

Neuro-Fuzzy 기법을 이용한 부분방전 패턴인식에 대한 연구

論 文

57-12-29

A Study on Partial Discharge Pattern Recognition Using Neuro-Fuzzy Techniques

朴 建 俊^{*} · 金 吉 成^{**} · 吳 聖 權[†] · 崔 源^{***} · 金 正 泰[§]
(Keon-Jun Park · Gil-Sung Kim · Sung-Kwun Oh · Won Choi · Jeong-Tae Kim)

Abstract - In order to develop reliable on-site partial discharge(PD) pattern recognition algorithm, the fuzzy neural network based on fuzzy set (FNN) and the polynomial network pattern classifier based on fuzzy Inference (PNC) were investigated and designed. Using PD data measured from laboratory defect models, these algorithms were learned and tested. Considering on-site situation where it is not easy to obtain voltage phases in PRPDA(Phase Resolved Partial Discharge Analysis), the measured PD data were artificially changed with shifted voltage phases for the test of the proposed algorithms. As input vectors of the algorithms, PRPD data themselves were adopted instead of using statistical parameters such as skewness and kurtosis, to improve uncertainty of statistical parameters, even though the number of input vectors were considerably increased. Also, results of the proposed neuro-fuzzy algorithms were compared with that of conventional BP-NN (Back Propagation Neural Networks) algorithm using the same data. The FNN and PNC algorithms proposed in this study were appeared to have better performance than BP-NN algorithm.

Key Words : Partial discharge, Pattern recognition, Dielectric degradation, Neuro-fuzzy algorithm, PRPDA

1. 서 론

최근 현장에서 부분방전을 측정하는 것은 전력설비 절연 열화의 가장 중요한 진단 기법으로 자리잡고 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 가장 좋은 결과를 보이는 알고리즘인 뉴럴네트워크(Neural Network, NN)[1-5]는 현장의 문제점을 고려하여 수정할 수 없다는 큰

단점을 갖고 있다[6-9].

현장 부분방전 측정의 또 다른 문제점은 실험실과는 달리 PRPDA(Phase Resolved Partial Discharge Analysis) 수행 시에 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. 따라서, NN 알고리즘과 같이 현장의 문제점 수정이 어려운 알고리즘은 이러한 전압 위상 문제점 측면에서는 더욱 불리한 알고리즘이 될 수 있다.

최근 NN 알고리즘의 단점을 보완하기 위해 퍼지 기능을 접목시킨 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]

이상과 같은 관점에서 본 연구에서는 보다 신뢰성 있는 현장 부분방전 패턴인식 알고리즘을 개발하기 위해, 퍼지 접합

* 교신저자, 正會員 : 水原大 工大 電氣工學科 教授 · 工博
E-mail : ohsk@suwon.ac.kr

* 正 會 員 : 水原大 工大 電氣工學科 博士課程

** 學 生 會 員 : 水原大 工大 電氣工學科 碩士課程

*** 學 生 會 員 : 大真大 工大 電氣工學科 碩士

§ 正 會 員 : 大真大 工大 電氣情報시스템工學科 教授 · 工博
接受日字 : 2008年 5月 12日
最終完了 : 2008年 9月 10日

기반 퍼지 뉴럴네트워크(Fuzzy Neural Network based on Fuzzy Set; FNN)와 퍼지 추론 기반 다항식 네트워크 패턴 분류기(Polynomial Network Pattern Classifier based on Fuzzy Inference; PNC)를 설계하고 부분방전 패턴인식 실험을 하여 그 특성과 성능을 비교 분석하였다. 입력벡터로는 PRPDA의 웨도(skewness)나 침쇄도(kurtosis)와 같은 통계적 파라미터를 사용하는 대신에, 통계적 파라미터가 주는 불확실성을 개선하기 위해 PRPD 데이터를 그대로 이용하는 방법을 사용하였다. 아울러, 기존 NN 방법인 BP-NN(Back Propagation - Neural Network)을 동일한 데이터에 대해 수행하여 뉴로-퍼지 기법과 비교하였다.

2. 부분방전 측정 및 데이터 구축

2.1 모델 결함 및 부분방전 측정 시스템

전력설비의 절연체에서 발생할 수 있는 부분방전 열화를 대상으로 하여, 다음과 같은 4 가지 모의 결함을 실험 대상으로 선정하였다. 우선, 절연체 결함의 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)에 대해서도 고려하였다. 그림 1(a)는 보이드 결함, (b)는 코로나 방전, (c)는 표면방전의 모델이며, 그림 1(d)는 접지측에서 측정한 노이즈의 예이다.

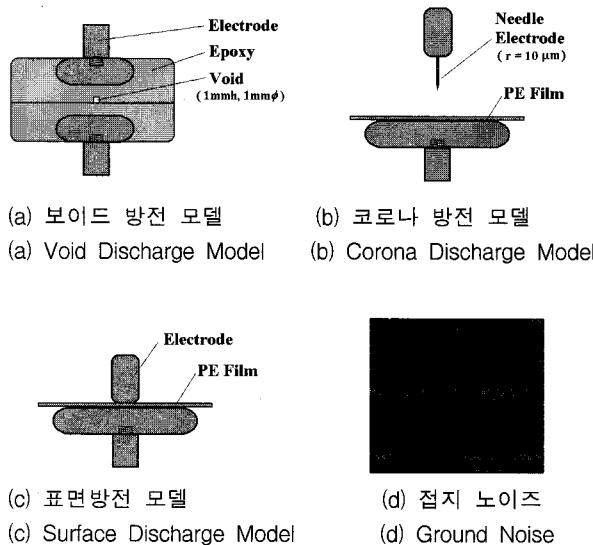


그림 1 모의 결함
Fig. 1 Artificial Defects

부분방전 측정 데이터를 구축하기 위한 실험장치 구성의 개념도를 그림 2에 나타내었으며, 현장 부분방전 측정에 많이 사용되는 대표적인 HFCT(High Frequency Current Transformer) 센서(200kHz~50MHz)를 이용하였다. 모의결함에 대해 고전압 전원을 인가하여 부분방전을 발생시킨 후, HFCT와 튜닝 앰프, 오실로스코프와 스펙트럼 어널라이저로 연동된 PC를 이용하여 측정 및 데이터 수집(LabVIEW 이용)을 하였다.

