

정보 입자화와 유전자 알고리즘에 기반한 자기구성 퍼지 다항식 뉴럴네트워크의 새로운 접근

論文

55D-2-1

A New Approach of Self-Organizing Fuzzy Polynomial Neural Networks Based on Information Granulation and Genetic Algorithms

朴浩成* · 吳聖權[†] · 金賢起^{**}
(Ho-Sung Park, Sung-Kwun Oh, and Hyun-Ki Kim)

Abstract - In this paper, we propose a new architecture of Information Granulation based genetically optimized Self-Organizing Fuzzy Polynomial Neural Networks (IG_gSOFPNN) that is based on a genetically optimized multilayer perceptron with fuzzy polynomial neurons (FPNs) and discuss its comprehensive design methodology involving mechanisms of genetic optimization, especially information granulation and genetic algorithms. The proposed IG_gSOFPNN gives rise to a structurally optimized structure and comes with a substantial level of flexibility in comparison to the one we encounter in conventional SOFPNNs. The design procedure applied in the construction of each layer of a SOFPNN deals with its structural optimization involving the selection of preferred nodes (or FPNs) with specific local characteristics (such as the number of input variables, the order of the polynomial of the consequent part of fuzzy rules, and a collection of the specific subset of input variables) 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-menas clustering method (HCM). To evaluate the performance of the IG_gSOFPNN, the model is experimented with using two time series data(gas furnace process and NOx process data).

Key Words : SOFPNN(Self-Organizing Fuzzy Polynomial Neural Networks), Information Granulation, FPN(Fuzzy Polynomial Neuron), Genetic Algorithms, Hard C-Means Clustering Method.

1. 서 론

일반적으로 비선형 시스템들의 패턴을 구하는 것은 주어진 데이터의 양 뿐만 아니라 시스템을 구성하고 있는 변수와 파라미터들이 상호 작용에 의해서 특성화되기 때문에 제한되어지고 있다. 따라서 고계 비선형과 다변수 방정식을 가진 수학적 모델을 처리할 때는 그들의 변수와 파라미터 모두를 평가할 수 있는 방대한 양의 데이터들이 필요하다.

이러한 문제를 풀기 위한 많은 방법 중의 하나로 GMDH(Group Method of Data Handling) 알고리즘이 소개되었다[1, 2]. 그러나 GMDH는 2입력 2차 회귀다항식의 형태로 복잡한 비선형 시스템을 표현하는데 어느 정도 한계가 있다. GMDH의 이러한 단점을 극복하고자, Oh 등에 의해 자기구성 다항식 뉴럴 네트워크(Self-Organizing Polynomial Neural Networks : SOPNN)[3, 4]와 자기구성 퍼지다항식 뉴럴 네트워크(Self-Organizing Fuzzy Polynomial Neural Networks : SOFPNN)[5, 6]가 개발되었다.

SOPNN의 구조는 GMDH의 2입력 2차 다항식에서 벗어나

다변수 다항식의 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. 그러나 최적의 네트워크를 구축하기 위해서는 다양한 네트워크 구조와 그와 관련된 다양한 방법론적 설계가 필요하였다.

SOFPNN은 GMDH의 단점을 극복한 SOPNN과 퍼지 추론 시스템을 결합한 구조이다. SOFPNN의 구조는 퍼지 추론 규칙을 기반으로 한 퍼지 다항식 뉴론(FPN)들로 구성되어 있으며, 일반적인 다층 퍼셉트론 구조의 경우와 달리 미리 정해져 있지 않고 층이 진행하는 동안 모델 스스로 노드의 선택과 제거를 통해 최적의 네트워크 구조를 생성할 수 있는 유연성을 가지고 있다. 그러나 SOFPNN 구조는 성능을 향상시키기 위하여 설계자의 경험 또는 반복적인 학습을 통해 선호된 네트워크 구조를 선택하였기 때문에 최적의 네트워크 구조를 구축하는데 어려움이 내재되어 있었다.

본 논문에서는 기존의 자기구성 퍼지 다항식 뉴럴네트워크(SOFPNN)을 최적화시키기 위해서 최적화 탐색 방법인 유전자 알고리즘[7-9]과 주어진 데이터의 특성을 반영하기 위한 information granulation [10-12]을 적용한 정보 입자화 기반 진화론적 최적 자기구성 퍼지다항식 뉴럴네트워크(Information Granulation based Genetically optimized SOFPNN : IG_gSOFPNN)을 제안한다.

