

입자 군집 최적화 알고리즘 기반 다항식 신경회로망의 설계

| |
|---------|
| 논 문 |
| 60-2-27 |

Design of Particle Swarm Optimization-based Polynomial Neural Networks

박 호 성** · 김 기 상* · 오 성 권†
(Ho-Sung Park · Ki-Sang Kim · Sung-Kwun Oh)

Abstract - In this paper, we introduce a new architecture of PSO-based Polynomial Neural Networks (PNN) and discuss its comprehensive design methodology. The conventional PNN is based on a extended Group Method of Data Handling (GMDH) method, and utilized the polynomial order (viz. linear, quadratic, and modified quadratic) as well as the number of node inputs fixed (selected in advance by designer) at Polynomial Neurons located in each layer through a growth process of the network. Moreover it does not guarantee that the conventional PNN generated through learning results in the optimal network architecture. The PSO-based PNN results in a structurally optimized structure and comes with a higher level of flexibility that the one encountered in the conventional PNN. The PSO-based design procedure being applied at each layer of PNN leads to the selection of preferred PNs with specific local characteristics (such as the number of input variables, input variables, and the order of the polynomial) available within the PNN. In the sequel, two general optimization mechanisms of the PSO-based PNN are explored: the structural optimization is realized via PSO whereas in case of the parametric optimization we proceed with a standard least square method-based learning. To evaluate the performance of the PSO-based PNN, the model is experimented with using Gas furnace process data, and pH neutralization process data. For the characteristic analysis of the given entire data with non-linearity and the construction of efficient model, the given entire system data is partitioned into two type such as Division I(Training dataset and Testing dataset) and Division II(Training dataset, Validation dataset, and Testing dataset). A comparative analysis shows that the proposed PSO-based PNN is model with higher accuracy as well as more superb predictive capability than other intelligent models presented previously.

Key Words: Polynomial Neural Networks(PNN), Particle Swarm Optimization(PSO), PSO-based PNN, Polynomial Neuron(PN), Group Method of Data Handling(GMDH), Standard least square method

1. 서 론

자동화 시스템이 산업구조에 전반적으로 적용됨으로써 시스템의 규모가 커지고 복잡해지면서 시스템 모델링에 많은 어려움을 겪고 있으며 이러한 문제점을 해결하고자 지난 수십 년간 다양한 방법들로 연구되었다[1-3]. 즉, 일반적인 수학적 방법을 적용하기보다는 진보된 지능 기반 연산기술에 많은 관심이 집중되고 있다.

A. G. Ivakhenko에 의해서 제안된 Group Method of Data Handling(GMDH) 알고리즘[4]은 이러한 지능 연산기술 중의 대표적인 모델링 방법으로써, 2변수의 2차식에 의한 부분표현식을 계층적인 조합으로 비선형 모델 추정식을 얻을 수 있다. 그러나 복잡한 입출력 관계나 모델의 함수형이 특정하지 않은 비선형 관계의 경우에 2변수 2차식에 의한

부분표현식으로 표현하기에는 한계가 있다.

이러한 한계를 극복하기 위하여 Oh et al.에 의해 제안된 Polynomial Neural Network(PNN)은 다변수 다차식의 확장된 부분표현식을 이용하여 연속적인 층과 노드(Polynomial Neuron : PN)를 생성함으로써 최적의 구조를 얻는 알고리즘으로 기존의 신경망 알고리즘보다 더 적은 노드수와 유연한 적용특성을 가지고 있다[5-7]. 그러나 기존의 다항식 신경회로망 모델은 성능 향상에 크게 영향을 미치는 파라미터들을 설계자의 경험 또는 시행착오에 의해서 결정하여 네트워크를 구축하게 되는데 이는 주관적이고 신뢰성이 떨어지는 단점이 있다. 이를 보완하기 위해 최적화 기법을 적용하여 좀 더 객관적인 모델설계에 초점을 두었고, 최적화 기법 중 하나인 유전자 알고리즘(Genetic Algorithm)을 결합한 다항식 신경회로망 모델이 출현하였다[8-11]. 그러나 유전자 알고리즘 특성상 연산자가 많고, 계산시간이 오래 걸린다는 단점을 가지고 있다.

본 논문에서는 이러한 단점을 보완하기 위하여 생체 군집이론에 바탕을 둔 Particle Swarm Optimization (PSO)을 이용하여 최적의 다항식 신경회로망을 설계하고자 한다. 최적화 알고리즘 중 하나인 PSO는 다양한 분야의 시스템 모델링에 새로운 방법론적 이슈로써 등장하고 있다[12-13]. PSO

* 준 회원 : 수원대 전기공학과 석사과정
** 정 회원 : 수원대 산업기술연구소 연구교수 · 공박
† 교신저자, 시니어회원 : 수원대 공대 전기공학과 교수 · 공박
E-mail : ohsk@suwon.ac.kr
접수일자 : 2010년 7월 2일
최종완료 : 2010년 9월 24일

알고리즘은 비선형 문제의 분석과 해결, 그리고 효과적인 지능형 모델의 구조 개발을 위한 광범위한 설계 방법으로써 유전알고리즘과 비교하여 더 간결하고 수렴이 빠른 장점이 있다[14-15].

본 연구에서 이러한 PSO 알고리즘의 장점을 이용하여 다항식 신경회로망 모델의 최적화에 중요한 역할을 하는 파라미터들(입력 변수의 수, 선택된 입력 변수 그리고 후반부 다항식 차수)을 동조하여 진화론적으로 최적화된 새로운 형태의 PSO 기반 다항식 신경회로망 모델을 제안한다.

2. 다항식 신경 회로망의 알고리즘과 구조

2.1 다항식 뉴런(Polynomial Neuron: PN)

다항식 뉴런은 그림 1에서 볼 수 있듯이, 다항식 신경 회로망에 있어서 가장 기본이 되는 유닛으로 선택되어진 입력들이 들어오면 표 1에서 보인 3가지 형태중 하나의 다항식 구조를 선택하여 다항식을 이루게 되는 구조를 가진다.