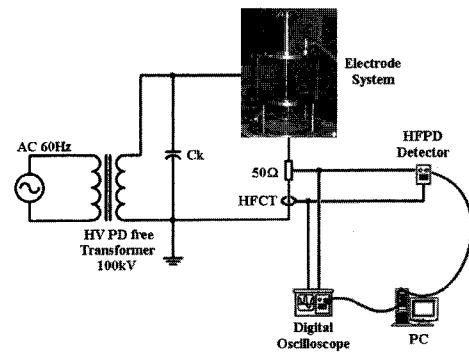


그림 2 부분방전 측정 시스템의 개념도

Fig. 2 Concept of Partial Discharge Measuring System

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 인가 전압의 위상에 맞추어 중첩시켜 분석하는 방법으로, 결함의 종류에 따라 다양한 형태의 패턴이 형성되기 때문에 측정된 부분방전의 원인 분석과 절연열화진단에 매우 유용한 분석방법이다. 패턴인식의 입력벡터로는 일반적인 PRPD의 웨도(skewness)나 침쇄도(kurtosis)와 같은 통계적 파라미터를 이용하지 않고, 패턴인식 정확도의 향상을 위하여 PRPD 화면 전체를 입력하는 방법을 택하였다. PRPD 데이터 중에는 위상 ϕ 에 따른 부분방전 펄스 수($\phi-n$)와 평균방전량($\phi-q$)을 이용하였다. 산출된 부분방전 펄스 수($\phi-n$)와 평균 방전량($\phi-q$) 2 개의 요소는 하나의 조를 이루어 입력벡터로서 적용하였다. 이에 따른 입력벡터의 수는 다음과 같다 :

$$\text{입력벡터의 수} = 128(\text{방전펄스수}) + 128(\text{평균방전량}) = 256$$

즉, PRPDA의 ($\phi-n$) 및 ($\phi-q$) Map에서 인가전압의 위상 360° 를 128개의 원도우로 나누어, 1개의 원도우가 약 2.8° 의 위상각에 해당되도록 하였다. 이에 따라, 측정 시간 동안 중첩된 부분방전 펄스 수($\phi-n$)는 128개 원도우에 대한 펄스 수 데이터가 되도록 변환하였으며, 평균 부분방전량($\phi-q$)도 마찬가지로 128개 원도우에 대한 평균방전량 데이터가 되도록 하였다. 결국, 패턴인식 프로그램의 입력벡터의 수는 2 개 요소의 합인 256개가 되었다.

2.3. 전압위상에 대한 고려

한편, 현장에서 부분방전을 측정할 경우 이와 매칭되는 전압 위상을 같이 측정하는 것은 거의 불가능하다. 따라서, 현장에서 측정 분석된 PRPDA의 ($\phi-n$) 및 ($\phi-q$) Map은 실제 전압위상과 매칭되었다고 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 쉬프트시켜 변형된 데이터를 구성하였다. 이 때, 현장에서 어느 정도의 위상 오차가 발생하는지를 알지 못하므로 본 연구에서는 임의로 14.1° (5개 원도우) 및 28.2° (10개 원도우)의 전압 위상

을 쉬프트시켜 변형된 데이터를 구축하고 이를 활용하였다. 즉, 패턴인식 알고리즘의 학습은 위상 쉬프트가 없는 원래의 측정 데이터로서 수행하고, 알고리즘에 대한 시험은 위상 쉬프트를 시킨 변형된 데이터를 이용하여 수행하여, 개발한 알고리즘이 이러한 현장 상황에 잘 적용될 수 있는지를 분석하였다.

3. 부분방전 패턴인식 시스템

본 연구에서는 부분방전 데이터의 패턴인식을 위해 3 가지 모델을 이용하여 그 성능을 비교하였다. 고급 CI(Computational Intelligence) 기법을 이용하여 학습속도가 빠르고, 수렴특성이 우수한 퍼지 집합 기반 퍼지 뉴럴 네트워크와 퍼지 추론기반 다항식 패턴분류기를 개발하였다. 아울러, 이 두 가지 모델의 효용성을 비교하기 위하여 현재 까지 적용된 알고리즘 중에서 패턴인식율이 높다고 알려져 있는 BP-NN(Back-Propagation Neural Network; BP-NN)을 구현하여 비교하였다.

3.1 BP-NN

BP-NN은 신경회로망을 기반으로 한 패턴 분류기의 모델 중 가장 많이 사용되는 모델이다. 일반적인 BP-NN는 입력 층, 은닉층, 출력층의 3층 구조를 가지며 3층 구조를 가지고도 경사하강법(Gradient Descent Method)을 통하여 복잡한 판정 경계를 생성할 수 있는 장점이 있다. 일반적인 BP-NN는 그림 3과 같은 형태를 갖는다.

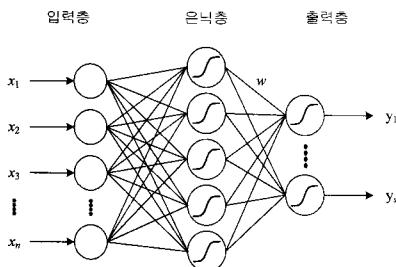


그림 3 일반적인 신경회로망의 기본 구조

Fig. 3 Basic architecture of a general neural network

여기서 n 은 입력 공간의 차원 수, s 는 출력 공간의 차원 수 또는 패턴분류의 클래스 수이다. 입력층은 입력 벡터 $\mathbf{x} = [x_1, \dots, x_n]^T$ 를 입력으로 받아 은닉층으로 전달한다. 은닉층과 출력층의 활성함수는 식 (1)의 시그모이드 함수를 사용하였다.

