

# 정보 입자기반 연속적인 최적화를 통한 자기구성 퍼지 다항식 뉴럴네트워크 : 설계와 해석

論 文
55D-6-3

## Self-Organizing Fuzzy Polynomial Neural Networks by Means of IG-based Consecutive Optimization : Design and Analysis

朴 浩 成<sup>†</sup> · 吳 聖 權<sup>\*</sup>  
(Ho-Sung Park · Sung-Kwun Oh)

**Abstract** - In this paper, we propose a new architecture of Self-Organizing Fuzzy Polynomial Neural Networks (SOPFNN) by means of consecutive optimization and also discuss its comprehensive design methodology involving mechanisms of genetic optimization. The network is based on a structurally as well as parametrically optimized fuzzy polynomial neurons (FPNs) conducted with the aid of information granulation and genetic algorithms. In structurally identification of FPN, the design procedure applied in the construction of each layer of a SOPFNN deals with its structural optimization involving the selection of preferred nodes (or FPNs) with specific local characteristics and addresses specific aspects of parametric optimization. In addition, the fuzzy rules used in the networks exploit the notion of information granules defined over system's variables and formed through the process of information granulation. That is, we determine the initial location (apexes) of membership functions and initial values of polynomial function being used in the premised and consequence part of the fuzzy rules respectively. This granulation is realized with the aid of the hard *c*-means clustering method (HCM). For the parametric identification, we obtained the effective model that the axes of MFs are identified by GA to reflect characteristic of given data. Especially, the genetically dynamic search method is introduced in the identification of parameter. It helps lead to rapidly optimal convergence over a limited region or a boundary condition. To evaluate the performance of the proposed model, the model is experimented with using two time series data(gas furnace process, nonlinear system data, and NOx process data).

**Key Words** : SOPFNN(Self-Organizing Fuzzy Polynomial Neural Networks), Information Granulation, Genetic Algorithm, FPN(Fuzzy Polynomial Neuron), Hard C-Means Clustering Method, Design Procedure

### 1. 서 론

컴퓨터의 획기적인 발달로 인해 최근 국내외적으로 인간의 사고 능력에 접근하고자 하는 지능형 기술[1-2]을 국가 차세대 성장 동력중의 하나로 보고 이에 관한 핵심기술에 대하여 많은 연구가 이루어지고 있다. 그러나 최근의 시스템들이 매우 비선형적이고 복잡해짐에 따라 이러한 시스템들의 모델링과 예측에 관한 패턴을 구하는 것은 기존의 전통적인 방정식 기반 근사화 이론들을 이용하여 구하기는 어려운 문제이다.

이러한 문제를 풀기 위한 많은 방법 중의 하나로 A. G. Ivakhnenko[3]는 GMDH(Group Method of Data Handling) 알고리즘을 소개하였다. GMDH는 시스템의 입력과 출력사이의 비선형 관계를 동정하기 위한 분석적인 기술이나 비교적 간단한 시스템에 대해서 매우 복잡한 다항식을 생성하는 경우가 있으며, 2입력, 2차 회귀다항식의 형태로 복잡한 비선형 시스템을 표현하는 데는 어느 정도 한계가 있다. GMDH의 이

러한 단점을 극복하고자, GMDH의 2입력 2차 회귀다항식을 다변수 다차식으로 확장한 자기구성 다항식 뉴럴 네트워크(Self-Organizing Polynomial Neural Networks : SOPNN)[4]와 퍼지추론시스템과 SOPNN을 융합한 자기구성 퍼지다항식 뉴럴 네트워크(Self-Organizing Fuzzy Polynomial Neural Networks : SOPFNN)[5]가 개발되었다. 그러나 SOPFNN 구조는 성능을 향상시키기 위하여, 노드의 입력변수의 수와 입력변수, 규칙 후반부 다항식 차수 그리고 선택된 입력변수의 멤버십 함수의 수와 같은 구조적인 측면에서의 파라미터값들을 설계자의 경험 또는 반복적인 학습을 통해 선택된 네트워크 구조를 선택하였기 때문에 최적의 네트워크 구조를 구축하는데 어려움이 내재되어 있었다.

따라서 본 논문에서는 SOPFNN의 최적 모델 구축을 위한 구조적 동정과 파라미터적 동정까지 유전자 알고리즘[6, 7]과 정보 입자화 알고리즘[8-10]을 사용하여 연속적인 최적화를 통한 최적의 SOPFNN을 구축하고자 한다. 먼저 유전자 알고리즘을 이용해서는 SOPFNN의 성능에 많은 영향을 미치는 입력변수의 수와 이에 해당되는 입력변수, 규칙 후반부 다항식의 차수 그리고 멤버십 함수의 수를 탐색하여 최적의 자기구성 퍼지 다항식 뉴럴 네트워크를 구축한다. 두 번째로는 정보 입자화 알고리즘으로써, 본 논문에서는 정보 입자화 모델에 적용하기 위해서 HCM(Hard *c*-Means) 클러스터링 방법[11]을 이용한다. 주어진 데이터의 특성을 분석하여 퍼지

<sup>†</sup> 교신저자, 正會員 : 圓光大學 制御計測工學科 專任講師 · 工博

E-mail : neuron@wonkwang.ac.kr

<sup>\*</sup> 正會員 : 水原大學 電氣電子工學部 副教授 · 工博

接受日字 : 2006年 3月 2日

最終完了 : 2006年 4月 3日

규칙 전반부에서는 멤버십 함수의 정점을 결정하며, 퍼지규칙 후반부에서는 후반부 다항식에 데이터의 특성을 반영하여 모델의 성능을 개선시키는 것뿐만 아니라 모델을 구축함에 있어 그 수렴 속도를 빠르게 하여 모델의 복잡성 및 계산적인 시간도 단축시키는 특징을 가진다.

모델의 파라미터적 동정을 위해서는 유전자 알고리즘을 사용한다. 본 논문에서 사용된 방법은 초기 범위 값을 주어졌다 하더라도 그 데이터의 특성에 맞게 그 범위 값을 자동 조절할 수 있도록 하여 최적의 정점을 찾을 수 있게 하였다.

이와같은 방법들을 이용해서 기존의 모델에 비해서 모델 구축에 있어서 데이터의 특징을 반영함으로써 유연성과 정확성을 가지며 객관적이고 좀 더 정확한 예측 능력을 가진 SOFPNN 모델 구조를 구축할 수가 있다. 본 논문의 평가를 위해서 Box와 Jenkins가 사용한 가스로 입출력 데이터[12], 비선형 함수 데이터[16], 그리고 가스 터빈 발전소의 NOx 배출 공정 데이터[26]를 이용하여 제안된 모델의 타당성, 정확성 및 예측 성능 등을 기존 지능 모델들과 비교를 통해 그 우수성을 보인다.

2. 자기구성 퍼지 다항식 뉴럴네트워크의 최적화

2.1 퍼지 다항식 뉴론(Fuzzy Polynomial Neuron; FPN)

FPN은 'If-then' 규칙들로 구성되고, 이 FPN들이 SOFPNN을 구축하는데 기본이 된다. 그림 1에서 보여진 것처럼 FPN은 2개의 기본적인 기능 모듈로 구성되어 있다(여기서 그림 1은 예를 들어 2입력이고 멤버십 함수의 수는 2x2인 경우이다). 처음 하나는 "F"로 표기되어진 것으로, 이는 퍼지 집합의 집합체로써 입력 수의 변수들과 뉴론에 의해 실현된 처리 부분사이를 상호 연결해 준다. "P"로 표기된 두 번째 모듈은 함수 기반 비선형(다항식) 처리에 관한 것이다. 이 비선형 처리는 어떤 입력 변수들( $x_i$ 와  $x_j$ )을 포함한다. 특별히, 비선형성의 다항식 형태인 퍼지 다항식 처리 유닛트를 사용한다.

