

Fuzzy Combined Polynomial Neural Networks

盧石範[†] · 吳聖權^{*} · 安泰天^{**}

(Seok-Beom Roh · Sung-Kwun Oh · Tae-Chon Ahn)

Abstract - In this paper, we introduce a new fuzzy model called fuzzy combined polynomial neural networks, which are based on the representative fuzzy model named polynomial fuzzy model. In the design procedure of the proposed fuzzy model, the coefficients on consequent parts are estimated by using not general least square estimation algorithm that is a sort of global learning algorithm but weighted least square estimation algorithm, a sort of local learning algorithm. We are able to adopt various type of structures as the consequent part of fuzzy model when using a local learning algorithm. Among various structures, we select Polynomial Neural Networks which have nonlinear characteristic and the final result of which is a complex mathematical polynomial. The approximation ability of the proposed model can be improved using Polynomial Neural Networks as the consequent part.

Key Words : fuzzy combined polynomial neural networks, polynomial fuzzy model, least square estimation, Polynomial Neural Networks, local learning algorithm

1. 장 서 론

L. A. Zadeh에 의해 제안된 퍼지 논리는 복잡하고 비선형성이 강한 시스템의 모델링 분야에 많은 가능성을 제시하였다[1]. Fuzzy model의 가능성이 제시된 이후, Tong[2]은 최초로 언어적 퍼지 모델을 제어에 응용하였고, 그 후에 수많은 연구자들에 의해 퍼지 모델과 퍼지 제어기에 대한 연구가 수행되어져 왔다. 특히 TSK 퍼지 모델은 모델링 분야를 비롯하여, 퍼지 제어 분야에서 많은 연구와 적용이 이루어져 왔다. Oh는 전형적인 TSK 퍼지 모델의 후반부 구조로 상수 형태를 포함한 4가지 종류의 회귀 다항식을 채택한 회귀다항식 퍼지 모델을 제안하였다[9,10]. 일반적인 함수 근사화 문제에서 가설 함수(hypothesis function)의 해 공간(solution space) 크기는 최적해 탐색에 큰 영향을 준다. 해 공간의 크기가 증가되면, 정의된 해공간에 절대적인 최적해가 포함될 수 있는 가능성은 증가된다. 그러나 해공간의 크기가 증가하면, 최적해를 찾기 위한 탐색이 어려워지게 된다. 적절한 해공간의 정의는 함수 근사화 문제에서 중요하다[16]. 현재 비선형 시스템의 모델 구축 및 제어분야에 많이 활용되고 있는 Mamdani 퍼지 모델, TSK 퍼지 모델과 회귀 다항식 퍼지 모델은 퍼지 규칙의 후반부 구조가 매우 제한적이다. 본 논문에서는 기존의 퍼지 모델의 후반부 구조를

다양화 시킨 퍼지 결합 다항식 뉴럴 네트워크를 제안하였다. 퍼지 결합 다항식 뉴럴 네트워크는 후반부 구조로 퍼지 모델의 후반부 구조의 다양성을 확보하기 위하여 동적 생성 모델인 다항식 뉴럴 네트워크[9]를 적용한 퍼지 모델이다. TSK 퍼지 모델의 경우에도, 후반부 다항식의 최대 차수를 증가시킴으로써, 후반부 구조 가설 함수 해공간을 확대시킬 수 있다. 그러나 다변수 고차 다항식을 퍼지 모델의 후반부 구조로 사용할 경우, 최소 자승법을 이용해 추정해야 할 다항식 계수의 수가 증가하게 된다. 이와 같은 경우, 주어진 실제 데이터의 개수가 충분히 많지 않으면, 최소 자승법을 이용하여 추정된 다항식 계수의 정확성을 보장하기 어려워진다. 고차 다항식의 정확한 계수 추정의 어려움을 해결하기 위하여 단순한 형태의 다항식을 반복적으로 중첩시킴으로써 비선형성이 강한 다항식을 구축하는 다항식 뉴럴 네트워크(Polynomial Neural Networks; PNN[9,10])가 제안되었다. 다항식 뉴럴 네트워크의 장점은 단순한 모델을 중첩시킴으로써 추정 알고리즘의 정확성을 높여 정확한 파라미터를 가진 비선형성이 강한 구조를 설계할 수 있다는 것이다. 다항식 뉴럴 네트워크는 GMDH(Group Method Data Handling) [6] 알고리즘에 기반을 두고 있기 때문에, 동적 생성 네트워크이다. 퍼지 모델의 후반부로 사용된 동적 생성 네트워크의 파라미터 추정을 위한 알고리즘으로는 지역적 학습 알고리즘인 가중 최소 자승법이 적합하다. 본 논문은 퍼지 결합 다항식 뉴럴 네트워크를 구축하고, 비선형 공정에 적용하기 위하여 가스로 데이터[14]와 가스터빈 발전소의 NOx 배출 공정 데이터[15]를 사용하여 제안된 모델의 타당성, 정확성 및 예측 성능 등을 보인다.