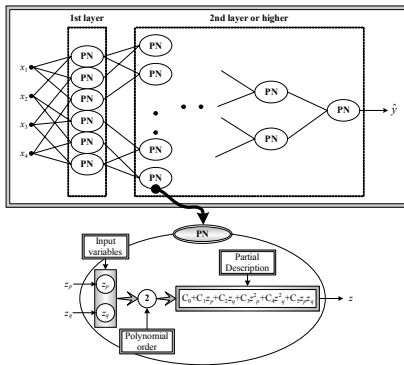


그림 1 다항식 뉴런(PN) 일반적인 구조
Fig. 1 A general topology of the Polynomial Neuron(PN)

그림 1은 기본적인 PN의 역할을 나타낸 것으로, 선택된 입력으로 2입력($\mathbf{z}_p, \mathbf{z}_q$) 그리고 후반부 다항식 차수가 2차식인 Type 2가 선택되어진 구조이다.

표 1 다항식 구조

Table 1 Type of Polynomial equation

| Type | Polynomial equation |
|------------------------------|---|
| Type 1 Linear | $y = a_0 + a_1x_1 + a_2x_2$ |
| Type 2 Quadratic | $y = a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2 + a_4x_1^2 + a_5x_2^2$ |
| Type 3 Modified quadratic | $y = a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2$ |

2.2 다항식 신경회로망 알고리즘

서론에서 언급하였듯이, 다항식 신경회로망은 GMDH 방법을 기반으로 하고 있으며, 그림 1에서 볼 수 있듯이 다항식 뉴런(Polynomial Neuron: PN)과 같은 부분 표현식을 구축할 수 있다. 전체 설계는 그림 1에서 보이듯이 각각의 층에서 최고의 노드(-즉, 다항식 뉴런)들의 선택에 의해서 실

행되며 최고의 성능에 도달할 때까지 하나의 층을 증가하며 생성되며 이는 최적의 다항식 신경회로망을 구축하기 위한 하나의 방법론에 해당된다.

식 (1)은 PN에 들어가는 입력으로 2 입력($\mathbf{x}_i, \mathbf{x}_j$), 2차식의 방정식이 주어졌을 때의 일반적인 구조를 나타낸 것이다.

$$z_a = A + Bx_i + Cx_j + Dx_i^2 + Ex_j^2 + Fx_ix_j \quad (1)$$

식 (1)과 같은 다항식들이 그림 1에서 보이듯이 각각의 노드들이 결합한다면, 최종적으로는 고차의 다항식을 얻게 된다. 최종 출력식은 다음과 같은 형태를 가지게 된다.

$$y = A + \sum_{i=1}^n B_i x_i + \sum_{i=1}^n \sum_{j=1}^n C_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n D_{ijk} x_i x_j x_k + \dots \quad (2)$$

2.3 다항식 신경회로망의 구조

다항식 신경회로망 구조는 몇 개의 층의 연속적인 생성으로 설계된다. 다항식 신경회로망은 층들의 구성과 노드들 사이의 상호 연결성뿐만 아니라 각각의 노드들의 유연성 때문에 매우 다양한 구조 생성이 가능하다. 결국 이러한 특성들은 네트워크 구조의 유연한 적응성에 기여하지만 보다 신중한 설계 방법론과 학습 메커니즘을 필요로 한다.

다음은 일반적인 다항식 신경회로망 구조로써 체계적이고 효율적인 구조를 설계함으로써 주어진 시스템 환경에 유연하게 적용할 수 있다.

- (a) 기본 다항식 신경회로망 구조 - 다항식 뉴런에서 입력변수의 수가 모든 층에서 동일한 경우
- (b) 변형된 다항식 신경회로망 구조 - 다항식 뉴런에서 입력변수의 수가 1층과 2층 이상에서 서로 다른 경우
 - CASE I - 다항식 뉴런의 다항식 차수가 모든 층에서 동일한 경우
 - CASE II - 2층 이상의 다항식 뉴런의 차수가 1층에서의 다항식 뉴런의 차수와 비교시 서로 다른 차수 및 변형된 차수를 가지는 경우
 - Generic type - 전체 시스템 입력변수의 수가 3입력 이거나 또는 그 이상인 경우
 - Advanced type - 전체 시스템 입력변수의 수가 3입력보다 작은 경우

3. 입자군집 최적화 알고리즘(Particle Swarm Optimization: PSO)

3.1 PSO 알고리즘의 특징

J. Kennedy와 R. Eberhart에 의해 1995년 제안된 PSO는 진화형 계산 기법의 일종으로, 이론의 간결성, 구현의 용이성, 연산의 효율성과 같은 특징을 보이며 다른 확률적 방법과 비교하여 보다 안정적인 수렴 특징을 가지고 유전자 알고리즘에 비해 computation time의 유리함을 가지고 있다[16].

PSO 알고리즘의 가장 두드러진 특징은 집단을 기본으로 한 탐색 알고리즘이라는 것이다. 즉, PSO는 확률론적 최적화 알고리즘의 한 종류로서 병렬적 진화를 내포하는 특성

때문에 다른 탐색 알고리즘들의 문제점인 지역 극소점을 최소화 할 수 있으며 탐색 공간 안에 안내 정보를 사용하여 미분가능 하지 않은 목적함수를 쉽게 다룰 수 있어 복잡하고 불확정적인 공간을 탐색할 수 있는 장점을 가지고 있다.

3.2 PSO 알고리즘 연산자

- Particle- $\mathbf{x}(t)$: 군집(swarm) 안에 속해 있는 각각의 개체는 하나의 particle이다. 군집의 모든 particle들은 같은 체제아래에서 개별적으로 동적하며 이것은 하나의 해를 나타내고 M-차원 실수 벡터로 표현된다.
- Swarm- $\mathbf{S}(t)$: Swarm은 n개 particle의 집합이다. 즉, $\mathbf{S}(t)=[\mathbf{x}_1(t), \mathbf{x}_2(t), \dots, \mathbf{x}_n(t)]^T$ 가 된다.
- Particle best-pbest(t) : 탐색 공간을 움직이는 particle들은 현재 위치 정보에 대한 적합도를 구하고 최적의 위치 정보를 가진 particle을 'pbest'라고 한다.
- Global best-gbest(t) : 최적의 위치 정보를 가지는 particle들, 즉, 'pbest'의 모든 particle 중 가장 최적의 위치 정보를 나타내는 particle이다.
- Inertia weight-w(t) : 현재 velocity에 대한 기존 velocity의 영향을 조절하기 위한 제어 파라미터이다.
- Particle velocity-v(t) : $\mathbf{v}(t)$ 는 PSO의 유일한 연산자이며, particle들의 이동 속도를 나타내는 M-차원 실수 벡터이다.

