_i(p-1)) \quad (25)$$

#### 4. PSO 알고리즘을 이용한 최적화

Particle Swarm Optimization(PSO)는 Kennedy and Eberhart[15]에 의해 처음 소개된, 새 떼와 물고기 떼와 같은 생체군집의 사회적 행동양식을 바탕으로 한 최적화 알고리즘이다. 일반적으로 PSO는 이론의 간결성, 구현의 용이성, 연산의 효율성과 같은 특징을 보인다[16]. 본 절에서는 지면상 PSO 알고리즘에 관하여 설명하며 PSO의 연산자는 참고문헌 [15,16]에 자세히 설명되어 있다.

##### 4.1 PSO 알고리즘

PSO 알고리즘에서 swarm은 m개의 particle을 가지며 이들은 주어진 문제의 해가 된다. 본 논문에서 제안된 T2FNNs 구조의 파라미터인 학습률과 모멘텀 계수, 2개의 퍼지화 계수의 선택 문제는 경사 하강법과 FCM 클러스터링을 사용하는 T2FNNs의 성능에 크게 영향을 미치는 중요한 문제이다. 이는 입력 데이터의 특성과 분류기 모델의 특성을 고려해야 하는 어려운 문제로서 기존의 여러 연구들에서 명확한 해결책이 제시되지 못하고 있다. 이러한 이유로 본 논문에서는 PSO 알고리즘을 사용하여 모델의 특징과 데이터 특성에 알맞은 최적의 학습률과 모멘텀 계수, 퍼지화 계수를 최적 동정하고 T2FNNs의 패턴인식 성능을 향상 시킨다. 아래의 그림 5은 PSO를 사용하여 T2FNNs 최적화시에 사용된 particle의 구조이다.

#### 5. 시뮬레이션 및 결과고찰

앞서 2장에서 언급한 바와 같이 본 연구에서는 4가지 모의 결합에 대하여 각 100개씩 총 400개의 부분방전 실험 데이터를 구축하였다. 뿐만 아니라 구축된 부분방전 데이터는 현장을 모의하기 위하여 전압 위상을 이동시킨 데이터를 테스트 데이터로 사용하였으며, 5, 10, 20%의 랜덤 노이즈를 첨가하여 실제 현장과 유사한 환경을 구축하였다.

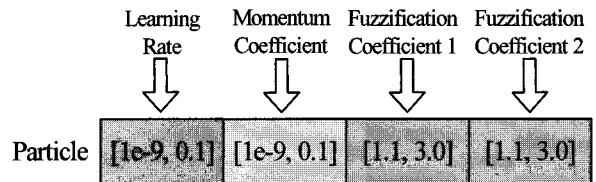


그림 5 PSO를 이용한 T2FNNs의 최적화에 사용된 particle 구조

Fig. 5 Particle structure for optimization of T2FNNs using PSO

실험은 2가지 경우를 나누어 실험 하였다. 첫 번째 실험(실험 1)은 네트워크를 학습 시키는 학습데이터에도 노이즈가 첨가되었으며 두 번째 실험(실험 2)은 학습데이터에는 노이즈가 첨가되지 않았다. 실험에 대한 설명은 아래의 표 1과 같다.

표 1 실험에 사용된 데이터 구성

Table 1 Taxonomy of individual experimental dataset

	dataset	노이즈	위상 5 이동	위상 10 이동
실험 1	학습 데이터	O		
	테스트 데이터 1	O		
	테스트 데이터 2	O	O	
	테스트 데이터 3	O		O
실험 2	학습 데이터			
	테스트 데이터 1			
	테스트 데이터 2	O	O	
	테스트 데이터 3	O		O

위의 표 1에서 위상 5이동은 5개 원도우( $14.1^\circ$ ) 만큼의 위상 이동을 의미하고, 위상 10 이동은 10개 원도우( $28.2^\circ$ ) 만큼의 이동을 의미한다. 이렇게 각 4개의 결합별로 100개씩의 데이터 중 7:3의 비율로 랜덤하게 Training(학습 데이터), Test 1 (테스트 데이터 1)로 나누어 5번 반복 실험하였으며 성능평가는 5-Fold Cross-Validation에 의한 분류 정확성의 평균과 표준편차에 의한다. N번을 반복 실험하는 N-Fold Cross-Validation 방법은 여러 연구에서 분류기의 성능 검증을 위해 많이 사용되는 방법이다[13]. Test 2 (테스트 데이터 2), Test 3 (테스트 데이터 3)은 테스트 데이터 1의 개수와 같게 랜덤하게 선택되었으며, 학습 데이터와 테스트 데이터 1은 네트워크의 학습 시 사용되는데 반해 Test 2, 3 데이터는 테스트에만 사용되는 데이터이다.