그림 1에서 언급했듯이, 각 규칙의 형태는 다음과 같다.

$$\text{If } x_p \text{ is } A_i \text{ and } x_q \text{ is } B_k \text{ then } y \text{ is } P_k(x_i, x_j, \mathbf{a}_k) \quad (1)$$

여기서  $\mathbf{a}_k$ 는 규칙 후반부의 파라미터 벡터이다.

FPN의 처리는 참고문헌 [13], [14]에 나타난 규칙 베이스 컴퓨팅 중에 있는 다음 표현식에 의해 연산처리 된다.

$$z = \frac{\sum_{K=1}^{\text{all rules}} \mu_K P_K(x_i, x_j, \mathbf{a}_K)}{\sum_{K=1}^{\text{all rules}} \mu_K} = \sum_{K=1}^{\text{all rules}} \tilde{\mu}_K P_K(x_i, x_j, \mathbf{a}_K) \quad (2)$$

여기서,  $\mu_K$ 는 각 규칙의 활성화 레벨을 표시하고,  $K=(1, k)$ 이다.

2.2 구조 동정에 의한 SOFPNN의 최적화

2.2.1 유전자 알고리즘에 의한 SOFPNN 구조의 최적화

유전자 알고리즘(GAs : Genetic Algorithms)은 모든 진화 기반의 탐색 알고리즘 가운데 유연하고 강인한 탐색능력으로 인해 불연속 함수 문제를 포함한 최적화문제를 해결할 수 있는 알고리즘으로써 유전학과 자연 진화를 흉내낸 적응 탐색 방법으로 1975년 Holland[6]에 의해 개발되었다.

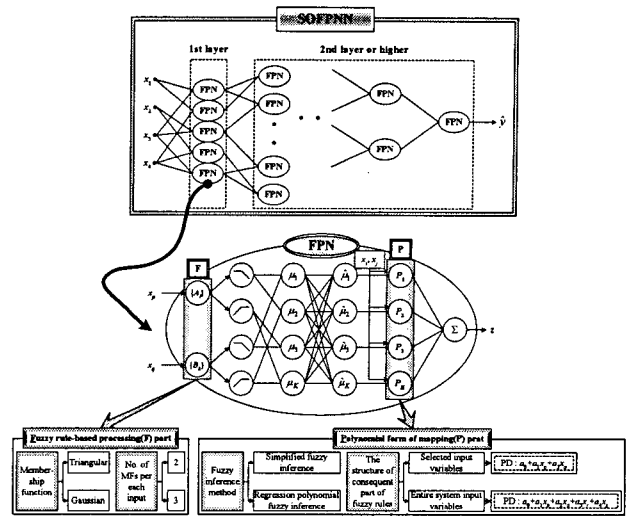


그림 1 SOFPNN의 일반적인 구조 (F : 퍼지 집합 기반 처리 부분, P : 선형변환의 다항식 형태) Fig. 1 A general topology of the generic SOFPNN (F : fuzzy set-based processing part, P : the polynomial form of mapping)

본 논문에서는 유전자 알고리즘을 시뮬레이션하기 위해 설정된 각각의 개체에 존재하는 염색체의 수와 군집의 크기에 대한 파라미터의 정의로써, 한 개체에 여러 변수의 정보를 담은 직렬 방식을 사용한다. 재생산(Reproduction)연산으로 roulette-wheel 방식, 돌연변이연산은 선택된 비트를 반전시키는 invert 방식, 교차(Crossover)연산은 one-crossover 방식을 사용하였다. 그러나 roulette-wheel 방식은 확률적 속성 때문에 선택 과정에서 최적자를 반드시 선택하지 못하는 단점을 가진다. 이를 보완해줄 수 있는 한 방법이 엘리트 전략 (Elitist strategy)을 사용하였다[7].

본 논문에서는 그림 2에서 보여준 것과 같이 각 노드의 입력변수의 수와 이에 해당하는 입력변수, 규칙 후반부 다항식 차수, 그리고 멤버십 함수의 수 선택을 유전자 알고리즘을 통해 탐색하여 객관적이고 효율적으로 구축하게 된다.

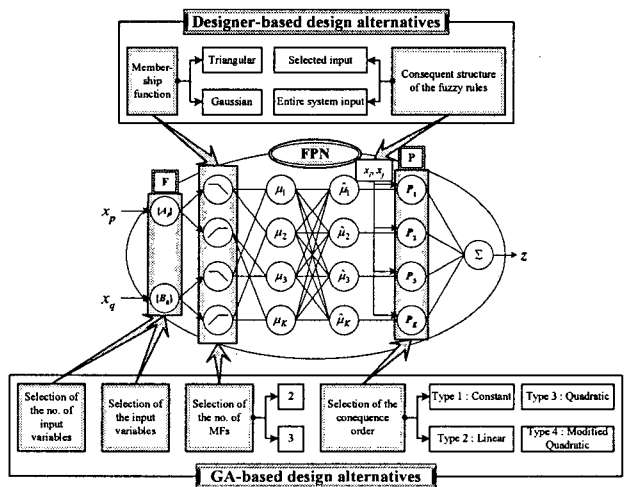


그림 2 유전자 알고리즘을 사용한 FPN 최적화 Fig. 2 Optimization of FPN using GAs

2.2.2 정보 입자화에 의한 SOFPNN 구조의 최적화

정보의 입자화의 목적이 한번에 처리하기 곤란한 방대한 문제를 몇 개의 처리할 수 있는 양으로 문제를 분리하는데 있다. 이와같은 정보의 입자화를 통하여, 우리는 한번에 처리하기 곤란한 방대한 문제를 몇 개의 처리 가능한 문제들로 분할하여 계산함으로써 계산적인 복잡성이 적고 시간적으로도 단축할 수 있다[15].

본 논문에서는 이러한 정보 입자화 알고리즘을 사용하기 위하여 그림 3에서 보여진 것과 같이 퍼지규칙 전반부와 후반부에 HCM 클러스터링 방법[11]을 이용하였다. 그림 3은 기존의 SOFPNN 모델을 최적화하기 위하여 본 논문에서 제안한 정보 입자화를 통한 FPN의 최적화과정을 간단하게 나타낸 것이다.




그림 3 HCM 기반 FPN 구조  
Fig. 3 HCM based FPN architecture

① IG를 위한 HCM 클러스터링 방법

제안된 IG를 수행하기 위하여 본 논문에서는 HCM 클러스터링 방법을 이용하였다. 클러스터링 알고리즘이란 데이터의 분류를 위해서 사용되는 것으로 데이터의 내부가 비슷한 패턴, 속성, 형태 등의 기준을 통해 데이터를 분류하여 내부의 구조를 찾아내는 것이다[11]. 본 논문에서는 클러스터링 알고리즘중 데이터들간의 거리를 기준으로 근접한 정도를 측정하고, 이를 바탕으로 데이터를 특성별로 분류하는 HCM 클러스터링을 이용하여 데이터들의 특성을 파악한다.

② IG를 통한 퍼지 규칙의 전반부 멤버십 함수 정점 결정

기존 SOFPNN 모델의 구조는 주어진 데이터의 Min-Max 값을 기준으로 임의의 개수로 분할하여 일률적으로 멤버십 함수의 정점을 정의하였으나 이는 주어진 데이터의 분포 특성을 모델에 적용하지 못하여서 모델의 성능에도 좋은 영향을 끼치지 못한다. 이러한 단점을 보완하기 위하여, 본 논문에서는 데이터들간의 거리를 기준으로 하여 근접한 정도를 측정하고, 이를 통해 데이터를 분류하는 HCM방법을 이용하여 데이터 특성에 맞는 멤버십 함수의 정점을 정의하였다. 즉, 그림 3과 같이 사용된 FPN의 전반부 멤버십 함수의 정점을 HCM 클러스터링 방법을 통해 얻은 각 입력 데이터의 중심점으로 이용하였다.

