

최적화된 pRBF 뉴럴 네트워크에 이용한 삼상 부분방전 패턴분류에 관한 연구

A Study on Three Phase Partial Discharge Pattern Classification with the Aid of Optimized Polynomial Radial Basis Function Neural Networks

오 성 권[†] · 김 현 기* · 김 정 태**
(Sung-Kwun Oh · Hyun-Ki Kim · Jung-Tae Kim)

Abstract - In this paper, we propose the pattern classifier of Radial Basis Function Neural Networks(RBFNNs) for diagnosis of 3-phase partial discharge. Conventional methods map the partial discharge/noise data on 3-PARD map, and decide whether the partial discharge occurs or not from 3-phase or neutral point. However, it is decided based on his own subjective knowledge of skilled experter. In order to solve these problems, the mapping of data as well as the classification of phases are considered by using the general 3-PARD map and PA method, and the identification of phases occurring partial discharge/noise discharge is done. In the sequel, the type of partial discharge occurring on arbitrary random phase is classified and identified by fuzzy clustering-based polynomial Radial Basis Function Neural Networks(RBFNN) classifier. And by identifying the learning rate, momentum coefficient, and fuzzification coefficient of FCM fuzzy clustering with the aid of PSO algorithm, the RBFNN classifier is optimized. The virtual simulated data and the experimental data acquired from practical field are used for performance estimation of 3-phase partial discharge pattern classifier.

Key Words : Radial basis function neural networks, Fuzzy C-means clustering, Subtractive clustering, Particle swarm optimization, 3-PARD(3-Phase Amplitude Relation Diagram), PA(Pulse Analysis).

1. 서 론

최근 들어, Computational Intelligence(CI) 기술의 합성을 통한 지능형 시스템의 점진적인 성장은 다양한 과학 및 공학 분야에서 주목을 받고 있다. 이런 추세는 CI 기술의 합성을 통한 고급 지능 시스템의 성능이 실제 시스템의 복잡성이 큰 문제를 분석하는데 있어서 단일 지능형 시스템보다 우수한 성능을 나타내는데 있다. 퍼지 모델, 신경회로망과 같은 지능형 모델에 관한 연구가 진행되었으며, 최근에는 이러한 모델들의 최적화를 통해 모델이 가지고 있는 독특한 특성을 살리면서 지능 시스템의 효율과 성능 향상을 최대한 이끌어 내는 연구가 활발히 진행되어지고 있다. 그 중에서도 방사형 기저 함수 신경회로망(Radial Basis Function Neural Networks; RBFNNs)은 기존의 다중(multilayer) 신경 회로망보다 구조가 간단하고 학습능력이 빠른 특징을 갖고 있으며 퍼지 모델에 비해 비선형적이고 다변수인 시스템을 대상으로 한 모델링에서 우수한 성능을 보인다. 따라서

function approximation, regularization, noisy interpolation, 패턴인식과 같은 다양한 응용분야에서 연구되고 있다[1-5].

현재 컴퓨터 지능 분야에서는 두 개 이상의 모델을 합성한 퍼지 신경 회로망[6], 퍼지 다항식 신경 회로망[7]과 같은 다양한 형태의 모델이 제안되고 있으며, 주어진 입력과 출력 데이터를 분석하고 유사성을 판단하기 위해 클러스터링 기술을 결합한 모델이 연구되고 있다. 클러스터링 방법으로는 FCM (Fuzzy C-Means) [8], K-Means [9], Mountain [10], Subtractive [11] 등이 대표적으로 퍼지 모델 및 신경회로망에 적용되고 있다. 또한 모델의 전체적인 구조 및 모델을 구성하는데 필요한 파라미터들을 최적화시키기 위해 많은 연구가 이루어지고 있으며 유전자 알고리즘(GA: Genetic Algorithms)[12]과 입자군집 최적화 알고리즘(PSO: Particle Swarm Optimization)[13]그리고 두 알고리즘의 개선된 방법들이 모델을 최적화하는데 주로 사용되고 있다.

부분방전 진단 분야는 여러 가지의 부분방전 진단 기법이 존재하나 3상 부분방전을 검출하기 위한 연구는 미약하다. 현재 국내에서는 3상에 Phase Resolved Partial Discharge Analysis(PRPDA) 분석을 MUX에 통해 채널을 바꿔가며 순차적으로 분석하고 노이즈를 제거하기 위해 주파수 튜닝 및 노이즈 게이팅 등의 방법을 사용한다. 기존의 방법은 신호의 주파수 스펙트럼을 먼저 분석한 후 원하는 주파수 대역에서 부분방전 신호를 검출하는 방법으로 검출 하지만 숙련된 전문가가 필요할 뿐 아니라, 작업자의 주관적 판단에 따른 영향이 매우 크게 작용한다.

본 논문에서는 3상 부분방전 진단을 위해 3-Phase

[†] 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

** Dept. of Electrical Information Systems, Daejeon University, Korea

Received : September 17, 2012; Accepted : January 21, 2013

Amplitude Relation Diagram(3-PARD)[14] map과 Pulse Analysis(PA)[15-16] map을 사용하여 데이터를 매핑 시키고 Subtractive 클러스터링 알고리즘을 이용하여 상의 클러스터를 형성하고 Fuzzy C-Means 기반 다항식 방사형 기저 함수 신경회로망 분류기를 통해 최종적으로 부분방전을 진단한다. 또한 제안된 분류기의 최적화를 위해 입자 군집 최적화(Particle Swarm Optimization; PSO) 알고리즘을 적용하여 FCM 클러스터링 알고리즘의 퍼지화 계수 및 분류기 다항식 연결가중치를 학습할 때 필요한 학습률 및 모멘텀 계수를 동조하였다.

2장에서는 3-PARD map과 PA map을 이용한 데이터 매핑방법과 Subtractive 클러스터링 방법에 대해 설명한다. 3장에서는 FCM 기반 다항식 방사형 기저 함수 신경회로망 분류기에 대해 자세히 서술하며, 4장에서는 제안된 분류기를 최적화하기 위한 PSO 알고리즘 및 분류기의 최적화 방법에 대해 설명한다. 5장에서는 모의 실험데이터와 실제 현장에서 취득한 실험데이터를 가지고 제안된 모델의 성능을 평가하며, 6장을 결론으로 논문내용을 정리하였다.