* 1: 會員 : 水原大學 電氣工學科 正教授

** 1: 會員 : 圓光大學 電氣電子 및 情報 工學部 正教授

† 교신저자, 正會員 : 圓光大學 制御計測 工學科 · 工博

E-mail : nado@wonkwang.ac.kr

接受日字 : 2007년 4월 16일

最終完了 : 2007년 6월 12일

2. 장 퍼지 규칙의 언어적 해석과 지역적 학습

상호 연관성이 배제된 퍼지 규칙들의 후반부 구조는 독립적인 동정이 가능하게 된다. 다시 말하면, 각 규칙이 할당된 공간의 지역적 특성만을 독립적으로 고려하여 파라미터를 추정하는 특성을 가지고 있다. 이러한 특성으로 인하여 Zadeh 교수가 제안한 퍼지 모델의 장점인 퍼지 모델의 언어적 해석을 용이하게 할 수 있다[5].

(1)과 같은 퍼지 규칙을 가진 회귀 다항식 퍼지 모델의 지역적 모델링 성능을 개선하기 위한 지역적 학습 알고리즘의 목적 함수를 (2)와 같이 정의 하였다.

$$R^j: \text{if } x_1 \text{ is } A_{1j} \wedge \dots \wedge x_m \text{ is } A_{mj} \text{ then } y = f_j(x_1, x_2, \dots, x_m; a_j) \quad (1)$$

$$J_L = \sum_{j=1}^r \sum_{k=1}^n \overline{w_{jk}} [(y_k - f_j(x_k))^2] = \sum_{j=1}^r (Y - X_j a_j)^T W_j (Y - X_j a_j) \quad (2)$$

여기서, $W_j = \begin{bmatrix} \overline{w_{j1}} & & 0 \\ & \overline{w_{j2}} & \\ 0 & & \overline{w_{jm}} \end{bmatrix}$, $X = \begin{bmatrix} 1 & x_{j1} & \dots & x_{m1} \\ 1 & x_{j2} & \dots & x_{m2} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{jn} & \dots & x_{mn} \end{bmatrix}$,

$$a_j = [a_{j0} \ a_{j1} \ \dots \ a_{jm}]^T \in R^{(m+1)}, \overline{w_{jk}} = \frac{w_{jk}}{\sum_{i=1}^r w_{ik}} \text{이다.}$$

위 식에서 w_{jk} 는 k-번째 데이터에 대한 j-번째 규칙의 적합도, $\overline{w_{jk}}$ 는 정규화된 적합도, m은 입력변수의 수, r은 규칙 수, n은 데이터의 수를 나타낸다. (2)는 각 규칙의 최종출력과 실제 시스템의 출력간의 오차를 가중치 W_j 을 이용하여 결합된 목적함수이다. (2)에 나타난 것과 같이 퍼지 규칙들간의 상호 관계는 가중치 행렬 W_j 에 의해 배제 될 수 있다. (2)를 최소화 시키는 각 규칙의 후반부 계수 벡터들은 (3)과 같이 구해 질 수 있다[5].

$$a_j = (X_j^T W_j X_j)^{-1} (X_j^T W_j Y) \quad (3)$$

3. 장 퍼지 결합 다항식 뉴럴 네트워크

제안된 퍼지 모델인 퍼지 결합 다항식 뉴럴 네트워크는 후반부 구조의 다양성을 확보하기 위하여 다항식 뉴럴 네트워크를 사용하였다. 다항식 뉴럴 네트워크는 GMDH 알고리즘을 기반으로 하여 다변수 다차식의 확장된 부분표현식을 이용하여 연속적인 층과 노드를 생성하는 네트워크이며, 기존의 신경망 알고리즘보다 적은 노드수와 유연한 적응특성을 가지고 있다[20,21]. 본 논문에서는 위에서 언급한 특성을 가진 다항식 뉴럴 네트워크를 퍼지 모델의 후반부 구조로 이용한 퍼지 결합된 PNN 모델의 구조를 제안하고 제안된 모델의 계수를 추정하기 위하여 지역 학습 알고리즘인 가중 최소 사승법(weighted Least Square Estimation: WLSE)을 사용하였다.