③ IG를 통한 퍼지 규칙의 후반부 다항식 재구성

유전자 알고리즘을 이용하여 구한 FPN의 설계 정보 즉, 입력변수의 수, 퍼지규칙 후반부 다항식 차수, 입력변수, 그리고 MF(Membership Function)의 수를 가지고 그림 3과 그림 4에서 보여진 것과 같이 퍼지규칙 후반부 다항식을 본 논문에서 제안한 새로운 방법인 IG를 통해서 새롭게 구성한다. 이는 주어진 데이터의 특성을 퍼지 규칙의 후반부 다항식에

서도 반영하여 모델의 성능을 개선시키는 것뿐만 아니라 모델을 구축함에 있어 그 수렴 속도를 빠르게 하여 모델의 복잡성 및 계산적인 시간도 단축시키는 특징을 가진다.

그림 4는 유전자 알고리즘에 의해서 시스템 입력 중 2입력을 선택하고, 입력변수로는  $x_1$ 과  $x_2$ 가 선택된 것이며, 후반부 차수로는 Type 2로 선형식으로 구성되며 멤버십 함수의 수는 각 입력변수당 2개씩 선택된 경우를 나타낸 것이다.

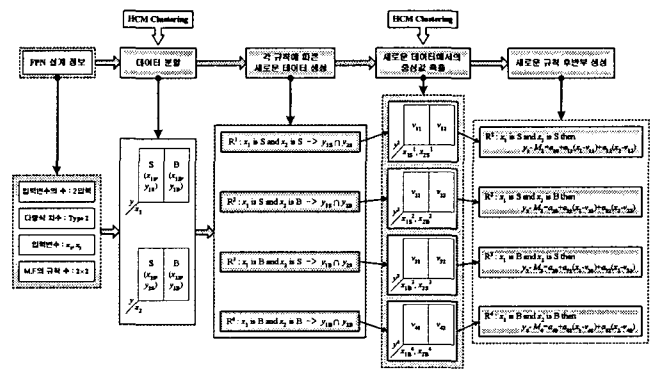


그림 4 IG에 의한 퍼지규칙 후반부 다항식 결정  
Fig. 4 Decision of consequence polynomial of fuzzy rule by IG

2.3 파라미터 동정에 의한 SOFPNN의 최적화

본 절에서는 모델의 멤버십 함수의 정점을 유전자 알고리즘으로 동정하여 모델을 구축할 때에 데이터의 특성에 맞는 모델을 구축하고자 그림 5에서 보여진 것과 같이 유전자 알고리즘의 동적 탐색영역을 통해서 최적의 멤버십 함수 정점을 동정한다.

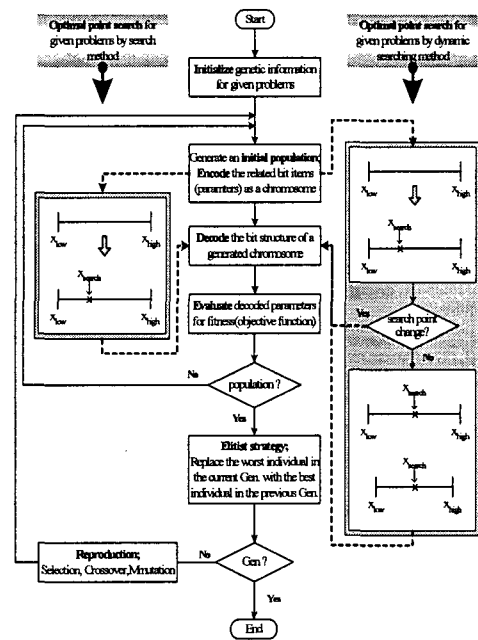


그림 5 동적 탐색 영역에 의한 유전자 알고리즘  
Fig. 5 Genetic algorithm with dynamic searching range

기존의 모델들은 멤버십 함수의 정점을 주어진 데이터의 Min-Max 방법을 이용하거나, 2.2.2-②에서 주어진 것과 같이 HCM 방법을 이용하였으나 정확하게 데이터의 특성을 파악하지 못하는 경우가 발생하였으며, 또한 유전자 알고리즘을 사용한다 하더라도 그림 5에서 왼쪽에 보여진 것과 같이 초기 범위( $x_{low} \sim x_{high}$ )을 고정하여 그 범위 안에서만 값을 동정하기 때문에 local minimum에 빠질 수 있는 단점을 가지고 있다. 따라서 본 논문에서는 이러한 요인을 개선하기 위해 동적인 탐색 공간 정의를 이용한다. 이는 충분히 큰 탐색공간에서 해의 영역을 탐색한 후 기준 해를 정의하고 기준 해의 이동 범위를 타당으로 탐색영역을 조절해 가며 최적의 해를 찾아가는 것이다.

### 3. 구조 동정과 파라미터 동정을 통한 자기구성 퍼지 다항식 뉴럴네트워크의 최적화 알고리즘과 설계

본 장에서는 기존의 자기구성 퍼지 다항식 뉴럴 네트워크를 최적화하기 위하여 구조 동정과 파라미터 동정을 통한 최적화 설계절차는 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 입력출력 데이터  $(x_i, y_i) = (x_{1i}, x_{2i}, \dots, x_{ni}, y_i), i=1, 2, \dots, N$ 을 학습용 데이터와 평가용 데이터로 분할한다. 학습용 데이터는 모델을 동정하기 위해 사용하는 데이터이고, 평가용 데이터는 모델을 평가하기 위해 사용하는 데이터이다.

#### [단계 3] 정보 입자화에 의한 멤버십 함수의 정점 결정

[단계 2]에서 분류된 학습용 데이터를 이용하여 기존의 모델과는 달리 멤버십 함수의 정점을 데이터의 Min-Max 방법을 이용하지 않고 HCM 클러스터링 방법을 이용하여 '2.2.2-② IG를 통한 퍼지 규칙의 전반부 멤버십 함수 정점 결정'에서 설명한 것처럼 초기 멤버십 함수의 정점을 결정한다. 이는 주어진 데이터의 특성을 모델 구축에 반영하여 좀 더 효과적인 모델을 구축할 수 있게 한다.

#### [단계 4] SOFPNN 구조 정보 결정

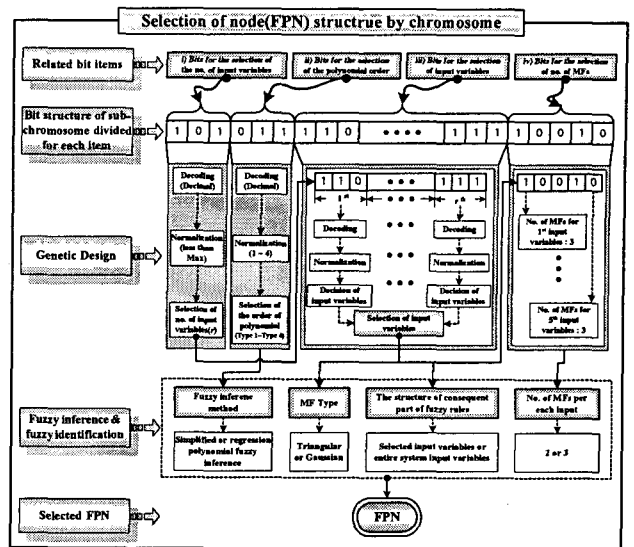
SOFPNN 구조를 구축하는 있어서 기본적인 정보를 결정한다. 즉, SOFPNN의 퍼지 추론 방법 및 동정을 설계하는 부분과 SOFPNN 모델의 구조를 결정하는 초기 정보를 결정한다.