3.3 PSO 알고리즘

[Step 1] Initialization - n개의 particle을 탐색 공간 내에서 랜덤하게 생성한다. 이들은 초기 swarm이 된다. 마찬가지로 초기 particle velocity를 $[-v_{max} \ v_{max}]$ 내에서 랜덤하게 생성한다.

[Step 2] Inertia weight & velocity updating - 관성하중 값을 계산하고 j번째 particle velocity를 계산한다.

[Step 3] Position updating - 식 (3)에 의해 particle의 위치 정보는 조절된다.

$$x_{jk}(t) = v_{jk}(t) + x_{jk}(t-1) \quad (3)$$

여기서, $x_k^{min} \leq x_{jk}(t) \leq x_k^{max}$ 이다.

[Step 4] Individual & global best updating - 새로운 위치 정보를 가진 particle들은 목적함수에 의해 평가된다.

[Step 5] Stopping criteria - 종료조건을 만족하면 탐색과정을 종료하고, 그렇지 않으면 [Step 2]부터 반복한다.

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

4. PSO 기반 최적 다항식 신경 회로망

본 논문에서 제안한 PSO 기반 최적 다항식 신경 회로망의 설계 절차는 다음과 같다.

[Step 1] 입력변수 선택 및 데이터 분할

출력변수 y에 관련된 n개의 입력변수를 설정하고, 다음과 같이 2가지 형태로 데이터를 분할하였다.

- Division I : 전체 데이터를 학습용 데이터(N_{PI})와 테스트용 데이터(N_{EPI})로 분할한다. 여기서, $N=N_{PI}+N_{EPI}$ 이다.

- Division II : 비선형이 강한 데이터들은 모델에 대한 구체적인 성능을 평가하기 위해서 전체 데이터를 학습용 데이터(N_{PI}), 평가용 데이터(N_{VPI}), 그리고 테스트용 데이터(N_{EPI})로 분할한다. 여기서, $N=N_{PI}+N_{VPI}+N_{EPI}$ 이다.

[Step 2] 다항식 신경회로망 구조 정보 결정

다항식 신경회로망 구조를 구축하는 있어서 기본적인 정보를 결정한다. 즉, 다항식 신경회로망의 a) 종료조건 선택-최적 노드의 적합도 값 비교 또는 최대 층 수 결정, b) 노드에 입력될 최대 입력변수의 수 결정, c) 하나의 층에서 생성될 노드의 수 결정 그리고 d) 목적함수의 하중계수 값을 결정한다.

[Step 3] PSO를 이용한 다항식 신경회로망 구조 결정

PNN 구조를 결정하기 위하여 PSO를 이용하여 다항식 신경회로망 모델의 최적화에 중요한 역할을 맡고 있는 입력변수의 수, 입력변수 그리고 후반부 다항식 차수를 결정한다. 그림 2에서는 PSO를 이용하여 노드의 구조를 설계하는 과정을 예로써 보여준 것이며, 세부적인 알고리즘은 다음과 같다.

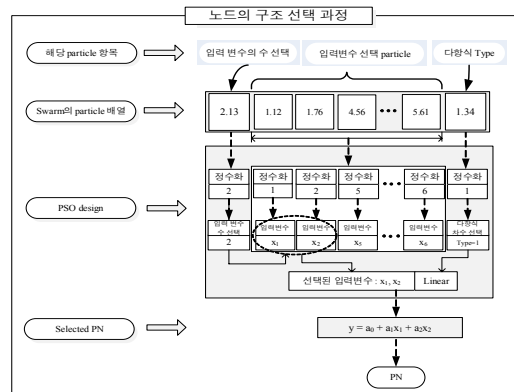


그림 2 PSO의 particle을 이용한 노드 설계의 예
Fig. 2 The example of node design available by using a particle of PSO

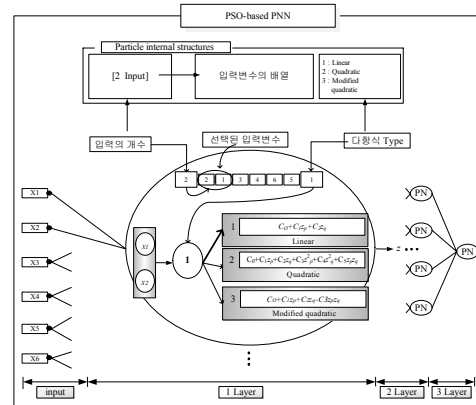


그림 3 PSO 기반 다항식 신경회로망 노드의 구조
Fig. 3 Structure of PSO based 다항식 신경회로망 nodes

그림 3은 전체 다항식 신경회로망 구조에서 첫 번째 층에서 첫 번째 PN 노드에 대해서 PSO 알고리즘에 의해서 선택된 파라미터들의 조합에 따른 설계 과정을 보여준 것이다. 그림 4는 본 논문에서 사용한 다항식 신경회로망의 노드 즉, PN의 구성에 대해서 설명한 것이다.




그림 4 PN의 구성
Fig. 4 Composition of PN

[Step 4] 모델의 구축과 평가 및 테스트 그리고 노드의 선택 각 PN 노드로부터 PSO 기반 PNN 구조의 전체 최적화 과정은 그림 5와 같이 수행되고 그 절차는 다음과 같다.

[단계 4-1] PSO 기반 PNN 모델의 최적화 모델 구축을 위한 세대 수, Swarm 수, 가속상수(acceleration constant), 관성하중(inertia weight) 등의 초기 정보를 설정한다.

[단계 4-2] 최적화하고자 하는 값들을 위해 velocity의 최대값을 구하고 임의의 숫자로 swarm을 생성하며 velocity 최대값을 이용하여 임의의 숫자로 velocity를 구하여 초기값을 설정한다.

[단계 4-3] Swarm에 의해서 생성된 노드의 성능 테스트를 위해서 본 논문에서는 모델의 근사화와 일반화 능력 사이의 합리적 균형을 얻기 위해 [단계 1]에서 분할된 데이터 형식에 따라 식 (4)와 식(5)와 같은 하중값을 가진 목적함수[17]를 이용하여 생성된 노드를 평가한다.

