

데이터 중심 다항식 확장형 RBF 신경회로망의 설계 및 최적화

논문
60-3-27

Design of Data-centroid Radial Basis Function Neural Network with Extended Polynomial Type and Its Optimization

오성권[†] · 김영훈^{*} · 박호성^{**} · 김정태^{***}
(Sung-Kwun Oh · Young-Hoon Kim · Ho-Sung Park · Jeong-Tae Kim)

Abstract - In this paper, we introduce a design methodology of data-centroid Radial Basis Function neural networks with extended polynomial function. The two underlying design mechanisms of such networks involve K-means clustering method and Particle Swarm Optimization(PSO). The proposed algorithm is based on K-means clustering method for efficient processing of data and the optimization of model was carried out using PSO. In this paper, as the connection weight of RBF neural networks, we are able to use four types of polynomials such as simplified, linear, quadratic, and modified quadratic. Using K-means clustering, the center values of Gaussian function as activation function are selected. And the PSO-based RBF neural networks results in a structurally optimized structure and comes with a higher level of flexibility than the one encountered in the conventional RBF neural networks. The PSO-based design procedure being applied at each node of RBF neural networks leads to the selection of preferred parameters with specific local characteristics (such as the number of input variables, a specific set of input variables, and the distribution constant value in activation function) available within the RBF neural networks. To evaluate the performance of the proposed data-centroid RBF neural network with extended polynomial function, the model is experimented with using the nonlinear process data(2-Dimensional synthetic data and Mackey-Glass time series process data) and the Machine Learning dataset(NOx emission process data in gas turbine plant, Automobile Miles per Gallon(MPG) data, and Boston housing data). For the characteristic analysis of the given entire dataset with non-linearity as well as the efficient construction and evaluation of the dynamic network model, the partition of the given entire dataset distinguishes between two cases of Division I(training dataset and testing dataset) and Division II(training dataset, validation dataset, and testing dataset). A comparative analysis shows that the proposed RBF neural networks produces model with higher accuracy as well as more superb predictive capability than other intelligent models presented previously.

Key Words : Radial Basis Function(RBF) Neural networks, Data-centroid, Extended polynomial type, K-means clustering, Particle Swarm Optimization(PSO), PSO-based design procedure, Standard least square method, Nonlinear process data

1. 서론

많은 분야에서 진행되고 있는 시스템 모델링에 관한 연구의 궁극적인 목표는 모델링에 적용될 실질적인 공정을 정확하게 이해하고 분석함으로써 원하는 정보를 이용하는데 있다. 그러나 대부분의 공정들에서는 비선형을 내포하고 있기 때문에 복잡한 비선형 공정을 모델링하고 예측하는데 있어서 기존의 방법들은 비교적 간단한 시스템에 대해서 매우 복잡한 다항식을 생성하는 것과 복잡한 비선형 시스템을 표현하는데 있어서 한계, 그리고 효율적인 모델을 구축하기가

어렵다는 단점을 가지고 있다[1].

이러한 단점들을 보완하고자, 최근 지능형 모델링 분야에서는 계산적 지능(Computational Intelligence: CI) 기술의 합성을 통한 진보된 시스템을 이용하여 시스템의 복잡성이 큰 문제를 분석하는데 있어서 활발히 진행되어져 오고 있다. 이는 독립적인 지능형 시스템보다 CI 기술의 합성을 통한 진보된 시스템이 우수한 성능을 가지기 때문이다[2]. 이에 본 논문에서는 CI 기술들의 합성을 이용하여 시스템이 복잡하고 대규모의 구조를 가지는 비선형 실 시스템의 동적 분석을 표현하고자 한다.

본 논문에서는 K-means 클러스터링 방법과 입자 군집 최적화(PSO) 알고리즘을 RBF 신경회로망에 접목한 데이터 중심 다항식 확장형 RBF 신경회로망을 제안하고, 제안된 모델을 비선형 공정으로 적용하고자 한다. 먼저 2장에서는 일반적인 RBF 신경회로망의 구조와 설계 방법에 대해서 알아보고, 3장에서는 제안된 데이터 중심 다항식 확장형 RBF 신경회로망의 최적화를 위한 K-means 클러스터링 방법과 PSO 알고리즘에 대해서 설명하였다. 4장에서는 본 논

† 교신저자, 시니어회원 : 수원대 공대 전기공학과 교수 · 공박
E-mail : ohsk@suwon.ac.kr

* 준 회원 : 수원대 전기공학과 석사과정

** 정 회원 : 수원대 산업기술연구소 학술연구교수

*** 정 회원 : 대진대 공대 전기정보시스템공학과 교수 · 공박
접수일자 : 2010년 9월 1일

최종완료 : 2010년 11월 10일

문에서 제안한 데이터 중심 다항식 확장형 RBF 신경회로망에 대해서 자세히 언급하였으며, 5장에서는 제안된 모델의 성능을 평가하기 위해 비선형 공정 데이터와 Machine Learning 데이터[11]를 실험적 데이터로 이용하여 구조적 개발의 다양성을 입증하고 모델의 성능을 확인하였다. 마지막으로 6장에서는 본 논문에서 제안한 모델에 대한 결론을 서술하였다.

2. 일반적인 RBF 신경회로망 구조와 설계

본 장에서는 본 논문에서 제안한 데이터 중심 다항식 확장형 RBF 신경회로망 구조의 기본 형태인 일반적인 RBF 신경회로망의 구조와 그들의 전형적인 설계 방법들에 대해서 살펴본다.

2.1 일반적인 RBF 신경회로망의 구조

RBF 신경회로망은 일반적으로 그림 1과 같이 3개의 층(입력층, 은닉층, 그리고 출력층)을 가진 신경회로망으로써 n 차원의 입력 벡터 $\mathbf{x}=[x_1, x_2, \dots, x_n]^T$ 는 은닉층을 통해서 비선형식으로 변환되고, 은닉층을 통해 얻어진 활성화 레벨들은 출력층에 위치한 뉴런에 의해서 최종적으로 선형 형태로 변환된다.

그림 1과 같은 구조로 되어 있는 일반적인 RBF 신경회로망 구조는 빠른 학습시간과 일반화(generality) 능력 그리고 단순화(simplicity) 능력이 다른 지능형 알고리즘에 비해 우수하여, 데이터를 분류하는 작업과 비선형 시스템 모델링 등에 적용되고 있다.