2. 3-PARD map과 PA map를 이용한 데이터 클러스터링

본 장에서는 전력 케이블에서 일어나는 3상에서의 진성 부분방전과 중성점에서 일어나는 노이즈 및 코로나 등으로부터 취득한 데이터를 이용하여 허수와 실수축으로 이루어진 3-Phase Amplitude Relation Diagram (3-PARD) map과 펄스를 분석하는 Pulse Analysis(PA)에 대해 서술한다. 그리고 상(Phase) 분류를 위해 사용된 subtractive 클러스터링 방법에 대해 자세히 설명한다.

2.1 3-PARD map과 PA map

부분방전 및 노이즈를 판별하기 위해 사용되는 3-Phase Amplitude Relation Diagram (3-PARD) 기법[14]에 Pulse Analysis (PA)기법[15-16]을 결합한 진단기법은 진단 및 노

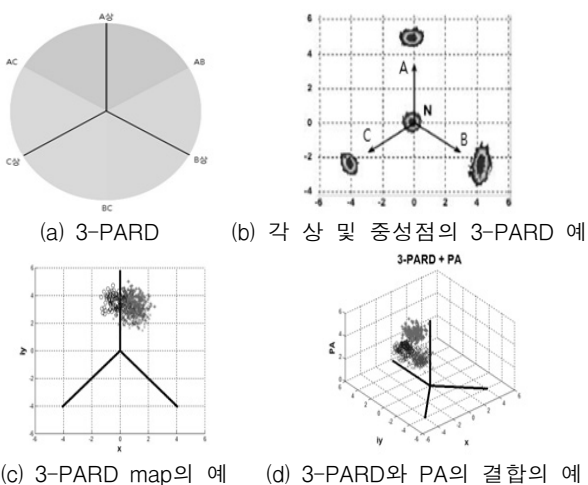


그림 1 3-Phase Amplitude Relation Diagram (3-PARD)
Fig. 1 3-Phase Amplitude Relation Diagram (3-PARD)

이즈 분석의 정확도를 높이기 위해 사용된다.

먼저 3-PARD는 독일의 IPH사에서 개발한 방법으로 3상 각각의 부분방전 펄스 크기를 측정 한 뒤 (A상,B상,C상) C/A와 C/B의 관계를 벡터 합으로 다이어그램에 표현한 방법이다. 다음의 그림 1은 3-PARD에 대해 나타내었다, (a)는 벡터의 관계를 보여주고 부분방전 데이터가 3-PARD map은 부분방전이 발생한 위치에서 매핑되지만 그것을 제외한 노이즈 및 코로나 등은 (b)에서 보는 것과 같이 중성점에 매핑 된다.

PA map은 부분방전 펄스를 고주파대역에서 측정하여 펄스 형태에 대한 통계적 처리를 통해 분석한 후 특정 좌표의 대표 값으로 매핑 하는 클러스터링 기법으로 PA map을 적용하면 결함의 종류에 따라 고유의 중심 좌표를 가지며 여기에서 얼마까지 떨어진 영역을 설정 가능하다는 특징이 있다.

이 두 가지 기법을 혼합의 예를 위하여 같은 데이터를 그림 1의 (c)는 3-PARD amp에만 매핑 시킨 결과이고 (d)는 3-PARD map에서의 한계점을 PA map을 결합함으로써 더욱 정확한 분류를 할 수 있다.

2.2 Subtractive Clustering 방법

Subtractive clustering 알고리즘[11]은 Mountain clustering 알고리즘[10]을 개선하여 계산 량을 줄인 방법으로 써, 데이터의 밀집도에 기반을 둔 클러스터링 알고리즘이다.

n차원 공간에서 m개의 데이터가 주어졌다고 가정하면, 모든 데이터는 클러스터의 중심이 될 수 있다. Mountain 클러스터링은 주어진 입력공간에서 일정간격으로 격자 선을 형성하고, 격자선의 교차점에 대하여 밀도를 측정하여 교차점 그리고 데이터 모두 연산하여 연산 량이 많은 반면 Subtractive는 교차점을 제외하고 주어진 데이터만으로 연산하여 연산 량이 적고 시간이 상대적으로 적게 걸리는 장점이 있다. Subtractive 클러스터링 알고리즘은 다음과 같다.

[Step 1] 각 데이터에 대하여 식(3-1) 밀도함수를 사용하여 밀도를 구한다.

$$D_i = \sum_{j=1}^m \exp\left(-\frac{\|x_i - x_j\|}{\gamma_a/2}\right) \quad (1)$$

여기서, γ_a 는 양의 상수로서 밀도함수의 반경을 의미한다.

[Step 2] D_i 로부터 가장 높은 밀도를 갖는 데이터 x_{c_1} 은 찾고 이 값은 첫 번째 클러스터의 중심이 된다.

[Step 3] [Step 2]에서 찾은 클러스터의 중심을 식(3-2)을 이용하여 파괴한다.

$$D_i = D_i - D_{c_1} \exp\left(-\frac{\|x_i - x_{c_1}\|}{\gamma_b/2}\right) \quad (2)$$

여기서 γ_b 는 양의 상수로서 파괴함수의 반경을 의미하며 일반적으로 $1.5\gamma_a$ 값을 사용한다. D_{c_1} 은 [단계 2]에서 찾은 데

이터 x_{c_i} 의 밀도측정값이다.

[Step 4] [Step 2]~[Step 3]을 가장 높은 밀도 측정값이 설정 값보다 작아질 때까지 반복적으로 수행한다.

3상 부분방전을 클러스터링 하기 위해서는 먼저 부분방전 등이 발생한 위치를 파악해야한다. 먼저 부분방전인지 아닌지 그리고 어느 상(Phase)에서 발생하였는지를 판단하여야 하는데, 이 때 검출된 데이터를 3-PARD map에 매핑 시켰을 때 상(A상,B상,C상 혹은 AP상,AC상,BC상)또는 중성점(Neutral Point; N상)에서 방전 등이 일어났는지 판단 할 수 있다. Subtractive 클러스터링 등의 기법을 통하여 부분방전 등이 발생한 상을 분류한다. 검출된 데이터가 같은 상에서 서로 다른 부분방전이나 노이즈 등이 발생하게 되면 3-PARD map을 사용하여도 구분하기가 쉽지 않게 된다. 그래서 Pulse Analysis(PA)기법을 조합하여 부분방전 등의 위치를 파악한다.

3. 클러스터링 기반 방사형 기저 함수 다항식 신경회로망의 구성

제안된 클러스터링 기반 다항식 방사형 기저 함수 신경회로망(pRBFNNs) 패턴분류기의 구조는 그림 2와 같다.