제안된 T2FNNs의 패턴인식 성능 비교를 위해서 앞서 설명한 BP-NN과 RBFNNs를 이용하여 같은 부분방전 데이터

를 가지고 패턴 인식 실험을 시행하였다. 아래의 표 2는 실험에 사용된 실험 파라미터들이다. T2FNNs은 학습률, 모멘텀 계수, 퍼지화 계수를 PSO를 사용하여 최적화 한다.

### 5.1 실험 1

아래의 표 3은 학습 데이터에도 노이즈를 추가하여 실험한 결과들이다. Training과 Test 1은 PSO의 목적 함수로서 학습 과정에 사용된 데이터들이므로 3가지 네트워크 모두 거의 100%에 가까운 인식률을 갖는다.

**표 2** 부분 방전 패턴 인식 실험 파라미터

**Table 2** Experimental parameters for pattern recognition of partial discharge

파라미터		값
BP-NN	온도 층 유닛 수	10, 20, 30
	학습 횟수	300
	학습률	0.01
	모멘텀 계수	0.1
RBFNNs	온도 층 유닛 수(규칙 수)	4, 6, 8
	학습 횟수	300
	학습률	0.001
	모멘텀 계수	0.01
T2FNNs	온도 층 유닛 수(규칙 수)	4, 6, 8
	학습 횟수	300
	세대수	5
	particle 수	50
PSO	umax	탐색 공간의 20%
	[wmin wmax]	[0.4, 0.9]]
	c1, c2	2.0
	탐색 범위	학습률 [1e-9, 0.1] 모멘텀 계수 [1e-9, 0.1] 퍼지화 계수 1,2

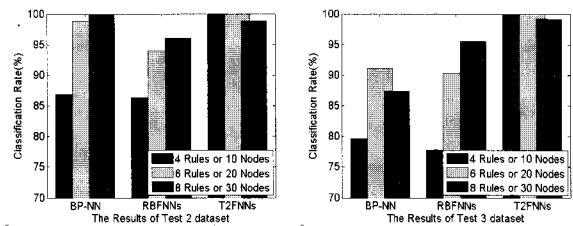
본 연구에서 각 모델별로 비교해야 할 성능은 Test 2와 Test 3에 대한 결과들이다. Test 2와 Test 3 데이터는 전압 위상 이동, 노이즈 추가 후 학습 시 사용되지 않은 데이터이다. 실험 1에서는 본 연구에서 제안된 T2FNNs이 거의 모든 경우에 100%의 안정적인 성능을 보였으며 BP-NN과 RBFNNs은 서로 비슷한 성능을 보였으나 T2FNNs에 비해서는 다소 성능이 떨어졌다.

**표 3** 20%의 노이즈 섞인 데이터에 대한 실험 결과 (실험1)

**Table 3** Experimental results for each dataset with 20% noise

Model	No. of Rules (Nodes)	Training	Test 1	Test 2	Test 3
BP-NN	10	90.00±13.53	90.00±13.69	86.83±12.34	79.67±18.67
	20	100.00±0.00	99.83±0.37	98.83±1.73	91.17±8.14
	30	100.00±0.00	100.00±0.00	100.00±0.00	87.33±11.48
RBFNNs	4	100.00±0.00	99.66±0.45	86.33±6.47	77.83±16.79
	6	100.00±0.00	99.66±0.74	94.00±7.48	90.33±10.74
	8	100.00±0.00	99.66±0.45	96.00±2.15	95.50±5.93
T2FNNs	4	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
	6	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
	8	100.00±0.00	100.00±0.00	98.83±1.26	99.16±1.44

아래의 그림 6은 표 3의 20% 노이즈 실험에 따른 각 모델별 성능을 비교한 그래프이다. 그림에서 볼 수 있듯이 Test 2의 경우에서 차이보다 Test 3 데이터에 대한 성능 차이가 크게 나타남을 볼 수 있다. 이는 위상의 이동이 클지라도 다른 모델에 비하여 T2FNNs는 그 성능이 안정적인 것을 알 수 있다. 뿐만 아니라 전반적으로 T2FNNs의 성능이 우수한 것을 알 수 있다.



