

HCM 클러스터링과 유전자 알고리즘을 이용한 다중 FPNN 모델 설계와 비선형 공정으로의 응용

Design of Multi-FPNN Model Using HCM Clustering and Genetic Algorithms and Its Application to Nonlinear Process Systems

박호성 · 오성권 · 안태천

Ho-Sung Park, Sung-Kwun Oh and Tae-Chon Ahn

원광대학교 전기전자공학부

요 약

본 논문에서는, 최적 시스템 동정을 위해서 FNN과 PNN에 기반을 둔 Multi-FPNN(다중 퍼지 다항식 뉴럴네트워크) 모델을 제안한다. 여기서 FNN 구조는 각각의 분리된 입력변수에 의해 분할된 퍼지 입력공간을 사용해서 설계되고, 간략 퍼지추론 방법과 오류 역전파 알고리즘을 이용한다. FNN은 더 좋은 출력성능을 얻기 위해 PNN과 결합된다. GMDH 방법에 기초한 PNN 구조의 각 노드는 1차 및 2차 고계 다항식의 두 형태를 사용하고, 그 노드의 입력은 2, 3, 4의 세 종류의 다변수 입력을 사용한다. 그리고 다중 FPNN 모델의 구조와 파라미터를 동정하기 위해 HCM 클러스터링방법과 유전자 알고리즘을 사용한다. 여기서, 시스템 모델링을 위해 데이터 전처리 기능을 수행하는 HCM 클러스터링 방법은 입출력 공간분할에 의해 다중 FPNN 구조를 결정하기 위해 사용된다. 모델의 근사화와 일반화 능력 사이에 충분한 균형을 얻기 위해 하중계수를 가진 합성 성능지수(목적함수)를 사용한다. 데이터 개수, 비선형성의 정도(입·출력 데이터 분포)에 의존하는 이 합성 목적함수의 하중계수의 선택 및 조절을 통하여 최적의 다중 FPNN 모델을 설계하는 것이 유용하고 효과적임을 보인다. 본 연구는 두 개의 대표적 수치예의 도움으로 설명되고, 그 모델의 근사화 및 일반화 능력에 관련된 합성 성능지수가 평가되고, 또한 토의된다.

ABSTRACT

In this paper, we propose the Multi-FPNN(Fuzzy Polynomial Neural Networks) model based on FNN and PNN(Polynomial Neural Networks) for optimal system identification. Here FNN structure is designed using fuzzy input space divided by each separated input variable, and utilizes both the simplified fuzzy inference method and the back-propagation algorithm. PNN is combined with FNN in order to get better output performance. Each node of PNN structure based on GMDH(Group Method of Data Handling) method uses two types of high-order polynomials such as linear and quadratic, and the input of that node uses three kinds of multi-variable inputs such as two, three, and four. And we use a HCM clustering method and Genetic Algorithms(GAs) to identify both the structure and the parameters of a Multi-FPNN model. Here, HCM clustering method, which is carried out for data preprocessing of process system, is utilized to determine the structure of Multi-FPNN according to the divisions of input-output space. A aggregate performance index with a weighting factor is used to achieve a sound balance between approximation and generalization abilities of the model. 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(distribution of I/O data), we show that it is available and effective to design an optimal Multi-FPNN model. The study is illustrated with the aid of two representative numerical examples and the aggregate performance index related to the approximation and generalization abilities of the model is evaluated and discussed.

1. 서 론

최근의 제어 시스템이 높은 역학적인 성능향상과 강인성이 요구됨과 동시에 훨씬 복잡하고 불확실하며 비선형성을 나타내는 공정의 제어까지도 요구된다. 이러

이 논문은 1999년도 원광대학교의 교비지원에 의해서 연구됨.