일반적으로 널리 사용되어진 방사형 기저 함수의 형태는 식 (1)과 같은 가우시안 형태로 표현된다.

$$R_i(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x}-\mathbf{v}_i\|^2}{2\sigma_i^2}\right) \quad (1)$$

식 (1)은 식 (2)와 같이 자세하게 표현할 수 있으며, 식 (2)에서 보이듯이 은닉층의 활성화함수가 동일한 분포상수를 갖는 형태가 된다.

$$\begin{aligned} R_i(\mathbf{x}) &= \exp\left\{-\left(\frac{(\mathbf{x}_1-v_{i1})^2}{2\sigma_i^2} + \frac{(\mathbf{x}_2-v_{i2})^2}{2\sigma_i^2} + \dots + \frac{(\mathbf{x}_n-v_{in})^2}{2\sigma_i^2}\right)\right\} \\ &= \exp\left\{-\frac{1}{2}\left(\frac{(\mathbf{x}_1-v_{i1})^2}{\sigma_i^2} + \frac{(\mathbf{x}_2-v_{i2})^2}{\sigma_i^2} + \dots + \frac{(\mathbf{x}_n-v_{in})^2}{\sigma_i^2}\right)\right\} \\ &= \exp\left\{-\frac{1}{2}\left(\sum_{j=1}^n \frac{(\mathbf{x}_j-v_{ij})^2}{\sigma_i^2}\right)\right\} \end{aligned} \quad (2)$$

여기서 \mathbf{x}_{kj} 는 j 번째 입력 데이터, v_{ij} 은 j 번째 입력의 $i(i=1, \dots, K)$ 번째 RBF의 중심, σ_i 는 i 번째 은닉층 노드에서 RBF의 활성화 영역을 결정하는 분포상수이며 일반적으로 은닉층을 구성하는 모든 노드들은 '1'의 값을 갖는다.




그림 1 일반적인 RBF 신경회로망의 구조
Fig. 1 Architecture of General RBF neural network

네트워크의 출력 $y(\mathbf{x})$ 는 각각의 활성화 레벨의 선형 조합으로써 다음 식 (3)과 같이 계산된다.

$$y(\mathbf{x}) = \sum_{i=1}^K w_i R_i(\mathbf{x}) \quad (3)$$

2.2 일반적인 RBF 신경회로망의 설계 방법론

은닉층에서의 개발이 결정적인 RBF 신경회로망 설계에 있어서 중요한 특징으로 부각된다. 그 이유로는 다음과 같이 들 수 있겠다.

- 은닉층의 형태와 수는 기본적인 설계의 초점이 된다.
- 입력공간에서의 은닉층의 분포는 네트워크의 기능에서 중요한 관련이 있다
- 각각의 은닉층에서의 파라미터의 최적화는 본질적으로 가장 중요하다.

기존의 논문들에서는 이와 같은 중요한 설계 이슈들을 다루기 위해서 여러 가지 방법을 시도하였다. 즉, RBF 노드 상호간의 연결 가중치 조절과 RBF 노드의 중심 및 폭과 같은 파라미터 변경 등이 연구되었으며, 입력 데이터 중에서 임의로 중심 선택법, 등이 사용되어지고 하였다. 또한 은닉층의 형태가 결정되어진 후에, 출력층에서의 뉴런들의 가중치에 대한 최적화가 직접적으로 이루어진 논문들도 있다.

3. 데이터 중심 다항식 확장형 RBF 신경회로망의 최적화

본 장에서는 K-Means 클러스터링 방법[18]과, 입자 군집 최적화 (Particle Swarm Optimization: PSO) 알고리즘을 적용한 데이터 중심 다항식 확장형 RBF 신경회로망의 최적화에 대해서 알아본다.

3.1 데이터 중심 처리를 위한 K-Means 클러스터링

클러스터링 방법이란 데이터의 분류를 위해서 사용되는 것으로 데이터의 내부가 비슷한 패턴, 속성, 형태 등의 기준을 통해 데이터를 분류하여 내부의 구조를 찾아내는 것이다. 그림 2는 임의의 2입력의 데이터를 생성한 후,

K-Means 클러스터링 방법을 이용하여 3개의 그룹으로 데이터를 분할한 것을 나타낸다. 그림에서도 알 수 있듯이, 기존의 Min-Max 방법으로 중심값을 구한 것보다 K-Means 클러스터링 방법으로 중심값을 구한 것이 주어진 데이터의 특징을 반영하는데 효율적임을 알 수 있다.

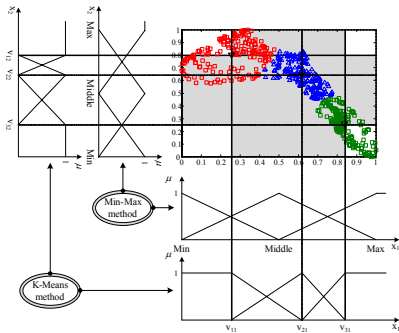


그림 2 K-Means 클러스터링 방법에 의한 데이터의 중심값
Fig. 2 Prototype of data by K-Means clustering method

3.2 파라미터 최적화를 위한 입자 군집 최적화(PSO) 알고리즘

PSO는 자연선택의 진화 메커니즘이 아닌 새떼와 물고기 떼와 같은 생체군집의 사회적 행동양식을 바탕으로 하고 있다. PSO 역시 군집기반 알고리즘으로 병렬처리 특징을 가지며, 군집과 개체는 Swarm과 Particle로 표현된다.

본 논문의 서론에서도 언급하였듯이, 주어진 데이터들을 효과적으로 모델의 구축에 반영하기 위하여 다음과 같이 2가지 방법으로 은닉층에서의 활성화함수를 설계하여 모델을 세분화하였다.




그림 3 PSO의 particle을 이용한 pRBFNN 설계 - CASE I
Fig. 3 The pRBFNN design using a particle of PSO - CASE I

- CASE I : 은닉층을 구성하고 있는 각 노드별로 서로 다른 분포상수 값 설정.

즉, 기존의 일반적인 RBF 신경회로망은 은닉층에서의 모든 노드의 활성화함수의 분포상수 값으로 '1'을 사용하였다. 그러나 이는 데이터의 특성이 모델 구축에 전혀 고려되지 못하므로 그 성능이 저조함을 알 수 있다. 이러한 단점을 보

완하고자 그림 3에서 보이듯이, 은닉층을 구성하고 있는 각 노드별로 서로 다른 분포상수 값을 설정함으로써 효율적으로 데이터의 특성을 모델에 반영하고자 하였다.

