

A new Design of Granular-oriented Self-organizing Polynomial Neural Networks

오 성 권[†] · 박 호 성^{*}
 (Sung-Kwun Oh · Ho-Sung Park)

Abstract - In this study, we introduce a new design methodology of a granular-oriented self-organizing polynomial neural networks (GoSOPNNs) that is based on multi-layer perceptron with Context-based Polynomial Neurons (CPNs) or Polynomial Neurons (PNs). In contrast to the typical architectures encountered in polynomial neural networks (PNN), our main objective is to develop a methodological design strategy of GoSOPNNs as follows : (a) The 1st layer of the proposed network consists of Context-based Polynomial Neuron (CPN). In here, CPN is fully reflective of the structure encountered in numeric data which are granulated with the aid of Context-based Fuzzy C-Means (C-FCM) clustering method. The context-based clustering supporting the design of information granules is completed in the space of the input data while the build of the clusters is guided by a collection of some predefined fuzzy sets (so-called contexts) defined in the output space. (b) The proposed design procedure being applied at each layer of GoSOPNN leads to the selection of preferred nodes of the network (CPNs or PNs) whose local characteristics (such as the number of contexts, the number of clusters, a collection of the specific subset of input variables, and the order of the polynomial) can be easily adjusted. These options contribute to the flexibility as well as simplicity and compactness of the resulting architecture of the network. For the evaluation of performance of the proposed GoSOPNN network, we describe a detailed characteristic of the proposed model using a well-known learning machine data(Automobile Miles Per Gallon Data, Boston Housing Data, Medical Image System Data).

Key Words : Granular-oriented self-organizing polynomial neural networks, Context-based polynomial neuron, Polynomial neuron, Context-based fuzzy C-means clustering method, Information granule, Learning machine data

1. 서 론

고전적 인공지능(traditional artificial intelligence) 방법들은 추상적 심볼들을 이용한 로직에 기초하여 계획 및 추론 등의 지능을 구현하고자 하였지만 이 방법들은 너무 많은 사실들을 로직으로 표현해 주어야하는 어려움이 있다. 또한 동적이고 불확실한 실제 환경에 적용하기에는 어려움이 있어서 제한된 분야에서만 활용이 되고 있다. 이에 대한 대안으로 계산 지능(Computational Intelligence: CI)가 제안되었으며, 실세계의 여러 가지 불확실성을 표현할 수 있는 수단으로서 활용되고 있다. 또한 CI의 합성을 통한 지능형 시스템의 점진적인 성장을 통한 진보된 시스템의 성능이 시스템의 복잡성이 큰 문제를 분석하는데 있어서 독립적인 지능형 시스템보다 우수한 성능을 가짐으로써 더 활발히 진행되어져 오고 있는 실정이다[1-5].

본 논문에서는 이러한 CI 기술들의 합성 즉, 다항식 신경 회

로망(Polynomial Neural Network: PNN)[6,7]와 Context-based Fuzzy C-Means (FCM) 클러스터링[8-13]의 결합을 통하여 새로운 형태의 입자화 중심 자기구성 다항식 신경회로망을 제안하고 이를 기반으로 시스템이 복잡하고 대규모의 구조를 가지는 비선형 실 시스템의 동적 분석을 표현하고자 한다.

복잡한 비선형 시스템을 표현하는데 있어서 한계, 그리고 효율적인 모델을 구축하기가 어렵다는 단점을 가지고 있는 Group Method of Data Handling(GMDH)[14]의 단점을 극복하고자 Oh et al.에 의해서 제안된 다항식 신경 회로망(Polynomial Neural Network: PNN)[6,7]은 전방향 뉴럴 네트워크의 구조와 비슷하며 단지 신경 회로망의 뉴런이 다항식 노드(Polynomial Neuron: PN)들에 의해서 대체되는 구조일 뿐 일반적인 신경 회로망과 같이 오류 역전파 알고리즘은 사용하지 않는다. 또한 GMDH의 2입력 2차 다항식에서 벗어나 다변수 다차식의 확장된 부분표현식을 이용하여 연속적인 층과 노드를 생성함으로써 최적의 구조를 얻는 알고리즘으로 기존의 신경망 알고리즘보다 더 적은 노드수와 유연한 적응특성을 가지고 있다[6,7]. 또한 제안된 GoSOPNN의 개발에 있어서, 제안된 GoSOPNN 네트워크의 구조의 1층에서는 정보 입자화의 도구로써 실현된 context-based fuzzy C-means(C-FCM) 클러스터링[8-13]을 이용하여 효율적으

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

* 정 회 원 : 수원대 산업기술연구소 학술연구교수
 접수일자 : 2011년 1월 17일
 최종완료 : 2011년 8월 16일

로 데이터를 처리하였다. 여기서, C-FCM 클러스터링 방법은 입력 공간(입력 변수)에서의 데이터 구조가 출력 공간에서 미리 정의된 몇 개의 언어적인 경계값을 기반으로 조건화 된다.

본 논문에서는 주어진 데이터의 특성인 정보 입자화의 효율적인 처리를 위한 context-based Fuzzy C-Means(C-FCM) 클러스터링 방법과 대규모 복잡한 구조를 가지고 있는 비선형 실 시스템의 동적 분석 표현을 위한 자기구성 다항식 신경 회로망을 결합한 입자화 중심 자기구성 다항식 신경 회로망(Granular-oriented Self-Organizing Polynomial Neural Networks: GoSOPNN)에 대한 새로운 구조와 설계 방법론을 제안한다.

본 논문에서는 제안된 모델의 장점과 한계를 정량화하기 위하여 기존의 모델의 성능 평가에 benchmarking되고 있는 Machine learning 데이터 집합[16]을 실험적 데이터로 이용하여 구조적 개발의 다양성을 입증하고 모델의 성능을 확인하였다.