한 비선형적인 공정을 모델링하기 위해서 퍼지이론[1], 신경망, 퍼지-뉴럴 네트워크와 같은 지능적인 시스템들이 다양하게 연구되고 있다. 특히, 보다 효과적인 시스템의 모델링을 위해 퍼지이론과 신경망 각각의 장점들을 상호 융합한 퍼지-뉴럴 네트워크에 대한 연구가 활발히 진행되고 있다[2]. 또한 복잡한 다변수계의 모델링은 많은 입출력 변수 중에서 모델을 구성하는

변수를 선택하여 모델의 구조를 결정하는데 어려움이 있으며, 추정방법의 계수가 많으면 추정에 필요한 데이터 양이 방대해지는 문제점을 지니고 있다. 이런 문제점을 해결하기 위한 방법으로 A. G. Ivakhnenko는 GMDH(Group Method of Data Handing) 알고리즘을 제안하였다[3].

본 논문에서 사용한 퍼지-뉴럴 네트워크는 간략 퍼지추론 방법과 오류 역전파 알고리즘을 이용한 것으로, 다른 비선형 모델에 비해서 학습속도가 빠르고 수렴 특성이 우수하다는 장점을 가졌다[4]. 또한 PNN은 GMDH 알고리즘을 기반으로 하며, 기존의 신경망 구조와 같이 고정되지 않고 새로운 구조를 생성하는 네트워크 구조를 가진다. GMDH 알고리즘은 단지 2변수 2차식의 부분표현식에 의해 시스템을 예측하였는데, 본 논문에서는 다변수를 사용하여 입력변수의 개수를 확장하고, 다항식의 차수를 1차 및 2차 고계 다항식의 두 형태를 사용하여 GMDH의 한계를 극복하였다[9].

본 논문에서는 복잡하고 불확실한 비선형 시스템의 최적 동정을 위해 FNN과 PNN에 기반을 둔 다중 FPNN를 제안한다. 각각의 FPNN 구조는 전반부로 FNN 구조가, 후반부로 PNN 구조가 사용되며, 이로부터 공정의 비선형 특성을 고려할 수 있고, 더 향상된 출력을 얻는 것이 가능하다. 또한 비선형적이고 복잡한 실 시스템의 데이터 특성에 맞춘 다중 FPNN 구조를 결정하기 위해 HCM 클러스터링 방법을 이용하여 입출력 데이터의 전처리 과정을 수행하고, 데이터 특성 분류에 따른 각 FPNN 구조의 최적화를 위해 유전자 알고리즘[5]를 이용하여 모델 전반부인 FNN의 멤버쉽함수 정점과 학습율, 모멘텀 계수를 최적으로 동조한다. 그리고 기존의 학습 데이터뿐만 아니라 테스트 데이터를 고려한 모델 성능 모두를 고려하여 실 공정 적용의 유용성에 그 방향을 맞추었고, 특히 하중계수를 가진 합성 성능지수[6]에 의해 설계자의 의도, 성능 결과의 상호균형, 시스템의 비선형 정도 등에 따른 최적 모델 동정을 시도하였다. 제안된 모델의 평가를 위해 Box와 Jenkins가 사용한 가스로 시계열 입출력 데이터[7]와 비선형 함수를 이용한 수치 데이터[8]를 사용하여 성능을 평가하며, 기존 방법과 비교하여 우수한 모델을 구축할 수 있음을 보여준다.

2. 다중 퍼지 다항식 뉴럴 네트워크

2.1 퍼지 뉴럴 네트워크(FNN)

본 논문에 제안한 모델의 전반부를 차지하는 퍼지-




그림 1. 퍼지-뉴럴 네트워크 구조
Fig. 1. Fuzzy-Neural Networks structure

뉴럴 네트워크 구조는 그림 1과 같으며, 이는 보수적(complementary)인 삼각형 형태의 멤버쉽 함수를 사용하기 때문에 다른 모델에 비해서 학습속도가 빠르고 수렴특성이 우수하다는 장점을 가졌다[4].

그림 1에서 각각의 입력은 HCM 클러스터링에 의해 데이터 특성에 맞게 분류된 입력이다. 각 퍼지-뉴런에 입력된 신호 x_i 는 퍼지-뉴런의 특성을 나타내는 비선형함수 f_i 에 의해 출력 $f_i(x_i)$ 을 생성한다. 일반적인 신경회로망과는 달리 함수 f_i 내에 시그모이드 함수를 사용하지 않는다. 각 퍼지-뉴런에서 출력된 값들은 식 (1)과 같이 모두 대수적으로 합해져 \hat{y} 를 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.

$$R^n: \text{IF } x_i \text{ is } A_{in} \text{ Then } y_{in} = w_{in} \quad (2)$$

식 (2)의 최종 추론결과는 식 (3)과 같다. 이 식은 무게 중심법에 의한 비퍼지화 과정까지 포함한다.

