

# HCM 클러스터링에 의한 다중 퍼지-뉴럴 네트워크 동정과 유전자 알고리즘을 이용한 이의 최적화

## Multi-FNN Identification by Means of HCM Clustering and Its Optimization Using Genetic Algorithms

오성권 · 박호성

Sung-Kwun Oh and Ho-Sung Park

원광대학교 전기전자공학부

### 요 약

본 논문에서는, HCM 클러스터링 방법과 유전자 알고리즘을 이용하여 다중 FNN 모델을 동정하고 최적화 한다. 제안된 다중 FNN은 Yamakawa의 FNN을 기본으로 하며, 퍼지 추론 방법으로 간략 추론을, 학습으로는 오류 역전파 알고리즘을 사용한다. 다중 FNN 모델의 구조와 파라미터를 동정하기 위해 HCM 클러스터링과 유전자 알고리즘을 사용한다. 여기서, 시스템 모델링을 위해 데이터 전처리 기능을 수행하는 HCM 클러스터링 방법은 I/O 프로세서 공정 데이터를 이용하여 입출력 공간분할에 의한 다중 FNN 구조를 결정하기 위해 사용된다. 또한 유전자 알고리즘을 사용하여 멤버쉽함수의 정점, 학습율, 모멘텀 계수와 같은 다중 FNN 모델의 파라미터들을 동조한다. 모델의 근사화와 일반화 능력 사이에 합리적 균형을 얻기 위해 하중계수를 가진 합성 성능지수를 사용한다. 이 합성 성능지수는 근사화 및 예측 능력사이의 상호 균형과 의존성을 고려한 하중계수를 가진 합성 목적함수를 의미한다. 데이터 개수, 비선형성의 정도에 의존하는 이 합성 목적함수의 하중계수의 선택, 조절을 통하여 최적의 다중 FNN 모델을 설계하는 것이 유용하고 효과적임을 보인다. 제안된 모델의 성능 평가를 위하여 가스로 공정의 시계열 데이터와 비선형 함수의 수치 데이터를 사용한다.

### ABSTRACT

In this paper, the Multi-FNN(Fuzzy-Neural Networks) model is identified and optimized using HCM(Hard C-Means) clustering method and genetic algorithms. The proposed Multi-FNN is based on Yamakawa's FNN and uses simplified inference as fuzzy inference method and error back propagation algorithm as learning rules. We use a HCM clustering and Genetic Algorithms(GAs) to identify both the structure and the parameters of a Multi-FNN model. Here, HCM clustering method, which is carried out for the process data preprocessing of system modeling, is utilized to determine the structure of Multi-FNN according to the divisions of input-output space using I/O process data. Also, the parameters of Multi-FNN model such as apexes of membership function, learning rates and momentum coefficients are adjusted using genetic algorithms. A aggregate performance index with a weighting factor is used to achieve a sound balance between approximation and generalization abilities of the model. The aggregate performance index stands for an aggregate objective function with a weighting factor to consider a mutual balance and dependency between approximation and predictive abilities. According to the selection and adjustment of a weighting factor of this aggregate objective function which depends on the number of data and a certain degree of nonlinearity, we show that it is available and effective to design an optimal Multi-FNN model. To evaluate the performance of the proposed model, we use the time series data for gas furnace and the numerical data of nonlinear function.

### 1. 서 론

우리가 시스템을 설계할 때 항상 문제가 되는 것은 복잡성과 불확실성이며 이에 대처하는 방법에 따라 설계한 대상의 기능에 대한 성능이 가려진다. 이러한 비

선형 공정에 대한 복잡성과 불확실성을 제어하기 위해 퍼지 이론과 신경망과 같은 지능형 모델에 대해 많은 연구가 이루어지고 있다.

최근에는 이러한 퍼지이론[1]과 신경망을 상호 융합한 지능형 모델 즉 퍼지-뉴럴 네트워크에 관한 많은 연구가 진행되고 있다. 이 구조는 시행착오와 전문가의 도움 없이 동적으로 변화하는 환경에 적응적으로

이 논문은 2000년도 원광대학교의 교비지원에 의해서 연구됨.

대처할 수 있도록 인간의 언어 및 사고에 관련된 애매함을 수리적으로 취급이 가능한 퍼지 이론과 학습 능력을 가진 신경망을 융합한 구조이다. 이들 대부분의 퍼지-뉴럴 네트워크모델은 찾고자 하는 퍼지 변수들의 일부를 신경망의 학습 연결 가중치로 표현하여 문제점을 해결하고자 하였다. Takagi, Hayashi[2] 등은 신경망으로 구동되는 퍼지추론을 제안하였으나 입출력 수가 적은 경우 그 효과가 미미하고, 전반부가 신경망으로 특성화된 함수로 구성되어 기존의 퍼지 추론보다 시스템표현에 있어서 정성적으로 이해하기가 힘들다는 단점을 가지고 있다. Horikawa [12]는 퍼지-뉴럴 네트워크에 의한 합성방법과 동정에 관한 연구를 하였는데, 이 경우에는 퍼지규칙의 전반부인 시그모이드 형태의 멤버쉽함수 초기치 선정이 어렵고, 최적성능으로의 수렴특성이 나쁘다. Imasaki[4]는 퍼지규칙이 전반부 네트워크, 추론네트워크, 후반부 네트워크로 구성된 구조화된 신경망을 제안하였으나, 추론네트워크의 추가학습에 의해 오랜 학습시간과 튜닝의 단점이 있다. Nomura[5]는 델타규칙에 의한 퍼지 추론의 자동동조 방법을 제안하였는데 학습에 의한 튜닝으로 각 규칙마다 멤버쉽함수가 변형되므로 퍼지규칙 수가 증가하며, 입출력수가 증가함에 따라 더 많은 퍼지 규칙수가 요구되는 단점을 가지고 있다.