2. 입자화 중심 자기구성 신경 회로망의 구조 및 형태

본 장에서는 입자화 중심 자기구성 다항식 신경 회로망(Granular-oriented Self-Organizing Neural Network: GoSOPNN)의 기본 처리 유니트로서 Context-based 다항식 뉴런(Context-based Polynomial Neuron: CPN)과 다항식 뉴런(Polynomial Neuron: PN)을 소개하고, 이를 바탕으로 구성된 입자화 중심 자기구성 다항식 신경 회로망(GoSOPNN)의 구조에 대해서 설명한다. GoSOPNN은 그림 1에서 보여진 것과 같이 기존의 다항식 신경 회로망(Polynomial Neural Network: PNN)[6,7] 구조를 기반으로 하고 있으며, 기존의 PNN과의 차이점은 1층에서의 구조가 주어진 데이터의 효율적인 처리를 위해 Context-based Fuzzy C-Means 클러스터링 방법(C-FCM)[8-13]을 이용한 CPN으로 구성되어 있어서 기존의 PNN 모델에 비해서 데이터의 특성 즉, 데이터 각각의 입자화를 중심으로 모델을 설계하는 것에 있다.

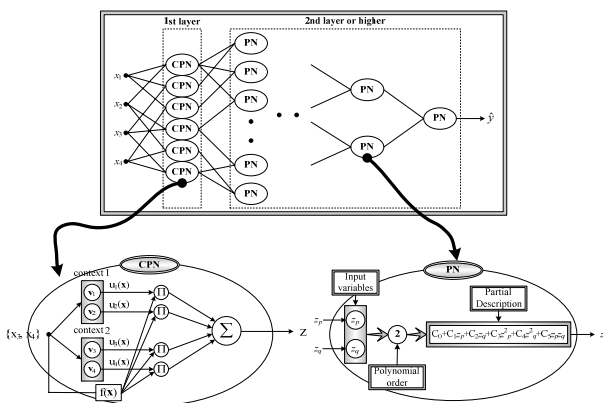


그림 1 입자화 중심 자기구성 다항식 신경 회로망의 구조
 Fig. 1 Architecture of the Granular-oriented Self-Organizing Polynomial Neural Networks

2.1 Context-based 다항식 뉴런(Context-based polynomial Neuron:CPN)

이 절에서 소개될 CPN은 그림 1에서 보이듯이 GoSOPNN의 1층 구조에서 사용된 처리 단위의 일반적인 형태로써, 본 절에서는 CPN의 주요한 구조적 특징과 주어진 데이터의 특성을 파악하는데 주요한 역할을 하는 입자화 중심 데이터 처리 기법인 context-based FCM 클러스터링 방법에 대해서 살펴본다.

2.1.1 입자화 중심 데이터 처리 기법

본 논문에서 제안한 GoSOPNN의 1층에서 사용된 CPN의 주요한 역할인 입자화 중심의 데이터 처리 방법을 위해 사용된 주요 설계 전략은 이용 가능한 데이터들을 위한 네트워크의 형태들의 명시적인 연결과 C-FCM에 의해서 획득된 정보 입자화들의 사용을 이용하는 것이다. 즉, 정보 입자화를 구축하기 위해서 클러스터링을 사용하는 것이다. 본 논문에서는 2개의 클러스터링 기법이 사용된다. 먼저 Fuzzy C-Means(FCM) 클러스터링을 이용하여 출력 공간에서의 구조를 결정한 후, 출력공간에서 이미 구축된 클러스터에 직접적으로 관련되어 형성된 정보 입자화들의 결과를 통해서 입력 공간은 context-based Fuzzy C-means 클러스터링을 이용한다.

A. Fuzzy C-Means 클러스터링 방법을 통한 출력공간의 입자화

클러스터링 알고리즘이란 데이터의 분류를 위해서 사용되는 것으로 데이터의 내부가 비슷한 패턴, 속성, 형태 등의 기준을 통해 데이터를 분류하여 내부의 구조를 찾아내는 방법으로, machine learning, data mining, pattern recognition, 그리고 image analysis와 같은 분야에 널리 사용되어지고 있다.

FCM 클러스터링 방법은 일반적으로 클러스터링 방법 중의 하나로써 데이터 전처리에 넓게 사용되어지고 있으며, 주어진 데이터의 특징을 해석하여 파악된 데이터의 정보를 기반으로 입력 데이터를 분할함으로써 기존의 데이터 전처리 방법들보다 더 효율적이고 유기적으로 주어진 데이터의 특성을 파악하는 장점을 가지고 있다[15].

본 논문에서는 FCM 클러스터링 방법을 이용하여 출력 데이터인 $\{target_k\}$ 를 P개로 분류하고 주어진 출력 데이터를 처리한다. 여기서 사용된 'P'를 'context'라 정의한다.

T라 표시되는 partition matrix를 구하기 위한 FCM 클러스터링 방법을 이용한다.

B. Context-based Fuzzy C-means Clustering을 통한 입력공간의 입자화

Context-based FCM 클러스터링은 출력공간에서 미리 정의된 몇 개의 context라 불리는 퍼지 집합의 분류들을 기준으로 입력 데이터에서의 공간을 정보 입자화의 특성에 맞게 분류하는 알고리즘이다[8-13]. 이와 같이 context를 고려함

으로써, 입력공간에서의 클러스터는 몇 개의 미리 정의된 context의 퍼지 집합에 의해서 분류되어져 간다. 이는 입력공간과 출력공간 영역에서 사이의 관계를 드러나게 함으로써, 기존의 입력만을 고려한 클러스터링 방법에서 벗어나 입력과 출력을 동시에 고려한 특징을 가지고 있다. 본 논문에서는 “A. Fuzzy C-Means 클러스터링 방법을 통한 출력공간의 입자화”에서 서술한 것과 같이 출력 공간에서의 퍼지 집합을 분류하기 위해서 FCM 클러스터링 방법을 이용한다.

Context-based FCM 클러스터링 방법으로 입력 데이터 $\{x_k\}$ 를 ‘c’개의 클러스터로 분할한다. $U(T_j)$ 라 표시되는 j-번째 context에 의해서 유도되는 partition matrix를 구하기 위한 context-based FCM 클러스터링 알고리즘을 사용한다.

2.1.2 Context-based Polynomial Neuron 구조

제안된 CPN의 네트워크는 context-based FCM 클러스터링 방법의 개념을 기반으로 하고 있으며 선택된 입력 변수들에 대해서 형성된 퍼지 분할의 형태는 그림 2에서 보여준 것과 같은 형태를 이루고 있다. 그림 2에서 보여준 구조는 전체 4개의 입력 변수들 중에서 2개의 입력 변수들(x_3, x_4)이 선택된 구조이며, context의 수가 2개이고 각 context당 2개의 클러스터로 이루어진 구조이다.