#### [단계 5] 유전자 알고리즘을 이용한 SOFPNN 구조 결정 및 FPN의 설계

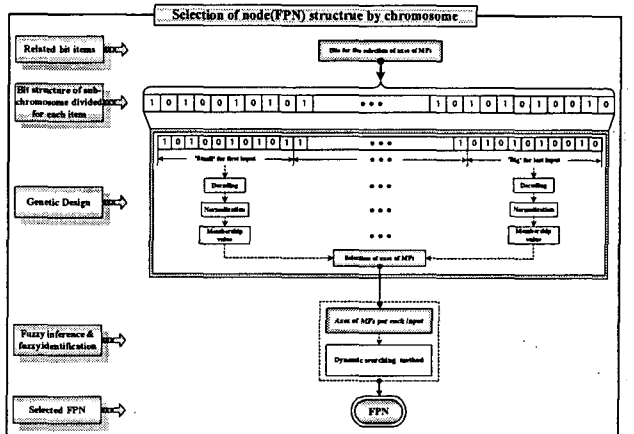
유전자 알고리즘을 이용한 SOFPNN 구조 결정은 그림 7에서 보여진다. SOFPNN 모델을 구축하는데 기본 유닛인 FPN 노드들을 유전자 알고리즘에서 각각의 염색체에 의한 구조 선택을 통해 최적 모델을 구축할 수가 있다.

#### [단계 6] 퍼지 추론 규칙과 파라미터 동정을 위한 매개변수 추정

유전자 알고리즘을 이용하여 [단계 5]에서 구한 FPN의 설계 정보 즉, 입력변수의 수, 퍼지규칙 후반부 다항식 차수, 입력변수, 그리고 MF의 수와 정점을 가지고 그림 4에서 보여진 것과 같이 퍼지규칙 후반부 다항식을 "2.2.2-③. IG를 통한 퍼지 규칙의 후반부 다항식 재구성"에서 언급한 방법과 같이 새롭게 구성한다.



(a) Structure optimization



(b) Parameter optimization

그림 6 유전자 알고리즘의 염색체를 이용한 SOFPNN 구조에서 이용할 수 있는 FPN 설계

Fig. 6 The FPN design available in SOFPNN architecture by using a chromosome of GAs

#### i) 간략 추론

본 논문에서 제안된 정보 granulation에 기반한 간략 추론의 구현 규칙들은 다음과 같이 구성된다.

$$R^j \text{ If } x_1 \text{ is } A_{j1} \text{ and } \dots \text{ and } x_k \text{ is } A_{jk} \text{ then } y_j - M_j = a_{j0} \quad (3)$$

여기서,  $M_j(j=1, \dots, n)$ 는 출력 데이터의 평균 중심 값이다. 추론된 값  $\hat{y}_i$ 는 다음과 같다.

$$\hat{y}_i = \frac{\sum_{j=1}^n \mu_{ji} y_j}{\sum_{j=1}^n \mu_{ji}} = \frac{\sum_{j=1}^n \mu_{ji} (a_{j0} + M_j)}{\sum_{j=1}^n \mu_{ji}} = \sum_{j=1}^n \hat{\mu}_{ji} (a_{j0} + M_j) \quad (4)$$

후반부의 파라미터는  $a_{j0}$ 로써 식 (5)와 같이 최소자승법에 의해 구해진다.

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

$$X = [x_1, x_2, \dots, x_m]^T, \quad x_i^T = [\hat{\mu}_{1i}, \hat{\mu}_{2i}, \dots, \hat{\mu}_{ni}], \quad a = [a_{10}, \dots, a_{n0}]^T$$

$$Y = [y_1 - (\sum_{j=1}^n M_j \hat{\mu}_{j1}), y_2 - (\sum_{j=1}^n M_j \hat{\mu}_{j2}), \dots, y_m - (\sum_{j=1}^n M_j \hat{\mu}_{jm})]^T$$

ii) 회귀다항식 추론

회귀다항식 추론 경우의 퍼지 모델은 다음과 같은 형태를 가지는 구현 규칙들로 구성된다.

$$R^j \text{ If } x_1 \text{ is } A_{j1} \text{ and } \dots \text{ and } x_k \text{ is } A_{jk} \text{ then } (6)$$

$$y_j - M_j = f_j\{(x_1 - v_{j1}), (x_2 - v_{j2}), \dots, (x_k - v_{jk})\}$$

여기서  $v_{jt}(j=1, \dots, n; t=1, \dots, k)$ 는 새롭게 생성된 입력 데이터의 중심값,  $M_j(j=1, \dots, n)$ 는 새롭게 생성된 출력 데이터의 중심값이다. 다항식이 1차식인 경우의  $i$ 번째 데이터의 추론된 값  $\hat{y}_i$ 는 다음과 같다.

$$\hat{y}_i = \frac{\sum_{j=1}^n \mu_{\bar{x}} y_j}{\sum_{j=1}^n \mu_{\bar{x}}} = \frac{\sum_{j=1}^n \mu_{\bar{x}} (a_{j0} + a_{j1}(x_{i1} - v_{j1}) + \dots + a_{jk}(x_{ik} - v_{jk}) + M_j)}{\sum_{j=1}^n \mu_{\bar{x}}} (7)$$

$$= \sum_{j=1}^n \hat{\mu}_{\bar{x}} (a_{j0} + a_{j1}(x_{i1} - v_{j1}) + \dots + a_{jk}(x_{ik} - v_{jk}) + M_j)$$

최소자승법에 의한 후반부 파라미터의 동정은 간략추론과 같이 식 (8)에 의해 구해진다.

$$a = (X^T X)^{-1} X^T Y (8)$$

$$Y = [y_1 - (\sum_{j=1}^n M_j \hat{\mu}_{j1}) \quad y_2 - (\sum_{j=1}^n M_j \hat{\mu}_{j2}) \quad \dots \quad y_m - (\sum_{j=1}^n M_j \hat{\mu}_{jm})]^T,$$

$$a = [a_{10} a_{20} \dots a_{n0} a_{11} \dots a_{n1} \dots a_{1k} \dots a_{nk}]^T, \quad X = [x_1, x_2, \dots, x_m]^T,$$

$$x_i^T = [\hat{\mu}_{1i} \quad \dots \quad \hat{\mu}_{ni} \quad (x_{i1} - v_{11}) \hat{\mu}_{1i} \quad \dots \quad (x_{i1} - v_{n1}) \hat{\mu}_{ni} \quad \dots \quad (x_{ik} - v_{1k}) \hat{\mu}_{1i} \quad \dots \quad (x_{ik} - v_{nk}) \hat{\mu}_{ni}]$$

[단계 7] 모델의 구축과 테스트 그리고 노드의 선택

본 논문에서 사용된 유전자 알고리즘의 적합도 함수는 population에 의해서 생성된 노드의 성능 테스트를 위해서 모델의 테스트 데이터만을 이용하여 노드를 테스트한다. 또한 테스트 데이터를 이용해서 구해진 성능지수를 유전자 알고리즘의 적합도 함수로 계산하기 위해서 다음 식 (9)와 같이 변환하여 유전자 알고리즘의 적합도 함수로 사용한다.

$$F(\text{Fitness Function}) = \frac{1}{1 + EPI} (9)$$

[단계 8] 종료판정

[단계 7]의 현재 층에서 얻어진 최적 노드의 최대 적합도 값  $F_1$ 이 다음 부등식을 만족하는 경우에 알고리즘을 종료한다.

$$F_1 \leq F. (10)$$

단,  $F$ 는 이전 층의 최적 노드인 최대 적합도 값이다. 그러나 위와 같은 종료판정은 네트워크 생성 중에 최대 층수가 과도하게 발생할 우려가 있으며 그럴 경우 프로그램 실행 시 많은 시간과 계산량을 요구하게 된다. 이와 같은 단점을 보완하기 위해 본 논문에서는 전체 층의 수를 최대 3층으로 제한하여 네트워크의 복잡성과 우수성의 상호 균형을 고려하여 알고리즘을 종료한다.

본 논문에서의 모델의 성능지수식으로 다음 식과 같이 MSE(Mean Squared Error)를 사용해서 하였다.

$$E = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 (11)$$

[단계 9] 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,  $x_{1j} = z_{1i}, x_{2j} = z_{2i}, \dots, x_{wj} = z_{wi}$ 로 구성하고, [단계 4]로 간다(여기서,  $j=i+1$ ). 이 후, [단계 4]부터 [단계 9]까지를 반복한다.