• Division I인 경우

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

• Division II인 경우

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

본 논문에서는 식 (4)와 식 (5)에 주어진 목적함수의 θ 값을 0.5로 설정하여 모델 구축에 있어서 근사화와 일반화 능력을 상호 고려하였다.

[단계 4-4] 다음 세대의 생성을 위해서 구해진 성능지수가 가장 뛰어난 swarm을 'pbest'으로 설정하고 성능지수가 가장 뛰어난 particle을 'gbest' 설정한다. 그리고 이들 값을 사용하여 particle velocity를 구한다.

[단계 4-5] 이전 세대에서 사용했던 swarm에 particle velocity값을 더하여 새로운 swarm을 생성한다.

[단계 4-6] 각 swarm의 particle을 생성할 때 입력변수와 같은 중복을 피해야 하는 particle은 중복된 값만 따로 중복을 피하기 위해 중복되지 않는 값을 넣어준다.

[단계 4-7] 중복된 적합도 값들을 하나로 처리한 후 설계자가 PNN 구조를 설계하기 전 결정된 노드의 제한된 개수 W 개만큼 선호되는 적합도 값들을 선택한다.

[단계 4-8] 다음세대에서의 particle velocity를 생성하기 위해서 선택된 노드들 중에서 최적의 적합도 값을 가지는 노드를 선택한다.

[단계 4-9] [단계 4-5]에서 얻어진 정보를 가지고 다음 세

대의 Swarm을 생성한 후 [단계 4-3]에서 [단계 4-8]까지 반복한다. 정해진 세대까지 이를 반복 실행한다.

[단계 4-10] 위의 단계들을 거처서 마지막 세대까지 PSO 알고리즘이 실행되면 최적의 노드들이 생성되며 생성된 노드들은 PNN 모델을 구축하는 하나의 층을 이루게 된다.

[Step 5] 종료판정

[단계 4]의 현재 층에서 얻어진 최적 노드의 최대 적합도 값 F1이 다음 부등식을 만족하는 경우에 알고리즘을 종료한다.

$$F1 \leq F^* \quad (6)$$

단, F^* 는 이전 층의 최적 노드인 최대 적합도 값이다.

본 논문에서는 전체 층의 수를 사용된 데이터의 특성에 따라 미리 제한하고 네트워크의 복잡성과 우수성의 상호 균형을 고려하여 알고리즘을 종료한다.

모델 후반부 다항식의 계수 추정은 최소자승법을 이용하였으며, 모델의 성능지수 식은 기존의 논문들에서 널리 사용되어진 식 (7)과 같은 Mean Square Error를 사용하였다.

$$E = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

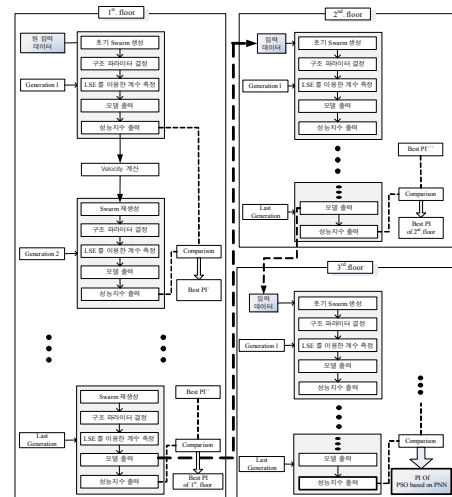


그림 5 PSO 기반 최적 다항식 뉴럴 네트워크의 순서도
Fig. 5 Flowchart of PSO based PNN

[Step 6] 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, $X_{1j}=Z_{1i}, X_{2j}=Z_{2i}, \dots, X_{wj}=Z_{wi}$ 으로 구성하고, [단계 3]로 간다(여기서, $j=i+1$). 이후, [단계 3]부터 [단계 6]까지를 반복한다.

5. 시뮬레이션 및 결과 고찰

본 논문에서 제안된 네트워크 구조는 몇 개의 수치적 실험을 통해서 모델의 특징과 성능에 대해서 알아본다.

표 2는 모델의 최적화를 위해 사용된 PSO 알고리즘과 다항식 신경회로망 모델의 파라미터들을 나타낸 것이다.

Machine Learning 데이터[24]의 경우, 실험에서 발생된 결과들의 타당성으로써 좀 더 높은 객관성을 제공하기 위해 10-fold cross validation 모드를 실행하였다.

표 2 PSO 알고리즘과 다항식 신경회로망의 파라미터

Table 2 Parameter of PSO algorithm and PNN

| | Data type | 가스료 | pH | MPG | BHD |
|-----|---------------------------------------|---------------------|-------------|---------|--------|
| PSO | Generation size | 150 | | | |
| | Swarm size | 100 | | | |
| | Selected swarm size | 30 | | | |
| | vmax | 20% of search space | | | |
| | [wmin wmax] | [0.4 0.9] | | | |
| | c1, c2 | 2.0 | | | |
| PNN | No. of input variables to be selected | 2 ~ 6 | 2 ~ 6 | 2 ~ 7 | 2 ~ 13 |
| | Polynomial type | 1 ≤ T ≤ 3 | | | |
| | Weighting factor(θ) | 0.5 | | | |
| | Maximum layer | 5 | 10 | 3 | 3 |
| | Division of data | Division I | 50%:50% | 60%:40% | |
| | Division II | | 50%:30%:20% | | |

여기서, T는 표 1에 나타난 다항식 구조

5.1. Gas furnace process data

제안된 PSO 기반 다항식 신경회로망의 성능을 평가하기 위해서 먼저 많은 연구자들이 제안하는 모델링 기법의 성능을 테스트하는데 널리 사용되는 가스료 시계열 데이터를 이용하였다. Box와 Jenkins[18]에 의해 사용된 가스료 시계열 데이터는 입력 데이터인 가스 흐름율(u(t))과 연소된 이산화탄소 농도(y(t))의 가스료 공정으로부터 추출된다.

1입력 1출력의 가스료 시계열 데이터 296쌍을 시뮬레이션하기 위해 전체 시스템 입력을 u(t-3), u(t-2), u(t-1), y(t-3), y(t-2), y(t-1)과 출력 y(t)의 6입력 1출력으로 설정하였다.