본 논문에서는 Yamakawa[6,7]에 의해 제안된 퍼지-뉴럴 네트워크모델을 단일 FNN 구조로 사용한다. 비선형적이고 복잡한 실 시스템의 데이터 특성을 해석하는데 HCM 클러스터링 알고리즘을 이용한 입출력 데이터의 전처리 과정을 수행함과 동시에 데이터 특성 분류에 따른 각 네트워크모델 구조의 최적화를 위해 GA를 이용한 다중 FNN 구조를 생성함으로써 단일 퍼지-뉴럴 네트워크모델의 한계성을 극복하고자 한다. 즉 HCM 클러스터링 알고리즘에 의해 데이터를 서로 유사한 특성을 가진 그룹으로 분류하고, 분류된 그룹은 다중 퍼지-뉴럴 네트워크 각각의 모델에 입력이 되어 출력하게 된다. 또한 유전자 알고리즘[8,9]에 의해 퍼지-뉴럴 네트워크의 멤버쉽함수 정점과 학습을 그리고 모멘텀 계수를 최적으로 동조한다. 더 나아가 학습 데이터 및 테스트 데이터를 고려한 퍼지-뉴럴 네트워크 모델의 성능 즉 근사화 및 일반화 능력 모두를 고려한 성능결과를 위해 하중 계수를 가진 합성 목적함수를 사용한다. 상호 균형과 의존성을 고려한 합성 목적함수의 하중계수 선택과 조절을 통하여 공정시스템의 최적모델을 구축하고자 한다. 제안된 모델은 가스로 공정[10]과 비선형 함수를 이용한 수치 데이터[11]를 사용하여 성능을 평가하며, 기존 방법과 비교하여 우수한 모델을 구축할 수 있음을 보여준다.

## 2. 다중 FNN(Fuzzy Neural-Networks)

### 2.1 기본 FNN(Fuzzy Neural-Networks) 구조

퍼지-뉴럴 네트워크 구조는 퍼지이론의 언어적 논리를 규칙의 형태로 표현할 수 있는 능력과 신경망의 오류 역전파 알고리즘을 사용한 학습기능이 서로 결합한 형태로서, 본 논문에서 제안한 다중 퍼지-뉴럴 네트워크의 기본 모델은 그림 1에서 보여준 바와 같이 다른 모델에 비해서 학습속도가 빠르고, 수렴특성이 매우 우수하다는 장점을 가진 각 입력변수에 따른 퍼지 입력공간분할에 의한 기본 FNN[6,7]구조를 사용한다.

그림 1에서  $x_i$ 는 HCM 클러스터링에 의해 데이터의 특성 즉, 데이터들간의 거리를 기준으로 분류된 입력으로써, 각 퍼지-뉴런에 입력된 신호  $x_i$ 는 퍼지-뉴런의 특성을 나타내는 비선형함수  $f_i$ 에 의해 출력  $f_i(x_i)$ 을 생성한다. 비선형 함수  $f_i$  즉, 각 퍼지-뉴런에서 입력 신호  $x_i$ 는 각 멤버쉽함수를 거쳐 적합도가 구해지고, 적합도는 연결 가중치와 곱해지며 이들이 대수적으로 합해져  $n$ 번째 퍼지-뉴런의 출력이 된다. 각 퍼지-뉴런에서 출력된 값들은 식 (1)과 같이 모두 대수적으로 합해져  $\hat{y}$ 을 최종적으로 출력하게 된다.

$$\hat{y} = f_1(x_1) + f_2(x_2) + \dots + f_m(x_m) = \sum_{i=1}^m f_i(x_i) \quad (1)$$

여기서,  $m$ 은 퍼지-뉴런의 수이다.

각각의 퍼지-뉴런( $f_i$ )의 내부구조는 퍼지규칙을 이루고 있으며 그 규칙은 식 (2)와 같은 간략추론 방법을 이용한다.

$$R^j: \text{IF } x_i \text{ is } A_{ij} \text{ Then } y_j = w_{ij} \quad (2)$$

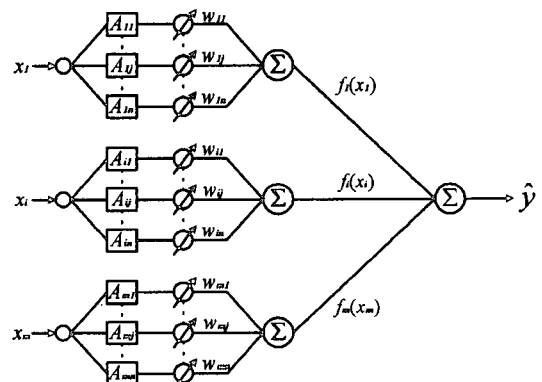


그림 1. 기본 퍼지-뉴럴 네트워크 구조  
Fig. 1. Basic FNN structure

식 (2)에서  $R$ 는  $j$ 번째 퍼지규칙을 나타내며,  $A_{ij}$ 는 전반부의 퍼지변수이고 멤버쉽함수  $\mu_p$ 로 표현된다. 후반부의  $w_{ij}$ 는 상수이며, 그림 1에서 나타내듯이 연결 가중치를 나타낸다.

$x_i$ 에서  $f_i(x_i)$ 로의 사상(mapping)은 퍼지추론과 비퍼지화에 의해 이루어진다. 식 (2)의 최종 추론결과는 식 (3)과 같다. 이 식은 무게 중심법(center of gravity)에 의한 비퍼지화(defuzzification) 과정까지 포함한다.

$$f_i(x_i) = \frac{\sum_{j=1}^n \mu_{ij}(x_i) \cdot w_{ij}}{\sum_{j=1}^n \mu_{ij}(x_i)} \quad (3)$$

입력변수  $x_i$ 는 보수적(complementary)인 특성에 의해 동시에 두개의 멤버쉽함수  $k, k+1$ 에만 영향을 받기 때문에 식 (3)은 다음과 같이 다시 쓸 수 있다.

$$f_i(x_i) = \frac{\mu_{ik}(x_i) \cdot w_{ik} + \mu_{ik+1}(x_i) \cdot w_{ik+1}}{\mu_{ik}(x_i) + \mu_{ik+1}(x_i)} \quad (4)$$

보수적 관계를 가지는 2개의 이웃하는 멤버쉽함수의 입력변수에 대한 적합도 합은 언제나 1이 되므로,  $\mu_{ik}(x_i) + \mu_{ik+1}(x_i) = 1$ 이 된다. 따라서, 식 (5)와 같이 쓸 수 있다.

$$f_i(x_i) = \mu_{ik}(x_i) \cdot w_{ik} + \mu_{ik+1}(x_i) \cdot w_{ik+1} \quad (5)$$

이와 같은 특징 때문에 추론속도가 증가하는 효과를 얻을 수 있다.