(4)는 PNN을 퍼지 규칙의 후반부 구조로 적용한 퍼지 결합된 다항식 뉴럴 네트워크의 퍼지 규칙을 보인다.

$$R^j: \text{if } x_1 \text{ is } A_{1j} \wedge \dots \wedge x_m \text{ is } A_{mj} \text{ then } y = PNN^j \quad (4)$$

여기서, R^j 는 j-번째 규칙의 나타내며, A_{ij} 은 j-번째 규칙의 i-번째 입력변수에 관련된 퍼지 집합을 의미하며, PNN^j 는 j-번째 퍼지 규칙의 후반부 구조로 사용된 PNN을 의미

한다. (4)와 같은 퍼지 규칙을 가진 퍼지 결합 다항식 뉴럴 네트워크는 최종 출력은 (5)와 같다.

$$y^* = \sum_{j=1}^r \overline{w_j}(x_j) \cdot PNN^j(x_j) \quad (5)$$

GMDH알고리즘에 기반을 두고 동정 생성되는 PNN^j 의 네트워크 구조는 그림 1과 같다.




그림 1 PNN의 구조
Fig. 1 Structure of PNN

그림 3에서 ㉔들은 PNN의 최종 네트워크의 구성 노드로 선택된 노드들이며, ㉕은 선택되지 않은 노드들이다. 다시 말하면, 선택된 노드들은 최종 출력 z^* 의 입력변수로 쓰이는 노드들이다. PNN을 구성하는 노드들은 표 1에 보인 다양한 형태의 다항식들이다.

표 1 퍼지 규칙 후반부의 다양한 회귀 다항식 형태
Table 1 Different forms of the regression polynomials forming the consequence part of the fuzzy rules.

다항식의 차수 \ 입력 변수의 수	1	2	3
0 (Type 1)	상수	상수	상수
1 (Type 2)	1입력 1차식	2입력 1차식	3입력 1차식
2 (Type 3)		2입력 2차식-1	3입력 2차식-1
2 (Type 4)	1입력 2차식	2입력 2차식-2	3입력 2차식-2

1: 기본형, 2: 수정형

다항식 뉴럴 네트워크의 각 노드와 입력변수의 수, 입력 변수 및 다항식의 차수는 대표적인 최적화 방법들 중 하나인 유전자 알고리즘을 이용하여 결정한다. 유전자 알고리즘을 이용한 퍼지 결합 다항식 뉴럴 네트워크의 최적화 설계 방법은 다음과 같다.

- 1) 시스템 입력변수의 결정
- 2) 데이터 분할: 전체 입력력 데이터를 학습용 데이터와 테스트용 데이터로 분할
- 3) PN의 입력 변수 수 결정 : PNN의 각 층에서 PN의 입력으로 선택될 수 있는 입력 변수의 수를 결정
- 4) 퍼지 모델 전반부 구조 및 파라미터를 결정 :
전반부 구조-멤버십 함수의 형태 (삼각형 or 가우시안 형태의 멤버십 함수), 멤버십 함수의 수
전반부 파라미터-퍼지 규칙을 구성하는 언어적 레이블인 멤버십 함수의 정점 결정
- 5) 퍼지 규칙의 적합도 계산 : 전반부 구조 및 파라미터를 기반으로 각 규칙의 적합도를 (6)을 이용하여 계산

$$w_k = \mu_{k1} \wedge \mu_{k2} \wedge \dots \wedge \mu_{km} \quad (6)$$

6) Weighting Factor 행렬 W_k^{tr} 와 W_k^{te} 설정 : W_k^{tr} 는 k-번째 규칙에 대한 학습 데이터에 의해 구해진 적합도를 (2)에 적용한 적합도 대각 행렬이며, W_k^{te} 는 k-번째 규칙에 대한 테스트 데이터에 의해 구해진 적합도를 이용하여 생성된 대각 행렬이다.

