

정보입자기반 퍼지 RBF 뉴럴 네트워크를 이용한 트래킹 검출

논문
58-12-35

Tracking Detection using Information Granulation-based Fuzzy Radial Basis Function Neural Networks

최정내* · 김영일** · 오성권[†] · 김정태***
(Jeoung-Nae Choi · Young-Il Kim · Sung-Kwun Oh · Jeong-Tae Kim)

Abstract - In this paper, we proposed tracking detection methodology using information granulation-based fuzzy radial basis function neural networks (IG-FRBFNN). According to IEC 60112, tracking device is manufactured and utilized for experiment. We consider 12 features that can be used to decide whether tracking phenomenon happened or not. These features are considered by signal processing methods such as filtering, Fast Fourier Transform(FFT) and Wavelet. Such some effective features are used as the inputs of the IG-FRBFNN, the tracking phenomenon is confirmed by using the IG-FRBFNN.

The learning of the premise and the consequent part of rules in the IG-FRBFNN is carried out by Fuzzy C- Means (FCM) clustering algorithm and weighted least squares method (WLSE), respectively. Also, Hierarchical Fair Competition-based Parallel Genetic Algorithm (HFC-PGA) is exploited to optimize the IG-FRBFNN. Effective features to be selected and the number of fuzzy rules, the order of polynomial of fuzzy rules, the fuzzification coefficient used in FCM are optimized by the HFC-PGA. Tracking inference engine is implemented by using the LabVIEW and loaded into embedded system. We show the superb performance and feasibility of the tracking detection system through some experiments.

Key Words : Tracking, Radial Basis Function Neural Networks, Fuzzy C-Means clustering, Hierarchical Fair Competition-based Parallel Genetic Algorithm, Weighted Least Squares Estimator

1. 서 론

빌딩 및 공장에서 전기를 각 부하까지 분배해주는 분전반에서 전기화재의 주요 원인은 단락에 의해 출화된 것으로 알려져 있다. 이러한 단락은 통상적으로 탄화(후연화)가 발생할 수 있는 피복류에서 일어날 위험이 큰 것으로 알려져 있다[1-5]. 과전류 및 누전은 과전류 차단기 또는 누전 차단기 설치 등으로 예방할 수 있지만 전기화재의 30% 이상을 차지하는 트래킹에 의한 화재 예방은 기술적 어려움 때문에 아직까지 실용화되지 않고 있다.

트래킹(Tracking)이란 절연물, 전선, 케이블 등의 표면에 부착된 먼지, 습기 등의 오염물질이나 또는 과열에 의한 절연물의 열화 등으로 인해 표면 누설 전류가 서서히 증가하고, 절연물이 분해하여 탄화 도전로가 생기는 방전현상을 말한다.

분전반 인출구나 옥내의 전선 및 케이블의 경우, 주변에 먼지나 습기가 차있을 때 전선 및 케이블 피복체를 통해서

도체 사이의 절연 층이 미소방전(Scintillation)에 의하여 탄화되고, 이 탄화도전로를 따라서 누설전류가 점차 증가하여 드디어는 도체 사이에 절연 파괴와 함께 전선피복재가 발화하는 트래킹화재가 발생하게 된다. 이러한 트래킹의 징후를 나타내는 전류의 크기는 수십 mA에서 수 A에 불과하나 배선용 차단기나 퓨즈의 정격전류는 20A 이상이므로 트래킹에 의한 발화전류는 검출할 수 없고, 누전 차단기는 5mA 이상에서 전로를 차단하지만 전선 상호간의 누설전류는 검출하지 못하는 실정이다.

유기절연재료 표면 및 옥내 배선에서 발생하는 트래킹 현상에 의한 발화 과정에 관한 연구는 많이 수행되어 왔다. 측정된 전압이나 전류 파형의 FFT변환을 통하여 고조파 성분의 분석을 통하여 트래킹의 발화 과정에 대한 분석이 이루어졌으며[1-4], 고조파 성분을 입력으로 한 신경망을 이용하여 트래킹의 발생을 판단하는 방법도 제시되었다[5]. 그렇지만 트래킹의 진화과정에 따라 다양한 패턴의 파형이 생성될 수 있으며 단지 고조파 성분을 이용하여 트래킹의 발생 유무를 판단하기에는 부족함이 많이 있다.

퍼지이론에 기반을 둔 퍼지 추론시스템, 퍼지뉴럴네트워크 등의 지능형 시스템은 시스템 모델링, 기계학습, 데이터 마이닝, 패턴분류 그리고 패턴인식 등의 다양한 영역에 유용하게 적용되어 왔으며 모델의 구조 및 학습방법에 대한 연구가 계속적으로 이루어지고 있다[9-15].

최근 컴퓨터 지능영역에서는 지능형 알고리즘, 클러스터링 알고리즘, 진화기반 최적화 알고리즘의 융합을 통하여 정

* 정 회 원 : 대림대학 전기과 교수 · 공박
** 정 회 원 : 대림대학 전기과 교수 · 공박
† 교신저자, 시니어회원 : 수원대학 전기공학과 교수 · 공박
E-mail : ohsk@suwon.ac.kr
*** 정 회 원 : 대전대 공대 전기정보시스템공학과 교수 · 공박
접수일자 : 2009년 8월 24일
최종완료 : 2009년 9월 7일

교하면서도 간단한 지능형모델의 구축에 관한 연구가 이루어지고 있다. 최근에 지능형 모델의 하나로써 정보입자 기반 퍼지 RBF 뉴럴네트워크(Information Granulation-based Fuzzy Radial Basis Function Neural Network ; IG-FRBFNN)가 제안되었다[6, 7]. 이 구조는 Fuzzy-C Means (FCM) 클러스터링 알고리즘과 RBF 뉴럴네트워크(RBFNN)가 융합된 형태로서, 전반부에서 FCM을 사용하고 후반부는 다양한 형태의 다항식으로 구성된다. FCM에 의하여 퍼지공간 분할과 멤버쉽값이 결정된다. 특히 기존 RBFNN과 달리 멤버쉽값은 삼각형이나 가우시안 등의 특정 방사기저 함수를 사용하지 않고 데이터들의 거리에 반하여 결정된다. 이 모델은 RBFNN에 기반을 두기 때문에 퍼지모델에서 입력변수의 수가 증가함에 따라 규칙수가 기하급수적으로 증가하는 “다차원성의 저주” 문제를 해결할 수 있으며, FCM을 사용하기 때문에 RBFNN에서 모든 입력 공간을 표현할 수 없는 문제를 해결하였다. 또한 후반부다항식의 계수를 추정하기 위해 로컬 학습 알고리즘의 하나인 weighted Least Squares (WLSE) 방법을 사용함으로써 모델의 해석력(interpretability)을 향상시키는 장점이 있다.