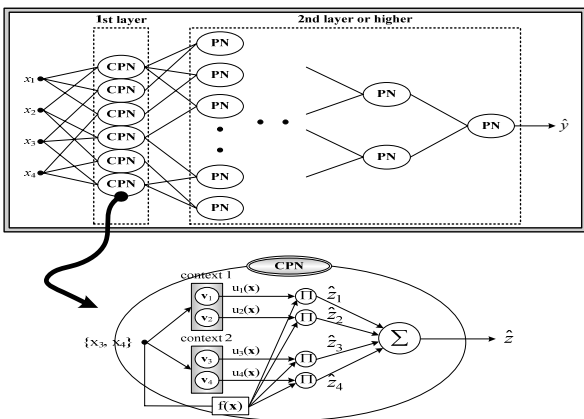


그림 2 CPN 기반 GoSOPNN의 일반적인 구조
Fig. 2 A general architecture of the CPN based GoSOPNN

제안된 CPN의 네트워크는 퍼지 규칙 기반 시스템의 형태로써, 후반부 다항식이 선형식을 사용하면 제안된 구조는 다음과 같은 규칙의 형태로 표현 할 수 있다.

$$R^i: \text{If } \mathbf{x} \text{ is "P - th context" and "c - th cluster" then } \hat{z}_i = \mathbf{a}_0^T + \mathbf{a}_1^T \mathbf{x}^i \quad (1)$$

여기서, \hat{z}_i 는 i번째 지역 모델 ($i=1, 2, \dots, Pc$), \mathbf{x}^i 는 P번째 context에 해당되는 선택된 입력 집합, 그리고 R^i 는 i번째 규칙을 의미한다.

그림 2에서 표현된 모든 규칙을 고려한다면, CPN 전체 네트워크 구조는 다음과 같이 표현된다.

$$\hat{z}(\mathbf{x}) = \sum_{i=1}^c u_i(\mathbf{x}) [\mathbf{a}_0^T + \mathbf{a}_1^T \mathbf{x}^i] + \sum_{i=c+1}^{2c} u_i(\mathbf{x}) [\mathbf{a}_0^T + \mathbf{a}_1^T \mathbf{x}^2] + \dots + \sum_{i=(P-1)c+1}^{P \times c} u_i(\mathbf{x}) [\mathbf{a}_0^T + \mathbf{a}_1^T \mathbf{x}^P] \quad (2)$$

제안된 CPN의 성능 지수식은 식 (3)에서와 같이 Root Mean Square Error (RMSE)을 사용하였다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (\text{target}_k - \hat{z}_k)^2} \quad (3)$$

여기서, target_k 는 k번째 원 출력 데이터이고 \hat{z}_k 는 k번째 모델의 출력 데이터를 나타낸다. 또한 각각의 지역 모델의 계수는 최소자승법(LSE)을 사용하였다.

그림 1과 그림 2에서 알 수 있듯이, 식 (2)에서 구해진 $\hat{z}(\mathbf{x})$ 는 현재 층에서의 CPN 노드의 출력인과 동시에 다음 층에서 PN의 입력과 같은 역할을 한다.

2.2 다항식 뉴런 (Polynomial Neuron : PN)

다항식 뉴런은 그림 3에서 볼 수 있듯이, 제안된 GoSOPNN의 전체 구조에서 2층 이상부터 층을 구성하는데 있어서 기본이 되는 유닛으로 선택되어진 입력들이 들어오면 다항식 구조 중에 하나를 선택하여 다항식을 이루게 되는 구조를 가진다[6,7].

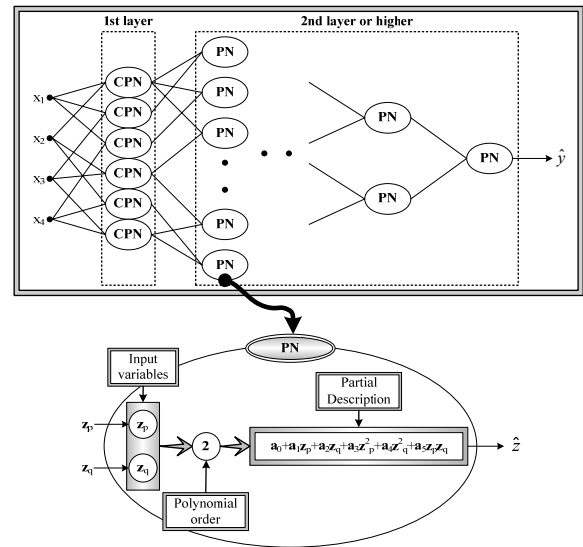


그림 3 PN 기반 GoSOPNN의 일반적인 구조
Fig. 3 A general architecture of the PN based GoSOPNN

그림 3은 기본적인 PN의 역할을 나타낸 것으로, 전 층의 각 CPN의 출력을 입력으로 하여 선택된 입력으로 2입력(z_p, z_q) 그리고 후반부 다항식 차수가 2차식인 형태가 선택되어진 구조로써, 다양한 후반부 다항식 형태를 구성하게 된다. 그림 3과 다항식 차수의 계수(a_i)의 최적화는 CPN에서와 마찬가지로 식 (3)이 최소가 될 수 있도록 최소자승법을 이용하여 실행하였다.

그림 1 ~ 그림 3에서 알 수 있듯이, 제안된 GoSOPNN 구조는 몇 개의 층이 생성되어가면서 모델을 형성해가는 구조이다.

3. 입자화 중심 자기구성 다항식 신경 회로망 설계

본 장에서는 주어진 데이터의 특성인 정보 입자화의 효율적인 처리를 위한 FCM 및 C-FCM 클러스터링 방법과 기존의 PNN을 이용한 입자화 중심 자기구성 다항식 신경 회로망의 설계 절차에 대해서 나타낸다. 기존의 다항식 신경 회로망[6,7]은 효율적인 데이터의 처리보다는 GMDH 방법의 개선된 방향으로 모델을 구축하였으나, 본 논문에서는 FCM 및 C-FCM 클러스터링 방법을 적용한 새로운 개념의 다항식 신경 회로망을 구축 하고자 한다. 입자화 중심 자기구성 다항식 신경 회로망의 설계 방법은 다음과 같다.