표 3은 모델에 가스료 시계열 데이터를 이용한 성능지수를 나타낸다.

표 3 제안된 PSO-based 다항식 신경회로망의 성능지수

Table 3 Performance Index of the proposed PSO-based PNN

| Layer | Node | | | | | Type | PI | EPI | |
|-------|------|----|----|----|----|------|-------|-------|-------|
| 1 | 2 | 4 | 5 | 6 | | 1 | 0.021 | 0.126 | |
| 2 | 8 | 13 | 15 | 17 | 20 | 28 | 2 | 0.012 | 0.103 |
| 3 | 17 | | | | | 18 | 3 | 0.012 | 0.098 |
| 4 | 5 | 6 | 22 | 25 | 28 | | 1 | 0.012 | 0.098 |
| 5 | 3 | 12 | 22 | 26 | | | 2 | 0.012 | 0.094 |

그림 6은 표 3에서 표시한 PSO 기반 다항식 신경회로망 모델의 최적화 과정을 세대별로 나타낸 그림이다.




그림 6 PSO 알고리즘에 의한 각 층 성능지수의 수렴 과정

Fig. 6 Convergence process of performance index of each layer by the PSO algorithm

그림 7은 표 3에서 보여준 최종 층인 5층에서의 성능지수인 PI=0.012, EPI=0.094에 대한 원 데이터 출력과 모델 데이터 출력과의 선형성을 나타낸 것이다.




그림 7 원 출력과 모델 출력의 비교

Fig. 7 Scatter plots showing model output vs. original output

그림 8은 표 3에서 보여준 층의 증가에 따른 성능지수중에서 3층에서의 네트워크 구조를 나타낸 것이다(PI=0.012, EPI=0.098).




그림 8 PSO기반 다항식 신경회로망의 네트워크

Fig. 8 Network of PSO-based PNN

표 4는 가스료 공정 데이터를 사용하여 모델의 성능을 평가한 기존의 모델과 본 논문에서 제안한 모델의 성능을 비교한 것이다.

표 4 기존의 모델들과의 성능 비교

Table 4 Comparative analysis of the performance of various models

| Model | No. of selected input variables | Layer | PI _t | PI | EPI | |
|----------------------------|---------------------------------|-------|-----------------|-------|-------|-------|
| Box and Jenkin's model[18] | | | 0.710 | | | |
| Fuzzy model[17] | | | | 0.020 | 0.271 | |
| FCM- based RBFNN[14] | | | | 0.017 | 0.299 | |
| FPNN[19] | CASE I | 4 | 5 th | 0.016 | 0.116 | |
| | CASE II | 4 | 5 th | 0.016 | 0.128 | |
| HFPNN[12] | Triangular | 4 | 5 th | 0.019 | 0.134 | |
| | Gaussian-like | 4 | 5 th | 0.021 | 0.119 | |
| Generic SOPNN[4] | Basic SOPNN | 4 | 5 th | 0.027 | 0.021 | 0.085 |
| | Modified SOPNN | 4 | 5 th | 0.035 | 0.017 | 0.095 |
| Advanced SOPNN[7] | Basic SOPNN | 4 | 5 th | 0.020 | 0.119 | |
| | Modified SOPNN | 4 | 5 th | 0.018 | 0.118 | |
| GA-PNN[8] | | | 5 th | 0.012 | 0.097 | |
| Proposed Model | | 4 | 1 st | 0.021 | 0.126 | |
| | | 3 | 3 rd | 0.012 | 0.098 | |
| | | 4 | 5 th | 0.012 | 0.094 | |

PI_t : Performance index for entire data set

5.2 pH 중화 공정 데이터

화학공정이나 오·폐수처리, 생물공학 등 많은 분야에서 널리 사용되는 pH중화 공정에 사용하여 모델링을 한다. 입력 데이터인 염기의 흐름율과 중화된 pH에 대하여 입력 변수는 $F_b(t-3)$, $F_b(t-2)$, $F_b(t-1)$, $Y_{pH}(t-3)$, $Y_{pH}(t-2)$, $Y_{pH}(t-1)$ 이고 출력변수는 $Y_{pH}(t)$ 이다. 500개의 입력력 데이터 쌍이 다항식 신경회로망 네트워크를 구성하는데 사용되었다. 표 5는 제안된 모델에 pH중화 공정 데이터를 사용하여 층 별 노드 중 가장 좋은 성능지수를 나타낸 것이다.

표 5 PSO-based 다항식 신경회로망의 성능지수

Table 5 Performance Index of PSO-based PNN

| Layer | Node | | | | | | Type | PI |
|-------|------|----|----|----|----|----|------|--------|
| 1 | 1 | 2 | 3 | 4 | 5 | 6 | 2 | 0.7609 |
| 2 | 3 | 11 | 12 | 15 | 16 | 24 | 2 | 0.2110 |
| 3 | 1 | 3 | 9 | 14 | 16 | 19 | 2 | 0.1117 |
| 4 | 2 | 7 | 8 | 10 | 16 | 20 | 2 | 0.0412 |
| 5 | 1 | 8 | 10 | 15 | 20 | 24 | 2 | 0.0170 |
| 6 | 2 | 7 | 16 | 18 | 22 | 24 | 2 | 0.0049 |
| 7 | 1 | 3 | 7 | 13 | 22 | 24 | 2 | 0.0027 |
| 8 | 2 | 3 | 12 | 15 | 21 | 27 | 2 | 0.0014 |
| 9 | 1 | 2 | 12 | 13 | 19 | 26 | 2 | 0.0007 |
| 10 | 1 | 7 | 12 | 15 | 24 | 25 | 2 | 0.0004 |

그림 9는 PI가 0.0004로 수렴해 가는 과정을 세대수별로 나타낸 그림이다.




그림 9 PSO-based 다항식 신경회로망 최적화를 위한 각 세대 성능지수의 수렴 과정

Fig. 9 Convergence process of performance index of each generation for the optimization of PSO-based PNN

표 6은 pH 중화 공정 데이터를 사용하여 구한 성능지수로서 기존의 모델과 본 논문의 모델을 비교한 것이다.