IG-FRBFNN의 성능을 사용하는 입력변수, 규칙 수, 퍼지규칙 후반부 다항식의 형태 그리고 FCM에서 사용하는 퍼지화 계수의 값에 의존하여 이들 값을 최적화 되어야 한다. 유전자 알고리즘(Genetic Algorithm; GA), Particle Swarm Optimization (PSO), 유전자 프로그래밍(Genetic Programming; GP) 등 다양한 진화 알고리즘이 적용될 수 있다.

본 연구에서는 부하의 전류파형으로부터 IG-FRBFNN를 이용하여 트랙킹의 발생유무를 판단할 수 있는 방법을 제시한다. 트랙킹 발생장치로부터 트랙킹이 발생했을 경우와 정상상태에서의 전류 파형을 측정하고, 측정된 전류파형으로부터 실효값, 첨도, 비대칭도, 스펙트럼분포 등의 트랙킹의 발생 유무에 사용 가능한 12개의 특징을 추출하여 실험 데이터를 취득한다. 취득한 데이터를 이용하여 트랙킹 발생 유무를 추론할 수 있는 IG-FRBFNN를 구축하였다. 여기서 IG-FRBFNN의 최적화를 위하여 병렬유전자 알고리즘(Parallel Genetic Algorithm; PGA)의 한 모델인 계층적 경쟁 기반 병렬 유전자 알고리즘 (Hierarchical Fair Competition-based PGA ; HFC-PGA)을 사용하였다. 데이터 취득 및 특징 추출은 LabVIEW를 사용하였으며, IG-FRBFNN의 최적화는 Matlab를 사용하여 수행하였다. 최종적인 트랙킹 검출알고리즘은 LabVIEW를 사용하여 구현하였고 임베디드 시스템에 탑재하였다. 그림 1은 제안된 트랙킹 검출 과정을 보인다.




그림 1 트랙킹 검출과정
Fig. 1 Tracking detection process

2. 트랙킹 장치 및 실험 데이터 추출


IEC 60112는 절연재료의 내트랙킹 특성 시험에 대한 방법과 기준을 제시한다. 본 연구에서는 IEC 60112의 규격에

따라 실험 장치를 설계하고 제작하여 실험에 사용하였다. 그림 2는 제작된 트랙킹 실험장치의 구성과 사진을 보인다. 시료는 폴리염화비닐 케이블을 사용하였으며, 케이블의 중간을 절취하여 심선을 노출시키고 절취부에 0.1%의 염화암모늄 수용액을 떨어트린다. 염화암모늄 수용액에 의하여 두 선 사이에 도전로가 형성되며 방전이 일어나기 시작한다. IEC 60112 내트랙킹 시험에서는 염화암모늄 수용액을 50방울 또는 100방울 떨어트려 불꽃이 발생하지 않으면 내트랙킹 시험에 통과함을 의미하지만, 본 연구에서는 트랙킹 진화과정에 대한 전류파형을 분석을 통하여 트랙킹의 발생 여부의 판단을 목표로 하기 때문에 AD변환 장치가 필요하다.

CT와 NI사의 AD변환기(NI 9233)를 이용하여 50kHz/s의 샘플링 주기로 1초 동안 50000개의 파형 데이터를 측정한다. 본 연구에서는 백열등 부하만을 사용하여 트랙킹 실험을 수행하였다.



(a) 실험 장치 구성도




(b) 제작된 실험 장치


그림 2 트랙킹 실험장치의 구성과 제작된 장치
Fig. 2 Architecture and picture of tracking device

그림 3은 백열등 부하를 사용하고 있을 때 정상적인 전류파형과, 염화암모늄을 떨어트려 트랙킹이 발생했을 경우의 파형을 보인다. 일반적으로 트랙킹 발생 시 파형의 피크 부분에서 펄스 형태의 신호가 감지되지만 트랙킹 진화 단계와 사용되는 부하, 시료에 따라 다양한 형태의 파형이 나타날 수 있다.

50000개의 샘플 데이터를 이용하여 트랙킹의 발생 유무를 판단하는 것은 매우 어려우며 비효율적이다. 본 연구에서는 실험의 통하여 전류 파형을 분석하고 FFT, Wavelet 등의 신호처리 기법을 이용하여 트랙킹의 판단에 사용할 수 있는 12개의 특징을 추출하고 이 값들은 트랙킹의 발생 유무를 판단하기 위한 추론엔진의 입력으로 사용된다. 1초 동안 샘플링된 데이터로부터 추출한 특징들은 다음과 같으며, 특징



(a) 정상 파형



(b) 트래킹 발생 시 전류 파형

그림 3 정상적인 전류 파형과 트래킹 발생 시 전류파형
Fig. 3 Current wave of normal and tracking

추출알고리즘은 LabVIEW를 사용하여 구현하였다. 이들 12개의 특징점들은 모두가 사용되지 않고, 최적화 알고리즘을 사용하여 판단에 많은 영향을 미치는 특징들을 찾아 추론엔진에 적용된다.