그림 3은 전체 입력변수의 수가 4이고 은닉층에서 노드의 수가 4개로 한정했을 때의 PSO의 설계과정을 나타낸 것이다. 그림 3에서는 PSO를 이용하여 CASE I에 대한 pRBFNN 구조를 설계하는 과정을 나타낸다.

- CASE II : 은닉층을 구성하고 있는 각 노드별로 선택된 입력변수들에 따라 서로 다른 분포상수 값 설정.

CASE II의 경우엔 그림 4에서와 같이 선택되어진 입력변수들의 각각의 특징을 좀 더 세밀하고 효율적으로 모델 구축에 반영하고자 각 노드에서의 분포상수 값들을 선택되어진 입력변수들의 수만큼 확장하여 모델에 적용하였다.

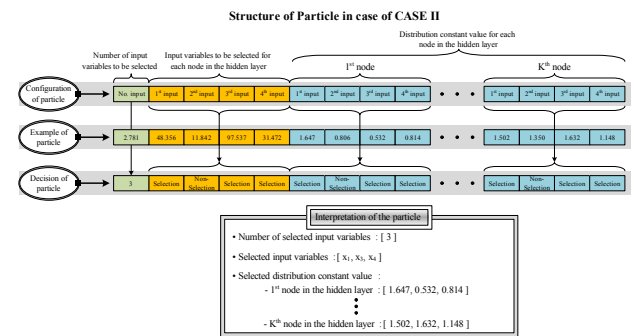


그림 4 PSO의 particle을 이용한 pRBFNN 설계 - CASE II
Fig. 4 The pRBFNN design using a particle of PSO - CASE II

본 논문에서는 모델의 근사화와 일반화 능력 사이의 합리적 균형을 얻기 위해 분할된 데이터 형식에 따라 식 (4), 식 (5)와 같은 하중값을 가진 목적함수를 이용하여 모델에 대한 성능을 효율적으로 평가하였다.

• Division I인 경우 :

$$F(\text{Fitness Function}) = \theta \times \text{PI} + (1 - \theta) \text{EPI} \quad (4)$$

• Division II 2인 경우:

$$F(\text{Fitness Function}) = \theta \times \text{PI} + (1 - \theta) \text{VPI} \quad (5)$$

식 (4)에서는 θ 값을 1로 설정하여 테스트 데이터는 순수하게 모델의 평가에만 사용하였다. 식 (5)에 주어진 목적함수의 θ 값을 0.5로 설정하여 모델 구축에 있어서 근사화와 일반화 능력을 상호 고려하였으며, 이를 기반으로 모델에 대한 성능을 해석하였다.

4. 데이터 중심 다항식 확장형 RBF 신경회로망

3장에서 언급되어진 알고리즘 및 구조를 기반으로 본 논문에서 제안한 데이터 중심 다항식 확장형 RBF 신경회로망은 그림 5에서 보인 것처럼 나타낼 수가 있다.

본 논문에서는 그림 5에서 보이듯이, 제안된 모델에서의 활성화함수는 식 (1)에서 나타낸 가우시안 함수를 이용하였으며 가우시안 함수를 구성하고 있는 중심값(v)과 분포 상수

(σ)를 K-means 클러스터링 방법과 PSO 알고리즘을 이용하여 모델의 성능에 주요한 영향을 미치는 파라미터들을 선택하였다. 또한 RBF의 형태를 결정하기 위한 방법으로서 분포상수 값의 구조에 따른 두 가지 경우(CASE I, CASE II)로 나누어 근사화 능력과 일반화 능력을 비교 분석하였다.

은닉층과 출력층사이의 연결가중치를 기존의 상수값에서 벗어나 표 1에서 보이듯이 4가지의 다양한 다항식 형태로 확장하여 주어진 데이터의 특성을 효율적으로 모델에 반영하였다.




그림 5 제안된 모델의 전체 구조
Fig. 5 The overall structure of the proposed model

표 1 포괄적인 방사형 기저 함수식

Table 1 Global radial basis function equation

Type	Polynomial equation
Type 1 Constant	$f_j(\mathbf{x}) = a_{j0}$
Type 2 Linear	$f_j(\mathbf{x}) = \sum_{i=0}^n a_{ij} \mathbf{x}_i$
Type 3 Quadratic	$n = 2: f_j(\mathbf{x}) = \sum_{i=0}^n a_{ij} \mathbf{x}_i + \sum_{i=1}^n a_{j(n+i)} \mathbf{x}_i^2 + a_{(2n+1)} \mathbf{x}_1 \mathbf{x}_2$ $n \geq 3: f_j(\mathbf{x}) = \sum_{i=0}^n a_{ij} \mathbf{x}_i + \sum_{i=1}^n a_{j(n+i)} \mathbf{x}_i^2 + a_{(2n+1)} \mathbf{x}_1 \mathbf{x}_2 + \dots + a_{(n(n+1)/2)} \mathbf{x}_{(n-1)} \mathbf{x}_n$
Type 4 Modified quadratic	$n = 2: f_j(\mathbf{x}) = \sum_{i=0}^n a_{ij} \mathbf{x}_i + a_{(2n+1)} \mathbf{x}_1 \mathbf{x}_2$ $n \geq 3: f_j(\mathbf{x}) = \sum_{i=0}^n a_{ij} \mathbf{x}_i + a_{(2n+1)} \mathbf{x}_1 \mathbf{x}_2 + \dots + a_{(n(n+3)/2)} \mathbf{x}_{(n-1)} \mathbf{x}_n$

그림 5에서 보인 모델에서 은닉층의 출력은 다음 식 (6), 식 (7)과 같이 나타낼 수 있다.