표 6 다른 모델링 방법과 성능 비교

Table 6 Comparison of performance with other modeling methods

| Model | | PI | |
|-----------------|---------------------------------------|------------------------|--------|
| Nie's model[20] | USOCPN | 0.230 | |
| | SOSOCPN | 0.012 | |
| SOPNN[6] | Basic PNN (15 th layer) | Case I | 0.0015 |
| | | Case II | 0.0052 |
| | Modified PNN (10 th layer) | Case I | 0.0039 |
| | | Case II | 0.0124 |
| Proposed Model | | 10 th layer | 0.0004 |

5.3 Machine Learning dataset

5.3.1 Automobile Miles Per Gallon(MPG)

MPG 데이터는 전체 392개의 입출력 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 (7)과 같이 MSE를 사용하여 모델을 평가하였다.

표 7은 표 2에서 주어진 정보를 기반으로 MPG 데이터에 대한 모델의 성능을 나타낸 것이다.

표 7 MPG 데이터에 대한 PSO 기반 PNN 모델의 성능지수

Table 7 Performance index of PSO-based PNN for the MPG data

| Layer | Division I | | Division II | | |
|-------|-------------|-------------|-------------|-------------|--------------|
| | PI | EPI | PI | VPI | EPI |
| 1 | 6.987±0.646 | 7.828±1.009 | 7.049±0.760 | 7.730±1.167 | 8.180±1.952 |
| 2 | 5.386±0.731 | 6.908±0.791 | 4.302±1.084 | 6.446±1.117 | 10.298±2.846 |
| 3 | 4.760±0.713 | 6.852±0.784 | 4.546±0.763 | 6.215±0.753 | 10.115±2.374 |

그림 10은 표 7에서 보여준 층의 증가에 따른 성능지수의 값(평균과 표준오차)을 나타낸 것이다.

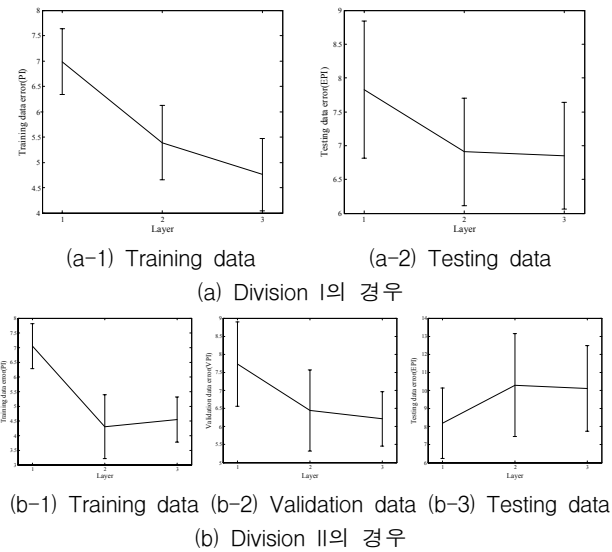




그림 10 층의 증가에 따른 성능지수

Fig. 10 Performance index regarded as a increase of layer



(a) Division I의 경우(3층에서의 PI=4.427, EPI=5.883)



(b) Division II의 경우(PI=3.812, VPI=5.318, 그리고 EPI=8.552)

그림 11 PSO 알고리즘에 의한 각 성능지수들의 최적화 과정
Fig. 11 The optimization process of each performance index by the PSO algorithms

그림 11은 표 7에서 보여준 네트워크 출력중에서 3층에서 가장 우수한 성능을 가진 모델의 각 층에서 generation 수행 과정에 따른 성능지수의 최적화 과정을 나타낸 것이다.

표 8은 기존의 모델과 본 논문에서 제시한 PSO 기반 다항식 신경 회로망 모델과의 성능비교를 한 것이다.

표 8 기존의 모델들과의 성능 비교

Table 8 Comparative analysis of the performance of various models

| Model | PI | VPI | EPI | 비고 |
|--|----------------------------|--------------|--------------|------|
| Linear regression model[18] | 3.383±0.194 | | 3.472±0.295 | RMSE |
| Linguistic Modeling[21] | Without | 3.78±1.52 | 4.22±1.22 | |
| | One-loop | 2.90±0.32 | 3.17±1.01 | |
| Incremental models[22] | Multi-step | 2.86±0.83 | 3.14±0.98 | RMSE |
| | Linear regression | 3.383±0.194 | 3.472±0.295 | |
| RBFNN I[23] | 2 nd Polynomial | 2.807±0.122 | 2.972±0.196 | RMSE |
| | Incremental model | 2.390±0.142 | 3.060±0.285 | |
| RBFNN II[23] | | 15.396±2.166 | 20.560±2.957 | MSE |
| FRBFNN[23] | | 15.678±1.231 | 17.918±1.934 | |
| Proposed Model (3 rd layer) | | 5.804±0.394 | 7.936±1.100 | MSE |
| | Division I | 2.182±0.845 | 2.618±0.885 | |
| | Division II | 2.132±0.874 | 2.493±0.868 | |
| | Division I | 4.760±0.713 | 6.852±0.784 | |
| | Division II | 4.546±0.763 | 10.115±2.374 | |

그림 12는 표 8에서 Division I의 경우에서 성능이 PI=4.427, EPI=5.884인 경우의 모델의 네트워크를 나타낸 것이다.

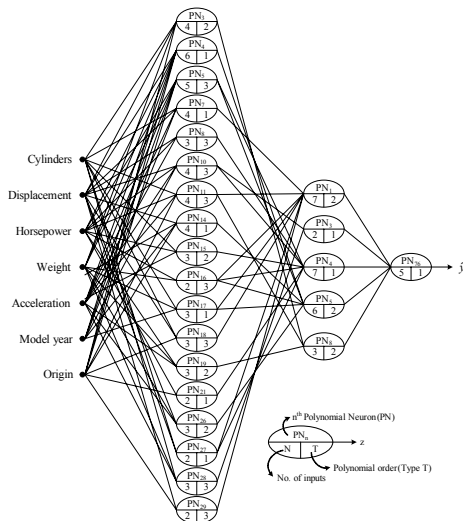


그림 12 PSO 기반 다항식 신경회로망의 최적 네트워크
Fig. 12 Genetically optimized PSO-based PNN architecture

5.3.1 Boston Housing Data(BHD)

Boston Housing 데이터는 보스턴 부근 주택의 가격을 다룬 데이터이다. 13종류의 입력에 의해 마지막 하나의 결과로 총 14종류의 데이터 쌍으로 되어있다.