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

m 개의 입출력 데이터 쌍이 주어진 경우, 퍼지-뉴럴 네트워크의 최종 출력 오차는 식 (4)와 같이 된다.

$$E = \frac{1}{m} \sum_{p=1}^m (y_p - \hat{y}_p)^2 \quad (4)$$

여기서 y_p 는 주어진 출력 데이터, \hat{y}_p 는 모델의 출력 데이터를 나타낸다.

연결 가중치의 조절은 식 (5)와 같이 기존값과 오차로부터 구해진 조절량 만큼의 변화를 더해주면 된다.

$$w(new) = w(old) + \Delta w \quad (5)$$

오차 E_p 를 최소화하기 위한 연결 가중치의 변화량 w 는 경사강화법을 이용하여 구할 수 있고, 최종적인 변화량은 식 (6)과 같이 된다.

$$\Delta w_{ij} = 2 \cdot \eta \cdot (y_p - \hat{y}_p) \cdot \mu_{ij}(x_i) \quad (6)$$

여기서, η 는 학습율이다.

여기에 모멘텀을 더해 학습시간을 좀 더 단축시키고, 또한 학습성능을 향상시킨다.

연결가중치의 최종조절식은 식 (7)과 같다.

$$\Delta w_{ij} = 2 \cdot \eta \cdot (y_p - \hat{y}_p) \cdot \mu_{ij}(x_i) + \alpha(w_{ij}(t) - w_{ij}(t-1)) \quad (7)$$

2.2 다항식 뉴럴 네트워크(PNN)

2.2.1 PNN 알고리즘

PNN 알고리즘은 고계다항식과 다변수 입력을 통해 차수 및 입력변수의 선택에 의하여, 파라미터 동정에 의한 모델을 선정하게 되고, 계층적 모델추정에 의하여 최종적으로 최적의 모델추정식을 얻는다. PNN 알고리즘의 수행 단계를 살펴보면 다음과 같다.

[단계 1] 입력변수 설정

출력변수 y 에 관련된 n 개의 입력변수를 설정한다. 이 입력변수를 x_1, x_2, \dots, x_n 이라 하자.

[단계 2] 데이터 분할

입출력 데이터(M)를 학습용(N_t)과 평가용 데이터(N_c)로 분할한다($N = N_t + N_c$).

[단계 3] 노드의 차수 및 입력변수 수 선택

n 개의 입력변수 x_1, x_2, \dots, x_n 중 노드의 입력변수를 선택한다.

[단계 4] 매개변수 추정

선형 회귀분석에 의해 학습용 데이터(N_t)를 사용하여, 식 (8)을 최소화하는 최적의 계수들을 최소 자승법을 이용하여 구한다.

$$E = \frac{1}{2} \sum_{i=0}^{N_t} (y_i - z_{ki})^2 \quad (8)$$

[단계 5] 평가후 노드의 선택

계수를 추정된 부분표현식에 평가용 데이터를 대입

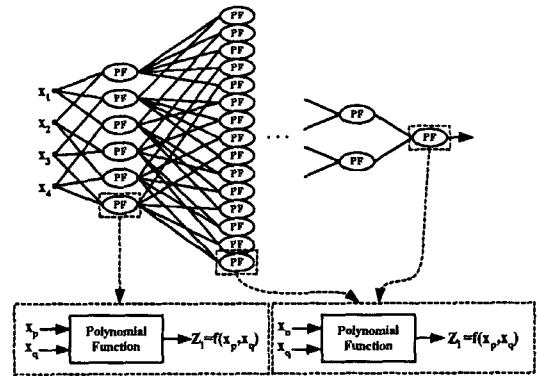


그림 2. PNN 구조
Fig. 2. PNN structure

하고, 평가용 데이터에 대한 식 (8)의 2승 오차 E 를 계산한다. 얻어진 E 에 대해서 값이 작은순으로 배열한다.