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

일반적인 BP-NN의 학습 알고리즘은 목표치 벡터와의 오차를 감소시켜 나가는 지도학습(supervised learning)이다. 이 알고리즘은 음성 및 화상 패턴인식 분야에서 매우 활용도가 높은 알고리즘으로 상대적으로 간단한 프로그램구성과 탁월한 패턴인식 결과를 제공하는 것으로 알려져 있다. 또한, 일단 학습이 되고 나면 매우 빠르게 패턴인식 결과를 제

공하므로 실시간 부분방전 패턴인식에는 매우 적절한 알고리즘으로 사용된다. 그러나 Back-propagation 알고리즘은 최소 점을 향해 오차곡선이 진행하다가 오차곡선이 지역 극소에 빠져서 더 이상 학습이 진행되지 않는 결점이 있다. 아울러, 일단 학습 후에는 수정이 어려워 현장 적용시 현장의 상황을 감안하여 수정할 수 없는 단점이 있다.

3.2 퍼지 집합 기반 퍼지 뉴럴 네트워크

퍼지 뉴럴 네트워크[11]는 언어적 애매함을 다루는 퍼지 이론과 인간의 두뇌가 이루고 있는 신경의 구조를 모방한 신경망을 상호 융합한 지능형 모델이다. 퍼지뉴럴네트워크는 기존의 모델에 비해서 학습속도가 빠르고, 수렴특성이 우수한 장점을 가진다. 아래의 그림 4는 제안된 퍼지뉴럴네트워크의 구조를 보여준다.

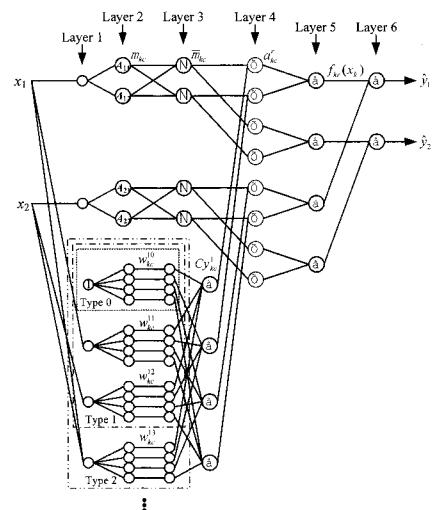


그림 4 퍼지 뉴럴 네트워크의 구조

Fig. 4 Architecture of FNN

3.2.1 퍼지 집합 퍼지 뉴럴 네트워크의 구조

각 입력신호는 각 멤버쉽함수를 거쳐 적합도가 구해지고, 적합도는 연결가중치와 곱해지며, 이들이 대수적으로 합해져 k 번째 출력 f_{kr} 를 생성한다. 최종 출력값은 f_{kr} 들의 대수적인 합이다.

$$\hat{y}_r = \sum_{k=1}^l f_{kr} \quad (2)$$

입력 x_k 에 대한 f_{kr} 은 퍼지규칙을 이루고 있으며 그 규칙은 다음과 같다.

$$R'_{kc}: \text{If } x_k \text{ is } A_{kc} \text{ then } C y'_{kc} = g(x_1, \dots, x_k) \quad (3)$$

간략 추론 (구조 1) : $g = w_{kc}^0$

선형 추론 (구조 2) :

$$g = w_{kc}^0 + w_{kc}^1 \cdot x_1 + \dots + w_{kc}^k \cdot x_k$$

여기서, R 은 입력에 대한 퍼지규칙을 나타내며, A_{kc} 는 전반부 퍼지변수로 멤버쉽함수로 표현된다. w 는 후반부 상수이며, 퍼지 규칙내의 연결가중치를 나타낸다. 전반부 멤버쉽함수는 이웃하는 멤버쉽함수와 보수적인 관계를 가지는 삼각형 멤버쉽함수를 사용한다.

설계된 퍼지 뉴럴 네트워크에서 각 층의 연산과정은 다음과 같다.

[1층] 입력층

[2층] 적합도 계산: μ_{kc}

[3층] 정규화된 적합도 계산: $\bar{\mu}_{kc} = \mu_{kc} / \sum_{c=1}^g \mu_{kc} = \mu_{kc}$

[4층] 연결가중치와의 곱: $a'_{kc} = \bar{\mu}_{kc} \cdot Cy'_{kc} = \mu_{kc} \cdot Cy'_{kc}$

[5층] 각 입력변수의 퍼지추론 값:

$$f_{kr} = \sum_{c=1}^g a'_{kc} = \sum_{c=1}^g \mu_{kc} \cdot Cy'_{kc}$$

[6층] 최종 출력: $\hat{y}_r = \sum_{k=1}^l f_{kr}$

3.2.2 퍼지 집합 퍼지 뉴럴 네트워크의 학습

네트워크의 학습은 연결가중치를 가장 적절한 값으로 조정해 나가면서 이루어진다. 학습방법은 오류역전파 알고리즘을 이용하며, 이는 원 출력과 모델 출력간의 차, 즉 오차를 바탕으로 이루어진다.

$$E_p = \sum_{r=1}^s (y_{pr} - \hat{y}_{pr})^2 \quad (4)$$

간략 추론과 선형 추론의 경우 연결가중치의 조절은 다음과 같이 기존의 값에 오차로부터 구해진 조절량 만큼의 변화를 더해 준다. 여기에서는 간략 추론의 경우를 설명한다.

$$w_{kc}^0(t+1) = w_{kc}^0(t) + \Delta w_{kc}^0 \quad (5)$$

$$\Delta w_{kc}^0 = n \left(-\frac{\partial E_p}{\partial w_{kc}^0} \right) \quad (6)$$

$$-\frac{\partial E_p}{\partial w_{kc}^0} = -\frac{\partial E_p}{\partial \hat{y}_{pr}} \cdot \frac{\partial \hat{y}_{pr}}{\partial f_{kr}} \cdot \frac{\partial f_{kr}}{\partial w_{kc}^0} \quad (7)$$