표 1 전류파형으로부터 추출한 특징

Table 1 The list of extracted features

No.	Variable	Description
1	RMS_{origin}	측정된 전류 파형의 실효값
2	$I_{high\ peak}$	측정된 전류 파형의 최대값
3	$I_{low\ peak}$	측정된 전류의 최소값
4	$RMS_{filtered}$	저역통과필터($f_c=65\text{Hz}$)를 사용하여 필터링된 신호의 실효값
5	Kurtosis	측정된 전류 파형의 첨도
6	Skewness	측정된 전류 파형의 비대칭도
7	$spectrum_{ave}$	고역통과 필터($f_c=1\text{kHz}$)를 사용하여 필터링된 신호를 FFT 변환한 후 스펙트럼 크기의 평균값
8	$spectrum_{std}$	스펙트럼 크기의 표준편차
9	$I_{high\ peaks\ ave}$	1초 동안 측정된 파형의 모든 상위피크값의 평균
10	$I_{high\ peaks\ std}$	1초 동안 측정된 파형의 모든 상위피크값의 표준편차
11	$I_{low\ peaks\ ave}$	1초 동안 측정된 파형의 모든 하위피크값의 평균
12	$I_{low\ peaks\ std}$	1초 동안 측정된 파형의 모든 하위피크값의 표준편차

3. IG-FRBFNN의 구조 및 학습

추출된 12개의 특징값으로부터 트래킹의 발생 유무를 판단해야 한다. 본 연구에서는 트래킹 추론엔진으로서 IG-FRBFNN 모델을 사용하였다. 즉, 특징점들은 IG-FRBFNN의 입력으로 사용되며, 입력된 특징들로부터 트

래킹의 발생여부를 추정해야 한다. 본 연구에서 사용된 IG-FRBFNN은 FCM과 퍼지추론을 사용한다. 이장에서 IG-FRBFNN의 구조와 학습에 대하여 설명한다. FCM은 잘 알려진 클러스터링이지만 IG-FRBFNN의 학습에 대한 이해를 돕기 위해 먼저 FCM에 대하여 언급한다.

3.1 Fuzzy C-Means 클러스터링

Bezdek은 초기 HCM(Hard C-Means) 클러스터링을 개선하여 퍼지집합이론과 최소자승 에러 평가에 기반을 둔 fuzzy C-means 클러스터링(FCM) 알고리즘을 제시하였다 [12-13]. FCM 알고리즘은 하나의 클러스터에 속해 있는 각각의 데이터 점을 소속 정도에 의해서 클러스터에 대한 데이터의 소속 정도를 열거한 데이터 분류 알고리즘이다.

FCM 알고리즘은 m 개의 벡터 $x_k, k=1, \dots, m$ 의 집합을 n 개의 퍼지 그룹들로 분할하고, 비유사성 측정의 비용함수가 최소가 되는 것과 같은 각각의 그룹 안에서 클러스터의 중심을 찾는다.

FCM과 HCM 알고리즘의 중요한 차이점은 HCM 알고리즘에서 임의의 데이터는 소속정도는 0 또는 1값을 가지게 되면 단지 하나의 클러스터에 속하게 되지만 FCM 알고리즘에서 임의의 데이터는 0과 1 사이의 멤버쉽 값으로 특정지어지는 소속정도를 가지고 여러 개의 클러스터에 속할 수 있다는 점이다. 그렇지만 FCM은 목적함수(비용함수)를 사용하며 데이터를 분할하는 동안에 비용함수가 최소가 되도록 분류한다.

소속 행렬 U 는 0과 1사이의 값을 가질 수 있으며 주어진 데이터가 각 클러스터에 속하는 소속정도의 합은 식(1)처럼 1이 된다.

$$\sum_{j=1}^n u_{jk} = 1, \quad \forall k=1, \dots, m \quad (1)$$

여기서 n 은 클러스터의 수, m 은 데이터의 수이다.

FCM 알고리즘에서의 비용함수는 식(2)처럼 일반화 된다.

$$J(U, v_1, \dots, v_n) = \sum_{j=1}^n J_j = \sum_{j=1}^n \sum_{k=1}^m u_{jk}^p d_{jk}^2 \quad (2)$$

여기서 u_{jk} 는 0과 1사이의 값이며, v_j 는 j 번째 클러스터의 중심값이다. $p \in [1, \infty]$ 은 퍼지화 계수이다.

d_{jk} 는 j 번째 클러스터의 중심과 k 번째 데이터 사이의 거리로써 식(3)처럼 정의되는 정규화된 유클리디안 거리를 사용한다.

$$d_{jk} = \|v_j - x_k\| = \sqrt{\sum_{i=1}^l \frac{v_{ji} - x_{ki}}{\sigma_i^2}} \quad (3)$$

여기서 l 은 입력공간의 차원이며, σ_i^2 은 i 번째 입력 변수의 분산이다. 정규화된 유클리디안 거리를 사용함으로써 큰 값을 갖는 입력변수가 작은 크기를 갖는 입력변수보다 클러스터의 중심을 결정하는데 많은 영향을 미치는 것을 방지할 수 있다.

식(2)의 비용함수가 최소가 되기 위한 필요조건은 식(4),(5)와 같다

$$v_j = \frac{\sum_{k=1}^m u_{jk}^p x_k}{\sum_{k=1}^m u_{jk}^p} \quad (4)$$

$$u_{jk} = \frac{1}{\sum_{j=1}^n \left(\frac{d_{jk}}{d_{ij}} \right)^{2/(p-1)}} \quad (5)$$

FCM 알고리즘은 식(4)과 식(5)을 더 이상 향상시키지 않을 때 까지 반복적으로 처리한다. FCM은 다음의 단계를 사용하여 소속행렬 U 와 클러스터 중심 v_j 을 결정한다.

- Step 1 : 식(1)을 만족하며 0과 1사이의 랜덤 값을 갖는 소속행렬 U 를 초기화한다.
- Step 2 : 식(4)를 이용하여 클러스터의 중심값, v_j 를 계산한다.
- Step 3 : 식(2)의 비용함수를 계산한다. 만약 허용오차보다 적거나 더 이상 개선되지 않으면 중단한다.
- Step 4 : 식(5)를 이용하여 새로운 소속행렬 U 를 구하고 Step 2를 수행한다.

3.2 IG-FRBFNN의 구조 및 학습

IG-FRBFNN의 구조는 그림 4와 같다. 이 구조는 RBFNN의 변형 및 확장된 구조이며 전반부와 후반부로 구성되어있다. 전반부 멤버쉽함수는 가우시안, 다원형, 삼각형 함수 등 특정 RBF 커널을 사용하지 않고 FCM에 의하여 퍼지공간 분할과 멤버쉽이 결정된다. 또한 후반부는 상수항으로 표현되는 기존 RBFNN과는 달리 상수항뿐만 아니라, 선형, 2차식, 그리고 수정된 2차식 등의 다양한 다항식 형태로 표현할 수 있도록 확장되었다[6,7].