퍼지-뉴럴 네트워크의 학습은 그림 1의 멤버쉽함수 뒷부분에 위치하는 연결 가중치를 모델에 가장 적절한 값으로 조정해 나가면서 이루어진다. 학습방법으로는 오류 역전파 알고리즘이 사용되는데, 이는 최종출력과 원 출력 데이터간의 차, 즉 오차를 바탕으로 이루어진다. 본 논문에서는 식 (6)과 같은 형태의 출력 오차를 사용한다[7].

$$E_p = (y_p - \hat{y}_p)^2 \quad (6)$$

여기서  $E_p$ 는 각 데이터에 대한 오차를 의미하며,  $y_p$ 는 주어진 출력 데이터,  $\hat{y}_p$ 는 모델의 출력 데이터를 나타낸다.  $m$ 개의 입출력 데이터 쌍이 주어진 경우, 퍼지-뉴럴 네트워크의 최종 출력 오차는 식 (7)과 같이 된다.

$$E = \frac{1}{m} \sum_{p=1}^m E_p \quad (7)$$

연결 가중치의 조절은 식 (8)과 같이 기존값과 오차로부터 구해진 조절량 만큼의 변화를 더해주면 된다.

$$w(new) = w(old) + \Delta w \quad (8)$$

오차  $E_p$ 를 최소화하기 위한 연결 가중치의 변화량  $\Delta w$ 는 식 (9)에서 보이는 것처럼 경사강하법(gradient descent method)을 이용하여 구할 수 있다.

$$\Delta w_{ij} = \eta \left( -\frac{\partial E_p}{\partial w_{ij}} \right) \quad (9)$$

여기서,  $\eta$ 는 학습율이다.

식 (9)에서 우변의 편미분은 사슬법칙(chain rule)에 의해 식 (10)과 같이 세 부분으로 전개될 수 있다.

$$-\frac{\partial E_p}{\partial w_{ij}} = -\frac{\partial E_p}{\partial y_p} \cdot \frac{\partial \hat{y}_p}{\partial f_i(x_i)} \cdot \frac{\partial f_i(x_i)}{\partial w_{ij}} \quad (10)$$

식 (10)에서 우측 식의 각 항은 다음 식 (11)~(13)과 같이 유도된다.

$$-\frac{\partial E_p}{\partial y_p} = 2(y_p - \hat{y}_p) \quad (11)$$

$$\frac{\partial \hat{y}_p}{\partial f_i(x_i)} = 1 \quad (12)$$

$$\frac{\partial f_i(x_i)}{\partial w_{ij}} = \mu_{ij}(x_i) \quad (13)$$

그러므로 변화량,  $\Delta w_{ij}$ 는 식 (11)~(13)으로부터 식 (14)와 같이 된다.

$$\Delta w_{ij} = 2 \cdot \eta \cdot (y_p - \hat{y}_p) \cdot \mu_{ij}(x_i) \quad (14)$$

여기에 모멘텀을 더해 학습시간을 좀 더 단축시키고, 또한 학습성능을 향상시킨다. 모멘텀은 식 (15)와 같이 현재의 연결 가중치와 그 이전 연결 가중치의 차이에 의해 계산된다.

$$m(t) = w(t) - w(t-1) \quad (15)$$

이렇게 계산된 모멘텀은 모멘텀 계수라 불리는  $\alpha$ 와 곱해져 연결 가중치 조절식에 추가된다. 모멘텀 까지 포함하는 연결 가중치의 최종 조절식은 식 (16)과 같다.

$$\Delta w_{ij} = 2 \cdot \eta \cdot (y_p - \hat{y}_p) \cdot \mu_{ij}(x_i) + \alpha(w_{ij}(t) - w_{ij}(t-1)) \quad (16)$$

## 2.2 다중 FNN 구조

제한한 다중 FNN 구조는 HCM 클러스터링을 이용하여 데이터 각각의 거리를 기준으로 서로 유사한 특성을 가진 그룹으로 데이터를 분류하여 특성에 맞




그림 2. 다중 퍼지-뉴럴 네트워크의 구조  
Fig. 2. Multi-FNN structure

는 각각의 퍼지-뉴럴 네트워크를 구축한 것이다. HCM 클러스터링에 의해 분류된 전체 클러스터 수는 그림 2와 같이 다중 퍼지-뉴럴 네트워크를 구성하기 위한 기본 모델의 수가 되고, 분류된 데이터 집합들은 각각 기본 모델의 입력이 되어 단일 퍼지-뉴럴 네트워크모델의 기능을 수행하게 된다.

따라서, 병렬로 연결되어 있는 각각의 퍼지-뉴럴 네트워크의 구조는 각 입력변수에 따른 퍼지 입력공간 분할에 의한 단일 기본 FNN 구조로, 단지 입력이 서로 유사한 특성을 가지는 데이터들의 집합으로 이루어져 특성에 맞는 모델을 구축할 수 있다. 그림 2에서의 Cluster 1, ..., Cluster n은 HCM 클러스터링에 의해 분류되고, 이 분류된 입·출력군으로부터 입력 Input 1, ..., Input n과 출력 Output 1, ..., Output n을 얻을 수 있다.

### 2.3 HCM 클러스터링 방법

본 논문에서는 클러스터링 알고리즘중 데이터들간의 거리를 기준으로 근접한 정도를 측정하고, 이를 바탕으로 데이터를 특성별로 분류하는 HCM 클러스터링을 이용하여 데이터들의 특성을 파악한다. 주어진 데이터 분류는 먼저 HCM 클러스터링에 의해 학습 데이터를 분류하고, 분류된 학습 데이터의 중심에 의해 테스트 데이터를 분류한다.

HCM 클러스터링에 의한 학습 데이터 분류는 다음과 같다.

[단계 1] 클러스터의 개수 ( $2 \leq c \leq n$ )를 결정하고, 소속행렬  $U$ 를  $U^{(0)} \in M_c$ 으로 초기화한다.

$$M_c = \left\{ U \mid u_{ij} \in \{0, 1\}, \sum_{i=1}^c u_{ik} = 1, 0 < \sum_{k=1}^n u_{ik} < n \right\} \quad (17)$$

여기서,  $u_{ij}$ 는 소속행렬의 파라미터,

[단계 2] 각각의 클러스터에 대한 중심벡터  $V_i$ 를 구한다.

$$V_i = \{v_{i1}, v_{i2}, \dots, v_{ij}, \dots, v_{im}\} \quad (18)$$

$$v_{ij} = \frac{\sum_{k=1}^n u_{ik} \cdot x_{ki}}{\sum_{k=1}^n u_{ik}}$$

여기서,  $i$ 는  $i$ 번째 클러스터,  $j$ 는  $j$ 번째 입력 변수( $j = 1, \dots, m$ ),  $n$ 은 data 수.