표 9는 표 2에서 주어진 PSO 및 모델 구축을 위한 정보를 기반으로 Boston Housing 데이터에 대한 모델의 성능을 나타낸 것이다.

표 9 BHD 데이터에 대한 PSO 기반 PNN 모델의 성능지수
Table 9 Performance index of PSO-based PNN for the BHD

| Layer | Division I | | Division II | | |
|-------|-------------|--------------|-------------|--------------|--------------|
| | PI | EPI | PI | VPI | EPI |
| 1 | 7.088±1.261 | 11.960±1.535 | 7.705±1.124 | 11.792±1.164 | 14.727±4.182 |
| 2 | 4.948±0.687 | 10.174±1.914 | 5.427±1.492 | 10.611±1.143 | 15.641±6.500 |
| 3 | 4.413±0.799 | 9.884±1.876 | 4.708±1.223 | 10.704±1.529 | 11.722±2.815 |

그림 13은 표 9에서 보여준 네트워크의 성능중에서 최고의 성능을 가지는 모델의 최적화 수렴과정을 나타낸 것이다.

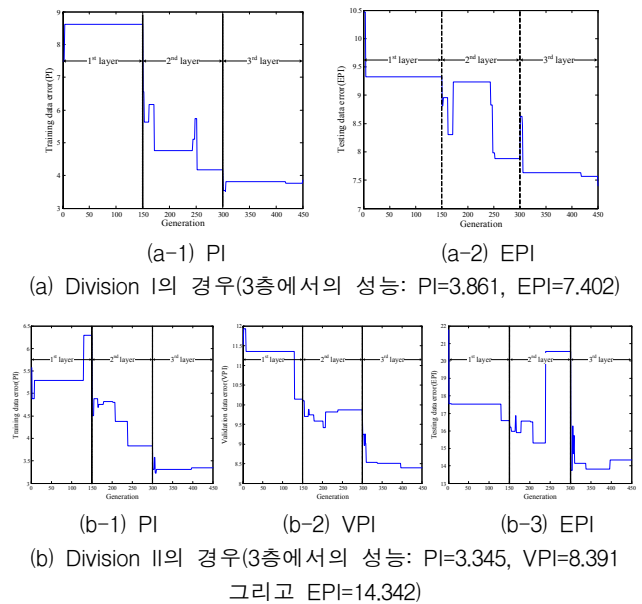




그림 13 PSO 기반 PNN 최적화를 위한 각 층 성능지수의 수렴 과정

Fig. 13 Convergence process for the optimization of PSO-based PNN

그림 14는 표 9와 그림 13에서 보여준 가장 우수한 성능을 가지는 모델의 출력과 원 출력과의 오차를 나타낸 것이다.



(a) Division I의 경우(3층에서의 성능: PI=3.861, EPI=7.402)



(b-1) Training data (b-2) Validation data (b-3) Testing data
 (b) Division II의 경우(3층에서의 성능: PI=3.345, VPI=8.391 그리고 EPI=14.342)

그림 14 PSO 기반 다항식 신경회로망의 오차곡선

Fig. 14 Errors curves of PSO-based PNN

표 10은 기존의 모델과 본 논문에서 제시한 PSO 기반 PNN 모델과의 성능비교를 한 것이다.

표 10 다른 모델링 방법과의 성능 비교

Table 10 Comparison of performance with other modeling methods

| Model | PI | VPI | EPI | 비고 |
|--|----------------------------|-------------|--------------|------|
| Linear regression model[22] | 4.535±0.240 | | 5.043±0.396 | RMSE |
| Linguistic Modeling[21] | Without | 5.21±0.12 | 6.14±0.28 | |
| | One-loop | 4.80±0.52 | 5.22±0.58 | |
| | Multi-step | 4.12±0.35 | 5.32±0.96 | |
| Incremental models[22] | Linear regression | 4.535±0.240 | 5.043±0.396 | |
| | 2 nd Polynomial | 3.815±0.264 | 4.455±0.399 | |
| | Incremental model | 3.279±0.177 | 4.298±0.439 | |
| RBFNN I[23] | 26.065±3.298 | | 34.897±5.345 | MSE |
| RBFNN II[23] | 49.448±4.851 | | 57.121±9.380 | |
| FRBFNN[23] | 4.724±0.644 | | 14.064±0.820 | |
| Proposed Model (3 rd layer) | Division I | 2.101±0.894 | 3.144±1.369 | RMSE |
| | Division II | 2.170±1.106 | 3.272±1.236 | |
| | Division I | 4.413±0.799 | 9.884±1.876 | MSE |
| | Division II | 4.708±1.223 | 10.704±1.529 | |

6. 결론

본 연구에서는 대규모의 구조를 가지는 공정뿐만 아니라 비선형이 강한 실 시스템의 동적 분석 및 모델링을 위해서 PSO 알고리즘을 이용한 새로운 형태의 다항식 신경회로망 (Polynomial Neural Network: PNN)의 최적 구조에 대한 폭넓은 설계과정 및 포괄적인 방법론을 제시하였다.

제안된 PSO 기반 다항식 신경회로망의 특징을 다음과 같이 나타낼 수 있다.

- 입자 군집 최적화(PSO) 방법을 이용하여 기존의 다항식 신경회로망 모델들에 비해서 간단하면서도 진보된 새로운 형태의 다항식 신경회로망을 구축할 수 있었다.
- PSO 알고리즘을 이용하여 다항식 신경회로망을 구축하는 다항식 뉴런의 성능을 향상시키는데 크게 영향을 미치는 파라미터들(-입력 변수의 수, 선택된 입력 변수, 그리고 후반부 다항식 차수)을 진화론적으로 탐색하여 모델 구축에 있어서 유연성과 정확성을 가지며 객관적이고 좀 더 정확한 예측 능력을 가진 모델을 구축할 수가 있었다.
- 기존의 유전자 알고리즘을 적용한 다항식 신경회로망이 가지고 있던 많은 계산량과 계산의 복잡성 그리고 장시간의 프로그램 실행시간과 같은 단점을 극복할 수가 있었다.