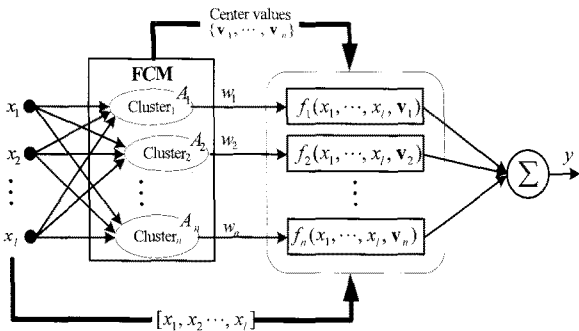


그림 4 IG-FRBFNN의 구조
Fig. 4 Architecture of IG-FRBFNN

IG-FRBFNN은 식(1)처럼 퍼지규칙으로 표현될 수 있으며 식(2)~(5)처럼 4가지 형태의 후반부 다항식을 고려한다. 여기서 $x = [x_1, x_2, \dots, x_i]$, l 은 입력변수의 수, R^l 는 j 번째 퍼지 규칙, $j = 1, \dots, n$, n 은 퍼지규칙 수, $f_j(x, v_j)$ 는 j 번째 규칙에 대한 후반부로서 j 번째 입력공간에 대한 로컬모델이며, v_j 는 j 번째 규칙에 대한 중심점이며, FCM으로부터 얻어진다.

$$R^j: \text{IF } x \text{ is included in } A_j \text{ THEN } y_j = f_j(x_1, \dots, x_i, v_j) \quad (6)$$

Type 1 : 간략식(Constant type)
 $f_j(x_1, x_2, \dots, x_i, v_j) = a_{j0} \quad (7)$

Type 2 : 선형식 (Linear type)
 $f_j(x_1, \dots, x_i, v_j) = a_{j0} + a_{j1}(x_1 - v_{j1}) + \dots + a_{jl}(x_l - v_{jl}) \quad (8)$

Type 3 : 2차식 (Quadratic type)
 $f_j(x_1, \dots, x_i, v_j) = a_{j0} + a_{j1}(x_1 - v_{j1}) + \dots + a_{jl}(x_l - v_{jl}) + a_{j(l+1)}(x_1 - v_{j1})^2 + \dots + a_{j(2l)}(x_l - v_{jl})^2 + a_{j(2l+1)}(x_1 - v_{j1})(x_2 - v_{j2}) + \dots + a_{j(l-2)(l+1)/2}(x_{l-1} - v_{j(l-1)})(x_l - v_{jl}) \quad (9)$

Type 4 : 변형된 2차식(Modified quadratic type)
 $f_j(x_1, \dots, x_i, v_j) = a_{j0} + a_{j1}(x_1 - v_{j1}) + \dots + a_{jl}(x_l - v_{jl}) + a_{j(l+1)}(x_1 - v_{j1})(x_2 - v_{j2}) + \dots + a_{j(l+1)(l)/2}(x_{l-1} - v_{j(l-1)})(x_l - v_{jl}) \quad (10)$

IG-FRBFNN 모델은 출력은 식(11)처럼 구해진다.

$$\hat{y} = \sum_{j=1}^n w_j f_j(x_1, \dots, x_i, v_j) \quad (11)$$

IG-FRBFNN의 학습은 크게 전반부 멤버쉽함수의 학습과 후반부 다항식의 학습부분으로 구성된다. 전반부 멤버쉽 함수는 삼각형이나 가우시안 형태 등의 특정 형태를 사용하지 않고 FCM 알고리즘을 통하여 멤버쉽 값이 결정된다. 식(6)에서 A_j 는 j 번째 클러스터(규칙)를 의미하며, 이때 소속정도는 FCM에서 소속정도를 결정해주는 식(5)로 부터 구해진다.

IG-FRBFNN의 후반부 학습은 각 퍼지규칙 후반부 다항식의 계수를 추정하는 것이며 Least Squares Method(RLS), Recursive LSE(RLSE), BP(Back Propagation)등 다양한 알고리즘을 적용할 수 있다. 본 연구에서는 WLSE를 사용하였다. LSE는 전역학습 알고리즘으로 잘 알려져 있다. 즉, 모델의 전체출력과 실제출력이 최소가 되도록 파라미터를 추정하는 알고리즘이지만 WLSE는 각 로컬영역에서 로컬모델(각 퍼지 규칙에서 후반부 다항식)과 모델의 출력이 최소가 되도록 파라미터를 추정하는 알고리즘이다. WLSE는 로컬모델의 학습을 수행하기 위한 방법으로써 식(12)처럼 정의 되는 성능평가함수가 최소가 되도록 각각의 로컬모델인 다항식의 계수를 추정한다.

$$J_L = \sum_{j=1}^n \sum_{k=1}^m w_{jk} (y_k - f_j(x_k, v_j))^2 \quad (12)$$

식(12)의 성능지수 J_L 은 식(13)처럼 행렬형태로 표현될 수 있다.

$$J_L = \sum_{j=1}^n (Y - X_j a_j)^T W_j (Y - X_j a_j)$$

여기서, W_j 는 j 입력공간에 대한 입력데이터의 활성레벨(소속값)을 의미하고, X_j 는 로컬모델의 계수를 추정하기 위한 입력데이터 행렬을 의미하며 로컬모델이 선형일 경우 다음과처럼 정의된다.

$$W_j = \begin{bmatrix} w_{j1} & 0 & \dots & 0 \\ 0 & w_{j2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & w_{jm} \end{bmatrix}, X_j = \begin{bmatrix} 1 & (x_{11} - v_{j1}) & \dots & (x_{1i} - v_{ji}) & \dots & (x_{1l} - v_{jl}) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ 1 & (x_{k1} - v_{j1}) & \dots & (x_{ki} - v_{ji}) & \dots & (x_{kl} - v_{jl}) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ 1 & (x_{m1} - v_{j1}) & \dots & (x_{mi} - v_{ji}) & \dots & (x_{ml} - v_{jl}) \end{bmatrix}$$

여기서, m 은 학습데이터의 수, $k=1, \dots, m$, l 은 입력변수의 수, $i=1, \dots, l$ 이다.

j 번째 규칙에 대한 로컬모델인 다항식의 계수는 식(13)에 의해서 구해진다.

$$\hat{a}_j = (X_j^T W_j X_j)^{-1} X_j^T W_j Y \quad (13)$$

WLSE는 각각의 로컬모델인 다항식의 계수를 추정하는 방법으로써 각각의 로컬모델을 독립적으로 추정할 수 있다는 장점이 있다. 이 방법은 컴퓨터의 계산부하를 줄일 수 있고, 각각의 로컬모델로써 서로 다른 차수의 다항식들을 사용할 수 있다는 장점이 있다. 또한 WLSE를 사용함으로써 해석력이 뛰어난 모델을 설계할 수 있다.