그림 2 클러스터링 기반 다항식 방사형 기저 함수 신경회로망 패턴분류기 구조

Fig. 2 Pattern Classifier Structure of clustering-based polynomial radial basis function neural networks

그림 2는 Fuzzy C Means 클러스터링 기반 다항식 방사형 기저함수 신경회로망 패턴분류기를 나타낸다. 그림에서 보듯이 각 모델은 크게 조건부, 결론부, 추론부로 나눌 수 있다. 각 부분에서의 역할은 다음과 같다.

3.1 조건부

그림 2의 경우 조건부는 Fuzzy C Means 클러스터링 알고리즘을 사용하였다. 그림에서 보듯이 조건부 전체가 FCM 클러스터링 알고리즘으로 구조적으로 간단하며 연산과정도 간소화되는 장점이 있다. FCM 클러스터링 알고리즘은 다음과 같다[8].

[Step 1] 클러스터의 개수 $c(2 < c < n)$ 을 정하고 퍼지화 계수 $m(1 < m < \infty)$ 을 선택한다. 초기 partition matrix $U(r)$ 을

초기화 한다. 알고리즘 반복 횟수를 $r(r=0, 1, \dots)$ 로 표시한다.

$$U^{(r)} = \left\{ u_{jk} \in [0, 1], \sum_{j=1}^c u_{jk} = 1 \forall k, 0 < \sum_{k=1}^N u_{jk} < n \forall j \right\} \quad (3)$$

[Step 2] 식 (5)을 이용하여 FCM 클러스터 중심 v 을 계산한다.

$$J(u_{jk}, v_j) = \sum_{j=1}^c \sum_{k=1}^N u_{jk}^m (d_{jk})^2 \quad (4)$$

여기서, u_{jk} 는 0과 1사이의 소속을 나타내는 정도의 값으로 $j(j=1, \dots, c)$ 번째 클러스터에 속해져 있는 x_i 의 $i(i=1, \dots, n)$ 번째 데이터의 소속정도를 나타낸다. v_j 는 $j(j=1, \dots, c)$ 번째 클러스터 중심 벡터이다. m 은 partition matrix의 애매함의 정도에 대한 영향을 나타내는 퍼지화 계수이다. 이 값은 $m \in [1, \infty)$ 와 같은 범위를 가지고 있다.

식 (4)의 목적함수를 최소화하기 위해서 먼저 v_i 와 u_{jk} 와 관련된 식의 목적함수를 다음과 같이 분화시켜야 한다.

$$v^{(r)} = \{v_{i1}^{(r)}, \dots, v_{ic}^{(r)}\}, v_{ij}^{(r)} = \frac{\sum_{k=1}^N (u_{jk})^m \cdot x_{ki}}{\sum_{k=1}^N (u_{jk})^m} \quad (5)$$

$$u_{jk} = \frac{(1/\|\mathbf{x} - \mathbf{v}_j\|^2)^{1/m-1}}{\sum_{j=1}^c (1/\|\mathbf{x} - \mathbf{v}_j\|^2)^{1/m-1}} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{2/m-1}} \quad (6)$$

식 (4)에서 주어진 목적함수를 만족하기 위하여 식 (5)과 식 (6)에 의해서 구해진 값들을 이용하여 각각의 클러스터 중심과 데이터와의 거리계산을 통해 새로운 소속행렬을 생성한다.

$$d_{ik} = d(\mathbf{x}_i - \mathbf{v}_j) = \left[\sum_{j=1}^c (x_{ki} - v_{ij})^2 \right]^{1/2} \quad (7)$$

[Step 3] 다음과 같이 새로운 소속행렬 $U(r+1)$ 을 계산한다.

$$u_{jk}^{(r+1)} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}^{(r)}}{d_{jk}^{(r)}}\right)^{2/(m-1)}} \quad (8)$$

[Step 4] 다음 식 (8)을 계산해서 만일 $\Delta > \epsilon$ 이면 $r=r+1$ 로 정하고 [단계 2]로 가서 다시 알고리즘을 반복 수행하고 그렇지 않고 $\Delta \leq \epsilon$ 이면 알고리즘을 종료한다. 여기서, ϵ 는 임계값이다.

$$\Delta = \|U^{(r+1)} - U^{(r)}\| = \max_{j,k} |u_{jk}^{(r+1)} - u_{jk}^{(r)}| \quad (9)$$

최종 U 의 소속 값이 적합도가 된다. 식(8)을 이용하여 소속행렬의 분포를 살펴보면 방사형 형태의 활성화함수가 나타나는 것을 알 수 있다. 따라서 소속 값을 모델의 적합도로

사용가능하며, 퍼지화 계수(m)는 방사형 함수의 활성화 영역을 조절하는 역할을 한다. 따라서 이 값을 조절함으로써 좀 더 다양한 형태의 활성화함수를 생성할 수 있다.

본 연구에서는 Subtractive 클러스터링으로 클러스터 수를 구하고 FCM 클러스터링으로 클러스터별 데이터를 분류를 통하여 패턴인식 알고리즘에 사용한다.

3.2 결론부

본 연구에서는 기존에 상수항으로 표현된 연결가중치를 다항식 형태의 연결가중치로 확장하여 사용한다. 기존 상수항을 포함한 결론부의 추론형태는 네 개로 구분할 수 있다.

상수항 이외에 다항식을 사용함으로써 모델의 성능을 개선시켰다. 또한 모델의 성능을 가장 잘 표현하는 다항식을 찾기 위해 최적화 알고리즘을 적용하여 최적의 다항식 타입을 동조하였다.

3.3 추론부

마지막으로 추론부에서는 네트워크의 최종출력을 구하게 된다. 그림 4의 $g_j(x)(j=1, 2, \dots, c)$ 는 은닉층 j번째 뉴런의 출력신호이며, 이 출력신호는 은닉층과 출력층 사이의 j번째 다항식과의 곱을 통하여 로컬출력을 얻게 된다. 이와 같은 일련의 과정은 퍼지 추론과 동일한 절차를 가지며, 식 (10)와 같이 퍼지 추론식과 동일한 식으로 표현된다.

$$y_q = g_q(\mathbf{x}) = \sum_{i=1}^c \frac{u_{qi} f_{ji}(\mathbf{x})}{\sum_{k=1}^c u_{qk}} = \sum_{i=1}^c u_{qi} f_{ji}(\mathbf{x}) \quad (10)$$

여기서, 식(10)의 f_{ji} 는 RBFNN의 j번째 클래스에 대한 판별 함수가 된다.