**그림 6** Test 2, 3에 대한 실험 결과 (실험 1, 20% noise)

**Fig. 6** Experimental results for Test 2 and 3 (Experiment 1, 20% noise)

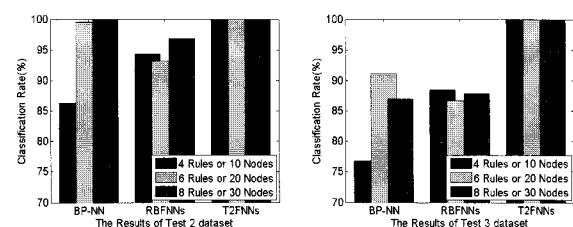
### 5.1 실험 2

아래의 표 4는 실험 2의 결과들이다. 실험 1과 크게 성능이 차이 나지는 않고 거의 비슷한 양상의 결과를 보임을 알 수 있다. 다만 그림 7에서 볼 수 있듯이 20%의 노이즈를 추가하였을 때 실험 1에 비해 BP-NN이나 RBFNNs와 T2FNNs의 성능 차이가 더욱 벌어짐을 알 수 있었다. 실험 1과 실험 2로 미루어 보건대 T2FNNs의 최대 장점은 위상의 변화에 덜 민감한 것으로 해석 할 수 있다.

**표 4** 20%의 노이즈 섞인 데이터에 대한 실험 결과 (실험2)

**Table 4** Experimental results for each dataset with 20% noise

Model	No. of Rules (Nodes)	Training	Test 1	Test 2	Test 3
BP-NN	10	87.21±12.68	87.83±12.11	86.33±11.97	76.83±14.05
	20	100.00±0.00	100.00±0.00	99.50±0.75	91.17±8.61
	30	100.00±0.00	100.00±0.00	99.83±0.37	87.00±14.20
RBFNNs	4	98.78±1.77	98.33±2.12	94.33±5.50	88.50±15.38
	6	100.00±0.00	100.00±0.00	93.16±2.78	86.66±8.87
	8	100.00±0.00	99.83±0.37	96.83±2.23	87.83±10.53
T2FNNs	4	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
	6	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
	8	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00



**그림 7** Test 2, 3에 대한 실험 결과 (실험 2, 20% noise)

**Fig. 7** Experimental results for Test 2 and 3 (Experiment 2, 20% noise)

아래의 그림 8은 PSO를 이용하여 최적의 학습률과 모멘텀 계수를 찾은 예이다. 실험 2의 20%의 노이즈 일 경우에 T2FNNs의 4, 6, 8개의 규칙(은닉층 노드 수)에서 식 (22)과 (25)의 학습률과 모멘텀 계수를 PSO를 이용하여 탐색한 결과를 그림 8에서 보여주고 있다. 그림 8(a)는 식(25)의 중심 학습, 그림 8(b)는 식 (22)의 너비 학습에서의 최적 학습률과 모멘텀 계수의 탐색 결과를 보여준다. 그림 8(a)에서 6개의 규칙에서 학습률은 평균 0.056, 표준 편차 0.014에서 최적의 학습률을 보임을 알 수 있다. 즉, PSO를 이용하여 T2FNNs의 학습의 최적화를 위하여  $0.056 \pm 0.014$ 의 구간에서 최적의 학습률을 찾았다.