4. HFC-PGA를 이용한 IG-FRBFNN의 최적화

IG-FRBFNN의 전반부학습은 FCM, 후반부 학습은 WLSE를 사용하여 수행되지만, 사용될 입력변수(사용되는 특징점), 퍼지규칙의 수, 후반부 다항식의 차수, 퍼지화 계수에 많은 영향을 받으며 이들 값들을 결정해야 한다. 본 연구에서는 HFC-PGA를 이용하여 IG-FRBFNN의 구조와 파라미터에 관련된 4가지의 값들을 최적화 한다.

4.1 계층적 경쟁 기반 병렬 유전자 알고리즘

GA는 생태계의 적자생존원리를 모태로한 잘 알려진 최적화 알고리즘으로써 광범위하게 사용되고 있다. 일반적으로 GA는 전역해를 효율적으로 찾을 수 있는 것으로 알려져 있지만, 세대수가 증가함에 따라 개체들이 비슷하게 되어 지역해에 빠지거나 조기 수렴하는 경우가 발생한다. 이러한 문제를 해결하기 위해하여 병렬 유전자 알고리즘(PGA)이 제시되었으며, HFC-PGA는 병렬유전자 알고리즘의 한 가지 경우이다[16-18]. PGA는 여러 개의 집단(population)을 사용하여 각 집단은 서로 다른 환경에서 진화하며 일정 세대간격으로 각 집단의 개체들이 다른 집단으로 이주를 한다.

HFC-PGA는 여러 개의 집단이 계층적으로 구성되어 다른 환경(교배율, 돌연변이율, 진화연산자 및 개체의 수를 다르게 설정할 수 있다)에서 독립적으로 진화한다. 각 집단은 특정 범위의 적합도를 갖는 개체들로 구성되어 있고, 하위 수준의 집단으로부터 개체의 진입을 위한 문턱적합도를 갖고 있다. 그리고 진화과정은 기존의 유전자 알고리즘과 비슷하지만 이주과정이 있다는 것이 다른 점이다. 그림 5는 HFC-PGA의 이주 구조를 보여주며 화살표는 개체들의 이동 가능한 방향을 의미한다. 개체들은 상위 집단으로만 이동할 수 있으며 하위 집단으로는 이동하지 않는다. HFCGA에서 이주과정은 정해진 일정한 세대 간격마다 수행하게 된다. 이주과정의 단계는 다음과 같다.

[Step 1] 각각의 집단 개체들의 적합도를 정규화한다.

$$nf_{j,i} = f_{j,i} / f_{max} \quad (14)$$

$f_{j,i}$ 는 j 번째 집단(deme)의 i 번째 개체 적합도, f_{max} 는 전체 집단의 최대 적합도

[Step 2] 정규화된 적합도를 정해진 문턱적합도들과 비교하여 적합도 수준에 맞는 임시버퍼(Admission buffer)에 개체들을 저장한다.

[Step 3] 각각의 임시버퍼에 저장된 개체들과 해당하는 집단의 낮은 수준의 개체들을 바꾸어준다. 그리고 최하위 수준의 집단은 개체들의 다양성을 유지하기 위해 모든 개체들을 랜덤하게 다시 생성한다.

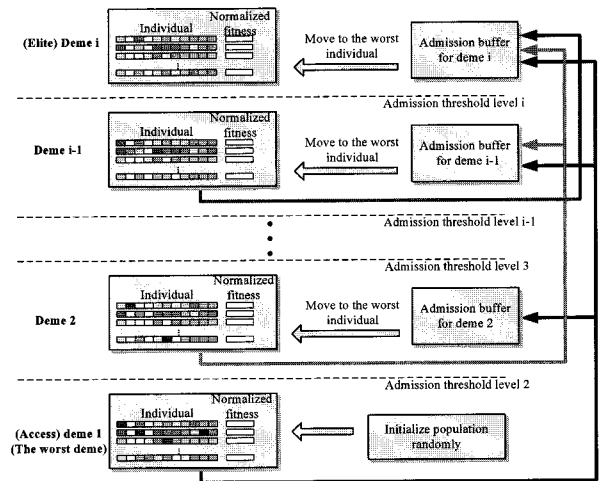


그림 5 HFCPGA의 이주구조

Fig. 5 The migration topology of HFCPGA

4.2 IG-FRBFNN의 최적화를 위한 염색체의 구성 및 해석

본 논문에서는 IG-FRBFNN의 구조와 파라미터에 관련된 값들의 최적화를 위해 HFC-PGA를 사용하였으며 그림 6(a)에 염색체의 구성 및 해석방법을 보인다. 염색체는 벡터형태로 표현될 수 있으며 사용할 입력변수를 의미하는 Sub1과 사용할 입력변수의 수, 퍼지규칙의 수, 후반부 다항식의 차수, 퍼지화 계수의 값을 의미하는 Sub2로 구성된다. Sub1의 길이는 주어진 입력변수의 수와 같으며 주어진 입력변수가 중복하지 않고 열거된다. 본 연구에서 12개의 특징을 사용하며 각각의 특징변수 수들은 1에서 12사이의 값으로 코딩되어 사용된다. 입력변수의 선택과정에 있어서 똑같은 특징이 중복적으로 선택되어서는 안 되는 제약을 가지고 있다. 이 문제를 해결하기 위하여 Sub1에 대하여 심블릭 코딩기반 유전자 알고리즘에서 사용하는 부분상교배연산자를 사용하고, Sub2에 대하여 실수코딩기반 유전자알고리즘에서 사용되는 산술교배연산자를 적용하였다.