- 이전에 연구되어진 지능형 모델에 비하여 모델의 근사화 및 일반화 능력이 우수함을 알 수 있었으며 비선형이 강하거나 제한된 데이터일지라도 구조 및 파라미터 동정에 의한 최적화된 다항식 신경회로망을 설계할 수 있음을 알 수 있었다.

감사의 글

본 연구는 2009년도 지식경제부의 재원으로 한국에너지 기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다 (2009T100100563) 그리고 경기도의 경기도 지역협력연구센터사업의 일환으로 수행하였음 [GRRC 수원2010-B2, U-city 보안감시 기술협력센터].

참고 문헌

- [1] V. Rouss, W. Charon, and G. Cirrincione, "Neural model of the dynamic behaviour of a non-linear mechanical system," Mechanical Systems and Signal Processing, Vol 23, pp. 1145-1159, 2009.
- [2] A. Tortum, and N. Yayla, "The modeling of mode choices of intercity freight transportation with the artificial neural networks and adaptive neuro-fuzzy inference system," Expert Systems with Applications, Vol 36, Issue 3, Part 2, pp. 6199-6217, 2009.
- [3] M. Khashei, S. R. Hejazi, and M. Bijari, "A new hybrid artificial neural networks and fuzzy regression model for time series forecasting," Fuzzy Sets and Systems, Volume 159, Issue 7, pp. 769-786, 2008.
- [4] A. G. Ivahnenko, "Polynomial theory of complex systems," IEEE Trans. on Systems, Man and Cybernetics, Vol. SMC-1, pp. 364-378, 1971.
- [5] S. K. Oh and W. Pedrycz, "The Design of Self-Organizing Polynomial Neural Networks," Information Sciences, Vol. 141, pp. 237-258, 2002.
- [6] S. K. Oh, T. C. Ahn, and W. Pedrycz, "Fuzzy Polynomial Neural Networks-Based Structure and Its Application to Nonlinear Process Systems," 7th IFSA World Conference, Vol. 2, pp. 495-499, 1997.
- [7] S. K. Oh, W. Pedrycz, and B. J. Park, "Polynomial Neural Networks Architecture : Analysis and Design," Computers and Electrical Engineering, Vol. 29, No. 6, pp. 703-725, 2003.
- [8] 박호성, 박병준, 장성환, 오성권 "진화론적 최적 자기구성 다항식 뉴럴 네트워크," 전기학회 논문지, Vol. 53D, No. 1, pp. 40-49, 2004.
- [9] 김완수, 이인태, 오성권, 김현기, "유전자 알고리즘 기반 최적 다항식 뉴럴네트워크 연구 및 비선형 공정으로의 응용," 퍼지 및 지능시스템학회 논문지, Vol 15, No 7, pp 846-851, 2005.
- [10] 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 Journal, Vol. 9, No. 3, pp.1068-1089, 2009.

[11] S. K. Oh, W. Pedrycz, and H. S. Park, “Genetically optimized fuzzy polynomial neural networks,” IEEE Trans. Fuzzy Syst., Vol. 14, No. 1, pp. 124-144, 2006.

[12] 박병준, 오성권, 김용수, 안태천 “PSO의 특징과 차원성에 관한 비교연구,” 제어·자동화·시스템공학 논문지 Vol. 12, No. 4, pp. 328-338, 2006.

[13] Y. Jiang, T. Hu, C. C. Huang, and X. Wu, “An improved particle swarm optimization algorithm,” Applied Mathematics and Computation, Vol 193, Issue 1, pp. 231-239, 2007.

[14] J. N. Choi, H. K. Kim, and S. K. Oh, “Optimization of FCM-based Radial Basis Function Neural Network Using Particl Swarm Optimization,” 대한전기학회, Vol. 57, No. 11, pp. 2108-2115, 2008.

[15] R. E. Perez and K. Behdinan, “Particle swarm approach for structural design optimization,” Computers & Structures, Vol 85, Issues 19-20, pp. 1579-1588, 2007.

[16] S. K. Oh, W. Pedrycz, and D. W. Kim, “Hybrid fuzzy polynomial neural networks,” Int. J. Uncert. Fuzzy. Knowledge-Based Syst. pp. 257-280, 2002.

[17] 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 System, Vol. 115, No. 2, pp. 205-230, 2000.

[18] D. E. Box and G. M. Jenkins, Time Series Analysis, Forecasting and Control, California: Holden Day, 1976.

[19] H. S. Park, S. K. Oh, and Y. W. Yoon, “A new modeling approach to fuzzy-neural networks architecture,” J. Cont. Automat. Syst. Eng. Vol. 7, pp. 664-674, 2001.

[20] J. Nie, A. P. Loh, and C. C. Hang, “Modeling pH neutralization processes using fuzzy-neural approaches,” Fuzzy Sets and Systems, Vol. 78, pp. 5-22, 1996.

[21] 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.

[22] W. Pedrycz and K. C. Kwak, “The development of incremental models,” IEEE Trans. Fuzzy Systems, Vol. 15, No. 3, pp. 507-518, 2007.

[23] W. Pedrycz, H. S. Park, and S. K. Oh, “A granular-oriented development of functional radial basis function neural networks,” Neurocomputing, Vol. 72, No. 1-3, pp. 420-435, 2008.

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

저 자 소 개



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 산업기술연구소 학술연구교수. 관심분야는 퍼지추론시스템, 신경 회로망, 퍼지-신경 회로망, 진화론적 최적화 알고리즘, 입자컴퓨팅, 뉴로퍼지컴퓨팅, 진화컴퓨팅등의 컴퓨터지능.
Tel : 031-222-6544
Fax : 031-220-2667
E-mail : parkhs@suwon.ac.kr



김 기 상 (金 基 祥)

2009년 수원대학교 전기공학과 졸업. 2009~현재 동 대학원 석사과정. 관심분야는 퍼지추론 시스템, 뉴럴 네트워크, Granular Computing, 진화론적 최적화 알고리즘.
Tel : 031-222-6544
Fax : 031-220-2667
E-mail : kskim@suwon.ac.kr



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 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 컴퓨터 지능, 지능제어.
Tel : 031-229-8162
Fax : 031-220-2667
E-mail : ohsk@suwon.ac.kr