본 논문에서는 유전자 알고리즘을 이용하여 자기구성 퍼지

* 교신저자, 正會員 : 水原大學 電氣工學科 教授 · 工博
E-mail : ohsk@suwon.ac.kr

* 正會員 : 圓光大學 制御計測工學科 專任講師 · 工博

** 正會員 : 水原大學 電氣工學科 教授 · 工博

接受日字 : 2005年 9月 26日

最終完了 : 2005年 12月 1日

다항식 뉴럴네트워크의 성능에 많은 영향을 미치는 입력변수의 수와 이에 해당되는 입력변수, 규칙 후반부 다항식의 차수 그리고 멤버쉽 함수의 수를 탐색하여 최적의 자기구성 페지 다항식 뉴럴 네트워크를 구축한다. Information granulation은 여러 연구자들에 의해서 서로 다른 방법과 서로 다른 형태로 자주 모델에 적용되어 왔다. Moore[10, 11]는 고전적인 집합기반 구조에 다양하게 정보 입자화를 적용하였으며, Zadeh[12]는 모델링 능력이 증가하는 동안 비선형 시스템의 모델에 정보 입자들과 같은 페지 집합을 이용할 수 있도록 소개하였다. 본 논문에서는 이러한 정보 입자화를 기준의 SOFPNN 모델에 적용하기 위해서 HCM 클러스터링 방법[13]을 이용한다. 주어진 데이터의 특성을 분석하여 페지규칙 전반부에서는 멤버쉽 함수의 정점을 결정하며, 페지규칙 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.

2. 자기구성 페지 다항식 뉴럴네트워크의 구조

2.1 페지 다항식 뉴론(Fuzzy Polynomial Neuron; FPN)

페지 다항식 뉴론은 SOFPNN을 구축하는데 기본이 된다. 그림 1에서 보여진 것처럼 FPN은 2개의 기본적인 기능 모듈로 구성되어 있다(여기서 그림 1은 예를 들어 2입력이고 멤버쉽 함수의 수는 2×2 인 경우이다). 처음 하나는 “F”로 표기되어진 것으로, 이는 페지 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 페지 다항식 처리 유니트를 사용한다.

FPN의 처리는 참고문헌 [15], [16]에 나타난 규칙 베이스 컴퓨팅 중에 있는 다음 표현식에 의해 연산처리 된다.

$$z = \frac{\sum_{K=1}^{\text{all rules}} \mu_K P_K(x_i, x_j, a_K)}{\sum_{K=1}^{\text{all rules}} \mu_K}$$

$$= \sum_{K=1}^{\text{all rules}} \widehat{\mu}_K P_K(x_i, x_j, a_K) \quad (1)$$

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

2.2 자기구성 페지 다항식 뉴럴네트워크의 구조

SOFPPNN의 구조는 참고문헌 [5], [6]에서 보여준 것과 같이 체계적이고 효율적인 구조를 설계함으로써 주어진 시스템 환경에 유연히 적용하도록 설계할 수 있다. 전체적인 SOFPNN 구조를 설계하는데 있어서 가장 중요한 점은 시스템 입력변수의 수, 각 층에서 노드의 입력변수들의 수와 규칙의 후반부에서 발생한 다항식 차수 그리고 멤버쉽 함수의 수의 결정이다. 표 1에서는 그림 1에서 보여준 SOFPNN 각 층에 사용될 FPN의 페지규칙 후반부 다항식을 나타낸다.

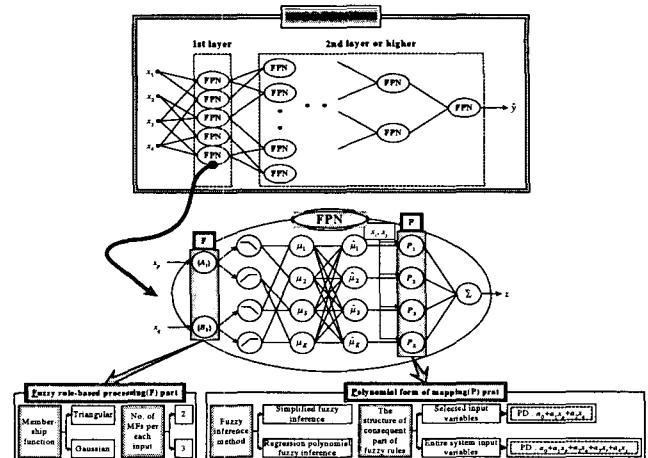


그림 1 SOFPNN의 일반적인 구조

(F : 페지 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)

표 1 페지규칙 후반부에서 회귀다항식의 서로 다른 형태
Table 1 Different forms of the regression polynomials standing in the consequence part of the fuzzy rules

입력수 다항식 Type(자수)	1	2	3
0(Type 1)	Constant		
1(Type 2)	Linear	Bilinear	Trilinear
2(Type 3)		Biquadratic	Triquadratic
2(Type 4)	Quadratic	Modified Biquadratic	Modified Triquadratic

3. SOFPNN의 최적화를 위한 IG 방법과 유전자 알고리즘

정보의 입자화를 통하여, 우리는 한번에 처리하기 곤란한 방대한 문제를 몇 개의 처리 가능한 문제들로 분할하여 계산함으로써 계산적인 복잡성 적고 시간적으로도 단축할 수 있다[17]. 그림 2는 기존의 SOFPNN 모델을 최적화하기 위하여 본 논문에서 제안한 information granulation과 유전자 알고리즘을 통한 FPN의 최적화과정을 간단하게 나타낸 것이다.

3.1 Information granulation(IG)에 의한 SOFPNN의 최적화

3.1.1 IG를 위한 HCM 클러스터링 방법

제안된 IG를 수행하기 위하여 본 논문에서는 HCM 클러스터링 방법[14]을 이용하였다. 단계별 HCM 클러스터링 알고리즘의 수행과정은 다음과 같다.