알고리즘이 종료할 경우, 마지막 층의 최적 적합도 값  $F$ 을 얻은 노드의 다항식에 입력이 되는 전 층의 출력을 대입하고

동일한 조작을 제 1층까지 반복하여 최종 추정 모델  $\hat{y}$ 를 얻는다.

4. 시뮬레이션 및 결과고찰

제안된 모델의 평가를 위해 가스로 공정[12], 비선형 함수[16], 그리고 NOx 배출공정[26]을 이용한다. 모델의 최적화를 위해 사용된 유전자 알고리즘과 SOFPNN의 연산자 및 파라미터는 표 1처럼 주어졌다.

표 1 유전자 알고리즘과 자기구성 퍼지 다항식 뉴럴네트 워크 정보

Table 1 Computational overhead and a list of parameters of the GAs and the SOFPNN

Parameters		1층	2층	3층
GAs	Maximum generation	S.O 150	P.O 150	100 or 150
	Total population size	S.O 100	P.O 300*No. of node in 1st layer	100
	Selected population size	30	30	30
	Crossover rate	0.65	0.65	0.65
	Mutation rate	0.1	0.1	0.1
	String length	3+3+30+5+90	3+3+30+5	3+3+30+5
	SOFPNN	Maximal no. of inputs to be selected(Max)	1 ≤ l ≤ Max(2~3)	1 ≤ l ≤ Max(2~3)
Polynomial Type(Type T) of the consequent part of rules		1 ≤ T* ≤ 4	1 ≤ T ≤ 4	1 ≤ T ≤ 4
Membership function(MF) type		Triangular	Triangular	Triangular
		Gaussian	Gaussian	Gaussian
No. of MFs per each input(M)	2 or 3	2 or 3	2 or 3	

l, T : integer, S.O : Structure Optimization, P.O : Parameter Optimization, \* : 규칙 후반부 다항식의 입력이 전체 시스템 입력이 사용된 경우

표 1에서 보여진 것처럼 최대 세대수는 구조 동정일 경우엔 각 층마다 150세대를 주었고, 파라미터 동정일 경우에는 구조 동정과 달리 가스로 공정과 비선형 데이터인 경우에는 전체 층에 100세대를, 그리고 NOx 공정인 경우에는 150세대를 주었다. 이는 주어진 데이터의 비선형 정도에 따라 그 차이를 두었기 때문이다.

4.1 가스로 시계열 공정

제안된 모델의 성능을 테스트하기 위해서 가스로 시계열 데이터를 이용하였다. Box와 Jenkins[12]에 의해 사용된 가스로 시계열 데이터는 입출력 데이터인 가스 흐름율( $u(t)$ )과 연소된 이산화탄소 농도( $y(t)$ )의 가스로 공정으로부터 추출된다. 전체 시스템 입력 데이터 296개 중 처음 148개의 데이터는 학습 데이터로 이용하고 나머지 148개의 데이터는 테스트 데이터로 나누어 모델을 최적화한다. 본 논문에서는 사용된 입력은 6입력 1출력  $\{u(t-3), u(t-2), u(t-1), y(t-3), y(t-2), y(t-1) : y(t)\}$ 을 사용한다.

표 2는 표 1에서 주어진 정보를 가지고 구조 동정만을 했을 경우(S.O)와 파라미터 동정까지 했을 경우(P.O)의 성능 중에서 마지막 층인 3층에서 최적의 값을 비교해서 나타낸 것이다.

표 2 가스로 공정에 대한 SOFPNN 구조의 성능지수

Table 2 Performance index of SOFPNN for the gas furnace process(S.O : Structure Optimization, P.O : Parameter Optimization)

Model	In case of selected input						In case of entire system input						
	S.O		P.O		S.O		P.O		S.O		P.O		
MF Max	Node(M)	T	PI	EPI	PI	EPI	Node(M)	T	PI	EPI	PI	EPI	
Tri	2	8(2) 29(3)	3	0.010	0.115	0.011	0.111	5(2) 6(3)	2	0.006	0.116	0.007	0.108
	3	15(225(3) 0	4	0.013	0.120	0.013	0.105	20(228(3) 0	2	0.006	0.118	0.007	0.117
Gau	2	9(2) 10(2)	3	0.010	0.122	0.011	0.120	11(2) 12(3)	2	0.006	0.121	0.006	0.124
	3	4(2)20(3) 0	4	0.012	0.113	0.013	0.103	7(2)15(3) 0	2	0.005	0.122	0.005	0.114

표 2에서 "Node"는 현재 층의 노드에 입력되는 이전 층의 노드 번호 나타내고, "M"은 선택되어진 입력변수의 멤버쉽 함수의 수를 나타낸다. "T"는 그 때 사용된 다항식 차수를 그리고 "PI(Performance Index)"와 "EPI(Evaluation Performance Index)"는 마지막 층인 3층에서의 노드들 중에서 최적의 학습 데이터와 테스트 데이터의 성능지수를 나타 낸 것이다. "Tri"는 멤버쉽 함수를 삼각형을, "Gau"는 가우시안형 멤버쉽 함수를 사용한 것을 나타낸다.

제안된 모델의 성능 중에서 가장 최적인 성능지수로는 삼각형 함수를 사용한 경우에는 Max=2일때 PI=0.007, EPI=0.108, 가우시안 함수를 사용한 경우에는 Max=3일때 PI=0.013, EPI=0.103이다.




그림 7 최적화된 SOFPNN 구조(Max=2, Type T)  
Fig. 7 Optimal SOFPNN architecture(Max=2, Type T)

그림 7은 표 2에서 주어진 성능지수중 최적 네트워크인 삼각형 함수를 사용하고 Max=2일때 PI=0.007, EPI=0.108을 나타낸 것이다. 그림 7에서 보여준 노드 "FPN<sub>NI</sub>T"는 다음과 같이 표현된다. 'FPNn'는 각 층에서 n번째 FPN 노드를 나타낸 것이고, 'NI'는 해당 노드로 들어오는 입력의 수를, 'T'는 해당 노드에 사용된 규칙 후반부 다항식 차수를 나타낸 것이다. 그리고 노드들의 앞에 표시되어 있는 사각형은 멤버쉽 함수의 수를 의미한다. 즉, □는 멤버쉽 함수의 수가 2개를 의미하고, ⊓은 멤버쉽 함수의 수가 3개를 의미한다. 그림 8은 그림 7에서 보여준 네트워크에서 GA를 통해 최적화된 1층 각 노드들의 MF의 정점을 기존의 방법들이 사용했을 때와의 비교를 나타낸 것이다.

그림 9는 표 2에서 Max가 2인 경우, 1층에서의 후반부 다항식 변수로는 시스템 입력변수를 사용하고 멤버쉽 함수로는 삼각형 함수를 사용했을 때의 모델의 최적화 과정을 나타낸 것이다.

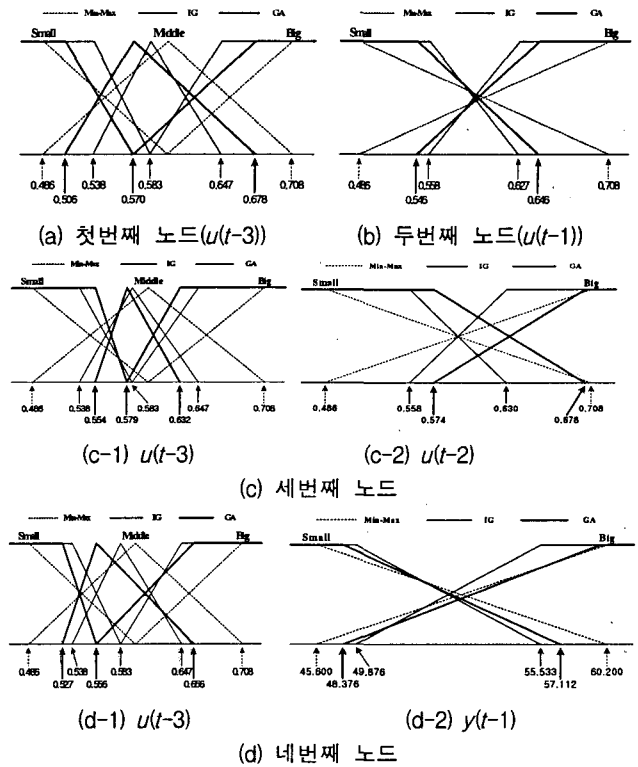


그림 8 GAs 이용한 가스로 공정의 멤버쉽 함수 정점의 최적화  
Fig. 8 Optimization of membership functions points of gas furnace process by GAs