Input variable	Input variable	...	Input variable	No. of input variables to be used	No. of fuzzy rules	The Order of polynomial	Fuzzification coefficient
Sub1				Sub2			

(a) 염색체의 구성

2	3	6	5	7	10	1	3	12	9	10	8	2.92	4.65	2.12	2.97
②												①	③	④	⑤

- ① The number of input variables : 3
- ② The selected input variable : 2, 3, 6
- ③ The number of fuzzy rules : 5
- ④ The order of polynomial of fuzzy rules : Linear(Type 2)
- ⑤ The fuzzification coefficient : 2.97

(b) 염색체 해석 예

그림 6 HFC-PGA에서 염색체의 구성 및 해석

Fig. 6 Composition and interpretation of chromosome

그림 6(b)는 염색체의 해석 예를 보인다. Sub2부분에서 실수코딩 기반 유전연산자를 사용하기 때문에 유전인자의 값 또한 실수값으로 표현된다. 그렇지만 입력변수의 수, 퍼지규칙의 수, 후반부다항식의 차수에 대한 값은 정수값으로 표현되어야하기 때문에 이들 값들은 정수값으로 반올림되어 사용된다. 먼저 유전인자①로부터 사용할 입력변수의 수는 2개가 결정되며, Sub1로부터 앞에서부터 2개의 입력변수 [2, 3]이 선택된다. ③으로부터 퍼지규칙의 수는 5, ④로부터 후반부 다항식의 차수는 Type 2(선형) 그리고 ⑤로부터 퍼지화 계수는 2.97이 된다.

5. 시뮬레이션 및 실험

제작된 트래킹 실험장비에서 인가전압은 220V, 60Hz로 하였으며, 부하로는 5, 40, 60W의 백열등의 부하용량을 변화시켜 실험을 수행하였다. 시료는 폴리에틸렌 비닐 케이블을 사용하였고 피복에 3mm 정도로 절취하여 심선을 노출시켜서 심선 간에 전압을 인가한 상태에서 피복재의 손상부에 0.1%의 염화암모늄(NH₄CL) 수용액을 30초 간격으로 떨어뜨리면서 심선간의 피복재를 통해서 흐르는 누설전류와 부하전류를 측정한다.

트래킹 실험을 통하여 트래킹 발생 시와 정상인 경우에 대하여 620개의 전류파형을 측정하고 각각의 전류 파형에 대하여 2장에서 설명한 12개의 특징을 추출하여 620개의 데이터를 취득하였다. 모델의 학습을 위해서 출력값을 지정해 줘야 하며, 본 연구에서는 트래킹이 발생했을 경우의 특징값에 대하여 출력을 1, 정상 파형으로부터 얻어진 특징에 대하여 -1을 할당하였다. 추출된 데이터의 60%는 IG-FRBFNN의 학습 및 최적화를 위한 학습데이터로 사용하였고, 나머지 40%를 모델의 평가를 위한 데이터로 사용하였다.

그림 7은 트래킹 실험으로부터 얻어진 12개의 특징들에 대한 분포를 보인다. 각각의 특징에 대하여 output이 -1인 경우의 입력은 트래킹인 경우, 1인 경우는 정상인 경우를 의미한다. 각각의 특징들을 분석했을 때 정상상태일 경우와 트래킹이 발생했을 경우 겹치는 경우가 많이 있으며, 트래킹인지 정상인지를 명확하게 구분할 수 있는 판단 경계를 찾는 것은 거의 불가능함을 알 수 있다. 본 연구에서는 12개의 특징들 중에서 판단에 많은 영향을 미치는 특징들을 HFC-PGA를 이용하여 선택한다.

HFC-PGA에서 집단 수는 5개, 각 집단에 대하여 50개의 개체를 사용하였고, 반복수는 100회를 사용하였다. HFC-PGA에서 목적함수로써 식(15)로 정의되는 RMSE를 사용하였다.

$$RMSE = \sqrt{\frac{1}{m} \sum_{k=1}^m (y_k - \hat{y}_k)^2}$$

IG-RBFNN의 학습 및 최적화의 목적은 트래킹인 경우의 특징이 입력되었을 경우 출력이 1이고, 정상일때의 특징값이 입력될 경우 -1이 나오도록 하는 것이다. 실제적으로 IG-FRBFNN의 출력은 실수값이 나오기 때문에 판단 경계는 출력의 중간인 0값으로 설정하여 IG-FRBFNN의 출력이 양수인 경우 트래킹으로 음수인 경우에는 정상으로 판정한다.

HFC-PGA를 이용하여 사용할 특징의 수를 2, 3, 4, 5, 6개로 설정했을 경우 사용할 특징, 퍼지 규칙의 수, 후반부 다항식의 차수, 퍼지화 계수들을 최적화 하였으며, 표 2에

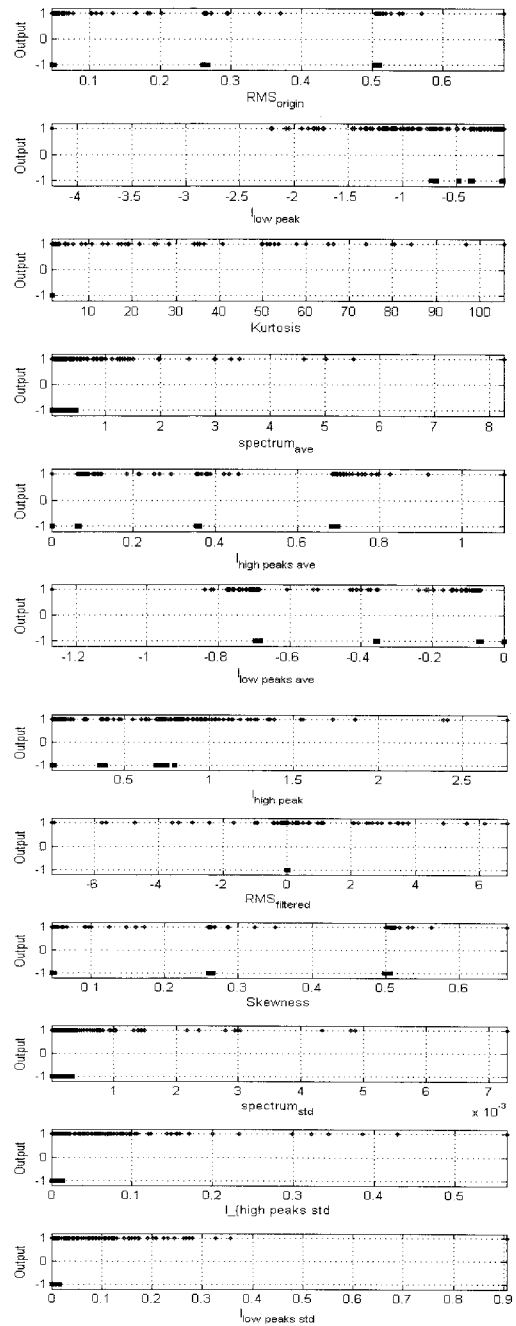


그림 7 추출된 특징 데이터의 분포
Fig. 7 Distribution of each extracted feature

각각의 경우에 대하여 최적화된 값과 성능을 보인다. 여기에서 선택된 입력번호는 표 1에 설명된 특징의 번호이다.