[Case 1] 입력 공간에 대한 각 특성을 모델에 반영하기 위한 첫 번째 방법으로 각 RBF에 대하여 다른 분포상수를 적용하면 식 (6)의 형태이다.

$$\begin{aligned} \text{CASE I: } \hat{R}_i(\mathbf{x}) &= \exp\left\{-\left(\frac{(\mathbf{x}_1 - v_{i1})^2}{2\sigma_i^2} + \frac{(\mathbf{x}_2 - v_{i2})^2}{2\sigma_i^2} + \dots + \frac{(\mathbf{x}_n - v_{in})^2}{2\sigma_i^2}\right)\right\} \\ &= \exp\left\{-\frac{1}{2}\left(\frac{(\mathbf{x}_1 - v_{i1})^2}{\sigma_i^2} + \frac{(\mathbf{x}_2 - v_{i2})^2}{\sigma_i^2} + \dots + \frac{(\mathbf{x}_n - v_{in})^2}{\sigma_i^2}\right)\right\} \\ &= \exp\left\{-\frac{1}{2}\left(\sum_{j=1}^n \frac{(\mathbf{x}_j - v_{ij})^2}{\sigma_i^2}\right)\right\} \end{aligned} \quad (6)$$

여기서, σ_i 는 i 번째 은닉층 노드에서 RBF의 활성화 영역을 결정하는 분포상수이며 본 논문에서는 그림 3에서 보듯이 PSO 알고리즘을 이용하여 분포상수 값을 구하였다.

$$\begin{aligned} \text{CASE II: } \hat{R}_i(\mathbf{x}) &= \exp\left\{-\left(\frac{(\mathbf{x}_1 - v_{i1})^2}{2\sigma_{i1}^2} + \frac{(\mathbf{x}_2 - v_{i2})^2}{2\sigma_{i2}^2} + \dots + \frac{(\mathbf{x}_n - v_{in})^2}{2\sigma_{in}^2}\right)\right\} \\ &= \exp\left\{-\frac{1}{2}\left(\frac{(\mathbf{x}_1 - v_{i1})^2}{\sigma_{i1}^2} + \frac{(\mathbf{x}_2 - v_{i2})^2}{\sigma_{i2}^2} + \dots + \frac{(\mathbf{x}_n - v_{in})^2}{\sigma_{in}^2}\right)\right\} \\ &= \exp\left\{-\frac{1}{2}\sum_{j=1}^n \frac{(\mathbf{x}_j - v_{ij})^2}{\sigma_{ij}^2}\right\} \end{aligned} \quad (7)$$

여기서 σ_{ij} 는 i 번째 은닉층 노드에서 j 번째 입력에 대한 활성화 영역을 결정하는 분포상수이다.

식 (6) 또는 식 (7)과 표 1에서 보여준 연결가중치를 나타낸 다항식과의 결합을 통해서 모델의 지역 모델이 다음 식 (8)에서 보여진 것과 같이 이루어진다. 식 (8)에서 x_0 는 1의 값을 가진 입력이고 Type 2인 선형형태의 다항식을 이용한 경우이다.

$$\begin{aligned} y_i(\mathbf{x}) &= \hat{R}_i(\mathbf{x}) \times f_i(\mathbf{x}) \\ &= \hat{R}_i(\mathbf{x}) \times (a_{i0}x_0 + a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n) \end{aligned} \quad (8)$$

제안된 모델의 전체 출력은 식 (9)와 같이 모두 클러스터의 개수의 지역 모델의 가중치에 의해서 계산된다.

$$\begin{aligned} \hat{y}(\mathbf{x}) &= \sum_{i=1}^K y_i = \sum_{i=1}^K \{\hat{R}_i(\mathbf{x}) \times f_i(\mathbf{x})\} \\ &= \sum_{i=1}^K \{\hat{R}_i(\mathbf{x}) \times (a_{i0}x_0 + a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n)\} \end{aligned} \quad (9)$$

여기서, 다항식 계수인 a_{in} 은 최소자승법(Least Square Estimation: LSE)을 이용하여 구하였다.

본 논문에서는 기존의 논문들과의 비교 및 모델의 평가를 위해서 사용된 데이터에 따라서 2가지의 성능지수식을 이용하여 제안된 모델의 성능을 평가하였다. 즉, 식 (10)에서 보여준 Mean Square Error (MSE)와 식 (11)에서 보여준 Root Mean Square Error (RMSE)을 이용하여 실행하였다.

$$E_{\text{MSE}} = \frac{1}{N} \sum_{t=1}^N (y(\mathbf{x}_t) - \hat{y}(\mathbf{x}_t))^2 \quad (10)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y(\mathbf{x}_t) - \hat{y}(\mathbf{x}_t))^2} \quad (11)$$

여기서, $y(\mathbf{x})$ 는 주어진 실제 출력 데이터이고 $\hat{y}(\mathbf{x})$ 는 모델의 출력 데이터를 의미한다.

5. 시뮬레이션 및 결과 고찰

본 논문에서 제안된 모델을 평가하기 위해서 2차원 synthetic data와 Mackey-Glass 시계열 공경 데이터[3] 그리고 Machine Learning 데이터[11]인 가스터빈 발전소의 NOx 배출공정 데이터[4]와 Automobile Miles per Gallon(MPG) 데이터 그리고 Boston Housing Data(BHD)를 이용하였다.

표 2 PSO 알고리즘 및 모델 구축을 위한 정보

Table 2 Values of the parameters of the PSO algorithm and the proposed model

Parameters	2D	MG	NOx	MPG	BHD
Generation size	100				
Swarm size	50				
V_{max}	20% of search space				
$[w_{min} \ w_{max}]$	[0.4 0.9]				
c_1, c_2	2.0				
Number of clusters	2~10	4~16	4~12	4~30	4~25
Polynomial type	$1 \leq T \leq 4$				
Weighting factor	Division I		1.0		
	Division II		0.5		
Division of data	Division I		50%:50%		
	Division II		50%:30%:20%		

여기서, T는 표 2에 나타난 다항식 구조

5.1 2-Dimensional Synthetic 데이터

제안된 모델의 성능을 평가하기 위한 첫 번째 데이터는 식 (12)를 이용한 2입력 1출력을 가진 비선형 데이터로써 전체 600개의 입출력 데이터를 생성하였다. 또한 성능지수 식으로는 식 (10)에서 나타난 MSE를 이용하여 모델의 성능을 평가하였다.

$$y = \{x_1^{1.5} - 1.5\sin(3x_2)\}^2, \quad 0 \leq x_1, x_2 \leq 3 \quad (12)$$

표 3은 표 2에서 주어진 정보를 바탕으로 2차원의 합성 데이터를 적용하여 2입력 모두를 사용했을 때의 모델의 성능을 나타낸 것이다.