[단계 3] 각각의 클러스터 중심과 데이터와의 거리를 계산하여 새로운 소속행렬  $U^{(r)}$ 을 생성한다.

$$d_{ik} = d(x_k - V_i) = \|x_k - V_i\| = \left[ \sum_{j=1}^m (x_{kj} - v_{ij})^2 \right]^{1/2} \quad (19)$$

$$u_{ik}^{(r+1)} = \begin{cases} 1 & d_{ik}^{(r)} = \min\{d_{jk}^{(r)}\} \text{ for all } j \in c \\ 0 & \text{otherwise} \end{cases} \quad (20)$$

여기서,  $d_{ik}$ 는  $k$ 번째 데이터 sample  $x_k$ 와  $i$ 번째 클러스터 중심  $V_i$ 의 기하학적 거리

[단계 4] 만일 식 (21)을 만족한다면 종료하고, 그렇지 않으면  $r = r + 1$ 로 놓고 [단계 2]로 간다.

$$\|U^{(r+1)} - U^{(r)}\| \leq \epsilon \quad (\text{tolerance level}) \quad (21)$$

위 단계를 걸쳐 학습 데이터를 데이터의 특성에 맞게 각각의 그룹으로 분류한다. 분류된 각 학습 데이터 그룹의 중심 벡터에 의해 각각의 테스트 데이터와의 거리를 식 (19)에 의해 계산하고, 각각의 테스트 데이터는 가장 가까운 위치에 있는 학습 데이터 그룹의 중심 벡터에 의해 데이터를 분류한다. 여기에서  $V_i$ 는 학습 데이터의 중심값이지만, 여기서  $x_k$ 는 학습 데이터를 분류할 때는 학습 데이터가 사용되고, 테스트 데이터를 분류할 때는 테스트 데이터가 사용된다. 분류된 데이터는 각각의 FNN모델에 의해 모델링된다.

그림 3은 학습 데이터와 테스트 데이터가 분류되는

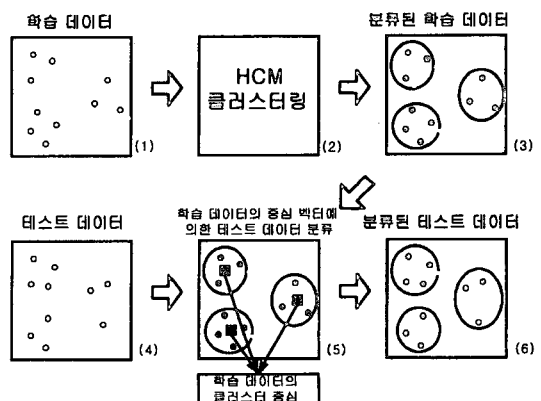


그림 3. 학습·테스트 데이터 분류  
Fig. 3. Classification of training and testing data

과정을 그림으로 표현한 것이다.

그림에서 (1)-(3)번까지는 HCM 클러스터링에 의해서 학습 데이터가 분류된 과정을 보여주며, (5)번 그림은 테스트 데이터를 분류된 학습 데이터의 클러스터 중심을 기준으로 분류되는 과정을 나타내며, 최종적으로 (6)번 그림과 같이 테스트 데이터가 분류된다.

### 3. 최적화를 위한 유전자 알고리즘과 합성 성능지수

본 논문에서는 최적의 다중 FNN 구조를 생성하기 위해서, HCM 클러스터링을 이용하여 분할된 데이터 그룹으로부터 각각의 FNN 모델을 구축하고, 구축된 각각의 FNN 모델은 유전자 알고리즘에 의해 멤버쉽 함수의 정점, 학습을 그리고 모멘텀 계수를 최적으로 동조한다. 또한 하중계수를 가진 합성 성능지수를 이용하여 각각의 FNN 구조에 대한 예측성능을 향상시킨다.

#### 3.1 유전자 알고리즘

유전자 알고리즘은 자연 선택과 유전학에 기반으로 하는 확률적인 탐색방법으로써 탐색과 해의 가능영역들을 균형있게 이용하기 위하여 생산, 교차, 돌연변이의 과정을 수행하는 일반성 있는 탐색법으로 비선형 최적화 이론에 탁월한 성능을 발휘하고 있다[8,9].

본 논문에서는 다중 퍼지-뉴럴 네트워크 각각의 모델에 대한 멤버쉽함수의 정점과 학습율, 모멘텀계수를 최적으로 설정해 주기 위하여 유전자 알고리즘을 이용하여 모델의 최적화 과정을 수행하게 된다. 제안한 모델의 최적화를 위하여 사용된 유전자 알고리즘은 각 염색체를 그림 4와 같이 모두 하나의 개체 안

변수 :  $a_{low}, b_{high}, a_{low}, b_{high}$ , 학습율, 모멘텀계수

염색체 : 

10 bit	10 bit	10 bit	10 bit	10 bit	10 bit
--------	--------	--------	--------	--------	--------

그림 4. 모델 최적화를 위한 유전자 알고리즘의 데이터 구조  
Fig. 4. Data structure of genetic algorithms for optimization of model

표 1. 유전자 알고리즘의 파라미터  
Table 1. Parameters of genetic algorithm

Population size	60
Maximum generation	100
Crossover rate	0.6
Mutation rate	0.35

에 연결해 사용한다. 염색체(변수)는 10 bit로 정의하고, 개체가 탐색할 때 사용되는 하나의 지점을 의미한다. 동시에 여러 점을 탐색하기 위해 개체를 동시에 여러 개 사용되는데 이를 군집이라 한다. 개체에 존재하는 염색체의 수와 군집의 크기는 표 1과 같이 정의하였고, 한 개체에 여러 변수의 정보를 담은 직렬 방식을 사용한다. 선택(selection)연산으로 roulette-wheel방식, 교차(crossover)연산은 one-crossover방식, 돌연변이연산은 선택된 비트를 반전시키는 invert방식을 사용하였다.