시뮬레이션 결과 실제 측정 전류의 최대값과, 첨도, 그리고 저역통과 필터링된 전류의 실효값을 입력으로 사용할 경우 평가 데이터에 대한 인식률이 가장 높았다. 그림 8은 2개의 특징을 사용하는 경우와 3개의 특징을 사용하는 경우에 대한 데이터의 분포를 보인다. (a)는 최대값과 첨도를 사용하는 경우이며 (b)는 최대값, 첨도, 필터링된 전류의 실효값을 사용한 경우이다. 사각형으로 표현된 패턴은 정상상태의 패턴이며, 원으로 표시된 것은 트래킹이 발생했을 경우의 패턴이다. 정상상태에서는 패턴이 규칙성을 갖고 일정 영역에

표 2 IG-FRBFNN의 최적화 파라미터와 성능분석

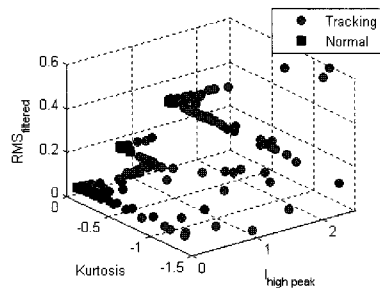
Table 2 The summarize of the optimized IG-FRBFNN

선택된 입력변수	규칙 수	후반부 다항식	퍼지화 계수	학습데이터 인식률	평가데이터 인식률
2, 3	18	선형식	1.1703	93.28%	95.56%
2, 3, 6	17	선형식	1.2152	93.82%	96.37%
1, 2, 3, 10	19	선형식	1.1362	94.08%	95.16%
1, 2, 3, 7, 12	18	선형식	1.2268	93.01%	94.76%
1, 2, 3, 5, 10, 11	20	선형식	1.1295	93.55%	93.95%

서 분포하지만 트래킹이 발생할 경우 트래킹의 진화 정도에 따라 광범위하게 패턴이 분포하며 심지어 정상상태일 경우와 겹치는 경우도 발생한다. 3개의 특징을 사용할 지라도, 정상일 경우와 트래킹이 발생했을 경우 판단 경계를 완벽하게 결정하는 것은 매우 어려움을 알 수 있다.



(a) 2가지 특징을 사용하는 경우



(b) 3가지 특징을 사용하는 경우

그림 8 HFC-PGA를 이용하여 선택된 특징의 분포
Fig. 8 Distribution of selected features using HFC-PGA

시물레이션에서 최대값, 첨도, 필터링된 전류의 실효값을 사용할 경우 성능이 가장 우수했으며, 이 경우의 IG-FRBFNN 모델을 사용하여 트래킹의 발생 유무를 판단하는 추론엔진을 LabVIEW를 이용하여 구현하였다.



그림 9 제작된 트래킹 검출 시스템
Fig. 9 manufactured tracking detection system

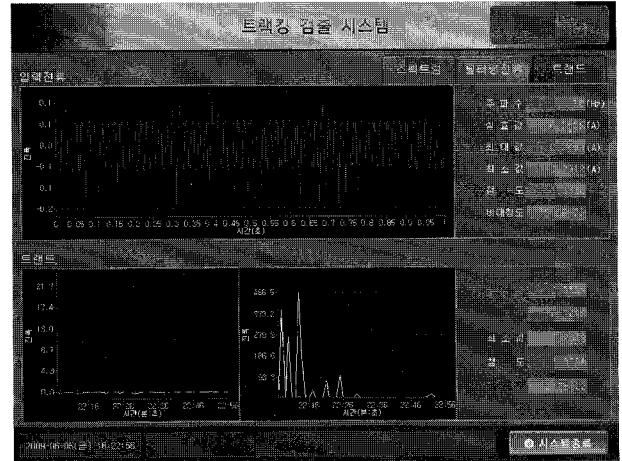


그림 10 임베디드 시스템의 화면
Fig. 10 Screen of embedded system

그림 9는 실제 구현된 트래킹 검출 시스템을 보인다. 오른쪽에는 백열등 부하와 수용액 드롭부이며, 중앙은 트래킹 발생장치와 AD변환기 그리고 왼쪽은 구현된 추론엔진을 탑재한 임베디드 시스템이다. 트래킹 검출 시스템의 구현에 있어서 원격감시를 위하여 서버용 프로그램과 클라이언트용 프로그램을 구현하였다. 서버용 프로그램은 LabVIEW로 구현되었으며, 전류측정, 특징추출, IG-FRBFNN 추론엔진을 이용한 트래킹의 판단, 클라이언트로의 데이터 전송을 수행하고, 클라이언트용 프로그램은 Delphi를 이용하여 구현하였으며 서버로부터 전류파형 데이터, 특징데이터, 판단결과에 대한 정보를 받아 디스플레이 해주는 기능을 한다. 서버용과 클라이언트용 프로그램은 임베디드 시스템에 탑재되어 동작하며 그림 10에 임베디드 시스템에서 동작하는 클라이언트 프로그램의 화면을 보인다.

6. 결 론

본 논문에서는 IG-FRBFNN에 기반을 둔 트래킹 검출방법을 제안하였다. 실험을 통하여 트래킹 발생 시와 정상상태에서의 전류 파형을 비교분석하여 트래킹의 발생 유무를 판단하기 위해 고려할 수 있는 다양한 특징점을 추출하고, 추출된 특징 데이터를 이용하여 최적의 IG-FRBFNN을 구축한다. HFC-PGA를 사용하여 IG-FRBFNN의 구조에 관련하여 사용한 특징의 수, 사용할 특징들, 퍼지규칙의 수 그리고 후반부 다항식의 차수, 그리고 모델의 파라미터에 관련하여 퍼지화 계수를 최적화 한다. Matlab를 사용하여 최적의 IG-FRBFNN를 설계하였으며, LabVIEW를 이용하여 트래킹 검출 알고리즘을 구현하고 임베디드 시스템에 탑재하였다.