여기서,

$$-\frac{\partial E_p}{\partial \hat{y}_{pr}} = -\frac{\partial}{\partial \hat{y}_{pr}} \left(\sum_{r=1}^s (y_{pr} - \hat{y}_{pr})^2 \right) = 2(y_{pr} - \hat{y}_{pr}) \quad (8)$$

$$\frac{\partial \hat{y}_{pr}}{\partial f_{kr}} = \frac{\partial}{\partial f_{kr}} \left(\sum_{k=1}^l f_{kr} \right) = 1 \quad (9)$$

$$\frac{\partial f_{kr}}{\partial w_{kc}^0} = \frac{\partial}{\partial w_{kc}^0} \left(\sum_{c=1}^g \mu_{kc} \cdot w_{kc}^0 \right) = \mu_{kc} \quad (10)$$

따라서

$$\Delta w_{kc}^0 = 2n(y_{pr} - \hat{y}_{pr})\mu_{kc} \quad (11)$$

또한, 모멘텀을 포함하는 연결가중치 변화량은 다음과 같다.

$$\begin{aligned} \Delta w_{kc}^{r0} &= 2n(y_{pr} - \hat{y}_{pr})\mu_{kc} \\ &+ \alpha(w_{kc}^{r0}(t) - w_{kc}^{r0}(t-1)) \end{aligned} \quad (12)$$

선형 추론 (구조 2)인 경우는 다음과 같이 유도된다.

$$\begin{aligned} \Delta w_{kc}^{rk} &= 2n(y_{pr} - \hat{y}_{pr})\mu_{kc}x_k \\ &+ \alpha(w_{kc}^{rk}(t) - w_{kc}^{rk}(t-1)) \end{aligned} \quad (13)$$

3.2.3 유전자 알고리즘을 이용한 퍼지 뉴럴 네트워크의 최적화

유전자 알고리즘[12]은 자연 선택과 유전학에 기반으로 하는 확률적인 탐색방법으로써 탐색과 해의 가능영역들을 균형 있게 이용하기 위하여 생산, 교배, 돌연변이의 과정을 수행하는 일반성 있는 탐색법으로 비선형 최적화 이론에 탁월한 성능을 발휘하고 있다. 기존의 다른 탐색방법들과 달리 유전자 알고리즘은 해가 될 가능성이 있는 개체집단을 유지하면서 그들 모두가 동시에 최적값을 찾아나가기 때문에 지역 극소에 빠질 위험을 어느 정도 해결할 수 있다는 점과 더불어 모델의 성능지수가 최소가 되는 전역 극소 영역을 찾는 능력을 갖고 있으며, 또한 기존의 방법들과는 달리 선형, 연속, 미분 가능 등의 제한이 없기 때문에 다양한 분야에 별다른 제한 없이 적용할 수 있다는 장점을 가진다는 것이 중요한 특징이다. 본 논문에서는 제안된 퍼지뉴럴 네트워크에 대한 전반부 멤버쉽함수의 정점과 학습률 및 모멘텀을 최적으로 설정해 주기 위하여 실수코딩 유전자 알고리즘을 이용하여 네트워크의 최적화 과정을 수행하게 된다.

3.3 퍼지 추론 기반 다항식 패턴 분류기

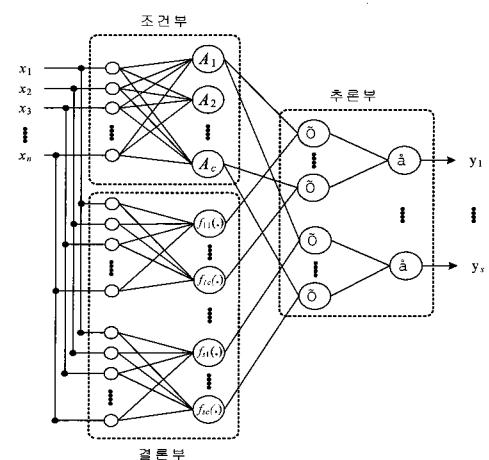


그림 5 조건부, 결론부, 추론부의 세 가지 모듈로서 표현된 PNC의 구조

Fig. 5 Topology of PNC showing three modules of condition, conclusion, and inference phases

본 연구에서 제안한 PNC 구조는 FCM(Fuzzy C-Means) 클러스터링 분할 함수와 다항식의 적용으로부터 식 (14)의 퍼지 규칙 표현과 같이 언어적 관점에서 해석될 수 있다.

$$\text{If } \mathbf{x} \text{ is } A_i \text{ then } f_{ii}(\mathbf{x}) \quad (14)$$

여기서, \mathbf{x} 는 입력 벡터, A_i 는 FCM 클러스터링에 의한 i ($=1, \dots, c$) 번째 그룹의 소속 함수, $f_{ji}(\mathbf{x})$ 는 $j (=1, \dots, s)$ 번째 출력에 대한 i 번째 퍼지 규칙의 다항식이다. 제안된 PNC 구조는 퍼지 규칙에 기반 한 네트워크 구조를 가지며, 조건부, 결론부, 추론부의 세 가지 기능적 모듈로 분리되어 동작한다. 그림 5는 기능적 모듈로서의 PNC 구조를 보여준다.

3.3.1 PNC의 조건부

FCM 클러스터링을 사용하는 PNC의 조건부 기능은 학습 데이터의 특성 반영을 위해 입력 공간을 c 개의 클러스터 수(퍼지 규칙 수)만큼의 로컬 영역으로 분리하고 각 로컬 영역의 소속정도를 퍼지 침합으로서 출력한다. FCM 클러스터 방법은 각 데이터와 특정 클러스터 중심과의 거리에 소속 정도를 부여하고 이 소속정도에 따라 데이터를 분류하는 알고리즘이다[13]. FCM 클러스터링은 목적함수인 식 (15)를 최소화함으로서 입력데이터의 각 클러스터에 대한 소속 값을 구한다.

$$Q = \sum_{i=1}^c \sum_{k=1}^N u_{ik}^m \| \mathbf{x}_k - \mathbf{v}_i \|^2 \quad (15)$$

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 1 사이의 실수이다. 식 (15)의 $\| \cdot \|$ 는 식 (16)으로 표현되는 각종 유clidean 거리를 사용한다.

$$\| \mathbf{x}_k - \mathbf{v}_i \|^2 = \sum_{j=1}^n \frac{(x_{kj} - v_{ij})^2}{\sigma_j^2} \quad (16)$$

여기서, σ_j 는 입력 패턴들의 j 번째 입력 차원의 표준편차이다.