#### 3.2 합성 성능지수

본 논문에서는 주어진 학습 데이터를 이용하여 퍼지-뉴럴 네트워크 모델을 구축하고 테스트 데이터를 사용하여 모델을 평가하기 위하여 근사화 및 일반화의 상호 균형과 의존 능력을 가진 합성 목적 함수(성능지수)를 이용하여 상호 연계된 최적 모델 구조를 생성한다[13]. 이를 위해 학습 및 테스트 데이터의 성능 결과에 대한 하중계수를 가진 목적함수인 합성 성능지수로써 식 (22)와 같이 정의한다.

$$f(PI, E\_PI) = \theta \times PI + (1 - \theta) \times E\_PI \quad (22)$$

$\theta$ 는  $PI$ 와  $E\_PI$ 에 대한 하중계수를 나타내고,  $PI$ 는 학습 데이터에 대한 성능지수,  $E\_PI$ 는 테스트 데이터에 대한 성능지수를 나타낸다. 그리고 목적함수는 모델의 성능향상이 최적이 되도록 하기 위해 각각의 퍼지-뉴럴 네트워크의 멤버쉽함수의 정점들과 학습율, 모멘텀 계수들은 유전자 알고리즘에 의해 조절된다. 식 (22)와 같이 정의한 하중계수를 가진 목적함수는 하중계수의 설정에 따라 다음과 같은 특징을 가진다.

$\alpha \in [0, 1]$ 에 대해서  $\theta = \alpha$ 이면 학습과 테스트 모두를 포함하고,  $\alpha$ 의 선택은 모델의 근사화와 일반화 사이에서 상호 균형에 의한 최적화를 시도한다. 이 의미는 학습 데이터에 의한 퍼지-뉴럴 네트워크 모델의 성능지수  $PI$ 를 구하고, 학습 데이터에 의해 생성된 퍼지-뉴럴 네트워크에 테스트 데이터를 가하여 평가용 성능지수  $E\_PI$ 를 구하는 것이다. 구해진  $PI$ 와  $E\_PI$  각각에 하중계수  $\theta$ 와  $1 - \theta$ 를 곱한 다음, 합에 의한 목적함수  $f(\cdot)$ 을 최적화시키는 방향으로 모델의 파라미터를 동조함으로써 최적 퍼지-뉴럴 네트워크를 구축한다. 이것은 모델 자체의 근사화 능력과 일반화 능력을 상호 고려한 목적함수의 형태로 적절한 하중계수 설정에 따라 최적 퍼지-뉴럴 네트워크 모델을 구축할 수 있다[13].

### 4. 실험적 연구

#### 4.1 가스로 공정


제안된 다중 FNN의 성능을 평가하기 위해서 가스로 시계열 데이터를 이용하였다. Box와 Jenkins[10]에 의해 사용된 가스로 시계열 데이터는 입출력 데이터인 가스 흐름율과 연소된 이산화탄소 농도의 가스로 공정으로부터 추출된다. 메탄가스 흐름율( $X(t)$ )은 실험에서 -2.5에서 2.5로 변하는 것을 사용하나 실제 공정에서의 메탄가스 흐름율 ( $X_m(t)$ )은 식 (23)에 의해 0.5에서 0.7로 변한다.

$$X_m(t) = 0.6 - 0.048 \times X(t) \quad (23)$$

입력( $u(t)$ )은 가스 흐름율이고 출력( $y(t)$ )은 이산화탄소 농도인 1입력 1출력의 가스로 시계열 데이터 296쌍을 시뮬레이션 하기 위해 균일한 입출력 분포구조 [16]를 가지는 입력  $u(t-3)$ ,  $y(t-1)$ 과 출력  $y(t)$ 의 2입력 1출력으로 설정하여 사용한다. 또한 입력 데이터의 집합을 학습과 테스트 데이터로 나누어 퍼지-뉴럴 네트워크를 모델링하고 유전자 알고리즘을 사용하여 모델을 최적화한다. 성능 평가 기준인 PI (Performance Index)는 오차의 제곱에 대한 평균을 구하는 식 (24)와 같은 형태인 MSE(Mean Squared Error)를 이용한다.

$$PI = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (24)$$

그림 5는 가스로 데이터를 HCM 클러스터링으로 분류했을 때, 4개의 클러스터로 입출력 데이터를 분할한 것이다. 테스트 데이터에 대한 데이터의 분할은 학습 데이터의 중심을 기반으로 나누어지므로 그림 5에서 보여지듯이 학습 데이터는 4개로 나누어지지만 테스트 데이터는 3개의 클러스터로 나누어짐을 알 수



(a) 학습 데이터 (b) 테스트 데이터

그림 5. HCM 방법에 의해 분류된 가스로 데이터  
Fig. 5. Classified Gas furnace data by HCM method

있습니다. 즉, 학습 데이터 제 4집단의 중심값을 기반으로 한 테스트 데이터가 존재하지 않으므로 3개의 테스트 데이터 집단으로 나누어진다.

그림 5에서  $x$ 축( $u(t-3)$ )과  $y$ 축( $y(t-1)$ )은 데이터의 입력을 나타내고 각 집단에서의 명암은 데이터의 출력( $y(t)$ )을 나타낸다. 명암에 있어서는 농도가 진할수록 데이터의 출력값( $y(t)$ )이 작고 연할수록 데이터의 출력값( $y(t)$ )이 큰 것을 의미한다.

표 2에서는 가스로 데이터를 2개의 클러스터로 나누었을 때, HCM 클러스터링을 통한 데이터의 특성을 고려해서 얻은 결과와 임의로 데이터를 균등 분할한 후 얻은 결과를 비교한 것이다. 이 결과로부터 알 수 있듯이, HCM clustering을 이용한 데이터 분할에 의해 우수한 성능의 다중 FNN 구조를 생성할 수 있다.

그림 6은 표 2에서 나타난 입출력 데이터의 분할방

표 2. 클러스터 개수( $c=2$ )에서의 성능지수  
Table 2. Performance Index of the number of Cluster,  $c=2$

		(a) 임의의 데이터 분할					
		다중 FNN				최종 결과	
입력	$\theta$	FNN 1		FNN 2		PI	E_PI
		PI	E_PI	PI	E_PI		
$u(t-3)$ $y(t-1)$	0.0	0.282	0.527	0.522	0.422	0.402	0.474
	0.25	0.290	0.517	0.411	0.436	0.351	0.476
	0.5	0.285	0.504	0.390	0.437	0.337	0.470
	0.75	0.270	0.530	0.367	0.476	0.318	0.503
	1.0	0.268	10.882	0.365	0.481	0.316	5.681
		(b) HCM clustering에 의한 데이터 분할					
		다중 FNN				최종 결과	
입력	$\theta$	FNN 1		FNN 2		PI	E_PI
		PI	E_PI	PI	E_PI		
$u(t-3)$ $y(t-1)$	0.0	0.059	0.312	0.133	0.253	0.100	0.297
	0.25	0.052	0.306	0.049	0.257	0.050	0.293
	0.5	0.023	0.320	0.027	0.263	0.025	0.305
	0.75	0.020	0.325	0.023	0.268	0.021	0.310
	1.0	0.020	0.323	0.021	0.293	0.020	0.317




그림 6. 데이터 분할방법에 의한 다중 FNN의 성능지수  
Fig. 6. Performance index of Multi-FNN according to the division methods of data set

법에 의해 하중계수  $\theta$ 에 따른 학습 및 테스트 입출력 데이터군에 의한 모델의 성능지수를 그래프로 표시한 것이다.