본 논문에서는 트래킹 검출을 위한 한 가지 방법론을 제시하였다. IG-FRBFNN의 학습을 위해 단지 백열등 부하에 대하여 취득한 데이터를 사용했기 다른 부하를 사용하지 않은 경우에는 좋은 성능을 보이지 않는다. 실제 적용하기 위하여서는 다양한 부하에 대하여 취득된 데이터를 사용하여 학습을 수행할 필요성이 있다. 또한 본 연구에서 제안된 특징들은 엄격히 트래킹을 구분할 수 없으며, 트래킹의 판단에 사용될 수 있는 특징들에 대한 심도 있는 연구가 요구된다.

감사의 글

본 연구는 지식경제부의 지원에 의하여 기초전력연구원 (2009T100100563)주관으로 수행된 과제임 그리고 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2009-0074928).

참 고 문 헌

[1] 지승욱, 이춘하, 윤대희, 송현직, 심광열, 박원주, 이광식, "전압파형을 이용한 트래킹 진전과정 분석방법에 관한 연구", 조명·전기설비학회논문지, Vol. 20, No. 8, pp. 30-35, 2006

[2] 최충석, 송길목, 김형래, 김향곤, 김동욱, 김동우, "트래킹에 의해 열화된 누전차단기 외함의 특성분석", 2002 한국화재 소방학회 추계학술논문, pp. 47-52

[3] 최원은, 조기선, 이승우, "고분자 절연재료의 트래킹 현상에 관한 연구", 전기학회논문지, Vol. 34, No. 12, pp. 457-463, 1985

[4] 지승욱, 이상훈, 김충년, 이춘하, 이광식, "트래킹 검출을 위한 주파수-시간 분석(분할-FFT)", 대한전기학회 논문지, Vol. 53c, No. 10, pp. 530-538, 2004

[5] 최태원, 이오걸, 김석순, "신경회로망을 이용한 옥내배선의 트래킹 검지 기법", 대한화재 소방학회지, Vol. 9, No. 1, pp. 3-9, 1995

[6] 최정내, 오성권, 김현기, "FCM 기반 퍼지 뉴럴 네트워크의 진화론적 최적화", 대한전기학회지, Vol. 57, No. 3, pp. 466-472, 2008

[7] 최정내, 김현기, 오성권, "PSO를 이용한 FCM 기반 RBF 뉴럴네트워크의 최적화", 대한전기학회지, Vol. 57, No. 1, pp. 2108-2116, 2008

[8] IEC 60112, "Method for the determination of the proof and the comparative tracking indices of solid insulating materials", 2004

[9] W. Pedryca and G. Vukovich, "Granular neural networks," Neurocomputing, Vol. 36, pp. 205-224, 2001.

[10] P. R. Krishnaiah and L. N. Kanal, editors. Classification, pattern recognition, and reduction of dimensionality, Vol. 2 of Handbook of Statistics. North-Holland, Amsterdam, 1982.

[11] S.-K. Oh and W. Pedrycz, "Identification of Fuzzy Systems by means of an Auto-Tuning Algorithm and Its Application to Nonlinear Systems," Fuzzy Sets and Syst., Vol. 115, No. 2, pp. 205-230, 2000.

[12] L. X. Wang, J. M. Mendel, "Generating fuzzy rules from numerical data with applications," IEEE Trans. Systems, Man, Cybern., Vol. 22, No. 6, pp. 1414-1427, 1992.

[13] J. S. R. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference System," IEEE Trans. System, Man, and Cybern., Vol. 23, No. 3, pp. 665-685, 1993.

[14] L. P. Maguire, B. Roche, T. M. McGinnity, L. J. McDaid, "Predicting a chaotic time series using a

fuzzy neural network," Information Sciences, Vol. 112, pp. 125-136, 1998.

[15] 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

[16] J.J. Hu, E.D. Goodman, The Hierarchical Fair competition (HFC) Model for Parallel Evolutionary Algorithms, CEC 2002 - Proceedings of the 2002 congress on Evolutionary Computation, IEEE, Honolulu, Hawaii (2002) 45-94

[17] J.J. Hu, E.D. Goodman, K. S. S대, M. Pei, Adaptive Hierarchical Fair competition (AHFC) Model for Parallel Evolutionary Algorithms, GECCO 2002 - Genetic and Evolutionary Computation Conference (2002) 772-779

[15] J.N. Choi, S.K. Oh, W. Pedrycz, Structural and parametric design of fuzzy inference systems using hierarchical fair competition -based parallel genetic algorithm and information granulation, International Journal of Approximate Reasoning 49 (2008) 631-648

저 자 소 개



최정내 (崔正乃)

1997년 : 원광대 제어계측과 졸업. 1999년 : 동 대학원 제어계측과 졸업(공학석사). 2004년 : 동 대학원 전기공학과 졸업(공학박사). 2006년~2007 : 수원대학교 전기공학과 Post-Doc. 2008년~현재 : 대림대학 전기과 전임강사. 관심분야 : PID 제어, 지능 제어, 최적화 기법, 퍼지이론, 신경망 이론 등.
Phone : (031) 467-4667.
E-mail : jnchoi@daelim.ac.kr



김영일 (金榮日)

승실대학교 졸업, 연세대학교 대학원 졸업(공학박사), 1987~1989 : LG산전 연구소 선임연구원, 1989~1992 : 동해중앙연구소 연구소장, 1993~현재 : 대림대학 전기과 교수. 1997~현재 : 중소기업청 기술혁신 심의위원. 1982~현재: 국립 기술 품질원 전기용품전품검토위원. 1998~현재 : 전기전자 시험연구원 기술심의위원. 1993~현재 : 중소기업 진흥공단 연수원 위촉교수. 관심분야 : 디지털 회로설계, 전자회로, 산업전자
Phone : (031) 467-4864
E-mail : yikim@daelim.ac.kr



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 : 시스템 자동화, 퍼지이론, 신경회로망 응용 및 제어, 컴퓨터 지능 등. Phone : (031) 229-8162. E-mail : ohsk@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(공박). 현재 대전대 공대 전기정보시스템공학과 교수. Tel : (031)539-1914 Fax : (031)539-1910 E-mail : jtkim@daejin.ac.kr