소속행렬 u_{ik} 와 클러스터 중심 \mathbf{v}_i 는 식 (17)과 식 (18)에 의해 각각 계산된다.

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{\| \mathbf{x}_k - \mathbf{v}_i \|^2}{\| \mathbf{x}_k - \mathbf{v}_j \|^2} \right)^{\frac{2}{m-1}}}, \quad 1 \leq k \leq N, \quad 1 \leq i \leq c \quad (17)$$

$$\mathbf{v}_i = \frac{\sum_{k=1}^N u_{ik}^m \mathbf{x}_k}{\sum_{k=1}^N u_{ik}^m}, \quad 1 \leq i \leq c \quad (18)$$

퍼지화 계수 “ m ”은 각 클러스터의 소속 함수의 형태를 결정하는 매우 중요한 요소이다.

3.3.2 PNC의 결론부

PNC 구조의 결론부는 조건부에서 분리한 각 로컬 영역을 다항식 함수의 로컬 회기모델로서 표현하여 식 (14)의

“then” 이후의 규칙을 형성한다. 식 (14)의 $f_{ii}(\mathbf{x})$ 에서 출력 뉴런에 대한 첨자 j ($=1, \dots, s$)를 생략한 $f_i(\mathbf{x})$ 는 식 (19)~(20)의 형태를 갖는 두 가지 타입의 함수 중 하나의 형태를 갖는다. 즉, 로컬 회기 모델은 상수형, 일차식 또는 이차식으로 표현되어 진다.

$$\text{Constant : } f_i(\mathbf{x}) = a_0 \quad (19)$$

$$\text{Linear : } f_i(\mathbf{x}) = a_0 + \sum_{j=1}^n a_{ij} x_j \quad (20)$$

3.3.3 PNC의 추론부

추론부에서는 “If-then” 퍼지 규칙 기반의 퍼지 추론에 의해 네트워크의 최종출력을 구하게 된다. 그림 5의 추론부의 “Π”로 표기된 뉴런은 각 퍼지 규칙의 소속 함수와 다항식 로컬모델의 곱을 의미하며, “Σ”로 표기된 뉴런에 의해 입력신호들은 합하여서 그 결과를 출력층 뉴런의 최종 출력으로 내보낸다. 최종출력은 퍼지 추론에 의한 식 다음과 같이 표현된다.

$$y_j = g_j(\mathbf{x}) = \sum_{i=1}^c \frac{u_i f_{ji}(\mathbf{x})}{\sum_{k=1}^c u_k} = \sum_{i=1}^c u_i f_{ji}(\mathbf{x}) \quad (21)$$

여기서, u_i 는 그림 5의 $A_i(x)$ 와 같고 모든 클러스터에 대한 총합은 1이다. 식 (21)의 $g_j(x)$ 는 PNC의 j 번째 클래스에 대한 판별 함수가 된다.

3.3.4 PNC의 학습

여기에서는 PNC의 식 (21)의 판별 함수 $g_j(x)$ 를 생성하기 위한 PNC 학습 과정을 설명한다. PNC의 학습은 경사 하강법과 모멘텀 방법을 통해 이루어진다. 계수 동정(Identification)을 위한 학습은 식 (22)으로 표현되는 오차를 모든 패턴에 대하여 최소화하도록 진행된다.

$$E_q = \frac{1}{2} (t_q - y_q)^2, \quad q = 1, \dots, N \quad (22)$$

여기서, E_q 는 q 번째 패턴에 대한 오차, N 은 입력 패턴 수이다. t_q 는 q 번째 패턴에 대한 목적 값이다. y_q 는 q 번째 패턴에 대한 네트워크의 최종출력이며 식 (23)과 같다.

$$y_q = \sum_{i=1}^c u_i f_i \quad (23)$$

PNC의 학습은 f_i 의 두 가지 타입에 따라 2 가지의 경우로 나뉜다.

i) 결론부 다항식 함수가 “Constant”인 타입

다항식 함수가 Constant인 경우 $f_i = a_0$ 이다. a_0 를 구하기 위해 식 (22)의 E_q 와 a_0 의 관계를 사슬법칙(Chain rule)으로 나타내면 식 (24)와 같다. 식 (24)의 우변의 첫째 항, 둘째 항, 셋째 항을 미분하여 정리하면 각각 식 (25)~(27)

과 같이 정리된다.

$$\frac{\partial E_q}{\partial a_0} = \frac{\partial E_q}{\partial y_q} \cdot \frac{\partial y_q}{\partial f_i} \cdot \frac{\partial f_i}{\partial a_0} \quad (24)$$

$$\frac{\partial E_q}{\partial y_q} = (-1)(t_q - y_q) \quad (25)$$

$$\frac{\partial y_q}{\partial f_i} = u_i \quad (26)$$

$$\frac{\partial f_i}{\partial a_0} = 1 \quad (27)$$

계수 a_0 의 변화분(delta)은 식 (28)과 같고 모멘텀까지 고려한 최종 식은 식 (29)와 같다.

$$\Delta a_0 = -n \cdot \frac{\partial E_q}{\partial a_0} = n(t_q - y_q)u_i \quad (28)$$

$$\begin{aligned} a_0(p+1) &= a_0(p) + n(t_q - y_q)u_i \\ &\quad + a(a_0(p) - a_0(p-1)) \end{aligned} \quad (29)$$

여기서 n 는 학습률, a 는 모멘텀 계수, $p+1$ 은 새로운 값, p 는 현재 값, $p-1$ 은 이전 값을 나타낸다.