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

$$M_c = \left\{ U^{(r)} \mid u_{ik}^{(r)} \in \{0, 1\}, \sum_{i=1}^c u_{ik}^{(r)} = 1, 0 < \sum_{k=1}^n u_{ik}^{(r)} < n \right\} \quad (2)$$

여기서, u_{ik} ($i=1, 2, \dots, c$; $j=1, 2, \dots, n$)는 소속행렬의 파라미터.

[단계 2] 각각의 클러스터에 대한 중심벡터 $v_i^{(r)}$ 를 구한다.

[단계 3] 각각의 클러스터 중심과 데이터와의 거리를 계산하여 새로운 소속행렬 $U^{(r+1)}$ 를 생성한다.

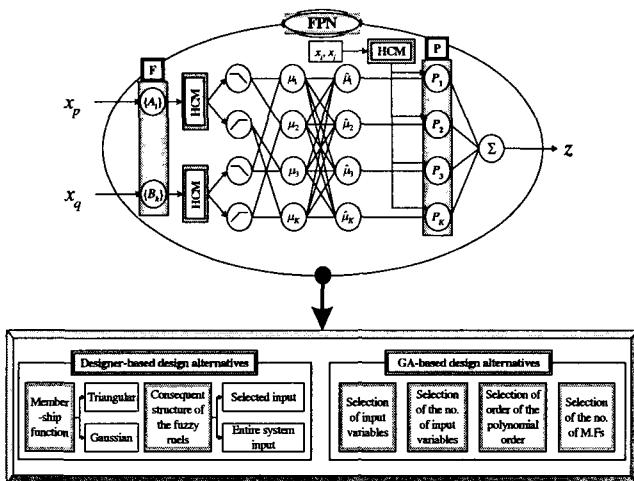


그림 2 유전자 알고리즘과 HCM 기반 FPN 구조

Fig. 2 GA and HCM based FPN architecture

[단계 4] 만일 식 (3)을 만족한다면 종료하고, 그렇지 않으면 $r = r+1$ 로 놓고 [단계 2]로 간다.

$$\| U^{(r+1)} - U^{(r)} \| \leq \epsilon \text{ (tolerance level)} \quad (3)$$

3.1.2 IG를 통한 퍼지 규칙의 전반부 멤버쉽 함수 정점 결정

기존 SOFPNN 모델의 구조는 주어진 데이터의 Min-Max 값을 기준으로 임의의 개수로 분할하여 주어진 데이터의 분포 특성을 모델에 적용하지 못하는 단점을 보완하기 위하여, 본 논문에서는 데이터들간의 거리를 기준으로 하여 근접한 정도를 측정하고, 이를 통해 데이터를 분류하는 HCM방법을 이용하여 데이터 특성에 맞는 멤버쉽 함수의 정점을 정의하였다. 즉, 그림 2와 같이 사용된 FPN의 전반부 멤버쉽 함수의 정점을 HCM 클러스터링 방법을 통해 얻은 각 입력 데이터의 중심점으로 이용하였다.

3.1.3 IG를 통한 퍼지 규칙의 후반부 다항식 재구성

유전자 알고리즘을 이용하여 구한 FPN의 설계 정보 즉, 입력변수의 수, 퍼지규칙 후반부 다항식 차수, 입력변수, 그리고 MF의 수를 가지고 그림 2에서 보여진 것과 같이 퍼지규칙 후반부 다항식을 본 논문에서 제안한 새로운 방법인 IG를 통해서 새롭게 구성한다. IG를 통한 퍼지 규칙의 후반부 다항식 재구성을 위한 알고리즘은 다음과 같다.

[단계 1] FPN 설계 정보

유전자 알고리즘을 통해서 얻은 정보를 기반으로 파라미터들을 초기화 한다.

[단계 2] HCM 클러스터링에 의한 데이터 분할

그림 3에서 보여진 것과 같이 [단계 1]에서 결정된 각 입력변수에 대한 클러스터 수(즉, M.F의 수)에 의해서 데이터를 분할한다.

[단계 3] 각 규칙에 따른 새로운 데이터 생성

퍼지규칙 후반부의 중심값 중에서 출력 y 에 관계되는 중심값 M 의 논리적인 값을 구하기 위하여 [단계 1]의 해 생성된 각 규칙의 전반부 조건에 맞게 새로운 데이터 그룹들을 생성한다.

[단계 4] 새로운 데이터에서의 중심값 축출

[단계 3]에서 새로이 생성된 데이터 그룹에서 중심값을 추출한다.

[단계 5] 새로운 퍼지규칙 후반부 생성

정보 Granule에 기초해서 새로운 퍼지규칙 후반부 다항식을 생성한다.

3.2 유전자 알고리즘에 의한 SOFPNN의 최적화

유전자 알고리즘(GAs)은 유전학과 자연 진화를 흡내낸 적응 탐색 법으로 1975년 Holland[7]에 의해 개발되었다. 유전자 알고리즘은 모든 진화 기반의 탐색 알고리즘 가운데 유연하고 강인한 탐색능력으로 인해 불연속 함수 문제를 포함한 최적화문제를 해결할 수 있는 알고리즈다[8].