[단계 1] 시스템 입력변수의 결정

출력변수 y 에 관계하는 n 개의 시스템 입력변수를 결정한다. 필요하면 데이터를 정규화한다. 이 시스템 입력변수를 x_1, x_2, \dots, x_n 이라 한다.

[단계 2] 데이터 분할

N 개의 입출력 데이터 $(x_i, y_i)=(x_{1i}, x_{2i}, \dots, x_{ni}, y_i), i=1, 2, \dots, N$ 을 효율적인 모델링을 위해서 전체 데이터를 학습용 데이터(N_{PI})와 테스트용 데이터(N_{EPI})로 분할한다. 학습용 데이터는 모델을 동정하기 위해 사용하는 데이터이고, 테스트용 데이터는 모델을 테스트하기 위해 사용하는 데이터이다. 여기서, $N=N_{PI}+N_{EPI}$ 이다.

[단계 3] GoSOPNN 구조 정보 결정

GoSOPNN 구조를 구축하는 있어서 기본적인 정보를 결정한다.

표 1 GoSOPNN 구축을 위한 기본 정보

Table 1 Basic information for architecture of GoSOPNN

Index	Item	Criterion
GoSOPNN	종료조건 선택	최적 노드의 적합도
		값 비교
		최대 층 수 결정(3층)
	노드에 입력될 최대 입력변수의 수(SI) 결정	2 ~ 4
	하나의 층에서 생성될 노드의 수 결정(W)	30
CPN	Context의 수(P) 결정	2 ~ 5
	Cluster의 수(c) 결정	2 ~ 5
	다항식 차수 결정	L
PN	다항식 차수 결정	L, Q, M

[단계 4] GoSOPNN 구조 선택

[단계 3]에서 주어진 표 2를 기반으로, n 개의 입력변수 x_1, x_2, \dots, x_n 중 노드의 입력변수 수, 1층을 구성하고 있는 CPN의 context와 cluster의 수를 선택하고 CPN과 PN에서의 입력에 대한 노드의 다항식 차수를 선택한다. r 개의 변수 선택 시 노드의 개수 k 는 $\frac{n!}{(n-r)!r!}$ 가 된다. 여기서 n 은 전체 입력변수의 수이고, r 은 선택된 입력변수의 수 즉, 노드의 입력변수 수이다. 예를 들어 GoSOPNN 각 노드의 부분 표현식을 살펴보면, CPN의 경우는 식 (2)와 같이 표현할 수

있고 PN의 경우 2입력 2차식이라 하면 그림 3에서 보이듯이 다음과 같은 부분표현식 k 개를 얻을 수 있다.

$$\hat{z}_k = a_0 + a_1 x_p + a_2 x_q + a_3 x_p^2 + a_4 x_q^2 + a_5 x_p x_q \quad (4)$$

$, k=1, 2, \dots, \frac{n!}{(n-2)!2!}$

표 1에서 보여준 GoSOPNN 구조를 구축하기 위한 기본적인 파라미터의 선택은 시스템의 특성, 모델 설계방법, 비선형성 및 예측성능 등을 고려함으로써 제기된 문제에 대해 적절한 구조를 결정하는데 도움을 준다.

[단계 5] 매개변수 추정

본 단계에서는 [단계 2]에서 분할된 학습 데이터를 이용하여 모델의 구축에 필요한 계수 즉, 식 (2)와 식 (4)에서 사용된 계수들을 성능지수식은 식 (3)이 최소가 될 수 있도록 최소자승법 (standard Least Squared Estimation)을 이용하여 구한다. 최소자승법에 의한 계수 동정은 식 (5)와 같다.

$$A = (X^T X)^{-1} X^T Y \quad (5)$$

[단계 6] 모델의 구축과 테스트 그리고 노드의 선택

식 (5)에 의해서 추정된 식 (4)의 계수 a_0, a_1, \dots, a_5 을 이용한 부분표현식에 테스트 데이터를 대입하고, 테스트 데이터에 대한 오차 EPI를 계산한다. 얻어진 $EPI_1, EPI_2, \dots, EPI_{n!/(n-r)!r!}$ 에 대해서 값이 작은 노드를 다음 층의 입력변수로 선택한다. 이때 노드 선택은 $EPI_1, EPI_2, \dots, EPI_{n!/(n-r)!r!}$ 에 대하여, 값이 작은 순으로 나란히 정렬하여 이들 중 값이 작은 순으로 다시 W 개를 선택하고, W 개를 제외한 나머지 값들은 버린다.

[단계 7] 종료판정

[단계 6]의 현재 층에서 얻어진 최적 노드의 에러 값 F_1 이 다음 부등식을 만족하는 경우에 알고리즘을 종료한다.

$$F_1 \leq F^* \quad (6)$$

단, F^* 는 이전 층의 최적 노드인 에러 값이다.

그러나 위와 같은 종료판정은 네트워크 생성 중에 최대 층수가 과대하게 발생할 우려가 있으며 그럴 경우 프로그램 실행 시 많은 시간과 계산량을 요구하게 된다. 또한 현재 층의 동정오차가 이전 층의 동정오차보다 크더라도 그 다음 연속 층에서의 동정오차가 이전 층들의 동정오차보다 더 적은 값이 나올 수 있는데도 프로그램을 종료시키는 단점이 있다. 이와 같은 단점을 보완하기 위해 알고리즘의 판정을 위의 경우와 병행하여 전체 층의 수를 최대 3층으로 제한하여 네트워크의 복잡성과 우수성의 상호 균형을 고려하여 알고리즘을 종료한다.