주어진 데이터를 2개로 분할한 Division I의 경우, CASE I과 CASE II의 경우 모두 다항식을 2차식인 Type 3을 사용했을 때 성능이 우수함을 알 수 있다. 또한 CASE I의 성능보다는 CASE II의 성능(PI=2.09e-6, EPI=4.43e-5)이 우수함을 알 수가 있었다. 표 2에서 언급하였듯이, 클러스터의 수는 4개부터 10개사이로 정하였는데 그 중에서 클러스터의 수가 10 즉, 은닉층에서의 노드의 수가 10개인 경우에 성능이 가장 우수함을 알 수 있었다.

Division II의 경우 역시 CASE I과 CASE II 모두에서 다항식 형태가 2차식인 Type 3을 사용했을 때 성능이 우수하였으며, CASE II의 성능(PI=0.0230, VPI=0.0215, 그리고 EPI=0.0522)의 성능이 CASE I보다 우수함을 알 수 있었다.

또한 2-Dimensional 데이터를 사용한 경우엔 Division I의 경우가 Division II의 경우보다 그리고 CASE I보다는 CASE II의 모델에서 근사화 및 일반화 성능이 우수함을 알 수 있다.

그림 6은 표 3에서 보여준 각 모델의 성능지수 중에서 다항식 형태가 2차식인 Type 3을 이용했을 때 클러스터의 수가 증가함에 따른 모델의 성능 변화를 나타낸 것이다. 그림에서도 알 수 있듯이, 클러스터의 수 즉, 은닉층에서의 노드의 수가 증가할수록 성능이 개선됨을 알 수 있다.

표 3 2차원 합성 데이터에 대한 제안된 모델의 성능지수

Table 3 Performance index of the proposed model for the 2D synthetic data

(a) Division I

	Polynomial type	c	PI	EPI
CASE I	Type1	10	1.7278	2.6116
	Type2		0.1009	0.3303
	Type3		0.0011	0.0101
	Type4		0.0522	0.1588
CASE II	Type1		0.7985	1.0478
	Type2		0.0001	0.0006
	Type3		2.09e-6	4.43e-5
	Type4		2.06e-5	0.0001

여기서, c는 클러스터의 수 즉, 은닉층에서의 노드의 수

(b) Division II

	Polynomial type	c	PI	VPI	EPI
CASE I	Type1	10	6.9449	5.8956	7.1616
	Type2		0.3366	0.4580	0.4106
	Type3		0.1793	0.2270	0.2380
	Type4		0.2426	0.3258	0.3488
CASE II	Type1		2.1148	1.6913	2.4586
	Type2		0.0342	0.0328	0.0701
	Type3		0.0230	0.0215	0.0522
	Type4		0.0280	0.0278	0.0635

여기서, c는 클러스터의 수 즉, 은닉층에서의 노드의 수

표 4는 2D synthetic 데이터에 대한 기존의 모델과 본 논문의 모델을 비교한 것이다. 최적화를 거친 모델의 효율성을 강조하기 위해서 모델의 성능 개선에 영향을 미치는 파라미터들(입력변수의 수와 입력변수)을 고정 시킨 모델들과의 성능도 비교하였다. 최적화 알고리즘을 적용하지 않은 모델에 있어서도 다항식을 표 1에서 보여준 4가지 형태를 적용하였으나, Division I의 경우엔 Type 3인 다항식의 형태가 2차식, Division II의 경우엔 다항식 형태가 선형식인 Type 2의 다항식일 때 성능이 가장 우수하여 표 4에서는 가장 좋은 성능만을 표시하였다.





그림 6 클러스터의 수 증가에 따른 모델의 성능
Fig. 6 Performance of the proposed model according to the increase of number of clusters

표 4 다른 모델링 방법과의 성능 비교(2D synthetic data)
Table 4 Comparison of performance with other modeling methods(2D synthetic data)

Model		input	c	PI	VPI	EPI
Regression Model	Division I			35.01		34.98
	Division II			40.86	31.57	29.52
RBFNN	Division I Type3	x ₁ , x ₂	10	0.045		0.175
	Division II Type3			1.726	1.802	1.622
Proposed Model						
Division I		Type3	x ₁	10	23.4740	28.7231
Division II		Type2	x ₂	5	50.9403	51.5148
Division I	CASE I	Type3	x ₁ , x ₂	10	0.0011	0.0101
	CASE II	Type3			2.09e-6	4.43e-5
Division I	CASE I	Type3	x ₁ , x ₂	10	0.1793	0.2270
	CASE II	Type3			0.0230	0.0215

5.2 Mackey-Glass 시계열 공정 데이터

Mackey-Glass 시계열 공정 데이터는 예측 알고리즘의 성능 평가를 위한 대표적인 예로서 사용되는 시계열 데이터이다[3]. 특히 Mackey-Glass 시계열 공정은 비선형 시스템으로부터 발생하는 카오스 신호의 일종으로 신호의 복잡성으로 인해 랜덤 시계열(Random Time Series)처럼 보일 수 있으나 다음 식 (13)과 같은 비선형 동력학 방정식에 의해 생성된다.

$$\dot{x}(t) = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (13)$$

본 논문에서는 식 (13)을 이용하여 6입력(x(t-30), x(t-24), x(t-18), x(t-12), x(t-6), x(t)) 1출력(x(t+6))을 사용하였으며, 또한 제안된 모델의 성능지수 식으로는 식 (11)과 같은 RMSE 방법을 이용하였다.

표 5 제안된 모델의 성능지수(MG)

Table 5 Performance index of the proposed model(MG)

(a) Division I

	Polynomial type	c	selected inputs	PI	EPI
CASE I	Type1	16	All	8.92e-3	9.23e-3
	Type2	16	All	3.41e-4	4.99e-4
	Type3	16	All	4.36e-5	1.17e-4
	Type4	16	All	4.08e-5	1.19e-4
CASE II	Type1	16	3, 4, 5, 6	6.90e-3	7.13e-3
	Type2	16	All	2.68e-4	5.11e-4
	Type3	16	All	2.65e-5	9.76e-5
	Type4	16	All	2.26e-5	9.00e-5