7) gPNN 구조 정보 결정 : 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 결정

8) 유전자 알고리즘을 이용한 퍼지 규칙 후반부인 gPNN 동적 설계

8.1) PNN 모델 구축을 위한 유전자 알고리즘의 초기값 설정 : 유전자 알고리즘의 세대, Population 개수, 돌연변이율, 교배율, 염색체의 길이와 같은 유전자의 정보, 다음층의 입력으로 사용될 노드의 개수를 결정

8.2) 유전자 알고리즘을 이용한 다항식 뉴럴 네트워크의 층 설계 (모델의 구축과 테스트 그리고 노드의 선택)

8.2.1) 유전자 알고리즘을 이용한 PN의 입력변수 수와 회귀 다항식 차수 선택 : 유전자 알고리즘을 이용한 다항식 뉴럴 네트워크의 각 층의 구성요소인 노드의 설계는 그림 4에 보인 것과 같다. 그림 2에서는 입력변수의 개수가 4, 선택할 입력 변수의 수가 2인 경우를 보인다. 그림 4에 보인 스위치는 유전자 알고리즘의 각 개체를 이용하여 입력변수를 선택하고 회귀 다항식의 구조를 선택한다.

여기서, N_{tr} : 학습데이터의 수, N_{te} : 평가 데이터의 수, P_{ij}^k : k-번째 퍼지 규칙의 PNN^k의 j-번째 layer의 i-번째 PN의 근사화 성능 지수, EP_{ij}^k : 일반화 성능지수, z_{ij}^k : k-번째 퍼지 규칙의 후반부 PNN^k의 j-번째 layer의 i-번째 PN의 출력력을 의미하며 (9)와 같이 구한다.

$$z_{ij}^k = X_k a_{k,ij} \tag{9}$$

여기서 $a_{k,ij}$ 는 (3)에 의해서 구해진 PNN의 j-번째 층의 i-번째 PN의 계수 벡터이다.

$$f(PI, EPI) = \theta \times PI + (1-\theta) \times EPI \tag{10}$$

8.2.4) Superior individuals Pool 초기화 및 갱신 : 현 세대가 첫 번째 세대이면 설정된 선택될 노드의 수만큼 우수 개체를 선택하여 Superior individuals Pool에 저장하며. 첫 번째 세대가 아니면, Superior individuals Pool에 저장된 개체의 성능과 현 세대에서 얻어진 개체들의 성능을 비교하여 우수한 개체들을 Superior individuals Pool에 저장한다.

8.2.5) 다음 세대의 population 생성 (유전자 연산자 적용) : 선택연산, 교배, 돌연변이연산 실행

8.2.6) 유전자 알고리즘의 종료 조건 검사 :

8.3) 다음 층의 새로운 입력변수 설정 : 현재 층인 i층에서 보존된 노드의 출력들($z_{i1}^k, z_{i2}^k, \dots, z_{iw}^k$)은 다음 층인 (i+1)층의 새로운 입력들($x_{(i+1)}^1, x_{(i+1)}^2, \dots, x_{(i+1)}^w$)로 (11)를 통해 구성된다. 여기에 원래 시스템 입력변수들이 추가되어 새로운 층의 입력변수로 정의된 후, $i=i+1$ 로 변경하고 8.1)부터 수행한다.

$$x_{(i+1)}^1 = z_{i1}^k, x_{(i+1)}^2 = z_{i2}^k, \dots, x_{(i+1)}^w = z_{iw}^k \tag{11}$$

9) 종료 조건 검사 : 만약 k가 퍼지 모델의 규칙 수에 비해 작으면 $k=k+1$ 로 변경하고, step 5에서부터 step 8까지의 절차를 반복수행하고 k가 퍼지 모델의 규칙 수와 동일하면 유전자 알고리즘을 이용한 Fc_gPNN의 설계 절차를 마친다.

4. 장 실험 연구 및 결과 고찰

본 논문에서 제안된 FcPNN은 지역 모델인 PNN들의 퍼지 결합 방법에 따라 세분화 되어 나누어 질 수 있다. 퍼지 결합 방법으로는 일반적인 TSK 퍼지 모델[4]의 결합 방법인 퍼지 관계 기반 결합과 Yamakawa에 의해 제안된 Yamakawa 퍼지 모델[17]의 결합 방법인 퍼지 집합 기반 결합방법으로 나누어 생각한다.

4.1 질 가스로 공정 데이터

가스로 공정 데이터는 benchmark 데이터로 많이 알려져 있어 새로 제안된 모델의 성능 분석할 때 자주 사용되는 데이터이다. 입·출력 형태는 $[u(t-3), u(t-2), u(t-1), y(t-3), y(t-2), y(t-1); y(t)]$ 인 데이터 쌍을 사용하여 제안된 모델의 성능을 평가 할 것이다.