ii) 결론부 다항식 함수가 “Linear”인 타입

다항식 함수가 Linear인 경우 f_i 는 식 (30)과 같다. Constant 타입의 경우와 마찬가지로 모멘텀까지 고려한 최종 식은 다음과 같이 표현된다.

$$f_i = a_0 + \sum_{j=1}^n a_j x_j \quad (30)$$

$$\Delta a_{ij} = -n \cdot \frac{\partial E_q}{\partial a_{ij}} = n(t_q - y_q)u_i x_j \quad (31)$$

$$\begin{aligned} a_{ij}(p+1) &= a_{ij}(p) + n(t_q - y_q)u_i x_j \\ &\quad + a(a_{ij}(p) - a_{ij}(p-1)) \end{aligned} \quad (32)$$

3.3.5 Particle Swarm Optimization

PSO(Particle Swarm Optimization)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. 여기에서는 PSO 알고리즘에 관하여 간략하게 설명하며 PSO의 연산자는 참고문헌 [15, 16]에 자세히 설명되어 있다. 본 연구에서는 PSO 알고리즘을 사용하여 학습률과 모멘텀 계수, 퍼지화 계수를 최적 동조하고 PNC의 분류기로서의 성능을 향상 시킨다.

4. 부분방전 패턴 인식 실험

4.1 모델 결합에 대한 PRPDA 결과

그림 6은 4 가지 인위적 결합 모델을 이용하여 구한 PRPDA의 예로서, $(\phi-n)$ 및 $(\phi-q)$ Map을 3 차원으로 표시하였다. 본 연구에서는 이와 같은 데이터를 각 결합별로 100 개 이상 준비하여, 패턴인식의 데이터 집합으로 사용하였다.

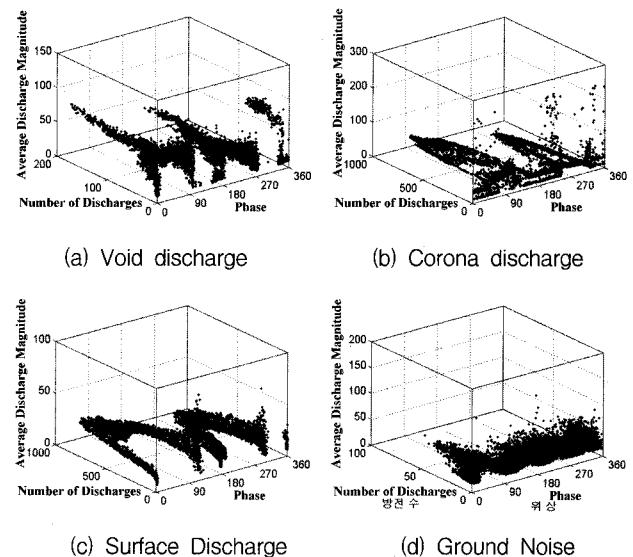


그림 6 인위적 모델 결합에 대한 PRPDA 결과의 예
Fig. 6 Results of PRPDA for various artificial defects

4.2. BP-NN에 의한 부분방전 패턴 분류

BP-NN를 사용한 부분방전 패턴 분류 실험은 초기값에 의한 수렴 특성을 고려하여 학습률 0.01, 모멘텀 계수 0.1을 사용하였으며 300번의 학습을 시행하였다. 은닉층 수를 12개와 16개에 대하여 실험하였다. 테스트는 위상шу프트 0 데이터(테스트 1), 14.1°(5개 원도우) 위상шу프트 데이터(테스트 2)와 28.2°(10개 원도우) 위상шу프트 데이터(테스트 3)를 가지고 수행하였다. 학습은 위상шу프트 0 데이터 집합을 7:3의 비율로 랜덤하게 학습 데이터와 테스트 데이터로 나누어 5번 반복 실험하였으며 성능평가는 random sub-sampling에 의한 분류 정확성의 평균과 표준편차에 의한다. 이에 대한 테스트 결과를 표 1에 나타내었다.

표 1 BP-NN를 이용한 부분방전 패턴인식 결과

Table 1 Results of PD pattern recognition using BP-NN

No. of Hidden Node	학습 결과	테스트 1 결과	테스트 2 결과	테스트 3 결과
12	100.00 ± 0.00	100.00 ± 0.00	95.17 ± 6.27	77.50 ± 10.42
16	97.57 ± 5.43	97.33 ± 5.96	95.00 ± 7.84	86.33 ± 10.75

테스트 결과, 위상шу프트를 더 많이 시킨 경우의 인식률이 더 나쁘게 나타났다. 은닉층의 노드 수가 12개인 경우에는 표면(Surface) 방전을 잘 구분하지 못하는 것으로 나타났다. 16개인 경우에는 12개인 경우보다 좋은 결과를 나타내긴 하였으나, 보이드 방전의 인식률이 68% 이어서 그다지 우수한 결과를 보이지는 않는 것으로 나타났다.

4.3. 퍼지 집합 기반 퍼지뉴럴 네트워크(FNN)에 의한 부분방전 데이터 패턴 분류

퍼지 집합 기반 퍼지뉴럴 네트워크에 의한 패턴인식에서는 각 입력 데이터에 대한 입력 공간을 최소값과 최대값 기준으로 균등하게 분할하였고, 분할된 점을 기준으로 하여 전반부 멤버쉽함수의 정점을 각각 할당하였다. 또한, 유전자 알

고리즘을 적용하여 전반부 멤버쉽함수의 정점과 학습률, 모멘텀을 자동 동조하였다. 표 2에 퍼지 집합 기반 퍼지뉴럴 네트워크 및 유전자 알고리즘의 파라미터를 나타내었으며, 각 파라미터들은 초기값에 의한 수렴 특성과 계산 시간을 고려하여 적절한 값을 설정하였다. 앞서 언급한 위상수프트 0 데이터를 이용하여 네트워크를 학습시킨 뒤, BP-NN의 경우와 같은 방법으로 테스트를 수행하였다. 표 3에 퍼지 집합 기반 퍼지뉴렐 네트워크에 의한 패턴인식 결과를 나타내었다.