4. 학습방법 및 최적화 과정

4.1 다항식 연결가중치 학습

RBFNN의 판별 함수를 생성하기 위한 제안된 분류기의 학습 과정을 설명 한다. 학습은 하나의 판별 함수를 가진(출력층 뉴런이 1개인) 2부류 분류문제를 기준으로 하며 다 부류 분류문제는 그림 4와 동일하게 첨자 j의 추가(출력 뉴런의 추가)로 유도될 수 있다. RBFNN의 학습은 경사 하강법과 모멘텀 방법을 통해 이루어진다. 계수 동정을 위한 학습은 식(11)으로 표현되는 오차를 모든 패턴에 대하여 최소화 하도록 진행된다.

$$E_q = \frac{1}{2}(t_q - y_q)^2, \quad (q = 1, \dots, N) \quad (11)$$

E_q 는 q번째 패턴에 대한 오차, N은 입력 패턴 수이다. t_q 는 q번째 패턴에 대한 목적 값이다. y_q 는 q번째 패턴에 대한 네트워크의 최종출력이다.

후반부 다항식이 상수항일 경우의 계수 동정 방법을 예를

들면 다음과 같다.

$$\begin{aligned} \frac{\partial E_q}{\partial a_{i0}} &= \frac{\partial E_q}{\partial y_q} \cdot \frac{\partial y_q}{\partial f_i} \cdot \frac{\partial f_i}{\partial a_{i0}} \\ \left(\frac{\partial E_q}{\partial y_q} = -(t_q - y_q); \frac{\partial y_q}{\partial f_i} = u_i; \frac{\partial f_i}{\partial a_{i0}} = 1 \right) \end{aligned} \quad (12)$$

출력의 오차와 후반부 다항식 계수의 편미분을 통해 계수의 변화량 Δa_{i0} 을 추정한다.

$$\Delta a_{i0}(l) = -\eta \cdot \frac{\partial E_q}{\partial a_{i0}} = \eta(t_q - y_q)u_i \quad (13)$$

여기서, η 은 오류역전파의 학습 횟수를 나타낸다.

모멘텀 계수가 포함된 최종 후반부 다항식 계수 추정은 식 (14)과 같이 표현할 수 있다.

$$a_{i0}(l+1) = a_{i0}(l) + \Delta a_{i0}(l) + \alpha(a_{i0}(l) - a_{i0}(l-1)) \quad (14)$$

여기서, η 는 학습률을 나타내며, α 는 모멘텀 계수를 나타낸다.

후반부 다항식이 1차선형식과 2차식일 때도 동일한 과정을 통해 계수를 추정할 수 있다.

4.2 입자 군집 최적화를 이용한 최적화 과정

PSO는 확률론적 최적화 알고리즘의 한 종류로서 병렬적 진화를 내포하는 특성 때문에 다른 탐색 알고리즘의 문제점인 지역 극소점을 최소화 할 수 있으며 탐색 공간 안에 미분가능 하지 않은 목적함수를 쉽게 다룰 수 있어 보다 효율적으로 다음 절차를 통해 수행한다.

[Step 1] S개의 개체 (Particle)을 탐색 공간 내에서 랜덤하게 생성한다. 이들은 초기 집단(Swarm)이 된다. 마찬가지로 초기 이동속도(Velocity)를 $[-v_{max} \ v_{max}]$ 내에서 랜덤하게 생성한다. 초기 집단의 각 개체 목적함수에 의해 평가되고, 이들 모두는 'pbest'로 설정한다. 'pbest'중 최적의 값은 다시 'gbest'로 선정된다.

[Step 2] 식 (15)을 이용하여 각 개체의 새로운 이동속도를 구한다.

$$v_{pq}(t+1) = w(t) \cdot v_{pq}(t) + c \cdot r_1 (pbest_{pq}(t) - x_{pq}(t)) + c \cdot r_2 (gbest_{pq}(t) - x_{pq}(t)) \quad (15)$$

여기서, $p(p=1, \dots, D)$ 는 개체의 차원수를 나타내며, $q(q=1, \dots, S)$ 의 집단의 크기를 나타낸다.

[Step 3] 식 (16)으로 새로운 개체를 생성한다.

$$x_{pq}(t+1) = v_{pq}(t+1) + x_{pq}(t) \quad (16)$$

여기서, $x_p^{\min} \leq x_p(t) \leq x_p^{\max}$ 이다.

[Step 4] 새로운 위치정보를 가진 개체들은 목적함수에 의해 평가된다. 각 particle의 적합도는 이전 'pbest'의 적합도와 비교되며 'pbest'를 갱신한다. 'pbest'의 개체 중 최적해를 가지는 개체의 적합도와 이전 'gbest'의 적합도를 비교하여 최적 위치정보를 가진 개체를 'gbest'로 갱신한다.

[Step 5] 종료조건을 만족하면 알고리즘을 종료하고, 그렇지 않으면 **[Step 2]**로 돌아간다.

[Step 6] 최종적으로 생성된 'gbest'는 최적의 위치정보를 가진다.

5. 실험 결과 및 고찰

부분방전 데이터를 가지고 부분방전이 일어난 상(Phase)의 위치 혹은 노이즈인지의 유무를 파악하고 분류된 데이터를 RBF 뉴럴 네트워크 패턴 분류기를 통해 부분방전을 판별한다. 본 논문에서는 모의 데이터를 통해 상 분류 기법에 대해 알아보고 동축케이블과 과형발생기 등을 이용하여 A상에서 부분방전을 발생시켜서 얻은 모의 실험한 데이터로 실험하였다. 5.1에서는 상 분류를 위한 Subtractive 등의 방법으로 실험하고 5.2에서는 부분방전 데이터를 이용해 RBF 뉴럴 네트워크 패턴분류기를 이용하여 패턴분류를 수행한다. 5.3에서는 실제 현장에서 일어난 접속재 결함, 코로나, 부유전극에 대한 부분방전 데이터를 이용하여 패턴분류를 수행한다.