4.1.1 질 진화론적 퍼지 관계 결합 다항식 뉴럴 네트워크 (FRc_gPNN)

앞서 언급한 바와 같이 다항식 뉴럴 네트워크의 전반부 퍼지 결합은 전형적인 TSK 퍼지 모델의 결합 구조를 사용하였고, 다항식 뉴럴 네트워크의 설계는 최적화 기법인 유전자 알고리즘을 사용하였다. 표 2는 유전자 알고리즘을 수행

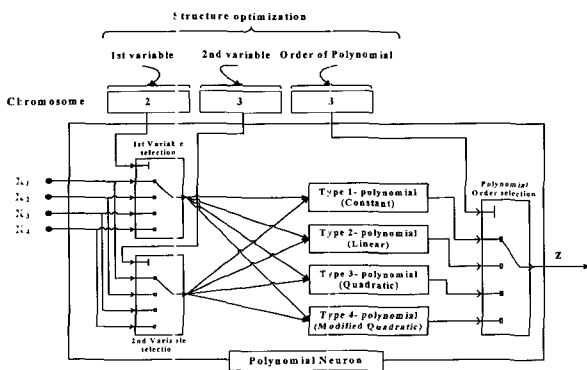


그림 2 유전자 알고리즘의 염색체를 이용한 PN 설계
Fig. 2 The PN design by using a chromosome of GAs

8.2.2) 지역 학습을 이용한 다항식 계수 추정 : (2)를 최소화 시키는 계수 a_k 를 식 (3)을 이용하여 추정

8.2.3) 유전자 알고리즘에 의해 생성된 PN의 평가 : 생성된 각 노드의 근사화 능력과 일반화 능력을 평가하여, 현재 층을 이루는 기본 노드로 적합한지 근사화 성능(PI)과 일반화 성능(EPI)을 판별하여 선택한다. 근사화 성능과 일반화 성능은 각각 (7)과 (8)을 이용하여 구할 수 있다. 본 논문에서는 모델의 근사화 성능과 일반화 능력 사이의 합리적 균형을 얻기 위해 하중값을 가진 목적함수 (10)를 이용하여 노드를 테스트한다.

$$PI_{ij}^k = \frac{1}{N_{tr}} (Y_{tr} - z_{ij}^k)^T W_k^{tr} (Y_{tr} - z_{ij}^k) \tag{7}$$

$$EPI_{ij}^k = \frac{1}{N_{te}} (Y_{te} - z_{ij}^k)^T W_k^{te} (Y_{te} - z_{ij}^k) \tag{8}$$

하기 전에 설계자가 미리 정하여 주어야 하는 초기정보를 보인다. 표 3은 FRc_gPNN을 이용한 가스로 공정데이터를 모델링한 성능지수를 보여주고 있다.

표 2 유전자 알고리즘의 초기 정보
Table 2 A list of parameters of the GAs

parameter	value
Maximum Generation	50
No. of Sub-populations	5
Size of Sub-populations	[30 30 30 30 30]
Crossover rate	[0.8 0.8 0.8 0.8 0.8]
Mutation rate	[0.1 0.1 0.1 0.1 0.1]
Immigration Term	Each 10 generation
Size of Immigration chromosomes	10% of Size of Sub-populations

표 3 FRc_gPNN의 성능지수
Table 3 Performance Index of FRc_gPNN

Max	MF	Input Variables	No. MF	PI	EPI
2	T	5, 6	2, 2	0.1108	0.1948
	G	5, 6	2, 2	0.1111	0.1954
3	T	1, 5, 6	3, 2, 3	0.0305	0.0850
	G	1, 5, 6	3, 3, 3	0.0306	0.0826

4.1.2 절 진화론적 퍼지 집합 결합 다항식 뉴럴 네트워크 (FRc_gPNN)

FSc_gPNN 모델은 유전자 알고리즘을 이용하여 후반부의 local model로 최적 구조를 가진 PNN 모델을 생성한다. 표 4는 FSc_gPNN을 이용한 가스로 공정데이터를 모델링한 성능지수를 보여주고 있다.