본 논문에서는 유전자 알고리즘을 시뮬레이션하기 위해 설정된 각각의 개체에 존재하는 염색체의 수와 군집의 크기에 대한 파라미터의 정의로써, 직렬 방식, roulette-wheel 방식, invert 방식, one-crossover 방식을 사용하였다. 또한 roulette-wheel 방식의 단점을 보완해줄 수 있는 한 방법인 엘리트 전략(Elitist strategy)을 사용하였다[9].

4. Information granulation 기반 진화론적 최적 자기구성 퍼지 다항식 뉴럴네트워크 알고리즘과 설계

유전자 알고리즘과 정보 입자화를 이용한 자기구성 퍼지 다항식 뉴럴 네트워크의 최적화 설계과정은 다음과 같다.

[단계 1] 시스템 입력변수의 결정

출력변수 y 에 관계하는 n 개의 시스템 입력변수(x_1, x_2, \dots, x_n)를 결정한다. 필요하면 데이터를 정규화한다.

[단계 2] 데이터 분할

N 개의 입력력 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.

[단계 3] IG에 의한 멤버쉽 함수의 정점 결정

[단계 2]에서 분류된 학습용 데이터를 이용하여 '3.1.2 IG를 통한 퍼지 규칙의 전반부 멤버쉽 함수 정점 결정'에서 설명한 것처럼 멤버쉽 함수의 정점을 결정한다.

[단계 4] SOFPNN 구조 정보 결정

SOFPNN 구조를 구축하는데 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

SOFPNN 모델을 구축하는데 기본 유닛인 FPN 노드들을 그림 3과 같이 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 정보를 가지고 퍼지규칙 후반부 다항식을 "3.1.3 IG를 통한 퍼지 규칙의 후반부 다항식 재구성"에서 언급한 방법과 같이 새롭게 구성한다.

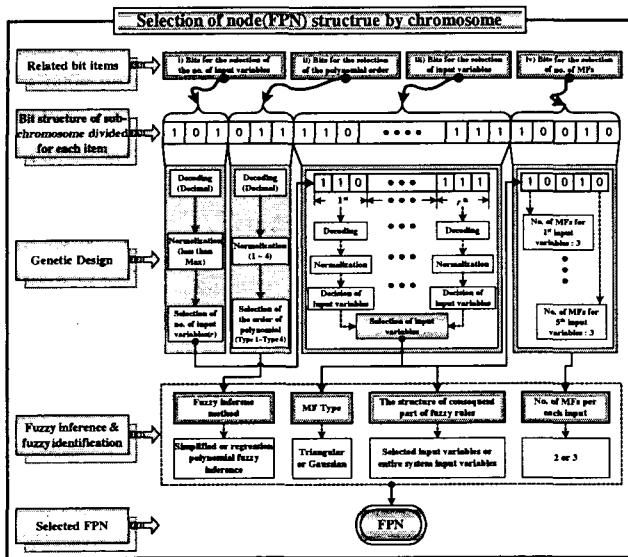


그림 3 GAs의 염색체를 이용한 FPN 설계

Fig. 3 The FPN design by using a chromosome of GAs

i) 간략 추론

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

$$R^n \text{ If } x_1 \text{ is } A_{n1} \text{ and } \dots \text{ and } x_k \text{ is } A_{nk} \text{ then } y_n - M_n = a_{n0} \quad (4)$$

여기서, $M_j (j=1, \dots, n)$ 은 출력 데이터의 평균 중심값이다.

추론된 값 \hat{y}_i 는 다음과 같다.

$$\hat{y}_i = \frac{\sum_{j=1}^n \mu_{ji} y_j}{\sum_{j=1}^n \mu_{ji}} = \frac{\sum_{j=1}^n \mu_{ji} (a_{j0} + M_j)}{\sum_{j=1}^n \mu_{ji}} = \sum_{j=1}^n \widehat{\mu}_{ji} (a_{j0} + M_j) \quad (5)$$

$$\mu_{ji} = A_{jl}(x_{l1}) \wedge \dots \wedge A_{jk}(x_{lk}) \quad (6)$$

여기서, $\widehat{\mu}_{ji}$ 는 μ_{ji} 의 정규화된 값이다.

후반부의 파라미터는 a_{j0} 로써 입출력 데이터가 주어졌을 때식 (7)과 같이 최소자승법에 의해 구해진다.

$$a = (X^T X)^{-1} X^T Y \quad (7)$$

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

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

ii) 회귀다항식 추론

회귀다항식 추론의 경우 페지 모델은 다음과 같은 형태를 가지는 구현 규칙들로 구성된다.

$$R^n \text{ If } x_1 \text{ is } A_{n1} \text{ and } \dots \text{ and } x_k \text{ is } A_{nk} \text{ then } y_n - M_n = f_n((x_1 - v_{n1}), (x_2 - v_{n2}), \dots, (x_k - v_{nk})) \quad (8)$$

여기서, $v_{lj} (j=1, \dots, n; l=1, \dots, k)$ 은 새롭게 생성된 입력 데이터의 중심값, $M_j (j=1, \dots, n)$ 은 새롭게 생성된 출력 데이터

의 중심값이다. 예로 후반부 다항식이 1차식인 경우의 i 번째 데이터의 추론된 값 \hat{y}_i 는 다음과 같다.