표 2와 그림 6에서 알 수 있듯이 HCM 클러스터링을 통한 성능이 임의로 분할해서 얻은 성능보다 월등히 우수함을 알 수 있으며, 따라서 데이터의 특성을 해석하고 특성에 따른 체계적이고 효율적인 모델을 구축하는데 있어서 HCM 클러스터링을 통한 모델 구축이 우수함을 알 수 있다.

표 3에서는 HCM 클러스터링을 통해 얻은 클러스터 개수와 하중계수  $\theta$ 에 따른 다중 FNN의 성능지수를 나타낸다. 각 입력에 따른 멤버십함수를 3개로 하여, 하중계수  $\theta$ 의 설정에 따라 FNN모델의 멤버십함수의 파라미터들과 학습율, 모멘텀 계수를 유전자 알고리즘에 의해 자동 동조함으로써 근사화 능력과 일반화 능력을 가진 최적 FNN모델의 성능지수를 구한 것이다. 표 3에서 보여지는 것처럼 HCM 클러스터링을 이용한 다중 FNN모델이 기존 FNN모델보다 학습 성능 및 테스트 성능이 향상됨을 알 수 있었고, 따라서 본 논문에서 제안한 방법이 데이터의 특성을 반영함으로써 좀 더 우수한 모델을 구축할 수 있음을 알 수 있다. 클러스터를 증가할수록 어느정도 학습 성능은 데이터의 압축성이 높아져 모델에서는 좋은 결과를 얻지만, 본 논문에서의 궁극적인 목적은 학습 성능을 최소화시키는 것이 아니라 설계자의 의도, 데이터 분포에 따른 비선형성 및 주어진 시스템에서 요구되는 특성에 따라, 학습 성능 및 테스트 성능을 상호 고려한 하중계수 및 클러스터 수 조절을 통하여 최적 모델을 생성하고자 한다. 표 3의 수치적 결과와 그림 7에서 보여진 바와 같이 다중 FNN모델에서 클러스터 수 증가에 따른 학습 성능과 테스트 성능 모두를 고려할 때, 클러스터의 개수가 4개 일 때 다른 클러스터 개수보다 향상된 성능지수값을 얻을 수 있음을 알 수 있다.

그림 7은 표 3에서 나타난 단일 FNN과 다중




그림 7. 하중계수  $\theta$ 에 따른 다중 FNN의 성능지수  
Fig. 7. Performance index of Multi-FNN according to weighting factor




그림 8. 유전자 알고리즘에 의한 FNN 모델의 최적화 탐색 과정( $\theta=0.5$ )  
Fig. 8. Optimal search process of FNN model by GA ( $\theta=0.5$ )

FNN의 각 클러스터 개수와 하중계수  $\theta$ 에 따른 학습 및 테스트 입출력 데이터군에 의한 각 모델의 성능지수를 그래프로 표시한 것이다.

그림 8은 클러스터 4개인 경우 하중계수  $\theta=0.5$ 로 설정한 경우, 각 클러스터의 입출력 데이터군에 의한 학습과 테스트 데이터로부터 각각의 퍼지-뉴럴 네트워크에 따른 모델의 최적화 과정을 보여준 것이다

그림 8(b)에서 모델이 3개인 이유는 그림 5에서 보았듯이 분류된 학습 데이터 중 제 4집단을 중심으로 테스트 데이터가 분포되어 있지 않기 때문이다.

표 4는 동일한 데이터를 사용하여 성능 지수를 식 (24)에 의해 계산된 값으로 다른 동정된 모델과 성능 비교를 나타낸다. 이 표에 의하면 본 논문에서 제안한 HCM 클러스터링으로 입출력 데이터를 분류하여 클러스터 개수를 결정하고, 결정된 개수를 기본으로 다

표 3. 클러스터 개수에 따른 성능지수  
Table 3. Performance Index according to the number of Cluster

입력	$\theta$	단일 FNN		다중 FNN							
				클러스터 2		클러스터 3		클러스터 4		클러스터 5	
		PI	E_PI	PI	E_PI	PI	E_PI	PI	E_PI	PI	E_PI
$u(t-3)$ $y(t-1)$	0.0	0.062	0.275	0.100	0.297	0.135	0.275	0.072	0.268	0.048	0.265
	0.25	0.077	0.272	0.050	0.293	0.038	0.286	0.046	0.272	0.030	0.269
	0.5	0.032	0.288	0.025	0.305	0.023	0.293	0.025	0.274	0.020	0.279
	0.75	0.026	0.304	0.021	0.310	0.020	0.301	0.018	0.289	0.018	0.291
	1.0	0.022	0.338	0.020	0.317	0.018	0.349	0.017	0.309	0.015	0.338

표 4. 기존 모델과 동정오차 비교

Table 4. Comparison of identification errors with conventional models

모델		PI	E_PI
Fuzzy model [13,14](Complex)	Simplified	0.024	0.328
	Linear	0.021	0.364
Fuzzy model[15] (GA)	Simplified	0.022	0.333
Adaptive FNN model[16]		0.021	0.332
	GA	0.026	0.304
FNN model[17]	HCM+GA	0.032	0.276
	$\theta = 0.5$	0.032	0.288
단일 FNN	$\theta = 1.0$	0.020	0.323
	$\theta = 0.5$	0.025	0.274
Our model	$\theta = 1.0$	0.017	0.309

중 퍼지-뉴럴 네트워크를 구축한 후 유전자 알고리즘과 하중계수를 가진 목적함수를 통해 얻은 결과가 기존 모델뿐만 아니라 단일 FNN 모델에 비해서 학습 성능 및 테스트 성능이 향상됨을 알 수 있었고, 또한 본 논문에서 제안한 방법이 데이터의 특성을 반영함으로써 좀 더 최적화된 모델을 구축할 수 있었다.