표 4 FSc_gPNN의 성능지수
Table 4 Performance Index of FSc_gPNN

Max	MF	Input Variables	No. MF	PI	EPI
2	T	5, 6	2, 2	0.1100	0.1928
	G	5, 6	2, 2	0.1109	0.1926
3	T	1, 5, 6	3, 3, 3	0.0374	0.0938
	G	1, 5, 6	3, 3, 3	0.0388	0.0957

표 5는 제안된 모델과 기존의 다른 모델과의 모델링 성능 비교를 보인다. 제안된 모델을 기존 모델들 중 우수한 성능을 보이는 IG_gFSPNN과 비교하면 근사화 능력 면에서는 IG_gFSPNN이 우수하지만, 일반화 성능 면에서는 제안된 FRc_gPNN이 월등히 우수한 것을 알 수 있다. 또한 각 모델의 복잡성 측면에서 분석하면, IG_gFPNN은 수개의 TSK 퍼지 모델들이 결합하여 한 층을 이루고 이러한 층들이 3층으로 이루어진 복잡한 구조를 가진 모델이지만, 제안된 FRc_gPNN은 전반부 구조는 일반적인 TSK 퍼지 모델과 동일하며, 후반부 구조로 쓰인 다항식 뉴럴 네트워크는 비선형성이 강한 고차의 다항식으로 변환되기 때문에 사용된 퍼지 규칙의 수는 TSK 퍼지 모델과 유사하다.

표 5 제안된 모델의 성능 비교

Table 5 Comparative analysis of the performance of the network

Model		Performance index		
		PI	PI _t	EPI _t
Pedrycz's model[7]		0.320		
Gomez-Skarmeta's model[11]		0.157		
Oh and Pedrycz's model[8]		0.123	0.020	0.271
Kim et al.'s model[12]			0.034	0.244
Lin and Cunningham's model[13]			0.071	0.261
FPNN	CASE I		0.016	0.116
	CASE II		0.016	0.128
PNN	Basic		0.021	0.110
	Modified		0.015	0.103
HFPNN	Triangular MF		0.019	0.134
	Gaussian MF		0.021	0.119
Generic SOPNN	Basic SOPNN	0.027	0.021	0.085
	Modified SOPNN	0.035	0.017	0.095
Advanced SOPNN	Basic SOPNN		0.020	0.119
	Modified SOPNN		0.018	0.118
gFPNN	Triangular MF		0.018	0.122
	Gaussian MF		0.020	0.104
gFSPNN	Triangular MF		0.011	0.112
	Gaussian MF		0.010	0.103
IG_gFSPNN	Triangular MF		0.008	0.110
	Gaussian MF		0.008	0.099
FRc_gPNN	Triangular MF		0.0305	0.0850
	Gaussian MF		0.0306	0.0826
FSc_gPNN	Triangular MF		0.0374	0.0938
	Gaussian MF		0.0388	0.0957

PI - performance index over the entire data set,
PI_t - performance index on the training data, EPI_t - performance index on the testing data.

4.2 절 가스터빈 발전소의 NOx 배출공정

제안된 모델의 성능을 평가하기 위하여 마지막으로 NOx 배출공정[15]을 적용하였으며, 입·출력 형태는 5입력 1출력 형태를 가지고 있다. 모델의 성능지수는 가스로 공정과 마찬가지로 MSE를 사용하였다. 합성성능지수를 위한 하중계수 값은 $\theta=0.5$ 으로 모델의 모델링 능력과 일반화 능력을 모두 고려하여 모델을 설계하였다.


4.2.1 절 진화론적 퍼지 관계 결합 다항식 뉴럴 네트워크

FRc_gPNN은 유전자 알고리즘을 이용하여 네트워크를 최적화 시킨다. 표 6은 FRc_gPNN의 모델링 성능지수를 나타낸다.


표 6 FRc_gPNN의 성능지수
Table 6 Performance Index of FRc_gPNN

Max	MF	Input Variables	No. MF	PI	EPI
2	T	1, 4	3, 3	2.4502	1.4592
	G	1, 4	3, 3	2.3255	1.4868
3	T	1, 2, 4	3, 3, 3	0.0098	0.0334
	G	1, 2, 4	3, 3, 3	1.9077	0.1809

표 6에 보인 4개의 구조들 중 근사화 능력과 일반화능력이 모두 우수한 모델은 max=3, 멤버집합수:T(삼각형), 27개의 규칙을 가진 모델이며, 근사화 능력 PI=0.0098, 일반화 능력 EPI=0.0334의 성능을 나타낸다. 그림 3은 앞에 설명한 가장 선호되는 모델의 출력과 실제 데이터를 비교한 것이다.



(a) training data



(b) testing data

그림 3 NOx공정데이터의 출력값과 FRC_gPNN모델의 출력값
Fig. 3 Original output and FRC_gPNN model output of NOx process

4.2.2 질 진화론적 퍼지 집합 결합 다항식 뉴럴 네트워크

유전자 알고리즘에 의해 최적화된 FSc_gPNN의 모델링 성능지수는 표 7과 같다.