5.1 3상 부분방전의 상 분류

부분방전을 패턴분류하기 위해서는 부분방전이 일어난 상의 위치를 파악해야한다. 그래서 3-PARD 기법과 PA 기법을 결합하여 데이터를 매핑 시켜 상을 분리한 다음 Subtractive 클러스터링 알고리즘으로 클러스터의 개수와 각 클러스터 중심점을 구한다. 클러스터의 중심점을 이용하여 FCM기반 다

표 1 3상 분류 모의실험

Table 1 Simulation for 3 phase classification

| 종류 | 패턴종류 | 부분방전 위치 | Map | 노이즈 유무 |
|--------|-------|-----------------------------|----------------|--------|
| Case 1 | Type1 | A상 1개, C상 1개 | 3-PARD | X |
| | Type2 | A상 1개, B상 1개, AB상 1개 | | |
| | Type3 | B상 2개 | | |
| Case 2 | Type1 | C상 4개 | 3-PARD & PA | X |
| | Type2 | A상 2개, B상 2개 | | |
| Case 3 | Type1 | A상 1개, B상 1개, 중성점 1개 | 3-PARD | ○ |
| | Type2 | A상 1개, 중성점 1개 | | |
| | Type3 | B상 1개, C상 1개, 중성점 2개 | | |
| Case 4 | Type1 | 중성점 3개 | 3-PARD & PA | ○ |
| | Type2 | AB상 1개, C상 1개, 중성점 2개 | | |

항식 방사형 기저 함수 신경회로망 분류기를 통해 클래스를 구분한다. 3-PARD map에서 x축은 실수를 나타내고 y축은 허수를 나타내는데, PA map과 결합했을 때는 x,y축은 3-PARD일 때와 같고 z축은 PA값이다.

PA map의 중요성과 노이즈 유무에 따른 분류를 알아보기 위하여 표 1과 같이 크게 4가지의 Case로 나누어 실험하였다.

(1) 3-PARD를 이용한 상 분류(Case 1)

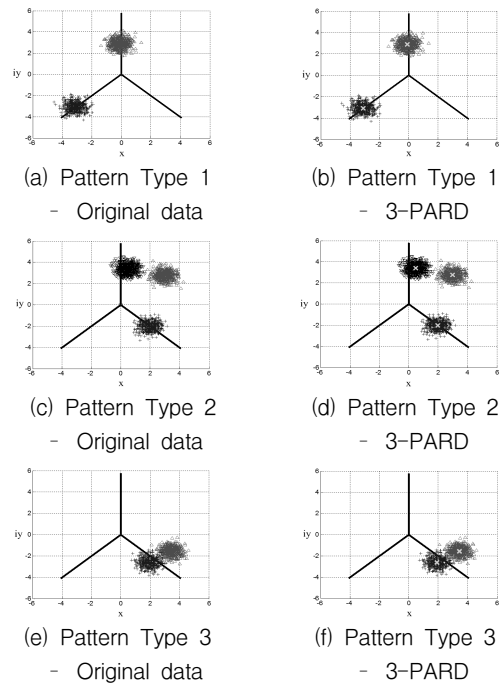


그림 3 3-PARD를 이용한 상 분류 (Case 1)
Fig. 3 Phase classification using 3-PARD (Case 1)

그림 3은 임의의 상에 부분방전이 일어났을 때 검출된 데이터를 가지고 Subtractive 클러스터링과 FCM 클러스터링을 사용하여 부분방전의 상을 분류하고 그 상에 위치한 데이터를 클러스터링 시킨 그림이다.

(2) 3-PARD와 PA를 이용한 상 분류(Case 2)

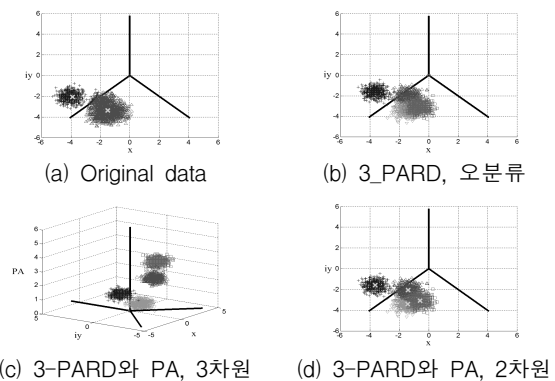


그림 4 3-PARD와 PA를 이용한 상 분류 (Case 2 - Type 1)
Fig. 4 Phase classification using 3-PARD and PA (Case 2 - Type 1)

그림 4는 4개의 부분방전이 C상에 일어났을 때 3-PARD만 이용했을 때와 3-PARD와 PA기법을 동시에 사용했을 때의 비교를 나타내었다. 3-PARD만 이용한 (d)처럼 2개로 잘못 판단할 수 있는데 (c)에서 보는 것과 같이 각각의 클러스터 특징에 따라 PA값이 달라져 구분할 수 있다.




그림 5 3-PARD와 PA를 이용한 상 분류 (Case 2 - Type 2)
 Fig. 5 Phase classification using 3-PARD and PA (Case 2 - Type 2)

그림 5도 그림 4와 같이 PA기법의 필요성에 대해 나타낸 그림인데 이번에는 클러스터가 A상과 B상에 각각 두 개씩 군집되어 있는 것을 볼 수 있다. 그런데 클러스터를 3개씩

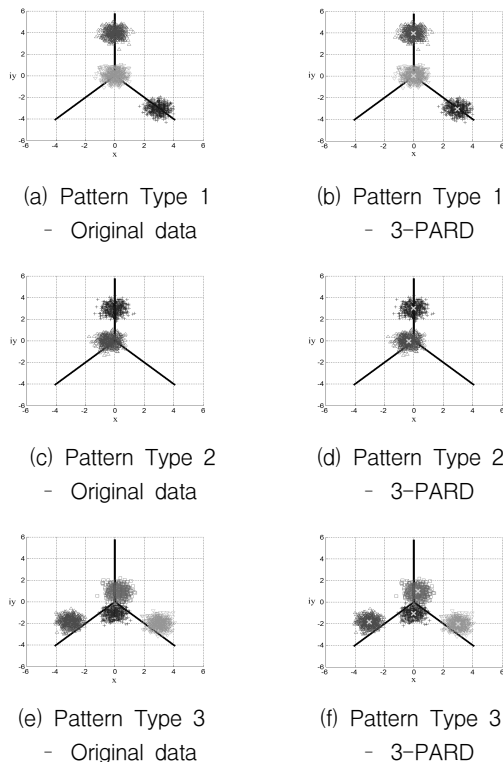


그림 6 3-PARD를 이용한 노이즈를 포함한 상 분류 (Case 3)
 Fig. 6 Phase classification including noise using 3-PARD (Case 3)

으로 오분류 하는데 역시 각각의 PA 특성에 따라 분리 될 수 있음을 알 수 있다

(3) 3-PARD를 이용한 노이즈를 포함한 상 분류(Case 3)

그림 6은 각 상 또는 중성점에 검출된 데이터가 겹치지 않고 나타났을 때 클러스터링 하는 실험이다. (a),(c) 그리고 (e)는 검출된 데이터를 나타낸 것이고, 이를 Subtractive 클러스터링 그리고 FCM 클러스터링을 이용해서 각각 (b),(d) 그리고 (f)에 나타내었다. Pattern Type 1의 경우에는 유관으로 봐도 구별되지만 Pattern Type 2의 경우 중성점에서 A상 쪽에 있는 집단은 잘못보면 중성점에 위치한다고 생각할 수 있다. 그러나 본 실험에서는 집단의 중심점의 위치를 파악하는데 데이터 위치를 보면 A상에 위치한다는 결과를 얻을 수 있다.