그림 9 파라미터 동정에 의한 최적화 과정  
Fig. 9 Optimization procedure by identification of parameters

표 3은 가스로 공정 데이터를 사용하여 기존의 모델과 본 논문에서 제시한 모델과의 성능비교를 한 것이다. 표 3에서 "PI"는 전체 데이터를 이용하여 모델의 성능지수를 구한 것이고, "PI<sub>s</sub>", "EPI<sub>s</sub>"는 전체 데이터를 학습 데이터와 테스트 데이터로 나누어 모델의 성능지수 값을 각각 구한 것이다. 그리고 S.O(Structure Optimization)는 구조 동조를, P.O(Parameter Optimization)는 파라미터 동조를 의미한다. 가스로 공정과 같이 데이터 분포가 일정한 즉, 비선형이 약한 데이터에서도 본 장에서 제안된 모델이 기존의 모델에 비해서 성능이 다소 우수함을 알 수 있다. 이는 데이터의 분포가 일정한 데이터 즉, 비선형이 약한 데이터에서도 제안한 방법이 효율적일 뿐만 아니라 그 성능이 개선됨을 알 수 있다.

표 3 다른 모델링 방법과의 성능 비교

Table 3 Comparison of performance with other modeling methods

Model		PI	PI <sub>s</sub>	EPI <sub>s</sub>	
Box and Jenkin's model[12]		0.710			
Pedrycz's model[13]		0.320			
Sugeno and Yasukawa's model[16]		0.190			
Chen's model[17]		0.268			
Gomez-Skarmeta's model[18]		0.157			
Oh and Pedrycz's model[19]		0.123	0.020	0.271	
Kim, et al.'s model[20]			0.034	0.244	
Lin and Cunningham's model[21]			0.071	0.261	
FPNN[5]	Gaussian	CASE I	0.045	0.116	
		CASE II	0.037	0.125	
HFPNN[22]	Triangular	3rd layer	0.020	0.109	
		5th layer	0.013	0.096	
	Gaussian	3rd layer	0.012	0.127	
		5th layer	0.009	0.120	
Our model	S.O	Triangular	3rd layer(Max=2)	0.006	0.116
		Triangular	3rd layer(Max=3)	0.006	0.118
		Gaussian	3rd layer(Max=2)	0.006	0.121
	P.O	Triangular	3rd layer(Max=2)	0.007	0.108
		Triangular	3rd layer(Max=3)	0.013	0.105
		Gaussian	3rd layer(Max=2)	0.006	0.124
Gaussian	3rd layer(Max=3)	0.013	0.103		

4.2 비선형 함수

본 논문에서 제안한 모델들의 적용 및 유용성을 비교 평가 하기 위하여 2입력 1출력의 비선형 함수[16]를 이용한다.

비선형 함수에 사용된 전체 50개의 입출력 데이터를 본 연구에 적용함으로써 제안된 각각의 모델을 비교하며, 타당성 및 정확도를 검토한다.

표 4는 본 논문에서 제안한 방법으로 주어진 데이터를 가지고 모델링한 결과이다.

표 4 비선형 함수에 대한 SOFPNN 구조의 성능지수

Table 4 Performance index of SOFPNN for the nonlinear function(S.O : Structure Optimization, P.O : Parameter Optimization)

Model	In case of selected input				In case of entire system input				
	S.O		P.O		S.O		P.O		
MF Max	Node(M)	T	PI	PI	Node(M)	T	PI	PI	
Trn	2	16(2) 26(2)	2	7.4e-23	6.2e-23	11(2) 0	3	5.0e-23	3.7e-21
	3	18(3) 0 0 3	3	1.2e-26	1.0e-27	1(3)22(2) 0	4	5.2e-26	3.8e-23
Gau	2	5(2) 26(3)	2	1.4e-21	1.6e-23	15(2) 22(2)	2	2.2e-21	3.5e-21
	3	10(2)22(2) 0	2	4.6e-26	6.1e-26	8(2)19(2) 0	2	1.5e-25	4.0e-23

제안된 모델의 성능 중에서 삼각형 함수를 사용한 경우엔, 후반부 다항식을 선택된 입력으로 구성하고 Max=3일때 PI=1.0e-27으로 가장 우수한 성능을 가짐을 알 수 있다. 가우시안 함수를 사용한 경우 역시 후반부 다항식을 선택된 입력 변수들로 구성된 경우에 성능이 더 우수함을 알 수 있으며, Max=3일때 PI=6.1e-26을 얻을 수 있었다.

그림 10은 표 4에서 주어진 성능지수중 최적 네트워크인 삼각형 함수를 사용하고 Max=3일때 PI=1.0e-27을 나타낸 것이다.




그림 10 최적화된 자기구성 퍼지다항식 뉴럴네트워크 구조  
Fig. 10 Optimized SOFPNN architecture

그림 11은 표 4에서 Max가 3인 경우, 1층에서의 후반부 다항식 변수로는 선택된 입력변수를 사용하고 멤버십 함수로는 삼각형 함수를 사용했을 때의 모델의 최적화 과정을 나타낸 것이다.

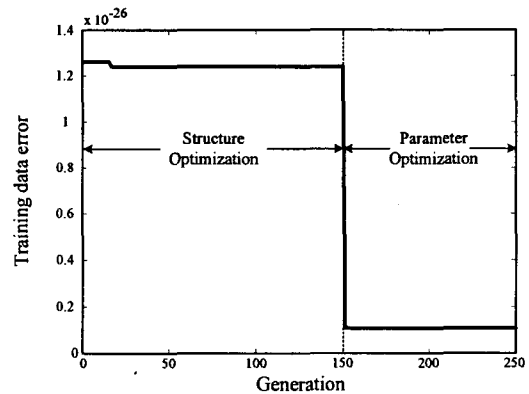


그림 11 파라미터 동정에 의한 최적화 과정  
Fig. 11 Optimization procedure by identification of parameters

표 5는 비선형 함수 데이터를 사용하여 기존의 모델과 본 논문에서 제시한 모델과의 성능비교를 한 것이다.

표 5 기존 모델들과의 네트워크 성능의 비교적인 분석

Table 5 Comparative analysis of the performance of network: considered are models reported in the literature

Model			PI	
Sugeno and Yasukawa's model[16]			0.0790	
Kim et als model[20]			0.0089	
Gomez-Skarmeta et als model[23]			0.0700	
PNN[24]	Basic	5th layer(Case 1)	0.0212	
	Modified	5th layer(Case 1)	0.0041	
SOFPNN[25]	Basic		0.0002	
	Modified		1.4e-06	
Our model	S.O	Triangular	3rd layer(Max=2)	7.4e-23
		Triangular	3rd layer(Max=3)	1.2e-26
		Gaussian	3rd layer(Max=2)	1.4e-21
	P.O	Gaussian	3rd layer(Max=3)	4.6e-26
		Triangular	3rd layer(Max=2)	6.2e-23
		Triangular	3rd layer(Max=3)	1.0e-27
Gaussian	3rd layer(Max=2)	1.6e-23		
	3rd layer(Max=3)	6.1e-26		

### 4.3 가스터빈 발전소의 NOx 배출공정

최근에는 Gas Turbine에 사용하는 입출력 변수 중에서, 입력으로 Tamb, COM, LPT, Pcd, Texh등의 주변 환경변수를 조절하며 출력으로는 Parts per million-volume dry 단위의 NOx양으로 배출 메카니즘을 모델링하고, 최적 모델을 구축하여 시뮬레이터를 구성함으로써 NOx를 효과적으로 관리하는 방법이 연구되고 있다[26].