[단계 6] 종료 판정

[단계 5]에서 얻어진 E_i 이 다음의 부등식을 만족하는 경우에 알고리즘을 종료한다.

$$E_i \geq E^* \quad (9)$$

단, E^* 는 전 층의 2승 오차치 E_i 이다.

[단계 7] 새로운 입력변수 선택

식 (9)를 만족하지 않을 경우, 전 층에서 다음 층으로의 새로운 입출력을 구성하고, [단계 3]으로 간다. 이후, [단계 3]부터 [단계 7]까지 반복한다.

2.2.2 PNN 구조

PNN 구조는 1, 2차 고계 다항식과 다변수 입력을 통한 각 계층의 부분표현식에 의하여 수 세대를 걸쳐 최적 추정 모델을 얻는 구조이다[9].

그림 2는 본 논문에서 사용한 PNN 구조를 보여준다.

2.3 다중 FPNN 구조

본 논문에서 제안한 다중 FPNN에서의 각각 FPNN은 FNN과 PNN의 결합으로 구성된다.

그리고 HCM 클러스터링을 이용하여 데이터 각각의 거리를 기준으로 서로 유사한 특성을 가진 그룹으로 데이터를 분류하여 특성에 맞는 각각의 FPNN 모델을 구축하였다. 또한 각각의 FPNN 모델에 대해서도 유전자 알고리즘과 합성 성능지수를 적용하여 최적의 다중 FPNN 모델을 설계하였다.

그림 3은 다중 FPNN 모델의 설계 흐름도를 나타낸 것이다.

그림 4는 단일의 FPNN의 구조를 보여준 것으로,

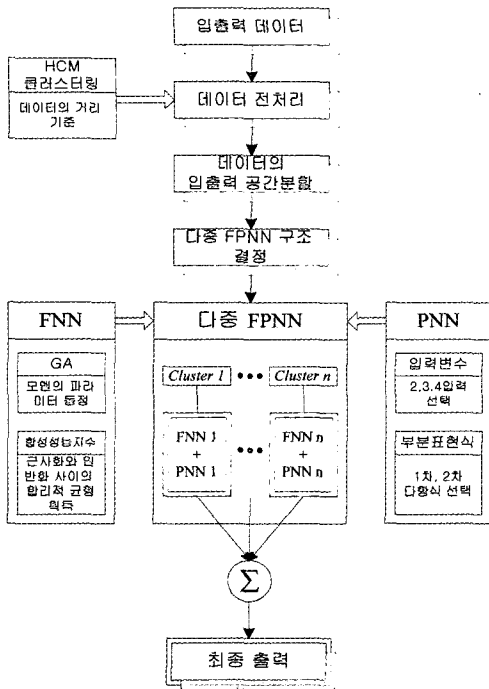


그림 3. 다중 FPNN의 흐름도
Fig. 3. Flowchart of Multi-FPNN




그림 4. FPNN의 구조
Fig. 4. FPNN structure

모델의 전반부는 FNN 구조이고 후반부는 PNN 구조가 결합된 모델이다.

3. 공정 데이터의 전처리 및 모델구조의 최적화

본 논문에서는 최적의 다중 FPNN 구조를 생성하기 위해서, HCM 클러스터링을 이용한 분할된 데이터 그룹으로부터 각 FPNN 모델을 구축하고 구축된 모델

의 전반부인 FNN은 유전자 알고리즘에 의해 최적화한다. 또한 하중계수를 가진 합성 성능지수를 이용하여 FPNN 구조의 예측성능을 향상시킨다.

3.1 HCM 클러스터링 방법

본 논문에서는 데이터들간의 거리를 기준으로 근접한 정도를 측정하고, 이를 바탕으로 데이터를 특성별로 분류하는 HCM 클러스터링을 이용하여 데이터들의 특성을 파악한다. 주어진 데이터 분류는 먼저 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.