4.2 비선형 함수

본 논문에서 제안한 모델의 적용 및 유용성을 비교 평가하기 위해 식 (25)로 표현되어지는 비선형 함수에 의해서 얻어진 40개의 입출력 데이터 쌍을 사용해서 처음 20개의 데이터는 학습 데이터로 나머지 20개 데이터는 테스트 데이터로 사용하여 모델의 성능을 평가하였다[11,12].

$$y = (1 + x_1^{0.5} + x_2^{-1} + x_3^{-1.5})^2 \tag{25}$$

비선형 함수 대한 성능지수는 식 (26)와 같이 APE(Average Percentage Error)를 이용하였다.

$$PI = \frac{1}{m} \sum_{i=1}^m \frac{|y_i - \hat{y}_i|}{y_i} \times 100(\%) \tag{26}$$

표 5에서는 비선형 함수에 의해 얻어진 데이터를 2개의 클러스터로 나누었을 때, HCM 클러스터링을 통한 데이터의 특성을 고려해서 얻은 결과와 임의로 데이터를 반절로 나누어 얻은 결과를 비교한 것이다.

그림 9는 표 5에서 나타난 최종 결과값 즉 입출력 데이터의 분할방법에 의해 하중계수  $\theta$ 에 따른 학습 및 테스트 입출력 데이터군에 의한 모델의 성능지수를 그래프로 표시한 것이다.

표 5와 그림 9에서 알 수 있듯이 HCM 클러스터

표 5. 클러스터 개수(c=2)에서의 성능지수

Table 5. Performance Index of the number of Cluster, c=2

(a) 임의의 데이터 분할						
다중 FNN						
$\theta$	FNN 1		FNN 2		최종 결과	
	PI	E_PI	PI	E_PI	PI	E_PI
	0.0	2.648	2.961	2.321	4.501	2.485
0.25	2.654	3.008	2.139	4.607	2.397	3.807
0.5	2.539	3.079	2.451	4.549	2.495	3.814
0.75	2.126	23.86	2.262	4.382	2.194	4.123
1.0	1.948	5.586	1.969	7.215	1.959	6.400
(b) HCM Clustering에 의한 데이터 분할						
다중 FNN						
$\theta$	FNN 1		FNN 2		최종 결과	
	PI	E_PI	PI	E_PI	PI	E_PI
	0.0	1.015	1.467	3.835	0.309	2.425
0.25	0.928	1.663	1.011	0.888	0.970	1.275
0.5	0.924	1.621	0.929	1.379	0.927	1.500
0.75	0.902	1.569	0.945	1.552	0.923	1.560
1.0	0.876	1.513	0.894	1.964	0.885	1.739




그림 9. 데이터 분할방법에 의한 다중 FNN의 성능지수  
Fig. 9. Performance index of Multi-FNN according to the division methods of data set

링을 통한 성능이 임의로 분할해서 얻은 성능보다 월등히 우수함을 알 수 있으며, 따라서 데이터의 특성을 해석하고 특성에 따른 체계적이고 효율적인 모델을 구축하는데 있어서 HCM 클러스터링을 통한 모델 구축이 우수함을 알 수 있다. 더욱이 비선형 함수를 통해 얻은 데이터에 대한 성능 결과에서 볼 수 있듯이, 입출력 데이터 분포가 균일한 가스로 공정 데이터보다 더 비선형적인 특성이 강하고, 데이터 수가 적을수록 HCM 클러스터링을 통한 효과를 더욱 확실하게 얻을 수 있다.

표 6에서는 비선형 함수에 의해 얻어진 데이터를 클러스터 개수에 따른 다중 퍼지-뉴럴 네트워크 모델의 성능지수를 나타낸 것이다. 각 입력에 따른 멤버십 함수를 3개로 하여, 하중계수  $\theta$ 의 설정에 따라 FNN 모델의 멤버십함수의 파라미터들과 학습율, 모멘텀 계



표 6. 클러스터 개수에 따른 성능지수  
Table 6. Performance Index according to the number of Cluster

$\theta$	단일 FNN		다중 FNN							
			클러스터 2		클러스터 3		클러스터 4		클러스터 5	
	PI	E_PI	PI	E_PI	PI	E_PI	PI	E_PI	PI	E_PI
0.0	2.877	3.219	2.425	0.888	1.172	0.778	1.346	0.879	3.062	0.883
0.25	2.884	3.218	0.970	1.275	1.088	0.902	1.083	1.006	2.675	1.011
0.5	2.865	3.206	0.927	1.500	0.813	0.994	0.865	0.956	2.681	0.870
0.75	2.800	3.271	0.923	1.560	0.720	1.158	0.715	1.099	2.428	1.178
1.0	2.771	3.892	0.885	1.739	0.700	1.304	0.698	2.067	2.380	3.512




그림 10. 하중계수  $\theta$ 에 따른 다중 FNN의 성능지수  
Fig. 10. Performance index of Multi-FNN according to weighting factor

수를 유전자 알고리즘에 의해 자동 동조함으로써 근사화 능력과 일반화 능력을 가진 최적 FNN모델의 성능지수를 구한 것이다.

클러스터의 개수가 3개일 때 표 6의 수치적 값과 그림 10의 그래프로부터 학습과 테스트에 대한 성능지수를 상호 고려할 때 가장 향상된 모델을 생성할 수 있음을 알 수 있다.

여기서, 그림 10은 표 6에서 나타난 단일 FNN과 다중 FNN의 클러스터 개수와 하중계수  $\theta$ 에 따른 학습 데이터와 테스트 데이터 각각의 성능지수를 그림으로 그려 놓은 것이다.

그림 11은 클러스터 3개인 경우 하중계수  $\theta=0.5$ 로 설정했을 시, 각 클러스터에서 학습과 테스트 데이터에 대한 각각의 퍼지-뉴럴 네트워크에 따른 모델의 최적화 과정을 보여준 것이다.

표 7은 동일한 데이터를 사용하여 성능 지수를 식 (26)에 의해 계산된 값으로 다른 동정된 모델과 성능비교를 나타낸다. 이 표에 의하면 본 논문에서 제안한 방법이 기존 모델보다 학습 성능 및 테스트 성능이




그림 11. 유전자 알고리즘에 의한 FNN 모델의 최적화 탐색과정( $\theta = 0.5$ )

Fig. 11. Optimal search process of FNN model by GA ( $\theta = 0.5$ )

표 7. 기존 모델과 동정오차 비교

Table 7. Comparison of identification errors with conventional models

모델	PI	E_PI	
선형 모델[18]	12.7	11.1	
GMDH[3]	4.7	5.7	
Sugeno's model	model I	1.5	2.1
	model II	1.1	3.6
Shin-ichi's model	Type I	0.84	1.22
	Type 2	0.73	1.28
단일 FNN	$\theta=0.5$	2.86	3.20
	$\theta=1.0$	2.77	3.89
	$\theta=0.5$	0.813	0.994
Our model	$\theta=0.75$	0.720	1.158
	$\theta=1.0$	0.700	1.304

보다 향상됨을 알 수 있다.