본 논문에서는 이러한 입출력 변수들을 이용하여 제안된 모델의 성능을 평가한다. 평가를 위해 전체 260개의 데이터를 랜덤하게 130개씩 선택하여 학습데이터와 테스트 데이터로 사용하며, 모델의 근사화와 일반화 성능을 얻는다.

표 6은 제안된 모델의 평가를 위해 NOx 배출공정 데이터를 적용에 따른 성능지수를 나타낸다.

표 6 NOx에 대한 SOFPNN 구조의 성능지수

Table 6 Performance index of SOFPNN for the NOx(S.O : Structure Optimization, P.O : Parameter Optimization)

Model	In case of selected input						In case of entire system input									
	S.O		P.O		S.O		P.O		S.O		P.O					
MF Max	Node(M)	T	PI	EPI	PI	EPI	Node(M)	T	PI	EPI	PI	EPI				
Tri	2	4(3)	27(2)	4	0.072	0.145	0.016	0.068	14(2)	20(3)	4	0.002	0.045	0.003	0.017	
	3	5(2)	13(3)	0	4	0.027	0.111	0.014	0.036	6(3)	15(2)	0	4	0.001	0.048	0.002
Gau	2	23(3)	29(2)	3	0.014	0.352	0.012	0.180	2(3)	14(2)	2	0.001	0.027	0.002	0.024	
	3	2(3)	16(2)	0	3	0.003	0.055	0.004	0.134	15(2)	28(2)	0	4	0.001	0.027	0.001

표 6에서 알 수 있듯이, NOx 공정 데이터의 경우엔 후반부 다항식 전체 시스템 입력으로 구성된 경우에서 성능이 월등히 우수하였으며, 멤버쉽 함수에 있어서도 가우시안보다는 삼각형 멤버쉽 함수를 사용했을 때 우수한 성능을 얻을 수 있었다. 즉, NOx 공정 데이터와 같이 데이터의 특성이 비선형성이 매우 강하고 데이터의 양이 많을수록 본 논문에서 제안한 방법의 효율성이 뚜렷하게 나타남을 알 수 있다.

그림 12는 표 6에서 주어진 성능지수중 후반부 입력변수로서 시스템 입력변수를 사용한 최적 네트워크인 삼각형 함수를 사용하고 Max=3일때 PI=0.002, EPI=0.008을 나타낸 것이다.




그림 12 최적화된 자기구성 퍼지다항식 뉴럴네트워크 구조  
Fig. 12 Optimized SOFPNN architecture

그림 13은 그림 12에서 보여준 네트워크에서 유전자 알고리즘의 동적 탐색방법을 이용하여 최적화된 1층 각 노드들의 MF의 정점을 기존의 방법들이 사용했을 때와의 비교를 나타낸 것이다.

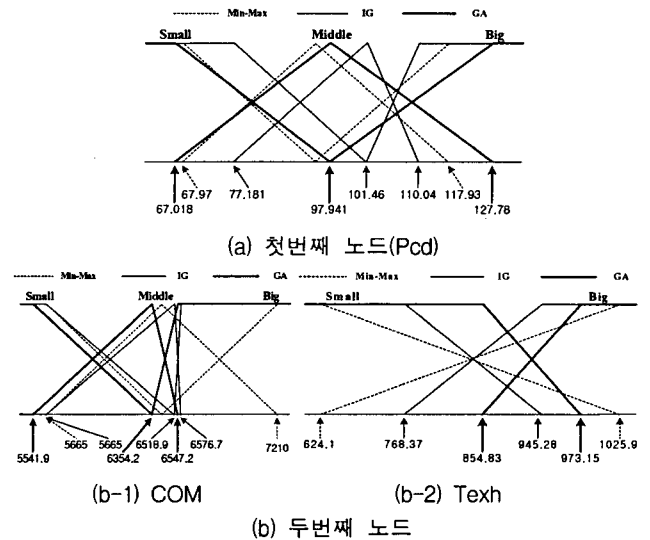


그림 13 GAs 이용한 NOx 공정의 멤버쉽 함수 정점의 최적화  
Fig. 13 Optimization of membership functions points of the NOx process by GAs

그림 14는 그림 13에서 보여준 네트워크의 최적화 과정을 보여준 것이다. 그림에서도 알 수 있듯이 구조를 최적화한 다음 파라미터를 최적화 하였을 경우 그 성능이 개선됨을 알 수 있다.

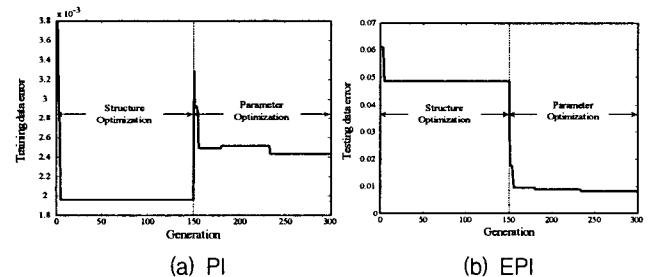


그림 14 GAs에 의한 최적화 과정(NOx 배출공정)  
Fig. 14 Optimal procedure by GAs(NOx process)

표 7은 NOx 배출 공정 데이터를 사용하여 기존의 모델과 본 논문에서 제시한 모델과의 성능비교를 한 것이다.

## 5. 결 론

본 논문에서는 SOFPNN을 구성하고 있는 FPN 노드의 구조와 파라미터를 연속적으로 최적화함으로써 효율적이고 객관적이며 성능이 우수한 SOFPNN의 효율적인 설계 방법론을 제안하였고 이를 기반으로 주어진 비선형 예제들을 통하여 제안된 모델의 우수성을 입증하였다.

본 연구에서는 최적화 방법인 유전자 알고리즘을 이용하여 구조 동정과 파라미터 동정으로 나누어 모델을 최적화 하였다. 구조 동정에 있어서는 노드의 입력변수의 수와 그에 해당하는 입력변수, 퍼지규칙 후반부 다항식 차수 그리고 멤버쉽 함수의 수 등의 구조를 위한 파라미터를 선택하여 모델 구축에 있어서 유연성과 정확성을 가지며 또한 주어진 데이터의



표 7 제안된 모델의 동정 오차의 비교

Table 7 Comparison of identification errors for the proposed model

Model		PIs	EPIs		
Regression model		17.68	19.23		
Hybrid Fuzzy Set-Based FNNs[27]	Simplified	2.806	5.164		
	Linear	3.725	5.291		
Hybrid Fuzzy Relation-Based FNNs[28]	Simplified	0.070	1.649		
	Linear	0.080	0.190		
Multi-FNN[29]	Simplified	2.806	5.164		
	Linear	0.720	2.025		
Hybrid Rule-Based FNNs[30]	GAs	4.038	6.028		
	Hybird	3.725	5.291		
gSOPFNN[31]	Triangular	5th layer(Max=2)	0.007	0.049	
		5th layer(Max=3)	0.007	0.049	
	Gaussian	5th layer(Max=2)	0.002	0.045	
		5th layer(Max=3)	0.001	0.042	
Our model	S.O	Triangular	3rd layer(Max=2)	0.002	0.045
			3rd layer(Max=3)	0.001	0.048
		Gaussian	3rd layer(Max=2)	0.001	0.027
	3rd layer(Max=3)		0.001	0.027	
	P.O	Triangular	3rd layer(Max=2)	0.003	0.017
			3rd layer(Max=3)	0.002	0.008
Gaussian		3rd layer(Max=2)	0.002	0.024	
	3rd layer(Max=3)	0.001	0.023		

인 HCM 클러스터링 방법을 이용하여 멤버십 함수의 정점과 후반부 다항식을 형성함에 있어서 데이터의 분포를 파악하여 데이터의 특성에 맞게 멤버십 함수의 정점 및 후반부 다항식을 결정함으로써 최적화된 SOPFNN 모델 구조를 구축할 수가 있었다.