[단계 8] 다음 층의 새로운 입력변수 설정

현재 층에서 보존된 노드의 출력들($z_{1i}, z_{2i}, \dots, z_{wi}$)에서 다음 층의 새로운 입력들($x_{1j}, x_{2j}, \dots, x_{wj}$)로, $x_{1j}=z_{1i}, x_{2j}=z_{2i}$,

..., $x_{wj}=z_{wi}$ 으로 구성하고, [단계 4]으로 간다(여기서, $j=i+1$). 이 후, [단계 4]부터 [단계 7]까지를 반복한다. 알고리즘이 종료할 경우, 마지막 층의 최적 적합도 값 F_c 을 얻은 노드의 다항식에 입력이 되는 전 층의 출력을 대입하고 동일한 작업을 제 1층까지 반복하여 최종 추정 모델 \hat{y} 을 얻는다.

4. 시뮬레이션 및 결과 고찰

본 논문에서 제안된 네트워크 구조는 Machine Learning repository로부터 구한 Machine Learning data(-Automobile Miles Per Gallon data, Boston Housing Data, Medical Imaging System data) 집합[16]을 통해서 모델의 특징과 성능에 대해서 알아본다. 모든 실험들은 발생된 결과들의 타당성으로써 좀 더 높은 객관성을 제공하기 위해 10-fold cross validation 모드를 실행하였다. 또한 데이터 분할에 있어서 전체 데이터를 랜덤하게 학습 데이터(60%)와 테스트 데이터(40%)로 나누어 모델의 성능을 평가하였다.

4.1 Automobile Miles Per Gallon(MPG) 데이터

본 논문의 성능을 평가하기 위한 첫 번째 데이터로써 Machine Learning data로써 일반적으로 지능형 모델링에 있어서 벤치마킹되고 있는 MPG 데이터를 이용하여 제안된 모델의 성능을 평가하였다. MPG 데이터는 전체 392개의 입력 출력 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. 모델의 성능지수는 식 (3)과 같이 RMSE를 사용하여 모델을 평가하였다.

표 2 MPG 데이터에 대한 GoSOPNN 모델의 성능지수
Table 2 Performance index of GoSOPNN for the MPG data

No. of selected input variables	No. of clusters (c)	No. of contexts (P)					
		2			5		
		Type	PI	EPI	Type	PI	EPI
2	2	Q	2.3735 ±0.1776	2.4459 ±0.2961	Q	1.0454 ±0.1774	1.4029 ±0.2346
	3	Q	2.1994 ±0.1597	2.5793 ±0.1489	L	1.0223 ±0.1453	1.4853 ±0.2269
	4	M	2.2801 ±0.1450	2.4598 ±0.3220	Q	0.9102 ±0.0930	1.7650 ±0.2859
	5	L	2.0699 ±0.1548	2.6373 ±0.3842	L	0.8603 ±0.1570	1.7880 ±0.3311
3	2	Q	2.0976 ±0.1978	2.1922 ±0.2684	Q	0.9411 ±0.1358	1.1806 ±0.2338
	3	M	2.0879 ±0.1593	2.2048 ±0.1855	Q	0.8777 ±0.1677	1.2271 ±0.2322
	4	Q	1.9054 ±0.1903	2.2922 ±0.2725	Q	0.7284 ±0.0990	1.4591 ±0.3160
	5	Q	1.8914 ±0.1239	2.3196 ±0.1449	M	0.5809 ±0.1000	1.8754 ±0.5754
4	2	Q	2.0324 ±0.1448	2.1188 ±0.1191	Q	0.9547 ±0.1170	1.1270 ±0.1634
	3	Q	1.8432 ±0.1380	2.3727 ±0.2565	M	0.8118 ±0.1418	1.7360 ±0.8227
	4	M	1.8826 ±0.0754	2.2298 ±0.1262	L	0.6132 ±0.0748	2.0297 ±0.5553
	5	M	1.7540 ±0.1290	2.2967 ±0.2812	M	0.4898 ±0.0542	2.8165 ±0.9727

표 2은 표 1에서 주어진 정보를 기반으로 MPG 데이터에 대한 모델의 성능을 나타낸 것으로, 전체 392개의 데이터를 학습 데이터 235개(60%)와 테스트 데이터 157개(40%)로 랜덤하게 분할하여 실시하였다.

각각 선택된 입력변수들의 수에 따라서 3가지의 후반부 다항식 즉, 선형(L), 2차식(Q), 그리고 변형된 2차식(M) 중 가장 우수한 성능을 가지는 모델들의 성능만을 나타낸 것이다. 표 2에서 보여준 성능들은 모두 모델의 구조에서 3층에서 얻은 결과들이다.

표 2에서도 알 수 있듯이, MPG 데이터를 이용한 제안된 모델의 성능은 모든 선택된 입력변수들에서 context의 수가 5개일 때 가장 좋은 성능을 가짐을 알 수 있으며, 또한 각각의 context에 해당되는 클러스터의 수가 적을수록 성능이 개선됨을 알 수 있다. 이는 제안된 모델의 1층을 구성하고 있는 CPN의 구조가 복잡한 것 보다는 간단한 형태일 때 성능이 개선됨을 유추할 수 있다.

선택된 입력변수의 수가 2입력일 경우엔, context의 수가 5개, 각각의 context에 해당되는 클러스터의 수가 2개, 그리고 다항식 형태가 2차식을 사용하였을 때 성능(PI=1.0454±0.1774, EPI=1.4029±0.2346)이 가장 우수하였으며, 이 중 가장 좋은 성능은 PI=0.8035, EPI=1.0459임을 알 수 있다.

3입력의 선택된 입력인 경우엔, 다른 선택된 모델들에 비해서 모델의 근사화 능력(학습 데이터 성능)과 일반화 능력(테스트 데이터 성능)을 상호 고려하였을 때 가장 우수함을 알 수 있었으며, context의 수가 5개, 각각의 context에 해당되는 클러스터의 수가 3개, 그리고 다항식 형태가 변형된 2차식에서 다른 구조에 비해서 우수한 성능을 가졌으며, 그 중에서 가장 효율적인 모델일 때의 성능은 PI=0.6972, EPI=0.9462를 나타냄을 알 수 있다.

선택된 입력변수의 수가 4입력인 경우엔, context의 수가 5개, 클러스터의 수가 2개이고 후반부 다항식의 형태는 변형된 2차식일 때 모델의 성능(PI=0.9547±0.1170, EPI=1.1270±0.1634)이 우수하였으며, 그 중 가장 우수한 모델은 PI=0.7895, EPI=0.9991의 성능을 보여준다.