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

[단계 2] 클러스터의 중심벡터를 구한다.

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

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

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

[단계 4] 식 (10)을 만족하면 종료하고, 그렇지 않으면 $r = r + 1$ 로 놓고 [단계 2]로 간다.

$$\|U^{(r+1)} - U^{(r)}\| \leq \epsilon \text{ (tolerance level)} \quad (10)$$

3.2 유전자 알고리즘

유전자 알고리즘은 진화, 자연선택, 유전자 재조합의 생물학 원리에 바탕을 둔 확률적 탐색 방법으로, 잠재적으로 좋은 결과를 가져다주는 과정을 추적하고, 반면에 지역 극소에 빠질 가능성을 제거하기 위해 임의의 지점을 검사함으로써, 해 공간 전체를 탐색할 수 있는 능력을 가진다[5]. 최적화 문제에서 탁월한 성능을 발휘하는 유전자 알고리즘은 기존의 방법들과는 달리 선형, 연속, 미분가능 등의 제한이 없기 때문에 다양한 분야에 별다른 제한 없이 적용할 수 있다는 장점을 가진다.

본 논문에서는 다중 FPNN 각각의 모델에 대한 멤버십함수의 정점과 학습율, 모멘텀계수를 최적으로 설

정해 주기 위하여 유전자 알고리즘을 이용하여 모델의 최적화 과정을 수행하게 된다.

3.3 하중계수를 가진 합성 성능지수

기존에 제시된 지능형 모델링 방법은 대부분 학습용 데이터 집합만을 사용하여 대상 공정의 모델을 구축하여 주어진 데이터에 의해서만 성능향상을 꾀하였기 때문에 실 공정에 적용하여 많은 오차를 발생시키고 정확한 예측 능력을 가지지 못하였다. 따라서 본 논문에서는 주어진 학습 데이터를 이용하여 각각의 FPNN 모델을 구축한 다음, 테스트 데이터를 사용하여 모델을 평가하기 위하여 식 (11)과 같이 근사화 및 일반화의 상호 균형과 의존 능력을 가진 합성 성능지수(목적함수)를 이용하여 상호 연계된 최적 모델 구조를 생성한다.

$$f(PI, E_PI) = \theta \times PI + (1 - \theta) \times E_PI \quad (11)$$

θ 와 $(1 - \theta)$ 는 각각 PI 와 E_PI 에 대한 하중계수이다. PI 는 학습 데이터에 대한 성능지수를, E_PI 는 테스트 데이터에 대한 성능지수를 의미한다.


4. 실험적 연구

4.1 가스로 공정


제안된 다중 FPNN 모델을 Box와 Jenkins가 사용한 가스로 시계열 데이터[7]를 이용하여 모델을 평가한다. 입력($u(t)$)은 가스 흐름율이고, 출력($y(t)$)은 이산화탄소 농도인 1입력 1출력의 데이터를 시뮬레이션하기 위해 입력 $u(t-3)$, $y(t-1)$ 과 출력 $y(t)$ 의 2입력 1출력으로 설정하여 사용한다. 성능 평가 기준인 PI 는 식 (12)와 같은 형태인 MSE (Mean Squared Error)를 이용한다.

$$PI = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (12)$$

그림 5는 클러스터 개수와 하중계수 θ 에 따른 다중



(a) 학습 데이터



(b) 테스트 데이터

그림 5. 하중계수 θ 에 따른 각각의 FNN 성능지수
Fig. 5. Performance index of each FNN by weighting factor

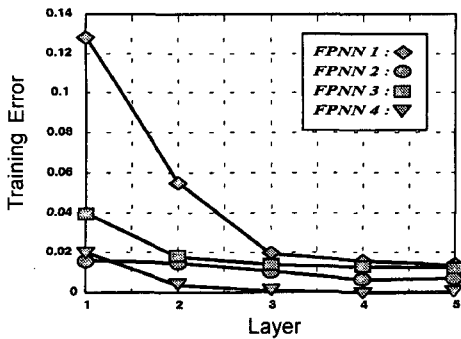
FPNN 모델의 전반부를 이루는 FNN의 성능지수를 나타낸다. 각 입력에 따른 멤버쉽함수를 3개로 설정하였다.