표 7에서도 볼 수 있듯이 기존의 모델들은 데이터의 특성을 효과적으로 모델에 반영하지 못하나, 제안된 모델은 데이터의 특성을 반영함으로써 보다 우수한 모델을 구축할 수 있음을 보인다.

## 5. 결 론

본 논문에서는 비선형적이고 복잡한 실 시스템의 테

이터 특성을 해석하고 데이터의 특성에 따른 체계적이고 효율적인 모델을 구축하기 위하여 HCM 클러스터링과 유전자 알고리즘을 사용하여 단일 FNN의 병렬구조로써 다중 FNN을 제안한다. 제안된 모델은 기존 모델들의 단점인 데이터의 특성을 고려하지 않고 모델을 구축하는 것에서 벗어나 HCM 클러스터링 알고리즘을 이용하여 데이터의 특성에 맞는 최적의 다중 FNN 모델을 구축하였다. HCM 클러스터링을 이용한 입출력 데이터의 분포 특성에 따른 클러스터의 개수 즉, 최적의 다중 퍼지-뉴럴 네트워크를 이루는 기본 퍼지-뉴럴 네트워크의 개수를 결정함으로써 복잡하고 비선형성이 강한 공정에서 기존의 모델들 보다 성능이 월등히 향상됨을 알 수 있었다. 이 제안된 방법은 비선형 시스템의 입출력 데이터를 분석하여 데이터 상호간의 연관성을 찾아 몇 개의 병렬구조를 이루어 전체적으로 적응력을 가진 강인한 구조를 생성하는 장점이 있다. 또한 유전자 알고리즘을 이용하여 보다 체계적인 방법에 의한 객관적인 모델을 획득할 수 있었으며, 하중계수를 가진 합성 목적함수에 의해 모델의 근사화 및 일반화를 고려한 최적 다중 FNN 모델을 생성할 수 있음을 보였다.

**참고문헌**

[1] L. A Zadeh, "Fuzzy sets", *Inf. Control* 8, 338-353, 1965.

[2] H. Takagi and I. Hayashi, "NN-driven Fuzzy Reasoning", *Int. J. of Approximate Reasoning*, Vol. 5, No. 3, pp. 191-212, 1991.

[3] T. Kondo, "Revised GMDH algorithm estimating degree of the complete polynomial", *Tran. of the Society of Instrument and Control Engineers*, Vol. 22, No. 9, pp. 928-934, 1986.

[4] 今崎直樹, 木治潤一, "フアジイル\_ル構造化ニユテ ネットワ\_ク", *日本フアジイル學會誌* Vol. 4, No. 5, pp. 987-995, 1992.

[5] H. Nomura and Wakami, "A Self-Tuning Method of Fuzzy Control by Descent Methods", 4th IFSA'91. pp. 155-159, 1991.

[6] Takeshi Yamakawa, "A Neo Fuzzy Neuron and Its Applications to System Identification and Prediction of the System Behavior", *Proceedings of the 2nd International Conference on Fuzzy logic & Neural Networks*, pp. 477-483, 1992.

[7] Takeshi Yamakawa, "A New Effectie Learning Algorithm for a Neo Fuzzy Neuron Model", 5th IFSA World Congress, pp. 1017-1020, 1993.

[8] David E. Goldberg, "Genetic Algorithm in search, Optimization & Machine Learning", Addison wesley, 1989.

[9] Zbigniew Michalewicz, "Genetic Algorithms + Data Structures = Evolution Programs", Springer-Verlag, 1992.

[10] Box and Jenkins, "Time Series Analysis, Forecasting and Control", 2nd ed. Holden Day, SanFrancisco, CA, 1976.

[11] G. Kang and M. Sugeno, "Fuzzy modeling", *Trans. SICE*, Vol. 23, No. 6, pp. 106-108, 1987(in Japanese).

[12] Shin-ichi Horikawa, Takeshi Furuhashi, and Yoshiki Uchigawa, "On Fuzzy Modeling Using Fuzzy Neural Networks with the Back Propagation Algorithm", *IEEE trans. Neural Networks*, Vol. 3, No. 5, pp. 801-806, 1992.

[13] 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.

[14] C. S. Park, S. K. Oh, and W. Pedrycz, "Fuzzy Identification by means of Auto-Tuning Algorithm and Weighting Factor", *The Third Asian Fuzzy Systems Symposium(AFSS)*, pp. 701-706, 1998.

[15] 박병준, 오성권, 안태천, 김현기, "유전자 알고리즘과 하중값을 이용한 퍼지 시스템의 최적화", *대한전기학회 논문지*, 제48A권, 제6호, pp. 789-799, 1999년 6월.

[16] 오성권, 박병준, 박춘성, "적용 퍼지-뉴럴 네트워크를 이용한 비선형 공정의 온-라인 모델링", *대한전기학회 논문지*, 제48A권, 제10호, pp. 1293-1302, 1999년 10월.

[17] 오성권, 윤기찬, 김현기, "유전자 알고리즘과 합성 성능지수에 의한 퍼지-뉴럴 네트워크 구조의 최적 설계", *제어·자동화·시스템공학회*, 제6권, 제3호, pp.273-283, 2000년 3월.

[18] 菅野道夫(譯: 박민용, 최항식), "퍼지제어 시스템", *大英社*, pp. 143-158, 1990.

**오성권 (Sung-Kwun Oh)**  
 1981년 : 연세대학교 전기공학과 졸업  
 1983년~1989년 : 금성산전연구소(선임연구원)  
 1993년 : 연세대 대학원 전기공학과 졸업(공학박사)  
 1996년~1997년 : 캐나다 Manitoba대학 전기 및 컴퓨터공학과 Post-Doc

1993년~현재 : 원광대 전기·전자공학부 부교수  
 관심분야 : 시스템자동화, 퍼지이론 및 신경망 응용, 지능형 모델링 및 제어 등

**박호성 (Ho-Sung Park)**  
 1999년 : 원광대 제어계측공학과 졸업  
 1999년~현재 : 동 대학교 제어계측공학과 석사과정  
 관심분야 : 시스템자동화, 퍼지이론 및 신경망 응용, 지능형 모델링 및 제어 등