(4) 3-PARD와 PA를 이용한 노이즈를 포함한 상 분류 (Case 4)

Case 4의 Pattern Type 1을 나타낸 그림 7은 중성점에




그림 7 3-PARD와 PA를 이용한 상 분류 (Case 4 - Type 1)
 Fig. 7 Phase classification using 3-PARD and PA (Case 4 - Type 1)

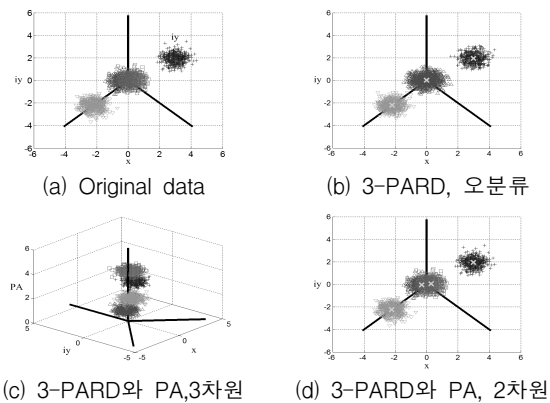


그림 8 3-PARD와 PA를 이용한 상 분류 (Case 4 - Type 2)
 Fig. 8 Phase classification using 3-PARD and PA (Case 4 - Type 2)

노이즈가 3개 생성된 것을 볼 수 있다. 부분방전을 검출하는데 있어서 노이즈의 제거가 필요하지만 노이즈의 생성 위치나 부분방전과의 구별을 위해서 노이즈도 구별해야한다. (d)를 보면 여러 가지의 노이즈가 하나로 오분류 되는 것을 볼 수 있는데 Case 2와 마찬가지로 PA 기법의 필요성이 느껴진다.

Case 4의 두 번째 패턴인 그림 8은 각 상 또는 중성점에 검출된 데이터를 3-PARD와 PA 기법을 조합하여 보다 효과적으로 클러스터링 하는 실험이다. 앞에서 언급한 3가지 Case를 복합적으로 나타낸 것인데 이번 실험은 조금 더 확실한 구별을 해보고자 중성점에 위치하고 PA기법을 결합하였을 때의 상황을 알아보려고 실험 하였다.

5.2 모의 데이터를 이용한 3상 부분방전 패턴분류

PSO로 최적화 시킨 RBF 뉴럴 네트워크 패턴 인식 알고리즘을 이용하여 패턴인식 실험을 시행한다. 본 실험에서 사용한 데이터는 표 2에서와 같이 5개로 구분된 데이터로 각각의 데이터 수는 Type 순서대로 207, 214, 220, 219, 219 개로 총 1079개를 학습 데이터와 평가 데이터, 테스트 데이터로 각각 70%와 30%로 나눠 실험을 시행하였다. 이 때 데이터를 랜덤하게 선출하여 실험의 좀 더 높은 객관성을 제공하기 위해 Re-sampling cross validation 모드를 10번 수행하여 그에 평균과 표준편차를 나타내었다. 각 데이터에 대한 입력 변수는 A상, B상, C상의 전압값과 A상의 펄스값으로 구해진 평균값, 표준편차, 분산, 왜곡도(skewness), 첨도(Kurtosis) 총 8가지이다. 입력변수별로 각 상의 전압값을 포함한 8가지 입력 변수를 모두 사용하여 실험하였다.

표 2 A상에서 일어나 부분방전 데이터
Table 2 Partial discharge date on A phase

| 종류 | 데이터 | | | |
|--------|-----------|-----------|-------------|-------|
| | 펄스의 과두 | 펄스의 과미 | 펄스 주입 지점 | 측정 지점 |
| Type 1 | 40ns | 40us | 100m | 100m |
| Type 2 | 40ns | 40us | 100m | 300m |
| Type 3 | 120ns | 40us | 100m | 100m |
| Type 4 | 120ns | 40us | 100m | 300m |
| Type 5 | 40ns | 100ns | 100m | 300m |




그림 9 3-PARD map에 분포된 부분방전 데이터
Fig. 9 Distributed Partial discharge data on 3-PARD map

A상에서 일어난 부분방전 데이터는 표 2에서와 같이 Type 1~5로 다섯 가지로 분류되는데 그림 9 중 왼쪽 그림은 3-PARD상 mapping된 그림이다. 오른쪽 그림은 이 때 데이터의 분포를 자세히 보기 위해서 데이터가 분포한 A상만을 확대하여 나타내었다.

표 3 RBF 뉴럴 네트워크 패턴 분류기의 파라미터
Table 3 Parameters for RBF neural network pattern classifier

| | Parameters | 3 Phase Partial Discharge | |
|-------|-------------------------------|-----------------------------|----------|
| | | 모의 데이터 | 실제 데이터 |
| PSO | No. of generation | 30 | 100 |
| | Swarm size | 30 | |
| | vmax | 20% of search space | |
| | [wmin wmax] | [0.4 0.9] | |
| | c1, c2 | 2.0 | |
| RBFNN | No. of nodes | 6, 7 | 2~6 |
| | No. of iterations | 20 | |
| | Polynomial type | Constant, Linear, quadratic | |
| | Weighting factor (θ) | 1 | 0.5 |
| | Division of data (%) | 70:30 | 50:30:20 |
| | Fuzzification coefficient | [1.1 ~ 3.0] | |
| | Momemtum Coefficient | [1e-9 ~ 0.1] | |
| | Learning Coefficient | [1e-9 ~ 0.1] | |

표 3은 최적화 알고리즘 및 제안된 분류기의 초기 설정 파라미터를 나타낸다. 초기 설정 파라미터와 탐색범위의 수치적 값들은 학습 성능과 수렴에 따른 페이스에 따라서 실험적 값과 모니터링의 운영에 의해서 시행착오적으로 선택하였다.