그림 5에서 볼 수 있듯이 각각의 FNN 모델 중에서 학습 성능 및 테스트 성능을 같이 고려한 경우 클러스터를 4개로 분류한 경우가 각 θ 에 대해 보다 우수한 성능을 나타남을 알 수 있다.


표 1은 클러스터 4개로 분류했을 때, 다중 FPNN의 전반부를 구성하는 FNN으로부터 입력을 받아 후반부를 구성하는 PNN으로부터의 최종적인 성능을 나타낸 것이다. 이때 하중 계수는 $\theta=0.5$ 와 $\theta=1.0$ 일

표 1. 다중 FPNN의 성능지수($c = 4$)
Table 1. Performance Index of Multi-FPNN($c = 4$)

θ	차수	2입력		3입력		4입력	
		PI	E PI	PI	E PI	PI	E PI
0.5	Type 1	0.026	0.270	0.026	0.265	0.019	0.285
	Type 2	0.020	0.250	0.009	0.261	0.013	0.317
1.0	Type 1	0.023	0.282	0.029	0.259	0.019	0.274
	Type 2	0.027	0.240	0.009	0.249	0.014	0.442



(a) 학습 데이터



(b) 테스트 데이터

그림 6. 학습 및 테스트 동정 오차

Fig. 6. Identification errors for Training and Testing

때를 고려하였다. 여기서 Type 1은 1차, Type 2는 2차 다항식이다.

그림 6은, 표 1에서 하중계수 $\theta=1.0$ 일 때 3입력을 선택하고 부분 표현식으로는 Type 2를 사용했을 때의 학습과 테스트 오차를 표현한 것이다. 그림 6의 (b)에서 FPNN 4에 대한 곡선이 없는 이유는 테스트 데이터 분류시 FPNN 4의 학습 데이터 중심에 대한 테스트 데이터가 분포되어 있지 않기 때문이다.

표 2는 동일한 데이터를 사용하여 성능 지수를 식 (12)에 의해 계산된 값으로 다른 동정된 모델과 성능 비교를 나타낸다. 이 표에 의하면 본 논문에서 제안한 다중 FPNN 모델이 기존 모델보다 학습 성능 및 테스트 성능이 향상됨을 알 수 있다.

4.2 비선형 함수

본 논문에서 제안한 모델의 적용 및 유용성을 비교 평가하기 위해 식 (13)으로 표현되어지는 비선형 함수에 사용하여 모델의 성능을 평가하였다[8].


$$y = (1 + x_1^{0.5} + x_2^{-1} + x_3^{-1.5})^2 \quad (13)$$

비선형 함수 대한 성능지수는 식 (14)와 같이


표 2. 기존 모델과 동정오차 비교

Table 2. Comparison of identification errors with conventional models

모델		PI	E_PI
Fuzzy model[6]	Simplified	0.024	0.328
	(Complex) Linear	0.021	0.364
Fuzzy model[10](GA)	Simplified	0.022	0.333
Adaptive FNN model[11]		0.021	0.332
FNN model[12]	GA	0.026	0.304
	HCM+GA	0.032	0.276
Our model	$\theta = 0.5$	0.0096	0.261
	$\theta = 1.0$	0.0093	0.249



(a) 학습 데이터



(b) 테스트 데이터

그림 7. 하중계수 θ 에 따른 각각의 FNN의 성능지수

Fig. 7. Performance index of each FNN by weighting factor

API(Average Percentage Error)를 이용하였다.

$$PI = \frac{1}{m} \sum_{i=1}^m \frac{|y_i - \hat{y}_i|}{y_i} \times 100(\%) \quad (14)$$

그림 7은 비선형 함수에 의해 얻어진 데이터를 클러스터 개수에 따른 FNN 모델의 성능지수를 나타낸 것이다. 각 입력에 따른 멤버쉽함수를 3개로 하였고, 그림에서도 볼 수 있듯이 클러스터가 3개일 경우 학

표 3. 다중 FPNN의 성능지수(c = 3)
Table 3. Performance Index of Multi-FPNN(c = 3)