그림 4는 표 2에서 보여준 성능지수중, 가장 우수한 성능(PI=0.7895, EPI=0.9991)을 가지는 모델의 원 출력과 모델 출력과의 선형성을 나타낸 것이다. 이때 선택된 입력은 4입력이고 context의 수는 5개, 각각의 context에 할당된 클러스터의 수는 2개 그리고 다항식으로 변형된 2차식이 사용되었다. 그림에서도 알 수 있듯이 학습 데이터에 대한 성능 즉, 모델의 근사화 능력이 일반화 능력(테스트 데이터에 대한 성능) 보다 선형성이 뚜렷함을 알 수 있다.

그림 5은 그림 4에서 보여준 모델(PI=0.7895, EPI=0.9991)의 네트워크를 보여준 것이다.

표 3는 MPG 데이터를 사용하여 성능 지수를 식 (3)에 의해 계산된 값으로 동일한 실험적 예제를 사용한 기존의 모델과 본 논문에서 제시한 방사형 기저 함수 기반 다항식 신경 회로망 모델과의 성능비교를 한 것이다. 기존의 지능형 모델들에 비해서 제안한 모델의 근사화 및 일반화 능력이 우수함을 알 수 있다.




그림 4 원 출력과 모델 출력의 비교(PI=0.7895, EPI=0.9991, SI=4, P=5, c=2)

Fig. 4 Scatter plots showing model output versus original output(PI=0.7895, EPI=0.9991, SI=4, P=5, c=2)




그림 5 입자화 중심 자기구성 다항식 신경 회로망 구조 (SI=4, PI=0.7895, EPI=0.9991, P=5, c=2)

Fig. 5 GoSOPNNNN architecture (SI=4, PI=0.7895, EPI=0.9991, P=5, c=2)

표 3 기존의 모델들과의 성능 비교

Table 3 Comparative analysis of the performance of various models

Model	PI	EPI	Index	
RBFNN[10]	3.24±0.24	3.62±0.31	RMSE	
RBFNN with context-free clustering[10]	3.21±0.21	3.51±0.27		
Linguistic Modeling[10]	Without optimization	3.78±1.52		4.22±1.22
	One-loop optimization	2.90±0.32		3.17±1.01
Incremental model[11]	Multi-step optimization	2.86±0.83	3.14±0.98	RMSE
	Linear regression	3.383±0.194	3.472±0.295	
	Polynomial (2 nd order)	2.807±0.122	2.972±0.196	
Functional RBFNN[12]	Incremental model	2.390±0.142	3.060±0.285	MSE
	m=2.0	2.905±0.441	12.024±1.897	
	m=2.05	2.369±0.339	13.841±1.452	
HFSPNN[7] (3 rd layer)	m=2.75	5.804±0.394	7.936±1.100	RMSE
	Triangular MF	1.962±0.214	2.396±0.180	
Proposed Model (3 rd layer)	Gaussian MF	1.886±0.133	2.479±0.192	RMSE
	SI = 2	1.045±0.177	1.402±0.234	
Proposed Model (3 rd layer)	SI = 3	0.877±0.167	1.227±0.232	RMSE
	SI = 4	0.954±0.117	1.127±0.163	

4.2 Boston Housing 데이터

Boston Housing 데이터는 Carnegie Mellon University의 Harrison, D. 와 Rubinfeld, D. L.이 1978년 개발하였다. 1993년에 Harrison, D.와 Rubinfeld, D. L.은 이 데이터를 공식화하고 있다. 이 데이터는 보스턴 부근 주택의 가격을 다룬 데이터이다. 13종류의 입력에 의해 마지막 하나의 결과로 총 14종류의 데이터 쌍으로 되어있다. 모델의 성능지수는 식 (3)과 같이 RMSE를 사용하여 모델을 평가하였다.

표 4는 Boston Housing 데이터에 대한 모델의 성능을 나타낸 것이다. 전체 506개의 데이터를 학습 데이터 304개 (60%)와 테스트 데이터 202개(40%)로 랜덤하게 분할하여 모델의 성능을 평가하였다.

표 4 BHD 데이터에 대한 모델의 성능지수

Table 4 Performance index of the BHD data

No. of selected input variables	No. of clusters (c)	No. of contexts (P)					
		Type	2		5		
			PI	EPI	Type	PI	EPI
2	2	Q	2.9357 ±0.1791	2.9864 ±0.2117	Q	1.3055 ±0.0810	1.4096 ±0.1275
	3	Q	2.6403 ±0.2495	3.0044 ±0.6144	Q	1.2509 ±0.1131	1.4628 ±0.1938
	4	Q	2.6553 ±0.2986	3.0506 ±0.2049	Q	1.1128 ±0.1617	1.7463 ±0.2386
	5	Q	2.3951 ±0.2193	2.9944 ±0.2492	Q	0.9050 ±0.1818	2.1147 ±0.4520
3	2	Q	2.5786 ±0.2351	2.5509 ±0.1158	Q	1.2680 ±0.0507	1.3433 ±0.0807
	3	Q	2.2588 ±0.1102	2.5652 ±0.1978	Q	1.1772 ±0.0739	1.4033 ±0.2433
	4	Q	2.0700 ±0.1342	2.5602 ±0.2467	Q	0.9546 ±0.1328	1.5690 ±0.1760
	5	Q	2.0030 ±0.1049	2.5296 ±0.0736	M	0.6985 ±0.0568	2.0965 ±0.6345
4	2	M	2.3779 ±0.1474	2.4825 ±0.1810	Q	1.1291 ±0.0668	1.3276 ±0.2031
	3	M	2.0739 ±0.1715	2.3460 ±0.1271	M	0.9738 ±0.0787	1.3827 ±0.1594
	4	M	1.8909 ±0.1704	2.4098 ±0.1448	M	0.9794 ±0.1437	2.1847 ±0.5255
	5	Q	1.7701 ±0.1179	2.4181 ±0.1590	M	0.6641 ±0.0759	3.0536 ±0.9264

표 4에서도 알 수 있듯이, BHD 데이터를 이용한 모델의 성능은 이전의 데이터인 MPG 데이터를 이용한 모델의 성과 그 성향이 유사함을 알 수 있다. 즉, 모든 선택된 입력변수들 중에서 모델의 일반화와 근사화 능력을 상호 고려하였을 때, context의 수가 5개인 경우가 다른 경우에 비해서 성능이 우수함을 알 수 있다.