$$\begin{aligned} \hat{y}_i &= \frac{\sum_{j=1}^n \mu_{ji} y_j}{\sum_{j=1}^n \mu_{ji}} = \frac{\sum_{j=1}^n \mu_{ji} (a_{j0} + a_{jl}(x_{li} - v_{jl}) + \dots + a_{jk}(x_{ki} - v_{jk}) + M_j)}{\sum_{j=1}^n \mu_{ji}} \\ &= \sum_{j=1}^n \widehat{\mu}_{ji} (a_{j0} + a_{jl}(x_{li} - v_{jl}) + \dots + a_{jk}(x_{ki} - v_{jk}) + M_j) \end{aligned} \quad (9)$$

최소자승법에 의한 후반부 파라미터의 동정은 간략추론과 같은 방식으로 식 (10)에 의해 구해진다.

$$a = (X^T X)^{-1} X^T Y \quad (10)$$

[단계 7] 모델의 구축과 테스트 그리고 노드의 선택

본 논문에서 제안된 IG-gSOFPPN의 FPN은 유전자 알고리즘을 이용하여 모델의 최적화에 맞게 각 노드들을 유연하게 구축할 수 있다. 유전자 알고리즘의 population에 의해서 생성된 노드의 성능 테스트를 위해서 모델의 테스트 데이터만을 이용하여 노드를 테스트한다. 테스트 데이터를 이용해서 구해진 성능지수를 유전자 알고리즘의 적합도 함수로 계산하기 위해서 다음 식 (11)과 같이 변환하여 유전자 알고리즘의 적합도 함수로 사용한다.

$$F(\text{Fitness Function}) = \frac{1}{1+EPI} \quad (11)$$

[단계 8] 종료판정

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

$$F_1 \leq F_* \quad (12)$$

단, F_* 는 이전 층의 최적 노드인 최대 적합도 값이다.

그러나 위와 같은 종료판정은 프로그램 실행 시 많은 시간과 계산량을 요구하게 된다. 이와 같은 단점을 보완하기 위해 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)을 사용해서 하였다.

$$E = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (13)$$

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

5. 시뮬레이션 및 결과고찰

모델의 최적화를 위해 사용된 유전자 알고리즘과 SOFPNN의 연산자 및 파라미터는 표 2처럼 주어졌다.

5.1 가스로 시계열 공정

제안된 모델의 성능을 테스트하기 위해서 첫 번째로 가스로 시계열 데이터[14]를 이용하였다. 가스로 시계열 데이터 296쌍을 시뮬레이션 하기 위해 전체 시스템 입력 데이터 296개 중 처음 148개의 데이터는 학습 데이터로 이용하고 나머지 148개의 데이터는 테스트 데이터로 나누어 모델을 최적화 한다. 본 논문에서는 사용된 입력은 6입력 1출력 ($u(t-3), u(t-2), u(t-1), y(t-3), y(t-2), y(t-1)$)을 사용한다.

표 3은 표 2에서 주어진 정보를 가지고 IG 기반 진화론적으로 최적화된 자기구성 페지 다항식 뉴럴 네트워크의 성능

중에서 각 층에서 최적의 값을 나타낸 것이다.

표 3에서 "Node"는 한 노드에 입력되는 입력변수, "M"은 선택되어진 입력변수의 멤버쉽 함수의 수, "T"는 그 때 사용된 다항식 차수를 그리고 "PI"와 "EPI"는 각 층에서 생성되는 노드들 중에서 최적의 학습 데이터와 테스트 데이터의 성능지수를 나타낸 것이다. 제안된 모델의 성능 중에서 가장 최적인 성능지수로는 삼각형 함수를 사용한 경우에는 Max=2 일 때 PI=0.006, EPI=0.116, 가우시안 함수를 사용한 경우에는 Max=2일 때 PI=0.006, EPI=0.121이다.

표 2 유전자 알고리즘과 자기구성 퍼지 다항식 뉴럴네트워크 정보

Table 2 Computational overhead and a list of parameters of the GAs and the SOFPNN

	Parameters	1층	2층	3층
GAs	Maximum generation	150	150	150
	Total population size	100	10	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	3+3+30+5	3+3+30+5
S O F P N N	Maximal no. of inputs to be selected(Max)	$1 \leq l \leq$ Max(2~3)	$1 \leq l \leq$ Max(2~3)	$1 \leq l \leq$ Max(2~3)
	Polynomial Type(Type T) of the consequent part of rules	$1 \leq T \leq 4$	$1 \leq T \leq 4$	$1 \leq T \leq 4$
	Membership function(MF) type	Triangular Gaussian	Triangular Gaussian	Triangular Gaussian
	No. of MFs per each input(M)	2 or 3	2 or 3	2 or 3