표 7 FSc_gPNN의 성능지수
Table 7 Performance Index of FSc_gPNN

Max	MF	Input Variables	No. MF	PI	EPI
2	T	1, 4	3, 2	0.2521	1.6103
	G	1, 4	3, 3	0.2459	1.6052
3	T	1, 2, 4	3, 3, 3	0.1462	1.2588
	G	1, 2, 4	3, 3, 3	0.1317	1.2601

표 8은 제안된 모델과 기존의 다른 모델과의 모델링 성능 비교를 보인다. 기존의 모델들 중 가장 우수한 모델인 gHFPNN과 비교해 보면, 전체 시스템 입력을 사용하지 않은 Type T의 모델에 비해서는 일반화 성능 (EPI) 뿐만 아니라 근사화 능력 (PI)에서도 월등한 결과를 보인다. 전체 시스템 입력을 사용하는 Type T* 모델과 비교할 경우, 5층 gHFPNN은 PI=0.005, EPI=0.032인 근사화성능과 일반화 성능을 보인다. FRC_gPNN은 PI=0.0098, EPI=0.0334의 성능을 보여 Type T* gHFPNN에 비해 좋지 못한 결과를 보인다. 그러나 제안된 FRC_gPNN은 선택된 시스템 입력(Max=3, 다시말하면 X_1, X_2, X_4)만을 사용하였고 Type T* gHFPNN은 시스템 입력 전체를 사용한 모델이다.

표 8 제안된 모델의 성능 비교

Table 8 Comparison of performance with other modeling methods

Model			Performance index		
			PI	PI _s	EPI _s
Regression model				17.68	19.23
Oh's model [9]	FNN		5.835		
	AIM		8.420		
FNN [10] (GAs+Complex)	Simplified	$\theta = 0.4$	6.269	8.778	
	Linear	$\theta = 0.2$	3.725	5.291	
Multi-FNN	Linear	$\theta = 0.75$	0.720	2.025	
gHFPNN	Type T	Triangular (Max=5)	2 layer	0.150	0.342
		Gaussian (Max=5)	5 layer	0.071	0.131
			5 layer	0.056	0.123
	Type T*	Triangular (Max=4)	2 layer	0.007	0.060
		Gaussian (Max=4)	5 layer	0.005	0.032
			5 layer	0.002	0.039
FRc_gPNN	Triangular	Max = 3	0.0098	0.0334	
	Gaussian	Max = 3	1.9077	0.1809	
FSc_gPNN	Triangular	Max = 3	0.1462	1.2588	
	Gaussian	Max = 3	0.1317	1.2601	

5. 장 결론

본 논문에서는 퍼지 모델의 후반부 구조로 다항식 뉴럴 네트워크를 후반부 구조로 사용한 새로운 모델을 제시 하였다. 제안된 퍼지 모델의 후반부 구조로 적용된 동적 생성 모델인 다항식 뉴럴 네트워크의 다항식 계수를 추정하기 위해서는 지역 학습 알고리즘을 이용하였다. 지역적 학습 알고리즘에 의해 상호 관계가 배제된 퍼지 규칙은 그 규칙이 할당된 부공간상의 실 시스템 입출력 관계를 충실히 나타낼 수 있게 된다. 퍼지 규칙의 후반부 파라미터 추정에 지역적 학습알고리즘을 사용하여 퍼지 규칙의 언어적 해석을 개선 하고, 퍼지 규칙의 후반부에 비선형성이 강한 다항식 뉴럴 네트워크를 적용함으로써 퍼지 모델의 근사화 성능도 개선 할 수 이었다. 제안된 모델의 근사화 성능과 일반화 성능을 TSK 퍼지 모델과 비교하기 위한 실 데이터에 대한 실험에서도 TSK 퍼지 모델에 비해 근사화 성능과 일반화 성능측면에서 모두 좋은 결과를 보인다. 또한 모델의 복잡성을 고려한다면, 기존의 모델에 비해 제안된 퍼지 모델이 단순한 구조를 가지면서도 우수한 성능을 보인다.

감사의 글

이 논문은 2006년도 정부(교육인적자원부)의 재원으로 한국 학술 진흥 재단의 지원을 받아 수행된 연구임 (KRF -2006-353-D00021)

참 고 문 헌

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

[2] Tong R. M., "Synthesis of fuzzy models for industrial processes," *Int. J. Gen. Syst.*, vol 4, pp. 143-162, 1978.