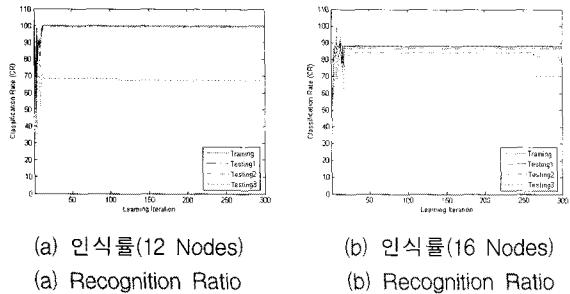


그림 7 BP-NN 의한 패턴인식률

Fig. 7 Pattern Recognition Ratio by BP-NN

표 2 퍼지뉴렐네트워크 및 유전자 알고리즘의 파라미터
Table 2 Parameters for FNN and GAs

파라미터	값
학습 횟수	300
멤버쉽함수의 수	각 입력당 2개 / 3개
세대수	50
유전자 알고리즘	개체수 30 교배율 0.65 돌연변이율 0.1

표 3 FNN를 이용한 부분방전 패턴인식 결과

Table 3 Results of PD pattern recognition using FNN

	학습 결과	테스트 1 결과	테스트 2 결과	테스트 3 결과
MF: 2개/ 간략추론	100.00±0.00	100.00±0.00	99.83±0.00	100.00±0.00
MF: 3개/ 간략추론	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00

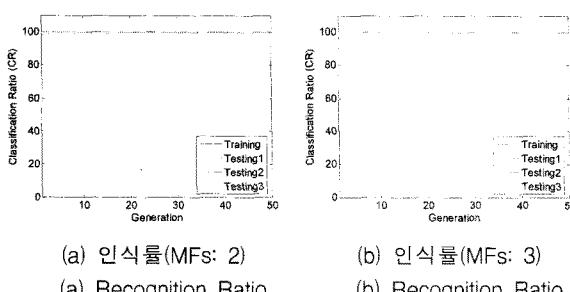


그림 8 FNN에 의한 패턴인식률

Fig. 8 Pattern Recognition Ratio by FNN

퍼지 집합 기반 퍼지뉴렐 네트워크에 의한 패턴인식은 상당히 우수한 결과를 보였다. 특히 멤버쉽 함수를 3개로 한 경우에는 28.2%의 전압위상 쉬프트 데이터에 대한 테스트에서도 100%의 인식율을 보였다. 이는 공간 분할을 보다 많이 한 결과로 보인다.

4.4. 퍼지 추론 기반 다항식 네트워크 패턴 분류기(PNC)에 의한 부분방전 데이터 패턴 인식

퍼지 추론 기반 다항식 네트워크 패턴 분류기에서는 PSO에 의하여 학습률, 모멘텀 계수, 퍼지화상수를 동조하여 최적의 패턴 인식 성능을 보이는 PNC를 구현하였다. 표 4는 PNC와 PSO 알고리즘의 파라미터를 보여준다. 또한, 앞서 언급한 경우와 같은 방법으로 학습 데이터와 테스트 데이터를 나누어 수행하였다.

한편, PNC에서는 결론부가 상수항인 Constant-PNC 및 결론부가 1차식인 Linear-PNC의 2 가지 방법을 적용해보았다. 학습 및 테스트 패턴인식 결과를 각각 표 5 및 표 6에 나타내었다.

표 4 PNC 및 PSO 알고리즘의 파라미터

Table 4 Parameters for PNC and PSO

	파라미터	값
PNC	학습 횟수	50
	퍼지 규칙수	4, 6
PSO	세대수	50
	particle 수	30
	vmax	탐색공간의 20%
	[wmin wmax]	[0.4, 0.9]
	c1, c2	2.0
탐색	학습률	[1e-9, 0.1]
모멘텀	계수	[1e-9, 0.1]
범위	퍼지화 계수	[1.1, 3.0]

표 5 PNC를 이용한 부분방전 패턴인식 결과

Table 5 Results of PD pattern recognition using PNC

Rules/ Type	학습 결과	테스트 1 결과	테스트 2 결과	테스트 3 결과
4/Constant	100.00±0.00	100.00±0.00	82.00±6.25	71.16±6.96
6/Constant	100.00±0.00	100.00±0.00	100.00±0.00	100.00±0.00
4/Linear	100.00±0.00	100.00±0.00	99.66±0.45	84.50±2.67
6/Linear	100.00±0.00	100.00±0.00	99.16±0.58	83.83±1.26

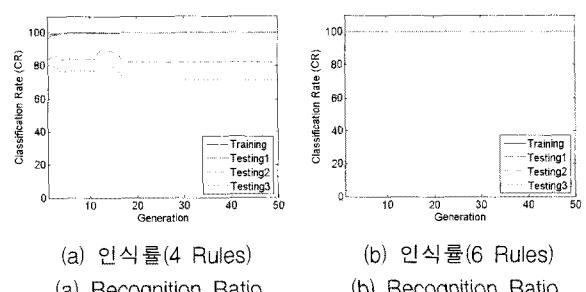


그림 9 Constant-PNC에 의한 패턴인식률

Fig. 9 Pattern Recognition Ratio by Constant-PNC

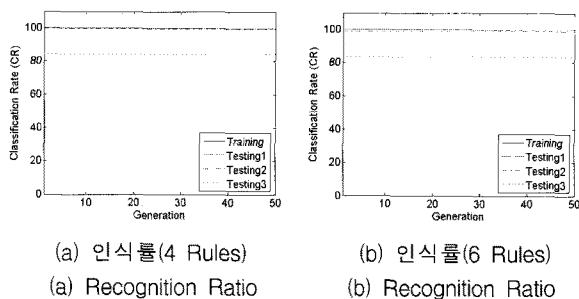


그림 10 Linear-PNC에 의한 패턴인식률

Fig. 10 Pattern Recognition Ratio by Linear-PNC

퍼지 추론 기반 다항식 네트워크 패턴 분류기에서는 간략 추론(Constant-PNC)인 경우 규칙수가 4개 보다 6개일 때 100%의 인식률을 보였다. 선형추론(Linear-PNC)인 경우에는 코로나 방전을 노이즈로 판별하는 오류가 나타났다. 따라서, PNC 알고리즘에서는 규칙수를 증가시키고 선형추론 보다는 간략추론인 경우 좋은 성능을 가지는 특징을 알 수 있다.