I,T : integer

* : 규칙 후반부 다항식의 입력이 전체 시스템 입력이 사용된 경우

표 3 가스로 공정에 대한 IG_gSOFPNN 구조의 성능지수

Table 3 Performance index of IG_gSOFPNN for gas furnace process

(a) In case of using selected inputs

M	1층			2층			3층									
	Node(M)	T	PI	EPI	Node(M)	T	PI	EPI	Node(M)	T	PI	EPI				
Triangular MF																
2	1(3)	6(3)	4	0.015	0.281	13(3)	21(2)	2	0.012	0.146	8(2)	29(3)	3	0.010	0.115	
3	2(2)	5(2)	6(2)	2	0.017	0.139	9(2)	30(3)	0	0.009	0.134	15(2)	25(3)	0	0.013	0.120
Gaussian-like MF																
2	1(2)	6(2)	3	0.017	0.273	6(2)	22(2)	2	0.013	0.142	9(2)	10(2)	3	0.010	0.122	
3	1(3)	5(3)	6(2)	2	0.007	0.195	3(2)	16(2)	0	0.014	0.144	4(2)	20(3)	0	0.012	0.118

(b) In case of using entire system inputs

M	1층			2층			3층											
	Node(M)	T	PI	EPI	Node(M)	T	PI	EPI	Node(M)	T	PI	EPI						
Triangular MF																		
2	3(2)	0	3	0.007	0.138	6(2)	28(2)	3	0.009	0.122	5(2)	6(3)	2	0.006	0.116			
3	3(2)	0	0	0.007	0.138	3(2)	25(2)	0	0.009	0.122	20(2)	28(3)	0	0.006	0.118			
Gaussian-like MF																		
2	2(2)	3(2)	2	0.013	0.151	5(2)	14(2)	2	0.007	0.131	11(2)	12(3)	2	0.006	0.121			
3	2(2)	3(2)	0	2	0.013	0.151	3(2)	26(2)	0	2	0.007	0.131	7(2)	15(3)	0	2	0.006	0.122

그림 4는 그림 3에서 보여준 염색체를 가지고 3층까지 진행했을 때의 최적 네트워크를 나타낸 것이다. 그림 4에서 보여준 노드 “”는 다음과 같이 표현된다. ‘FPNn’은 각 층에서 n번째 FPN 노드를 나타낸 것이고, ‘NI’는 해당 노드로 들어오는 입력의 수를, ‘T’는 해당 노드에 사용된 규칙 후

반부 다항식 차수를 나타낸 것이다. 그리고 노드 앞에 붙어 있는 사각형은 멤버쉽 함수의 수를 나타낸다. 즉, □내의 숫자는 멤버쉽 함수의 수를 의미한다.

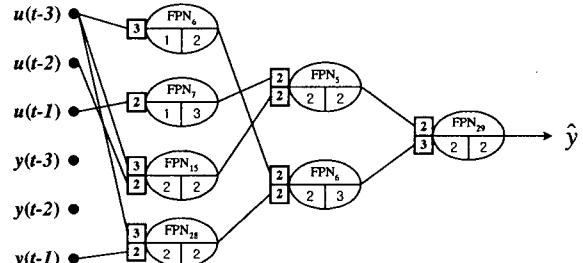


그림 4 최적 IG_gSOFPNN 구조(Max=2, Type T*)

Fig. 4 Optimal IG_gSOFPNN architecture

그림 5는 표 3-(b)의 Max가 2인 경우, 삼각형 멤버쉽 함수를 사용했을 때의 층의 진행에 따른 모델의 성능과 본 논문에서 제안한 information granulation 방법을 배제한 모델과의 성능을 비교한 것이다.

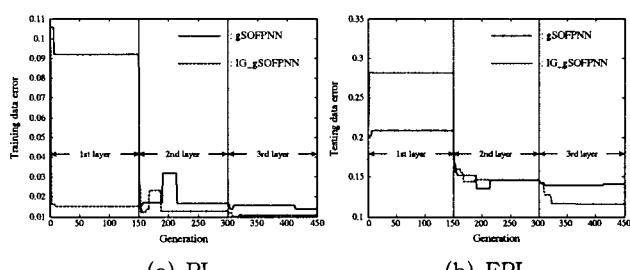


그림 5 GAs에 의한 최적화 과정(가스로 공정)

Fig. 5 Optimal procedure by GAs(gas furnace process)

표 4는 가스로 공정 데이터를 사용하여 성능 지수를 식(13)에 의해 계산된 값으로 기존의 모델과 본 논문에서 제시한 유전자 알고리즘을 이용한 SOFPNN 모델과의 성능비교를 한 것이다.

표 4 다른 모델링 방법과의 성능 비교

Table 4 Comparison of performance with other modeling methods

Model		PI	PI _s	EPI _s
Box and Jenkins's model[14]		0.710		
Pedrycz's model[15]		0.320		
Lin and Cunningham's model[18]			0.071	0.261
NNFS model[19]		0.128		
FPNN[5]	CASE I	0.045	0.016	0.116
	CASE II	0.037	0.012	0.125
gSOFPNN	3rd layer(Max=4)	0.018	0.122	
	5th layer(Max=5)	0.015	0.103	
	3rd layer(Max=4)	0.020	0.104	
	5th layer(Max=5)	0.016	0.100	
IG_gSOFPNN (Our model)	3rd layer(Max=2)	0.006	0.116	
	3rd layer(Max=3)	0.006	0.118	
	3rd layer(Max=2)	0.006	0.121	
	3rd layer(Max=3)	0.005	0.122	

5.2 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[20].

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.