파라미터 동정에 있어서는 비록 구조 동정에 정보 입자화를 통하여 주어진 입력변수의 멤버십 함수의 정점을 결정하였다 하더라도 이는 정확히 데이터의 특성을 반영하지는 못하였다. 그러므로 유전자 알고리즘을 이용하여 멤버십 함수의 정점을 동조함으로써 더욱 정확한 예측 능력 및 데이터의 특성을 반영한 SOPFNN 모델을 구축할 수가 있었다.

각 공정의 시뮬레이션을 통해서 알 수 있듯이 제안한 모델은 각 노드들의 유기적인 조직으로부터 기존의 다른 모델들보다 성능이 우수함을 알 수 있으며, 데이터 특성이 비선형성이 강하거나 또는 데이터의 수가 적더라도 체계적이고 효율적인 최적의 자기구성 퍼지 다항식 뉴럴 네트워크를 구축함을 보였다.

감사의 글

이 논문은 2005년도 정부(교육인적자원부)의 재원으로 한국학술진흥재단의 지원을 받아 수행된 연구임 (KRF-2005-041-D00713)

참 고 문 헌

[1] W. Pedrycz, J. F. Peters, Computational Intelligence and Software Engineering, World Scientific, Singapore, 1998.

[2] W. Pedrycz, Fuzzy system development: software methodology and design tools, Int. Handbook of Fuzzy Sets and Possibility Theory, Kluwer Academic Publishers, in press.

[3] A. G. Ivakhnenko, "Polynomial theory of complex systems", IEEE Trans. on Systems, Man and Cybernetics, Vol. SMC-1, pp. 364-378, 1971.

[4] S. K. Oh and W. Pedrycz, "The design of self-organizing Polynomial Neural Networks", Information Science, Vol. 141, pp. 237-258, 2002.

[5] 박호성, 오성권, 윤양웅, "퍼지 뉴럴 네트워크 구조로의 새로운 모델링 연구", 제어·자동화·시스템 공학회, Vol. 7, No. 8, pp. 664-673, 2001. 8.

[6] Holland, J. H., Adaptation In Natural and Artificial Systems, The University of Michigan Press, Ann Arbour. 1975.

[7] K. De Jong. Are genetic algorithms function optimizers? In Proc. of PPSN II (Parallel Problem Solving from Nature), pages 3-13, Amsterdam, North Holland, 1992.

[8] R. Moore, Interval analysis, Prentice-Hall, Englewood Cliffs, NJ, 1966.

[9] R. Moore (Ed.), Reliability in Computing, Academic Press, New York, 1988.

[10] L. A. Zadeh, in: L.A. Zadeh, R. Yager, et al., (Eds.), Fuzzy Sets and Applications: Selected Papers, Wiley, New York, 1987.

[11] J. C. BEZDEK, Pattern Recognition with Fuzzy Objective Function Algorithms, New York, Plenum, 1981.

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

[13] W. Pedrycz, "An identification algorithm in fuzzy relational system", Fuzzy Sets Syst., Vol. 13, pp. 153-167, 1984.

[14] J. Leski and E. Czogala, "A new artificial neural networks based fuzzy inference system with moving consequents in if-then rules and selected applications", Fuzzy Sets and Systems, Vol. 108, pp. 289-297, 1999.

[15] W. Pedrycz, G. Vukovich, "Granular neural networks", Neurocomputing, Vol. 36, pp. 205-224. 2001.

[16] M. Sugeno and T. Yasukawa, "A Fuzzy-Logic-Based Approach to Qualitative Modeling", IEEE Trans. Fuzzy Systems, Vol. 1, No. 1, pp. 7-31, 1993.

[17] J. Q. Chen, Y. G. Xi, and Z.J. Zhang, "A clustering algorithm for fuzzy model identification", Fuzzy Sets and Systems, Vol. 98, pp. 319-329, 1998.

[18] A. F. Gomez-Skarmeta, M. Delgado and M.A. Vila, "About the use of fuzzy clustering techniques for fuzzy model identification", Fuzzy Sets and Systems, Vol. 106, pp. 179-188, 1999.

[19] 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 Systems, Vol. 115, No. 2, pp. 205-230, 2000.
- [20] E. T. Kim, et al, “A simple identified Sugeno-type fuzzy model via double clustering”, Information Science, Vol. 110, pp. 25-39, 1998.
- [21] Y. Lin, G. A. Cunningham III, “A new approach to fuzzy-neural modeling”, IEEE Trans. Fuzzy Systems, Vol. 3, No. 2, pp. 190-197, 1995.
- [22] 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, June, 2002.
- [23] A. F. Gomez-Skarmeta, M. Delgado and M.A. Vila, “About the use of fuzzy clustering techniques for fuzzy model identification”, Fuzzy Sets and Systems, Vol. 106, pp. 179-188, 1999.
- [24] S. K. Oh, D. W. Kim, B. J. Park, and H. S. Hwang, “Advanced Polynomial Neural Networks Architecture with New Adaptive Nodes”, Transactions on Control, Automation and Systems Engineering, Vol. 3, No. 1, pp. 43-50, March, 2001
- [25] D. W. Kim, S. K. Oh, and H. K. Kim, “A Study on the Self-organizing Fuzzy Polynomial Neural Networks”, J. of Korean Institute of Electrical Engineers, Vol. 11, No. 2, pp. 79-89, Jun., 2001.
- [26] 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.
- [27] S. K. Oh, W. Pedrycz and H. S. Park, “Hybrid Identification in Fuzzy-Neural Networks”, Fuzzy Sets and Systems, Vol. 138, Issue 2, pp. 399-426, 2003.
- [28] H. S. Park and S. K. Oh, “Fuzzy Relation-based Fuzzy Neural-Networks Using a Hybrid Identification Algorithm”, International Journal of Control, Automation, and Systems, Vol. 1, No. 3, pp. 289-300, Sept., 2003.
- [29] H. S. Park and S. K. Oh, “Multi-FNN Identification Based on HCM Clustering and Evolutionary Fuzzy Granulation”, International journal of Control, Automations, and Systems, Vol. 1, No. 2, pp. 194-202, June, 2003.
- [30] S. K. Oh, W. Pedrycz and H. S. Park, “Implicit Rule-based Fuzzy-Neural Networks Using the Identification Algorithm of GA Hybrid Scheme Based on Information Granulation”, Advanced Engineering Informatics, Vol. 16, No. 4, pp 247-263, Oct. 2002
- [31] S. K. Oh, W. Pedrycz and H. S. Park, “Genetically Optimized Multi-layer Fuzzy Polynomial Neural Networks: Analysis and Design”, Journal of Advanced Computational Intelligence and Intelligent Informatics, Vol. 10, No. 1, pp. 1-15, 2006.

저 자 소 개



**박 호 성(朴 浩 成)**

1999년 원광대학교 제어계측공학과 졸업. 동 대학원 석사(2001), 박사(2005). 2005~현재 원광대학교 전기전자 및 정보공학부 전임강사. 관심분야는 퍼지, 뉴럴네트워크 및 퍼지-뉴럴네트워크, Computational Intelligence 등의 인공 지능형 모델링과 제어, 시스템 자동화 등.

Tel : 063-850-6342  
E-mail : neuron@wonkwang.ac.kr



**오 성 권(吳 聖 權)**

1981년 연세대학교 전기공학과 졸업. 1983-89년 금성산전연구소(선임연구원). 1993년 연세대 대학원 전기공학과 졸업(공학박사). 1996-1997년 캐나다 Manitoba대학 전기 및 컴퓨터공학과 Post-Doc. 1993년~2004년 원광대 전기전자 및 정보공학부 교수. 2005년~현재 수원대학교 전기공학과 부교수. 2002년~현재 대한전기학회 및 제어·자동화·시스템공학회 편집위원, 관심분야는 시스템자동화, 퍼지이론 및 뉴로퍼지네트워크 응용, 계산지능 및 소프트 컴퓨팅 등.

Tel : 031-220-6544  
E-mail : ohsk@suwon.ac.kr