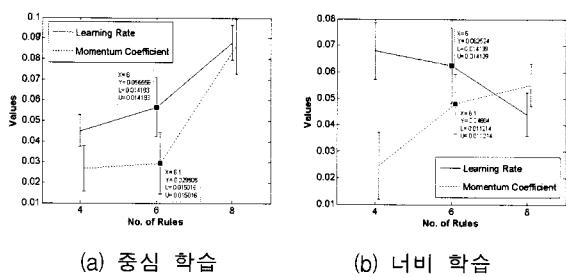


그림 8 PSO를 이용하여 탐색한 최적의 학습률과 모멘텀 계수 (실험 2, 20% noise)

Fig. 8 Optimized Learning ratio and momentum Coefficient

## 6. 결 론

본 연구에서는 현장 적용성이 우수한 부분방전 패턴인식 기법을 개발하기 위해 뉴로-퍼지 기법의 최신 이론인 Type-2 퍼지 이론을 적용한 Type-2 Fuzzy Neural Networks를 설계하였다. 이를 위해 현장에서 많이 사용하는 HFCT 센서를 이용하여 부분방전 데이터를 구축하였으며, PRPDA의 전압위상을 파악하기 어려운 현장 상황과 노이즈 섞인 상황을 고려하여 실험 데이터를 구축, 제안된 네트워크와 기존에 패턴 인식에 많이 사용되었던 모델들을 이용하여 부분 방전 패턴 인식 실험을 수행하였다.

그 결과, 본 연구에서 설계한 T2FNNs이 기존에 사용된 일반적인 BP-NN과 RBFNNs보다 우수한 패턴 분류 성능을 보였다. 안정적이고 우수한 성능을 보인 이유는 아래의 2가지 이유로 해석 할 수 있다.

첫째, Type-2 퍼지 집합의 interval set기반의 연산을 통하여 위상의 이동에도 덜 민감한 패턴 분류기를 설계 할 수 있었다.

둘째, 최근 많은 분야의 최적화 문제에서 그 성능을 입증 받고 있는 생체 군집 이론에 바탕을 둔 Particle Swarm Optimization(PSO)을 이용한 T2FNNs의 최적화를 수행함으로서 네트워크 구조의 최적화를 이를 수 있었다.

추후 연구로는 위상의 이동에 대하여 보다 많은 경우의 전압 위상을 고려한 실험이 시행 되어야 할 것으로 생각되며, 본 연구의 결과를 토대로, 두 가지 이상의 다양한 방전이나 노이즈가 포함되는 다중 방전에 대해서 본 연구에서 제안한 패턴 분류기의 성능을 확인할 필요가 있다. 나아가, 현장 적용을 통해 본 분류기의 성능을 개선해 나가야 할 것으로 사료된다.

## 감사의 글

이 논문은 2008년 정부(교육과학기술부)의 재원으로 한국학술진흥재단의 지원을 받아 수행된 연구임(KRF-2008-314-D00376). 그리고 본 연구는 경기도의 경기도 지역협력연구센터사업의 일환으로 수행하였음 (GRRC 수원2009-B2, U-city 보안감시 기술협력센터)

## 참 고 문 헌

- [1] H. G. Kranz, "Diagnosis of Partial Discharge Signals using Neural Networks and Minimum Distance Classification", IEEE Trans. Electr. Insul., Vol. 28, pp. 1016-1024, 1993.
- [2] E. Gulski and A. Krivda, "Neural Networks as a Tool for Recognition of Partial Discharges", IEEE Trans. Electr. Insul., Vol. 28, pp. 984-1001, 1993.
- [3] A. A. Mazroua, M. M. A. Salama and R. Bartnikas, "PD Pattern Recognition with Neural Networks using the Multilayer Perceptron Technique", IEEE Trans. Electr. Insul., Vol. 28, pp.1082-1089, 1993.
- [4] R. Candela, G. Mirelli, and R. Schifani, "PD recognition by means of statistical and fractal parameters and a neural network", IEEE Trans. Dielectr. Electr. Insul., Vol. 7, No. 1, pp. 87-94, 2000.
- [5] M. M. A. Salama and R. Bartnikas, "Determination of neural-network topology for partial discharge pulse pattern recognition", IEEE Trans. Neural Netw., Vol. 13, No. 2, pp. 446 - 456, 2002.
- [6] F. M. Frattale Mascioli and G. Martinelli, "A constructive approach to neuro-fuzzy networks", Signal Process, Vol. 64, No. 3, pp. 347-358, 1998.
- [7] C. Mazzetti, F. M. Frattale Mascioli, F. Baldini, M. Panella, R. Risica, and R. Bartnikas, "Partial Discharge Pattern Recognition by Neuro-Fuzzy Networks in Heat-Shrinkable Joints and Terminations of XLPE Insulated Distribution Cables", IEEE Trans. on Power Delivery, Vol. 21, No. 3, pp.1035-1044, 2006.
- [8] T. K. Abdel-Galil, R. M. Sharkawy, M. M. A. Salama and R. Bartnikas, "Partial Discharge Pulse Pattern Recognition using an Inductive Inference Algorithm", IEEE Transactions on Dielectrics and Electrical Insulation Vol. 12, No. 2, pp.320-327, 2005.
- [9] Rhee, F. C.-H, "Uncertain fuzzy clustering: insights and recommendations", IEEE Computational Intelligence Magazine, vol. 2, pp. 44-56, 2007, 2.
- [10] M. M. A. Salama and R. Bartnikas, "Fuzzy logic applied to PD pattern classification", IEEE Trans. Dielectr. Electr. Insul., Vol. 7, No. 1, pp.118 - 123, 2000.
- [11] Takeshi Yamakawa, "A Neo Fuzzy Neuron and Its