근사화와 일반화 능력을 측정하는 성능지수는 식 (13)과 같다. 표 5는 제안된 모델의 평가를 위해 NOx 배출공정 데이터를 적용에 따른 성능지수를 나타낸다.

표 5 NOx에 대한 IG_gSOPNN 구조의 성능지수

Table 5 Performance index of IG_gSOPNN for NOx

(a) In case of using selected inputs

M	1층			2층			3층									
	Node(M)	T	PI	EPI	Node(M)	T	PI	EPI	Node(M)	T	PI	EPI				
Triangular MF																
2	4(3)	5(2)	3	4.018	7.151	6(3)	12(2)	3	0.071	1.498	4(3)	27(2)	4	0.072	0.145	
3	2(3)	4(2)	5(2)	2	1.072	3.830	1(2)	4(3)	0.4	0.080	0.484	5(2)	13(3)	0.4	0.027	0.111
Gaussian-like MF																
2	4(3)	5(2)	3	3.898	8.190	4(3)	8(2)	4	0.267	0.772	23(3)	29(2)	3	0.014	0.352	
3	1(2)	4(2)	5(2)	2	0.191	1.922	7(3)	17(3)	0.4	0.027	0.204	2(3)	16(2)	0.3	0.003	0.055

(b) In case of using entire system inputs

M	1층			2층			3층									
	Node(M)	T	PI	EPI	Node(M)	T	PI	EPI	Node(M)	T	PI	EPI				
Triangular MF																
2	4(3)	0	3	0.012	0.419	12(2)	13(2)	4	0.033	0.080	14(2)	20(3)	4	0.002	0.045	
3	4(3)	0	3	0.012	0.419	8(2)	12(2)	0.4	0.033	0.080	6(3)	15(2)	0.4	0.001	0.045	
Gaussian-like MF																
2	3(2)	5(2)	3	0.008	0.193	19(3)	28(2)	4	0.003	0.050	2(3)	14(2)	2	0.001	0.027	
3	3(2)	5(2)	0	3	0.008	0.193	15(3)	22(2)	0.2	0.003	0.067	15(2)	28(2)	0.4	0.001	0.027

그림 6은 표 5-(b)에서 보여준, 가우시안 멤버쉽 함수를 사용하고 Max=2일 때의 3층까지의 최적 네트워크를 그린 것이다. 표 6은 NOx 배출 공정 데이터를 사용하여 기존의 모델과 본 논문에서 제시한 IG_gSOPNN 모델과의 성능비교를 한 것이다.

6. 결 론

본 논문에서는 최적화 알고리즘인 유전자 알고리즘과 데이터의 특성을 분석하여 모델의 구축에 효과적인 정보 입자화 방법을 이용하여 정보 입자화 기반 진화론적 최적 자기구성 퍼지 다항식 뉴럴 네트워크의 효율적인 설계 방법을 제안하였고 이를 기반으로 주어진 비선형 예제들을 통하여 제안된 모델인 IG_gSOPNN의 우수성을 입증하였다.

본 연구에서는 최적화 방법인 유전자 알고리즘을 이용하여 노드의 입력변수의 수와 그에 해당한 입력변수, 퍼지규칙 후반부 다항식 차수 그리고 멤버쉽 함수의 수 등의 파라미터를 선택하여 모델 구축에 있어서 유연성과 정확성을 가지며 또한 주어진 데이터의 특성을 모델에 반영하기 위하여 정보 입

자화 방법중의 하나인 HCM 클러스터링 방법을 이용하여 멤버쉽 함수의 정점을 기존의 Min-Max 방법이 아닌 데이터의 분포를 파악하여 데이터의 특성에 맞게 멤버쉽 함수의 정점을 결정함으로써 더욱 정확한 예측 능력을 가진 최적화된 SOFPNN 모델 구조를 구축할 수가 있었다.

Tamb •

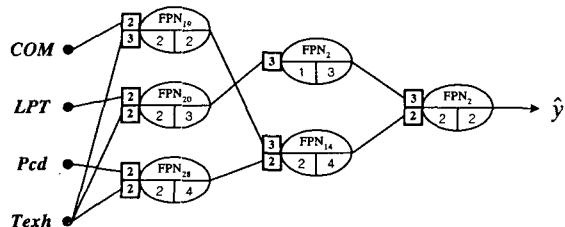


그림 6 최적 IG_gSOPNN 구조(Gaussian MF, Max=2, Type T*)

Fig. 6 Optimal IG_gSOPNN architecture with gaussian-like MF(Max=2, Type T*)

표 6 다른 모델링 방법과의 성능 비교

Table 6 Comparison of performance with other modeling methods

Model	PIs	EPIs
	Regression model	17.68
Hybrid Fuzzy Set-Based FNNs[21]	Simplified	2.806
	Linear	5.291
gSOPNN	5th layer(Max=2)	0.007
	5th layer(Max=3)	0.007
	Gaussian	0.002
	5th layer(Max=2)	0.045
	5th layer(Max=3)	0.001
IG_gSOPNN (Our model)	3rd layer(Max=2)	0.002
	3rd layer(Max=3)	0.001
	Gaussian	0.027
	3rd layer(Max=2)	0.001
	3rd layer(Max=3)	0.001

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 적더라고 체계적이고 효율적인 최적의 자기구성 퍼지 다항식 뉴럴 네트워크를 구축함을 보였다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초전력연구원(R-2003-B-274) 주관으로 수행된 과제임.