(a) Division II

	Polynomial type	c	selected inputs	PI	VPI	EPI
CASE I	Type1	16	3, 4, 5	9.15e-3	9.53e-3	8.69e-3
	Type2	16	All	3.57e-4	4.72e-4	5.66e-4
	Type3	16	All	4.39e-5	8.76e-5	9.33e-5
	Type4	16	All	6.25e-5	9.81e-5	1.23e-4
CASE II	Type1	16	3, 4, 5, 6	7.55e-3	7.64e-3	7.25e-3
	Type2	16	All	3.43e-4	4.83e-4	6.09e-4
	Type3	16	All	3.56e-5	9.22e-5	1.58e-4
	Type4	16	All	3.04e-5	6.75e-5	9.67e-5

표 5은 제안된 모델에 Mackey-Glass 시계열 공정 데이터를 사용하여 CASE 별로 가장 좋은 성능지수를 나타낸 것이다. 표 5에서도 알 수 있듯이, 대부분의 모델에서 전체

입력이 선택되었을 때 성능이 우수함을 알 수 있었으며, 또한 다항식 형태에 있어서도 대부분의 모델에서 변형된 2차식인 ‘Type 4’를 사용했을 때 성능이 우수함을 알 수 있었다. 주어진 전체 데이터를 학습과 테스트 데이터로 분할한 경우에는 표 6에서도 알 수 있듯이, 은닉층에서의 노드의 수가 증가하고 연결가중치의 함수를 변형된 2차식인 Type 4을 사용할 때 CASE I(PI=4.08e-5, EPI=1.19e-4)과 CASE II(PI=2.26e-5, EPI=9.00e-5)에서 성능이 가장 우수함을 알 수 있었다.

Division II의 경우에는 CASE I의 모델에서는 다항식의 형태가 2차식인 ‘Type 3’(PI=4.39e-5, VPI=8.76e-5, 그리고 EPI=9.33e-5)일 때, 그리고 CASE II의 모델에서는 변형된 2차식인 ‘Type 4’(PI=3.04e-5, VPI=6.75e-5, 그리고 EPI=9.67e-5)일 때 성능이 가장 우수하였다. 앞선 예제와 달리 Division II에서의 모델의 성능이 Division I의 성능보다 우수하였으나, CASE I의 성능보다 CASE II의 성능이 개선 되어짐은 똑같음을 알 수 있었다.

그림 7은 표 5에서 보여준 데이터의 성능 중에서 가장 우수한 모델들의 학습 데이터 성능과 테스트 데이터의 성능을 노드의 수 증가에 따라서 보여준 것이다. 그림에서도 알 수 있듯이 노드의 수 즉, 클러스터의 수가 증가함에 따라 성능이 개선됨을 알 수 있다. 그러나 클러스터의 수가 12개부터 수렴함을 알 수 있어서 16개 이상의 클러스터의 수는 계산의 지속성 및 모델의 복잡성 때문에 본 논문에서는 클러스터의 수를 16개로 한정하여 모델을 구축하였다.

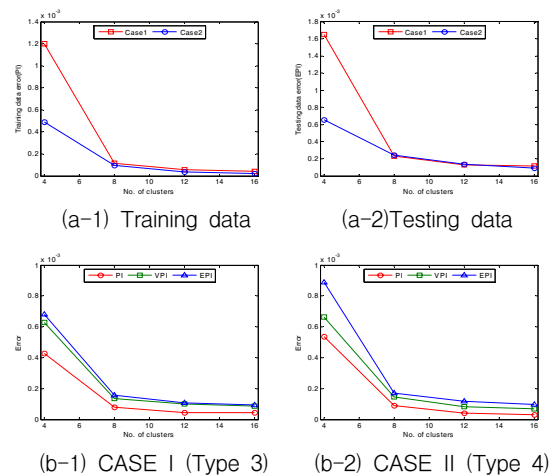


그림 7 클러스터의 수 증가에 따른 모델의 성능

Fig. 7 Performance of the proposed model according to the increase of number of clusters

그림 8은 표 5와 그림 7에서 보여준 모델의 성능 중에서 Division I의 경우엔 PI=2.26e-5, EPI=9.00e-5을 나타낸 CASE II의 대한 원 출력 데이터와 모델의 출력 데이터와의 선형성을 나타낸 것이다. 그림에서도 알 수 있듯이, 원 출력과 모델의 출력이 거의 유사함을 나타내며 이를 통해 제안된 모델의 근사화 및 일반화 능력이 매우 우수함을 알 수 있었다.

그림 9는 표 6에서 보여준 성능지수중에서 Division II, CASE II의 모델중에서 다항식 형태가 Type 4인 모델에 대

해서 학습데이터의 성능지수(PI=3.04e-5)와 평가용 데이터에 대한 성능지수(VPI=6.75e-5) 그리고 테스트 데이터의 성능지수(EPI=9.67e-5)의 세대별 최적화 과정을 보여준 것이다.




그림 8 모델의 출력과 원 출력과의 선형성
Fig. 8 Linearity of model output vs. original output




그림 9 PSO 알고리즘에 의한 성능지수의 수렴 과정
Fig. 9 Convergence process of performance index by the PSO algorithm

표 6 다른 모델링 방법과의 성능 비교(MG)
Table 6 Comparison of performance with other modeling methods(MG)

Model			Input	c	PI	VPI	EPI	
Regression Model	Division I	All	16	0.0891	-	0.0931		
	Division II			0.0891	0.0888	0.0993		
ANFIS[5]				0.0015	-	0.0016		
FNN[6]				0.0140	-	0.0090		
SONN[12]	Basic			0.0011	-	0.0011		
	Modified			0.0012	-	0.0011		
HFPNN[7]				3.3e-5	-	5.7e-5		
RBFNN	Division I	Type3	All	16	3.65e-4	-	6.67e-4	
	Division II	Type3			3.64e-4	6.44e-4	0.7e-4	
Proposed Model								
Division I	CASE I	Type3	All	16	0.0011	-	0.0101	
	CASE II	Type3			2.09e-6	-	4.43e-5	
Division I	CASE I	Type3	All	16	0.1793	0.2270	0.2380	
	CASE II	Type3			0.0230	0.0215	0.0522	

표 6은 Makey-Glass 시계열 데이터를 사용하여 성능 지수를 식 (11)에 의해 계산된 값으로 기존의 모델과 본 논문에서 제시한 모델과의 성능비교를 한 것이다. 표 6으로부터 제안된 모델은 기존의 모델들과 비교해서 학습 데이터에 대한 성능지수인 모델의 근사화 능력뿐만 아니라 평가용 데이터와 테스트용 데이터에 대한 성능지수 역시 뛰어난 것을 알 수 있다.