(1) RBFNN의 결론부가 Constant인 경우





그림 10 RBFNN에 의한 테스트 데이터 패턴인식률 (Case1 - Constant)

Fig. 10 Classification rate of testing data by RBFNN (Case1 - Constant)

그림 11을 보면 PSO의 세대 별로 나타낸 인식률을 보았을 때, 규칙수가 6개 보다 7개 일 때 빨리 수렴하는 것을 알 수 있다. 규칙이 6개 일 때 테스트가 떨어지는 것을 볼 수 있는데 이는 학습률이 상대적으로 높아져 나타난 결과로 볼 수 있다.




(a) 세대에 따른 인식률 (6 Rules)
(a) Classification rate on generation(6 Rules)
(b) 세대에 따른 인식률 (7 Rules)
(b) Classification rate on generation(7 Rules)

그림 11 RBFNN에 의한 패턴인식률 (Case1 - Constant)
Fig. 11 Classification rate by RBFNN (Case1 - Constant)


(2) RBFNN의 결론부가 Linear인 경우

결론부가 Constant일 때보다 인식률이 뛰어나지만 연산식이 복잡하여 많은 시간과 계산량이 요구된다. 그러나 패턴인식기는 학습시간이 오래 걸리고 연산이 복잡하다고 해서 실제 적용되는 파라미터만 구해진다면 실제 적용할 때의 연산시간은 크게 다르지 않다.



(a) 인식률 (6 Rules)
(a) Classification rate (6 Rules)
(b) 인식률 (7 Rules)
(b) Classification rate (7 Rules)

그림 12 RBFNN에 의한 테스트 데이터 패턴인식률 (Case1 - Linear)
Fig. 12 Classification rate of testing data by RBFNN (Case1 - Linear)



(a) 세대에 따른 인식률 (6 Rules)
(a) Classification rate on generation (6 Rules)
(b) 세대에 따른 인식률 (7 Rules)
(a) Classification rate on generation (7 Rules)

그림 13 RBFNN에 의한 패턴인식률 (Case1 - Linear)
Fig. 13 Classification rate by RBFNN (Case1 - Linear)

5.3 실제 현장데이터를 이용한 부분방전 패턴분류

본 절에서는 실제 PSD Tech 회사의 3상 부분 방전 데이

터를 이용하여 제안하는 부분방전 패턴 분류기가 실제 현장 데이터로의 사용이 적합한지를 판단하기 위한 실험을 한다. 이 부분방전 데이터를 3개로 구분하여 각각의 데이터 수를 256, 256, 256개, 총 768개를 Re-sampling 방법을 사용하여 학습데이터, 검증 데이터, 테스트 데이터를 각각 50%, 30%, 20% 나누어 사용하였다. 데이터의 특성을 반영하기 위해 FCM 클러스터링을 기반으로 PSO로 최적화된 RBF 뉴럴 네트워크 모델을 사용하여 각 Rules에 따른 각각의 패턴 인식을 적용하였다.

표 4는 RBF 뉴럴 네트워크의 후반부 다항식이 1차 선형 식일 때 패턴 분류율을 학습데이터와 검증 데이터, 테스트 데이터로 나누어 각각 평균과 표준편차를 나타내었다. 좋은 패턴 인식률을 보이는 것으로 나타나며, 실제 현장에서 패턴 분류를 하는데 있어 무리가 없을 것으로 사료 된다.

표 4 RBF 뉴럴 네트워크를 이용한 패턴분류률(Linear)
Table 4 Pattern classification rate used RBFNN (Linear)

| Proposed Model | RBFNN | | | | | |
|---------------------------|-------|--------------|-------------|-------------|-------------|-------------|
| | rules | 2 | 3 | 4 | 5 | 6 |
| Fuzzification coefficient | | 2.88 | 1.9 | 2.79 | 1.54 | 2.54 |
| Training Classification | | 88.88 ±27.21 | 100 ±0 | 99.73 ±0.59 | 100 ±0 | 100 ±0 |
| Validation Classification | | 99.72 ±0.68 | 99.51 ±1.08 | 99.64 ±0.8 | 97.78 ±1.81 | 97.78 ±1.81 |
| Testing Classification | | 87.77 ±26.73 | 99.11 ±1.21 | 97.78 ±0 | 89.44 ±9.66 | 90.75 ±9.78 |

표 5 다른 모델과의 성능 비교

Table 5 Comparison of performance with other models

| Model | NN | | | | |
|------------------------|--------------|-------------|-------------|-------------|-------------|
| P-Type | | | | | |
| rules | 2 | | 3 | | |
| Testing Classification | 63.78±3.57 | | 65.57±4.21 | | |
| Model | RBFNN | | | | |
| P-Type | Constant | | | | |
| rules | 2 | 3 | 4 | 5 | 6 |
| Testing Classification | 51.33 ±0.54 | 51.33 ±3.29 | 48.44 ±3.71 | 50.99 ±4.44 | 51.22 ±2.53 |
| Model | RBFNN | | | | |
| P-Type | Linear | | | | |
| rules | 2 | 3 | 4 | 5 | 6 |
| Testing Classification | 87.77 ±11.73 | 99.11 ±1.21 | 97.78±0 | 89.44 ±9.66 | 90.75 ±9.78 |
| Model | RBFNN | | | | |
| P-Type | Quadratic | | | | |
| rules | 2 | 3 | 4 | 5 | 6 |
| Testing Classification | 87.77 ±12.56 | 86.13 ±1.21 | 88.56 ±6.54 | 93.55 ±8.12 | 91.67 ±6.83 |