[3] Huang Y. L., Helen H. L., Gong J. P., and Edgar T. F., "Fuzzy Model Predictive Control," *IEEE Trans. on Fuzzy Sytems*, vol 8, No 6, pp. 665-678, Dec. 2000.

[4] Takagi T. and Sugeno M., "Fuzzy identification of systems and its applications to modeling and control", *IEEE Trans. Syst. Man Cybern.*, vol. 15, pp. 116-132, Jan. 1985.

[5] John Yen, Liang Wang, and Charles Wayne Gillespie, "Improving the Interpretability of TSK Fuzzy Models by Combining Global Learning and Local Learning", *IEEE Trans. on Fuzzy Systems*, vol 6, No 4, Nov. 1998.

[6] Ivahnenko A. G., "Polynomial theory of complex systems", *IEEE Trans. on Systems, Man and Cybernetics*, Vol. SMC-12, pp. 364-378, 1971.

[7] Pedrycz W. and Reformat M., "Evolutionary Optimization of Fuzzy Models in Fuzzy Logic: A framework for the New Millennium", V. Dimitrov and V. Korotkich (eds.), 'Studies in Fuzziness and Soft Computing', Vol. 8, Physica-Verlag, pp. 51-67, September 1996.

[8] Oh S. K. and Pedrycz W., "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.

[9] Oh S. K., Pedrycz W. and Park B. J., "Polynomial Neural Networks Architecture: Analysis and Design", *Computers and Electrical Engineering*, Vol. 29, Issue 6, pp. 703-725, 2003.

[10] Oh S. K. and Pedrycz W., "Fuzzy Polynomial Neuron-Based Self-Organizing Neural Networks", *Int. J. of General Systems*, Vol. 32, No. 3, pp. 237-250, May, 2003.

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

[12] Kim E. T., et al, "A simple identified Sugeno-type fuzzy model via double clustering", *Information Science*, Vol. 110, pp. 25-39, 1998.

[13] Lin Y., G. Cunningham A. III, "A new approach to fuzzy-neural modeling", *IEEE Trans. Fuzzy Systems*, Vol. 3, No. 2, pp. 190-197, 1995.

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

[15] Vachtsevanos G., Ramni V. and Hwang T. W.. "Prediction of Gas Turbine NOx Emissions using Polynomial Neural Networks", *Technical Report*, Georgia Institute of Technology, Atlanta, 1995.

[16] Vapnik, V., "Statistical Learning Theory", John Wiley, New York, 1998.


[17] Yamakawa T., "A New Effective Learning Algorithm for a Neo Fuzzy Neuron Model", *5th IFSA World Conference*, pp. 1017-1020, 1993.

저 자 소 개



노 석 범 (盧石範)

1994년 원광대 제어계측공학과 졸업.
 1996년 동 대학 컴퓨터 공학과 졸업(석사).
 2006년 동 대학 제어계측공학과 졸업(박사).
 관심 분야 : 퍼지 모델링, 컴퓨터 지능, statistical learning
 Tel : (063) 850-6344
 E-mail : nado@wonkwang.ac.kr



오 성 권 (吳聖權)

1981년 연세대 전기공학과 졸업. 1983-89년 금성산전연구소(선임연구원). 1983년 연세대 대학원 전기공학과 졸업(공학박사).
 1996-1997년 캐나다 Manitoba대학 전기 및 컴퓨터공학과 Post-Doc. 1983-2003년 원광대학교 전기전자 및 정보공학부 교수.
 2004년-현재 수원대학교 정교수. 관심 분야 : 시스템 자동화, 퍼지 이론 및 뉴로 퍼지 네트워크 응용, 계산지능 및 소프트 컴퓨팅
 Tel : (031) 229-8162
 E-mail : ohsk@suwon.ac.kr



안 태 천 (安泰天)

1976년 연세대 전기공학과 졸업. 1980년 동대학원 전기공학과 졸업(석사). 1986년 동대학원 전기공학과 졸업(박사). 1987년-1988년 Uppsala 대학 방문교수. 1996년-1997년 Georgia 공대 방문교수. 1981년-현재 원광대학교 전기 전자 및 정보 공학부 교수. 관심분야는 digital granular control, 실시간 데이터 계측 및 처리, FPGA 설계, 지능 시스템, Rough Set theory.
 Tel : (063) 850-6344
 E-mail : tcahn@wonkwang.ac.kr