2개의 입력변수가 선택되어진 경우엔, 다항식의 형태가 2차식이고 context의 수가 5개 그리고 각각의 context에 할당된 클러스터의 수가 2개인 경우 PI=1.3055±0.0810, EPI=1.4096±0.1275로 성능이 가장 우수하였으며, 3개의 입력변수가 선택되었을 때에는 가장 우수한 모델은 context의 수가 5개, 각각의 context에 할당된 클러스터의 수는 4개 그리고 후반부가 변형된 2차식일 때 PI=0.9546±0.1328, EPI=1.5690±0.1760의 성능을 나타냈으며, 선택된 입력변수의

수가 4개인 경우에는 마찬가지로 context의 수가 5개 그리고 각각의 context에 할당된 클러스터의 수는 3개, 후반부 다항식이 변형된 2차식을 가질 때 $PI=0.9738\pm 0.0787$, $EPI=1.3827\pm 0.1594$ 의 성능을 나타내어 다른 모델들에 비해서 우수한 성능을 나타냄을 알 수 있었다.

그림 6은 표 4에서 보여준 모델의 성능 중에서 가장 우수한 성능을 가지고 있는, $PI=0.9716$, $EPI=1.1443$ 에 대한 원 모델의 출력과 모델을 통한 출력과의 오차를 나타낸 것이다. 이때 사용된 선택된 입력변수의 수는 4입력이고 context의 수는 5개 그리고 각각 context에 사용된 클러스터의 수는 3개를 사용했으며 다항식 형태는 변형된 2차식을 사용하였다.

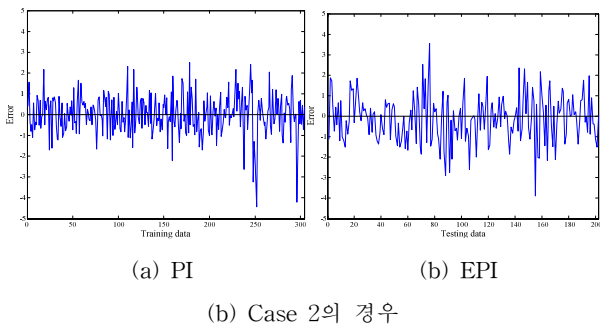


그림 6 GoSOPNN의 오차곡선 (SI=4, P=5, c=3, $PI=0.9716$, 그리고 $EPI=1.1443$)

Fig. 6 Errors curves of GoSOPNN (SI=4, P=5, c=3, $PI=0.9716$, and $EPI=1.1443$)

그림 7은 그림 6에서 보여준 성능을 가지고 있는 GoSOPNN의 전체 네트워크를 나타낸 것이다.

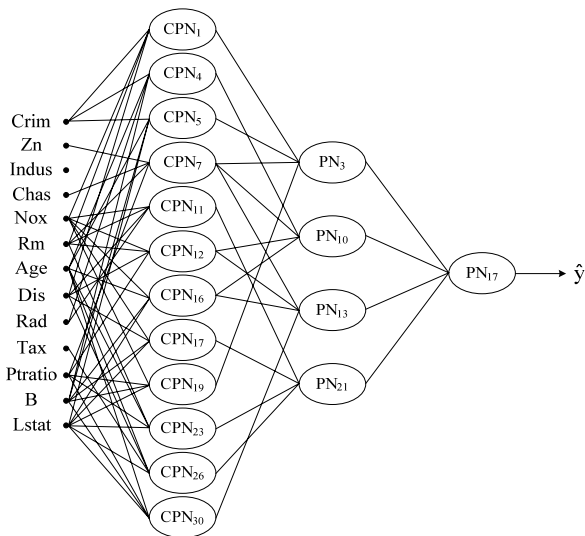


그림 7 입자화 중심 자기구성 다항식 신경 회로망 구조 (SI=4, P=5, c=3, $PI=0.9716$, 그리고 $EPI=1.1443$)

Fig. 7 GoSOPNN architecture (SI=4, P=5, c=3, $PI=0.9716$, and $EPI=1.1443$)

표 5는 Boston housing 데이터를 사용하여 성능 지수를 식 (3)에 의해 계산된 값으로 기존의 모델과 본 논문에서 제시한 모델과의 성능비교를 한 것이다. 표 5로부터 제안된 모델은 기존의 모델들과 비교해서 학습 데이터에 대한 성능 지수인 모델의 근사화 능력 및 일반화 능력 모두 뛰어남을 알 수 있었다.

표 5 다른 모델링 방법과의 성능 비교

Table 5 Comparison of performance with other modeling methods

Model		PI	EPI	Index
RBFNN[6]		6.36±0.24	6.94±0.31	RMSE
RBFNN with context-free clustering[6]		5.52±0.25	6.91±0.45	
Linguistic Modeling[6]	Without optimization	5.21±0.12	6.14±0.28	
	One-loop optimization	4.80±0.52	5.22±0.58	
	Multi-step optimization	4.12±0.35	5.32±0.96	
Incremental model[8]	Linear regression	4.535±0.240	5.043±0.396	RMSE
	Polynomial(2 nd order)	3.815±0.264	4.455±0.399	
	Incremental model	3.279±0.177	4.298±0.439	
Functional RBFNN[9]	m=2.00	4.724±0.644	14.064±0.820	MSE
	m=2.50	8.079±1.762	14.825±1.361	
	m=3.50	8.450±1.029	14.523±1.563	
HFSPNN[8] (3 rd layer)	Triangular MF	2.576±0.236	3.372±0.344	RMSE
	Gaussian MF	2.475±0.138	3.228±0.349	
Proposed Model (3 rd layer)	SI = 2	1.305±0.081	1.409±0.127	RMSE
	SI = 3	0.954±0.132	1.569±0.176	
	SI = 4	0.973±0.078	1.382±0.159	

5. 결 론

본 논문에서는 주어진 데이터의 특성인 정보 입자화의 효율적인 처리를 위한 Context-based Fuzzy C-Means(C-FCM) 클러스터링 방법과 대규모 복잡한 구조를 가지고 있는 비선형 실 시스템의 동적 분석 표현을 위한 자기구성 다항식 신경 회로망을 결합한 입자화 중심 자기구성 다항식 신경 회로망(Granular-oriented Self-Organizing Polynomial Neural Networks: GoSOPNN)에 대한 새로운 구조와 설계 방법론에 대해서 제안하고 폭넓은 성능평가를 하였다.