5.3 Machine Learning data

Machine Learning 데이터[11]인 가스 터빈 발전소의 NOx 배출공정 데이터[4]과 Automobile Miles per Gallon(MPG)

데이터 그리고 Boston Housing Data(BHD)를 이용하였다.

A. 가스 터빈 발전소의 NOx 배출 공정 데이터

표 7은 가스 터빈 발전소의 NOx 배출 공정 데이터를 사용하여 성능 지수를 식 (10)에 의해 계산된 값으로 기존의 모델과 본 논문에서 제안된 모델의 성능비교를 한 것이다.

표 7-(a)로부터 제안된 모델은 기존의 모델들과 비교해서 학습 데이터에 대한 성능지수인 모델의 근사화 능력뿐만 아니라 평가용 데이터와 테스트용 데이터에 대한 성능지수인 일반화 능력에 있어서도 뛰어난 것을 알 수 있다.

B. Automobile Miles Per Gallon (MPG) data

MPG 데이터는 전체 392개의 입력력 데이터 쌍으로 이루어져 있으며, 출력은 gallon당 mile로 표현되는 자동차 연료 소비이며 입력은 출력과 관련된 7가지 요소(Cylinders, Displacement, Horsepower, Weight, Acceleration, Model year, Origin)들로 구성되어 있다.

표 8은 MPG 데이터를 사용하여 성능 지수를 식 (11)에 의해 계산된 값으로 기존의 모델과 본 논문에서 제시한 퍼지 모델과의 성능비교를 한 것이다. 표에서도 알 수 있듯이 제안된 모델의 성능이 다른 지능형 모델들에 비해서 우수함을 알 수 있다.

C. Boston housing 데이터

Boston Housing Data (BHD)는 Carnegie Mellon University의 D. Harrison와 D. L. Rubinfeld이 1978년 개발하였고, 1993년에 이 데이터를 공식화하고 있다. 이 데이터는 보스턴 지역의 부동산의 정보와 관련이 있으며 총 506개의 입력력 데이터 쌍으로 13입력 1출력의 구조를 가지고 있다.

표 9는 Boston housing 데이터를 사용하여 성능 지수를 식 (11)에 의해 계산된 값으로 기존의 모델과 본 논문에서 제시한 퍼지 모델과의 성능비교를 한 것이다. 표 9로부터 제안된 모델은 기존의 모델들과 비교해서 학습 데이터에 대한 성능지수인 모델의 근사화 능력뿐만 아니라 평가용 데이터와 테스트용 데이터에 대한 성능지수 역시 뛰어난 것을 알 수 있다.

표 7 다른 모델링 방법과의 성능 비교
Table 7 Comparison of performance with other modeling methods

(a) NOX

Model			Input	c	PI	VPI	EPI
Regression Model	Division I	All	10	-	16.8620	-	19.6840
	Division II			-	17.1286	20.5429	18.7632
FNN[8]				30	3.725	-	5.291
Multi-FNN[9]				30	0.720	-	2.025
pRBFNN[11]	Type2	All	7	0.7039	-	3.7178	
	Type3			0.4626	-	2.7944	
IT2pRBFNN[11]	Type2	All	7	0.2269	-	0.7236	
	Type3			0.1377	-	0.4370	
RBFNN	Division I	Type2	All	10	0.0275	-	0.1180
	Division II	Type3			0.0245	10.7064	0.1429
Proposed Model							
Division I	CASE I	Type2	All	10	0.0050	-	0.1023
	CASE II	Type2	All	10	0.0027	-	0.0323
Division II	CASE I	Type3	1,2,4	4	0.0169	0.0332	0.0215
	CASE II	Type4	1,2,3,5	6	0.0066	0.0210	0.0202

(b) MPG

Model			Input	c	PI	VPI	EPI
Regression Model	Division I	All	-	3.2026	-	3.4855	
	Division II		-	3.3243	3.4408	3.1131	
ANFIS[12]	Type2	All	128	0.0851	-	541.323	
Linguistic Modeling[10]	Without optimization	All	36	3.78±1.52	-	4.22±1.22	
	One-loop optimization			2.90±0.32	-	3.17±1.01	
	Multistep optimization			2.86±0.83	-	3.14±0.98	
pRBFNN[12]	Type3	All	7	2.2331	-	2.3427	
IT2pRBFNN[12]	Type2	All	5	1.9761	-	2.7342	
RBFNN	Division I	All	4	2.3547	-	2.8550	
	Division II		4	2.5313	2.7230	2.8530	
Proposed Model							
Division I	CASE I	Type2	All	4	2.5265	-	2.4140
	CASE II	Type1	All	25	1.8976	-	3.0677
Division II	CASE I	Type2	1,3,4,6,7	30	2.1490	2.4409	2.4361
	CASE II	Type3	2,3,4,6,7	4	2.2090	2.5100	2.1495

(c) BHD

Model			Input	c	PI	VPI	EPI
Regression Model	Division I	All	-	4.4928	-	5.1089	
	Division II		-	4.7418	5.2129	3.9567	
RBFNN[10]			All	25	6.36±0.24	-	6.94±0.31
RBFNN with context-free clustering[10]			All	25	5.52±0.25	-	6.91±0.45
Linguistic modeling[10]	Without optimization	All	25	5.21±0.12	-	6.14±0.28	
	One-loop optimization			4.80±0.52	-	5.22±0.58	
	Multistep optimization			4.12±0.35	-	5.32±0.96	
RBFNN	Division I	Type2	All	4	3.7913	-	6.4228
	Division II	Type2	All	4	3.117861	4.494951	3.995009
Proposed Model							
Division I	CASE I	Type2	All	4	3.08737	-	4.10006
	CASE II	Type1	1,6,8,13	12	2.97935	-	4.52512
Division II	CASE I	Type2	1~11,13	4	2.7728	3.5761	3.9528
	CASE II	Type2	All	4	2.4204	2.7822	3.1231

6. 결 론

본 논문에서는 비선형 시스템의 효율적인 모델링을 위해 서 기존의 RBF 신경회로망에 K-Means 클러스터링 방법과 입자 군집 최적화 (Particle Swarm Optimization: PSO) 알고리즘을 이용한 데이터 중심 다항식 확장형 RBF 신경회로망의 구조를 설계하였다.