참 고 문 현

- A. G. Ivakhnenko, "Polynomial theory of complex systems", IEEE Trans. on Systems, Man and Cybernetics, Vol. SMC-1, pp. 364-378, 1971.
- A. G. Ivakhnenko and G. A. Ivakhnenko, "The Review of Problems Solvable by Algorithms of the Group Method of Data Handling (GMDH)", Pattern Recognition and Image Analysis, Vol. 5, No. 4, pp.

- 527-535, 1995.
- [3] S. K. Oh and W. Pedrycz, "The design of self-organizing Polynomial Neural Networks", *Information Science*, Vol. 141, pp. 237-258, 2002.
- [4] S. K. Oh, W. Pedrycz and B. J. Park, "Polynomial Neural Networks Architecture: Analysis and Design", *Computers and Electrical Engineering*, Vol. 29, Issue 6, pp. 703-725, 2003.
- [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] 박호성, 박건준, 이동윤, 오성권, "경쟁적 퍼지다항식 뉴런에 기초한 고급 자기구성 뉴럴네트워크", 대한전기학회, Vol. 53D, No. 3, pp. 135-144, March, 2004.
- [7] Holland, J. H., *Adaptation In Natural and Artificial Systems*, The University of Michigan Press, Ann Arbor. 1975.
- [8] D. E. Goldberg, *Genetic Algorithm in search, Optimization & Machine Learning*, Addison wesley, 1989.
- [9] 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.
- [10] R. Moore, *Interval analysis*, Prentice-Hall, Englewood Cliffs, NJ, 1966.
- [11] R. Moore (Ed.), *Reliability in Computing*, Academic Press, New York, 1988.
- [12] L. A. Zadeh, in: L.A. Zadeh, R. Yager, et al., (Eds.), *Fuzzy Sets and Applications: Selected Papers*, Wiley, New York, 1987.
- [13] J. C. BEZDEK, *Pattern Recognition with Fuzzy Objective Function Algorithms*, New York, Plenum, 1981.
- [14] D. E. Box and G. M. Jenkins, *Time Series Analysis, Forecasting and Control*, California: Holden Day, 1976.
- [15] W. Pedrycz, "An identification algorithm in fuzzy relational system", *Fuzzy Sets Syst.*, Vol. 13, pp.153-167, 1984.
- [16] 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.
- [17] W. Pedrycz, G. Vukovich, "Granular neural networks", *Neurocomputing*, Vol. 36, pp. 205-224. 2001.
- [18] 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.
- [19] Yin Wang and Gang Rong, "A self-organizing neural-network-based fuzzy system", *Fuzzy Sets and Systems*, Vol. 103, pp. 1-11, 1999.
- [20] G. Vachtsevanos, V. Ramani and T. W. Hwang, "Prediction of Gas Turbine NO_x Emissions using Polynomial Neural Network", Technical Report, Georgia Institute of Technology, Atlanta, 1995.
- [21] 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.
- [22] 오성권, 프로그래밍에 의한 컴퓨터지능, 내하 출판사, 2002. 9.
- [23] 오성권, 프로그래밍에 의한 하이브리드 퍼지추론 시스템, 내하 출판사, 2005.10.
- [24] 오성권, 하이브리드 퍼지추론시스템 국제 저널 논문집, 내하 출판사, 2005.10.
-
- ### 저 자 소 개
- 
- #### 박 호 성(朴 浩 成)

1999년 원광대학교 제어계측공학과 졸업. 동대학원 석사(2001), 박사(2005). 2005~현재 원광대학교 전기전자 및 정보공학부 전임강사. 관심분야는 퍼지, 뉴럴네트워크 및 퍼지-뉴럴네트워크, Computational Intelligence등의 인공 지능형 모델링과 제어, 시스템 자동화 등.
- 
- #### 오 성 권(吳 聖 權)

1981년 연세대학교 전기공학과 졸업. 1983-89년 금성산전연구소(선임연구원). 1993년 연세대 대학원 전기공학과 졸업(공박). 1996-1997년 캐나다 Manitoba대학 전기 및 컴퓨터공학과 Post-Doc. 1993년~2004년 원광대 전기전자 및 정보공학부 교수. 2005년~현재 수원대학교 전기공학과 교수. 2002년~현재 대한전기학회 및 제어·자동화·시스템공학회 편집위원, 관심분야는 시스템자동화, 퍼지이론 및 뉴로퍼지네트워크 용용, 컴퓨터지능 및 소프트 컴퓨팅 등.
- 
- #### 김 현 기(金 賢 起)

1977년 연세대 전기공학과 졸업. 동대학원 석사(1985), 동대학원 박사(1991). 1987년~현재 수원대 전기공학과 교수, 산학협력단장, 2002년~현재 한국 산학연기술학회 부회장 및 한국산학연 논문집 편집위원. 관심분야는 뉴로퍼지컴퓨팅, 퍼지이론, 유전 알고리즘, 지능형 모델링 및 제어, 자동화 시스템 등.