6. 결 론

본 논문에서는 3상 부분방전 패턴 분류를 위해 3-PARD map과 PA map 기법을 결합하여 데이터를 매핑시키고 이를

Subtractive 및 FCM 클러스터링 과정을 통해 상 분류와 노이즈를 판단하고 방사형 기저 함수 신경회로망을 통해 패턴 분류한다. 제안된 방사형 기저 함수 신경회로망은 퍼지 추론 기반의 메커니즘을 사용하며, FCM 클러스터링을 사용하여 전반부 멤버십을 결정한다. 생성된 멤버십은 네트워크의 구조적인 측면으로 볼 때 은닉층의 활성화함수로 사용되고, 네트워크의 연결가중치는 상수항뿐만이 아니라 일차선형식 및 이차식을 사용하여 비선형성을 확장하였다. 그리고 최적화 알고리즘인 PSO 알고리즘을 사용하여 모델을 구성하는데 중요한 파라미터를 동조하였다. 즉, 학습률, 모델턴 계수, FCM 클러스터링의 퍼지화 계수(fuzzification Coefficient)를 최적화하여 최적화된 패턴 분류기를 설계하였다. 기존의 방사형 기저 함수 신경회로망과 기본적인 메커니즘은 같지만 세부적인 기능의 추가 및 확장을 통하여 주어진 데이터의 특성에 고려한 최적화된 분류기를 구현하였다. 제안된 3상 부분방전 패턴분류기는 각 상의 전압 값 등의 입력을 통하여 비전문가를 위한 진단 시스템으로써 자동측정 및 분석에 유용하게 사용할 수 있다.

감사의 글

이 논문은 2012년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (NRF-2012-003568) 및 경기도의 경기도지역협력연구센터사업(GRRC 수원2012-B2, U-city 보안감시 기술협력센터)에서 지원하여 연구하였음.

References

[1] A. Kandal, L. Li, and Z. Cao, "Fuzzy Inference and Its Application to Control Systems," Fuzzy Sets and Systems, Vol. 48, No. 1, pp. 99-111, 1992.
 [2] Z-B. Xu, H. Q, J. Peng, and B. Zhang, "A Comparative Study of Two Modeling Approaches in Neural Network," Neural Networks, Vol. 17, No. 1, pp. 73-85, 2004.
 [3] L. Sanchez, I. Couso, and J. Casillas, "Genetic Learning of Fuzzy Rules based on Low Quality Data," Fuzzy Sets and Systems, Vol. 160, No. 17, pp. 2524-2552, 2009.
 [4] S. Kiranyaz, T. Ince, A. Yildirim, and M. Gabbouj, "Evolutionary Artificial Neural Networks by Multi-dimensional Particle Swarm Optimization," Neural Networks, Vol. 22, No. 10, pp. 1448-1462, 2009.
 [5] A. A. Frolov, D. Husek, I. P. Muraviev, P. Y. Polyakov, "A Boolean Factor Analysis by Attractor Neural Network," IEEE Trans. Neural Networks, Vol. 3, pp. 698-707, 2007.
 [6] R. A. Aliev, B .G. Guirimov, B. Fazlollahi, and R. R. Aliev "Evolutionary Algorithm-based Learning of Fuzzy Neural Networks. part 2: Recurrent Fuzzy Neural Networks," Fuzzy Sets and Systems, Vol. 160, No. 17, pp. 2553-2566, 2009.
 [7] S. B. Roh, S. K. Oh, and W. Pedrycz, "A Fuzzy

Ensemble of Parallel Polynomial Neural Networks with Information Granules formed by Fuzzy Clustering," Knowledge-Based Systems, Vol. 23, No. 3, pp. 202-219, 2010.
 [8] James C. Bezdek, Robert Ehrlich, William Full "FCM: The Fuzzy C-Means Clustering Algorithm" Computers & Geosciences, Vol. 10, No. 2-3, pp. 191-203, 1984.
 [9] S. P. Lloyd, "Least Squares Quantization in PCM," IEEE Trans. on Inf. Theory, Vol. 28, No. 2, pp. 129-137, 1982.
 [10] R. R. Yager, D. P. Filev, "Approximate Clustering via the Mountain Method," IEEE Trans. on S.M.C, Vol. 24, pp. 1279-1284, 1994.
 [11] S. L. Chiu, "Fuzzy Model Identification Based on Cluster Estimation," Journal of Intelligent and Fuzzy Systems, Vol. 2, No. 3, 1994.
 [12] J. Holland, "Adaptation In Natural and Artificial Systems," University of Michigan Press, 1975.
 [13] J. Kennedy and R. Eberhart, "Particle Swarm Optimization," Proc. of IEEE International Conference on Neural Networks, Vol. 4, pp. 1942-1948, 1995.
 [14] R. Heinrich, S. Schaper, W. Kalkner, R. Plath, A. Bethge, "Synchronous Three Phase Partial Discharge Detection on Rotating Machines," ISH, pp. 542, 2003.
 [15] J. T. Kim, J. H. Kim, J. Y. Koo, "Noise Discriminations in Measuring Particle Discharges using Pulse Wave Shape Analysis," CMD, pp. 698. 2006.
 [16] J. T. Kim, J. H. Kim, Y. M. Chang, J. Y. Koo, "Pulse Analysis Algorithms for Distinguishing Discharge Sources using Different Types of Sensors," IEEE Trans. FM, Vol. 128, No. 5, pp. 350-356. 2008.

저 자 소 개



오 성 권 (吳 聖 權)

1981년 연세대학교 전기공학과 졸업, 동대학원 석사 (1983), 박사(1993). 1983-1989년 금성산전연구소(선임연구원). 1996-1997년 캐나다 Manitoba 대학 전기 및 컴퓨터공학과 Post-Doc. 1993-2004년 원광대학교 전기전자 및 정보공학부 교수. 2005~현재 수원대학교 전기공학과 교수, 2002~현재 대한전기학회, 제어로봇시스템학회, 퍼지및지능시스템학회 편집위원. 관심분야는 퍼지 시스템, 퍼지-뉴럴 네트워크, 자동화 시스템, 고급 computational intelligence, 지능 제어 등.
 Tel : 031-229-8162
 Fax : 031-220-2667
 E-mail : ohsk@suwon.ac.kr



김 현 기 (金賢起)

1977년 연세대학교 전기공학과 졸업, 동대학원 석사(1985), 박사.(1991). 1997~2009 경기지역 산학연 기술지원단 단장, 1998~2009 산업기술정책연구소 심의위원, 2000~2009 사단법인 산학연 컨소시엄 전국협의회 회장, 1989~현재 수원대

학교 전기공학과 교수, 관심분야는 시스템 자동화 및 감시제어, 지능형모델링 및 제어등.

Tel : 031-220-2666

Fax : 031-220-2667

E-mail : hkkim@suwon.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(공학박). 현재 대진대 공대 전기정보시스템공학과 교수.

Tel : 031-539-1914

Fax : 031-539-1910

E-mail : jtkim@daejin.ac.kr