제안된 모델의 구축 방법 및 설계 목적은 다음과 같은 특징들을 가지고 있다. (a) K-means 클러스터링 방법을 이용한 활성화수의 중심값을 결정함으로써 주어진 데이터의 효율적인 처리를 도모하였다. (b) 복잡하고 비선형이 강한 데이터를 효율적으로 모델 구축에 반영하고자 다항식 형태의 연결가중치를 적용함으로써 데이터의 비선형적인 특성을 모델에 충분히 반영하도록 하였다. (c) 모델의 성능 개선에 주요한 역할을 하는 파라미터들을 PSO 알고리즘을 이용하여 모델의 구축을 최적화 하였으며, 특히 활성화수의 분포상수 값 결정에 있어 CASE I(은닉층을 구성하고 있는 각 노드별로 서로 다른 분포상수 값 설정)과 CASE II(은닉층을 구성하고 있는 각 노드별로 선택된 입력변수들에 따라 서로 다른 분포상수 값 설정)로 나누어 선택되어진 입력변수들의 각각의 특성을 좀 더 세밀하고 효율적으로 모델의 구축에

반영하였다. (d) 객관적인 모델 평가를 위해 Division I(학습 데이터, 테스트 데이터)과 Division II(학습데이터, 평가데이터, 테스트데이터)로 나누어 제안된 모델에 대한 근사화와 일반화 능력을 좀 더 세밀하고 효율적으로 평가 하였다.

실험적 예제의 비교 결과에서도 알 수 있듯이 표준적인 지능형 모델 및 이전에 연구되어진 지능형 구조에서 얻어진 결과보다 본 논문에서 제안한 알고리즘에서의 근사화 및 일반화 능력이 우수함을 알 수 있었으며, 특히, 모델 구축에 주요한 영향을 미치는 입력변수, 다양한 클러스터 수 및 활성화수에서의 효율적인 분포상수 값 사용에 대한 효과적인 메카니즘은 모델의 구축에 있어서 효과적인 설계 매체라고 간주되어짐을 알 수 있었다.

감사의 글

본 연구는 2009년도 지식경제부의 재원으로 한국에너지 기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다 (2009T100100563) 그리고 그리고 2010년도 정부(과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2010- D00065).

참 고 문 헌

- [1] T. Tagaki and M. sugeno, "Fuzzy identification of system and its applications to modeling and control", IEEE Trans. Syst. Cybern., Vol. 15, No. 1, pp. 116-132, 1985.
- [2] H. Nomura, I. Hayashi, and N. Wakami, "A self-tuning method of fuzzy reasoning by method of the steepest descent and its application to moving obstacle avoidance", 6th Fuzzy System Symposium, Tokyo, pp. 423-426, 1990.
- [3] M. C. Mackey and L. Glass, "Oscillation and chaos in physiological control system", Science, New Series, Vol. 197, pp. 287-289, 1977.
- [4] G. Vachtsevanos, V. Ramani, and T. W. Hwang, "Prediction of gas turbine NOx emissions using polynomial neural network", Technical Report, Georgia Institute of Technology, Atlanta, 1995.
- [5] J. S. R. Jang, "ANFIS: Adaptive-network-based fuzzy inference systems", IEEE Trans. on Systems, Man, and Cybernetics, Vol. 23, pp. 665-685, 1993.
- [6] L. P. Maguire, B. Roche, T. M. McGinnity, and L. J. McDaid, "Predicting a chaotic time series using a fuzzy neural network", Information Sciences, Vol. 112, pp. 125-136, 1998.
- [7] S. K. Oh, W. Pedrycz, and D. W. Kim, "Hybrid fuzzy polynomial neural networks", Int. J. of Uncertainty, Fuzziness and Knowledge-Based Systems, Vol. 10, No. 3, pp. 257-280, 2002.
- [8] S. K. Oh, W. Pedrycz, and H. S. Park, "Hybrid identification in fuzzy-neural networks", Fuzzy Sets

Syst., Vol. 138, No. 2, pp. 399-426, 2003.

[9] S. K. Oh, W. Pedrycz, and H. S. Park, "Rule-based multy-FNN identification with the aid of evolutionary fuzzy granulation", J. Knowledge-Based Syst., Vol. 17, No. 1, pp. 1-13, 2004.

[10] W. Pedrycz and K. C. Kwak, "Linguistic models as a framework of user-centric system modeling", IEEE Transactions on SMC-Part A, Vol. 36, No. 4, pp. 727-745, 2006.

[11] <http://archive.ics.uci.edu/ml/datasets/>

[12] 백진열, "Type-2 퍼지추론 기반의 다항식 RBF 뉴럴 네트워크에 관한 연구", 수원대학교 공과대학 전기공학과 석사학위논문, 2008.

저 자 소 개



오 성 권 (吳 聖 權)

1981년 연세대학교 전기공학과 졸업, 동 대학원 석사(1983), 박사(1993). 1983-1989년 금성산전연구소(선임연구원). 1996-1997년 캐나다 Manitoba 대학 전기 및 컴퓨터공학과 Post-Doc. 1993-2004년 원

광대학교 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 영 훈 (金 榮 勳)

2009년 수원대학교 전기공학과 졸업. 2009~현재 동 대학원 석사과정.

관심분야는 퍼지추론시스템, 신경 회로망, 퍼지-신경 회로망, 진화론적 최적화 알고리즘, Granular computing, Neuro-fuzzy computing, Evolutionary

computing등의 Computational Intelligence 등.
 Tel : 031-222-6544
 Fax : 031-220-2667
 E-mail : yhkim82@suwon.ac.kr



박 호 성 (朴 浩 成)

1999년 원광대학교 제어계측공학과 졸업. 동 대학원 석사(2001), 박사(2005). 2005-2006년 원광대학교 전기전자 및 정보공학부 전임강사, 2006-2007년 캐나다 Alberta 대학 전기 및 컴퓨터공학과 Post-Doc. 2008~현재 수원대학교 산업 기술연구소 학술연구교수. 관심분야는 퍼지추론시스템, 신경 회로망, 퍼지-신경 회로망, 진화론적 최적화 알고리즘, Granular computing, Neuro-fuzzy computing, Evolutionary computing등의 Computational Intelligence 등.

Tel : 031-222-6544
 Fax : 031-220-2667
 E-mail : parkhs@suwon.ac.kr



金 正 泰 (Jeong-Tae Kim)

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