제안된 입자화 중심 자기구성 다항식 신경 회로망의 설계 관점에서의 특징은 다음과 같이 나타낼 수 있다.

- 본 논문의 1층에서 형성된 Context-based Polynomial Neuron(CPN)을 구축하기 위해 사용된 C-FCM은 출력

공간에서 정의된 퍼지 집합들(즉 context)을 입력 공간의 정보 입자화의 형성에 중요한 역할을 수행함으로써 주어진 데이터를 효과적으로 처리할 수 있었다.

- 기존의 다항식 신경 회로망 구조에 정보 입자화의 효율적인 처리를 위한 C-FCM 클러스터링 방법을 접목함으로써 새로운 형태의 진보된 계산적 지능(Computational Intelligence) 시스템을 구축할 수 있었다.
- 제안된 GoSOPNN 모델의 성능을 시뮬레이션하기 위하여 GoSOPNN을 구축하는 CPN과 PN의 성능을 향상시키는 데 크게 영향을 미치는 파라미터들(-context의 수, 클러스터의 수, 각 노드에 선택될 입력 변수의 수, 다항식 차수)을 다양하게 적용함으로써 유연성과 정확성을 가지며 객관적이고 좀 더 정확한 예측 능력을 가진 GoSOPNN 모델을 구축할 수가 있었다.
- 다양한 실험적 예제를 통해서 알 수 있듯이, 대체적으로 GoSOPNN의 층이 증가할수록 모델의 근사화 능력은 개선되어지나 일반화 능력은 저조함을 알 수 있었으며, 또한 모델의 성능을 개선함에 있어서 각각의 CPN과 PN에 할당된 주요 파라미터들은 일정한 패턴이 존재하는 것이 아니라 주어진 데이터의 정보 입자화 특성에 의존하는 것처럼 보임을 알 수 있었다.

결과에서도 알 수 있듯이 이전에 연구되어진 기존의 지능형 네트워크의 구조에서 얻어진 결과보다 본 논문에서 제안한 입자화 중심 자기구성 다항식 신경 회로망의 성능이 데이터 특성과 같은 주변 환경을 고려하였을 때 우수함을 알 수 있었으며, 제안된 효과적인 방법론은 최적의 지능형 시스템을 구축함을 보였다.

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] K. D. Karatzas and S. Kaltsatos, "Air pollution modelling with the aid of computational intelligence methods in Thessaloniki, Greece", *Simulation Modelling Practice and Theory*, Vol. 15, pp. 1310-1319, 2007.
- [2] C. Riziotis and A. V. Vasilakos, "Computational intelligence in photonics technology and optical networks: A survey and future perspectives", *Information Sciences*, Vol. 177, pp. 5292-5315, 2007.
- [3] R. del-Hoyo, B. Martin-del-Brio, N. Medrano, and J. Fernandez-Navajas, "Computational intelligence tools for next generation quality of service management", *Neurocomputing*, Vol. 72, pp. 3631-3639, 2009.
- [4] D. Srinivasan, C. W. Chan, and P. G. Balaji, "Computational intelligence-based congestion prediction for a dynamic urban street network", *Neurocomputing*, Vol. 72 pp. 2710-2716, 2009.
- [5] M. R. AlRashidi and M. E. El-Hawary, "Applications of computational intelligence techniques for solving the revived optimal power flow problem", *Electric Power Systems Research*, Vol. 79 pp. 694-702, 2009.
- [6] S. K. Oh and W. Pedrycz, "The design of self-organizing polynomial neural networks", *Information Sciences*, Vol. 141, No. 3-4, pp. 237-258, 2002.
- [7] S. K. Oh, W. Pedrycz, and S. B. Roh, "Hybrid fuzzy set-based polynomial neural networks and their development with the aid of genetic optimization and information granulation", *Applied Soft Computing*, Vol. 9, No. 3, pp. 1068-1089, 2009.
- [8] W. Pedrycz, "Conditional fuzzy c-means", *Pattern Recognition Letters*, Vol. 17, pp. 625-631, 1996.
- [9] W. Pedrycz, "Conditional fuzzy clustering in the design of radial basis function neural networks", *IEEE Trans. Neural Networks*, Vol. 9, No. 4, pp. 601-612, 1998.
- [10] W. Pedrycz and K. C. Kwak, "Linguistic models as a framework of user-centric system modeling", *IEEE Trans. SMC-A*, Vol. 36, No. 4, pp. 727-745, 2006.
- [11] W. Pedrycz and K. C. Kwak, "The Development of Incremental Models", *IEEE Trans. Fuzzy Systems*, Vol. 15, No. 3, pp. 507-518, 2007.
- [12] W. Pedrycz, H. S. Park, and S. K. Oh, "A granular-oriented development of functional radial basis function neural networks", *Neurocomputing*, Vol. 72, pp. 420-435, Dec., 2008.
- [13] H. S. Park, W. Pedrycz, and S. K. Oh, "Granular Neural Networks and Their Development Through Context-Based Clustering and Adjustable Dimensionality of Receptive Fields", *IEEE Transactions on Neural Networks*, Vol. 20, No. 10, pp. 1604-1616, Oct., 2009.
- [14] A. G. Ivahnenko, "The group method of data handling: a rival of method of stochastic approximation", *Soviet Automatic Control*, 1-3, pp. 43-55, 1968.
- [15] J. C. Bezdek, "Pattern Recognition with Fuzzy Objective Function Algorithms", Plenum, New York, 1981.
- [16] <http://archive.ics.uci.edu/ml>

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 컴퓨터 공학과 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 제어등.

Tel : 031-229-8162

Fax : 031-220-2667

E-mail : ohsk@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 Intelligence등.

Tel : 031-222-6544

Fax : 031-220-2667

E-mail : parkhs@suwon.ac.kr