5. 결 론

본 연구에서는 현장 적용성이 우수한 부분방전 패턴인식 기법을 개발하기 위해 배타적이지 않은 뉴로-퍼지 기법 2 가지를 검토하였다. 이를 위해 현장에서 많이 사용하는 HFCT 센서를 이용하여 부분방전 데이터를 구축하였으며, PRPDA의 전압위상을 파악하기 어려운 현장 상황을 고려하여 패턴 분류기에 대해 테스트하였다.

그 결과, 본 연구에서 검토한 뉴로-퍼지 기법인 뉴럴 네트워크(FNN) 및 퍼지 추론기반 다항식 네트워크(PNC)은 BP-NN보다 우수한 패턴 분류 성능을 보였다. 이와 같이 부분방전 패턴인식 실험에서 뉴로-퍼지 모델들의 성능이 우수하게 나온 것은 각 입력 데이터의 전체 공간을(Universal Input Space) 데이터의 특성에 맞게 퍼지 공간 분할을 시행하여 Membership 함수를 구성하였기 때문에, 기존의 BP-NN 보다 데이터의 특성을 더 잘 표현하는 판별함수(discriminant function)가 출력 공간상에 생성되었기 때문으로 생각된다. 아울러 최소-최대값을 이용한 멤버쉽함수와 FCM 클러스터링을 이용한 멤버쉽함수의 2가지 멤버쉽함수를 이용하여 불확실성을 다루므로서 학습후 수정할 수 없는 단점과 전압위상을 파악하기 어려운 현장 상황을 고려할 수 있었다. 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

본 연구는 2007년 및 2008년도 정부재원(교육과학기술부)으로 한국학술진흥재단의 지원을 받아 연구되었음(KRF-2007-313-D00710, KRF-2007-511-D00103, KRF-2008-314-D00376), 그리고 이 논문은 2008년도 한국전자통신연구원의 재원으로 부분적 지원을 받아 수행된 연구임 (과제번호:2008-35MIC).

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] 김정태, 이호근, 임윤석, 김지홍, 구자윤, "SOM 알고리즘을 이용한 부분방전 패턴인식에 대한 연구", 대한전기학회논문지, 제53C권 10호, pp. 515-522, 2004.
- [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] D. E. Goldberg, "Genetic Algorithm in search, Optimization & Machine Learning," Addison wesley, 1989.
- [13] M.J. Er, S.Q. Wu, J.W. Lu, H.L. Toh, "Face recognition with radical basis function (RBF) neural

- networks," IEEE Trans. Neural Networks, vol. 13, No. 3, pp. 697-710, 2002.
- [14] 김길성, 박병준, 오성권, "퍼지 추론 메커니즘에 기반한 다항식 네트워크 패턴 분류기의 설계와 이의 최적화," 한국 지능시스템학회 연구지, Vol 17, No. 7, pp. 970-976, Dec. 2007.
- [15] J. Kennedy and R. Eberhart, "Particle swarm optimization," Proc. IEEE Int. Conf. Neural Networks, vol. 4, pp. 1942-1948, 1995.
- [16] J. Kennedy, "The particle swarm: Social adaptation of knowledge," Proc. IEEE Int. Conf. Evolutionary Comput., pp. 303-308, 1997.
- [17] 오성권, 프로그래밍에 의한 컴퓨터지능(퍼지, 신경회로망 및 유전자알고리즘을 중심으로), 내하 출판사, 2002. 8.

저 자 소 개



박 건 준 (朴 建 俊)

2003년 : 원광대학교 전기전자공학부 졸업. 2005년 : 동 대학원 제어계측공학과 졸업(공학석사). 2005~현재 : 수원대학교 전기공학과 박사과정.
관심분야 : 컴퓨터 및 인공지능, 퍼지추론시스템, 신경망, 유전자 알고리즘 및 최적화이론, 자동화시스템 및 제어 등
Tel : (031) 222-6544
Fax : (031) 220-2667
E-mail : birds@suwon.ac.kr



김 길 성 (金 吉 成)

2007년 : 수원대 컴퓨터학과 졸업.
2007년~현재 : 동 대학원 전기공학과 석사과정.
관심분야 : 패턴인식, 퍼지논리시스템, 영상처리, 최적화이론 등
Tel : (031) 222-6544
E-mail : gilsung@suwon.ac.kr



오 성 권 (吳 聖 權)

1981년 : 연세대학교 전기공학과 졸업.
1983년 : 동 대학원 전기공학과 졸업(석사). 1983~1989년 : 금성산전연구소(선임 연구원). 1993년 : 연세대 대학원 전기공학과 졸업(공박). 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.

Tel : (031) 229-8162

Fax : (031) 220-2667

E-mail : ohsk@suwon.ac.kr



최 원 (崔 源)

1980년 9월 3일생. 2003년 대진대 공대 전기공학과 졸업(학사). 2008년 대진대 대학원 전기공학과 졸업(석사).
Tel : (031)539-1910
Fax : (031)539-1910
E-mail : cwsoma@daejin.ac.kr



김 정 태 (金 正 泰)

1960년 1월 1일생. 1982년 한양대 공대 전기공학과 졸업(학사). 1987년 한양대 공대 전기공학과 졸업(석사). 1992년 한양대 공대 전기공학과 졸업(공박). 현재 대진대 공대 전기정보시스템공학과 교수.
Tel : (031)539-1914
Fax : (031)539-1910
E-mail : jtkim@daejin.ac.kr