Application to System Identification and Prediction of the System Behavior", Proceeding of the 2nd International Conference on Fuzzy logic & Neural Networks, pp. 447~483, 1992.

- [12] A. Staiano, R. Tagliaferri and W. Pedrycz, "Improving RBF networks performance in regression tasks by means of a supervised fuzzy clustering", Neurocomputing, Vol. 69, Issue 13~15, pp. 1570~1581, 2006.
- [13] Yang, Zheng R. "A Novel Radial Basis Function Neural Network for Discriminant Analysis", IEEE Transactions on Neural Networks. Vol. 17. No. 3 , pp. 604~612, 2006.
- [14] N. Karnik, J. Mendel, and Q. Liang, "Type-2 Fuzzy Logic Systems", IEEE Trans. On Fuzzy Systems, Vol. 7, No. 6, pp. 643~658, 1999.
- [15] J. Moody and C. J. Darken, "Fast learning in network of locally-tuned processing units", Neural Comput., Vol. 1, pp. 281 ~ 294, 1989.
- [16] A. Staiano. J. Tagliaferri, W. Pedrycz, "Improving RBF networks performance in regression tasks by means of a supervised fuzzy clustering Automatic structure and parameter", Neurocomputing, Vol. 69, pp. 1570~1581, 2006.
- [17] J. M. Mendel, "Uncertain Rule-Based Fuzzy Logic Systems: Introduction and New Directions", Prentice-Hall: NJ, 2001.



### 오 성 권 (吳 聖 權)

1981년 : 연세대학교 전기공학과 졸업.  
 1983년 : 동 대학원 전기공학과 졸업(공학석사). 1983~1989년 : 금성산전연구소(선임연구원). 1993년 : 연세대 대학원 전기공학과 졸업(공학박사). 1996~1997년 : 캐나다 Manitoba대학 전기 및 컴퓨터공학과 Post-Doc. 1993~2005년 : 원광대 전기전자 및 정보공학부 교수  
 2005년~현재 : 수원대 전기공학과 교수.  
 2002년~현재 : 대한전기학회, 퍼지및지능시스템학회 및 제어자동화시스템 공학회 편집위원. 관심분야 : 시스템자동화, 퍼지이론 및 제어, 컴퓨터 지능 등.  
 Tel : (031) 229-8162  
 E-mail : ohsk@suwon.ac.kr

### 저 자 소 개



#### 김 길 성 (金 吉 成)

2007년 : 수원대 컴퓨터학과 졸업.  
 2007년~현재 : 동 대학원 전기공학과(공학석사). 관심분야 : 퍼지추론시스템, 신경회로망, 유전자 알고리즘 및 최적화이론, 지능시스템 및 제어 등  
 Tel : (031) 222-6544  
 E-mail : gilsung@suwon.ac.kr



#### 안 인 석 (安 寅 錫)

1987년 : 연세대 전기공학과 졸업.  
 1997년 : 동 대학원 전기공학과 졸업(공학박사). 1999~현재 : 동 대학원 전기공학과 석사과정. 관심분야 : 로보틱스, 지능제어, 지능시스템  
 Tel : (054) 760-1623  
 E-mail : isahn@uu.ac.kr