θ	차수	2입력		3입력		4입력	
		PI	E_PI	PI	E_PI	PI	E_PI
0.5	Type 1	2.053	0.714	2.001	0.713	0.316	0.725
	Type 2	0.304	0.633	0.299	0.292	0.914	2.495
1.0	Type 1	2.084	0.973	2.042	0.870	0.312	0.878
	Type 2	0.604	1.978	0.299	0.527	0.299	7.343

표 4. 기존 모델과 동정오차 비교

Table 4. Comparison of identification errors with conventional models

모델	PI	E_PI	
선형 모델[13]	12.7	11.1	
GMDH[14]	4.7	5.7	
Sugeno's model [8]	model I	1.5	2.1
	model II	1.1	3.6
Shin-ichi's model [15]	Type 1	0.84	1.22
	Type 2	0.73	1.28
Our model	$\theta=0.5$	0.299	0.292
	$\theta=1.0$	0.299	0.527

습과 테스트 데이터의 성능지수를 고려한 결과가 뚜렷이 향상됨을 알 수 있다

표 3은 클러스터 3개로 분류했을 때, 다중 FPNN의 전반부를 구성하는 FNN으로부터 입력을 받아 후반부를 구성하는 PNN으로부터의 최종적인 성능을 나타낸 것이다. 하중 계수는 $\theta=0.5$ 와 $\theta=1.0$ 일 때를 고려하였다. 표 3에서 볼 수 있듯이 3입력이고 부분 표현식으로 2차 다항식을 사용한 경우 우수한 성능을 나타냄을 알 수 있다.

표 4는 비선형 데이터를 사용하여 성능 지수를 식(14)에 의해 계산된 값으로 다른 동정된 모델과 성능 비교를 나타낸다.

표 4에서도 볼 수 있듯이 특히, 데이터의 수가 적고 비선형적인 특성이 강할수록 본 논문에서 제안한 방법이 기존의 모델들보다 우수한 모델을 구축할 수 있음을 보인다.

5. 결 론

본 논문에서는 비선형 공정의 최적 시스템 동정을 위해서 FNN과 PNN 구조의 상호 결합으로부터 다중 FPNN 구조의 최적 설계 방법을 제안하였다. FNN은 PNN의 입력층으로, 입력변수들을 확장시키는 역할을

함으로써 PNN 입력변수들의 관계를 돕고 모델 출력을 개선시켰다. PNN은 FNN의 출력층을 형성하며 모델의 성능을 향상시켰다. 이로부터 공정의 비선형 특성을 고려할 수 있고, 더 향상된 출력 특성을 얻는 것이 가능하다. 또한 데이터의 특성에 따른 체계적이고 효율적인 모델을 구축하기 위하여 HCM 클러스터링을 사용하여 모델의 구조를 결정하고, 모델의 최적화를 위하여 유전자 알고리즘과 하중계수를 가진 합성 목적함수를 사용한다. 제안된 다중 FPNN 구조는 시뮬레이션을 통해 근사화 및 일반화 사이의 상호연계를 통한 구조설계로 예측성능 향상에 따른 실 공정 적용 가능성 및 용이함을 보였다.

참고문헌

- [1] L. A. Zadeh, "Fuzzy sets", *Inf. Control* 8, 338-353, 1965.
- [2] J. R. Jang, C. T. Sun and C. Mizutani, *Neuro-Fuzzy and Soft Computing : A Computational Approach to Learning and Machine Intelligence*, Prentice-Hall, 1997.
- [3] A. G. Ivahnenko, "The group method of data handling; a rival of method of stochastic approximation", *Soviet Automatic Control*, 1-3, pp. 43-55, 1968.
- [4] Takeshi Yamakawa, "A New Effective Learning Algorithm for a Neo Fuzzy Neuron Model", 5th IFSA World Congress, pp. 1017-1020, 1993.
- [5] David E. Goldberg, "Genetic Algorithm in search, Optimization & Machine Learning", Addison wesley, 1989.
- [6] 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.
- [7] Box and Jenkins, "Time Series Analysis, Forecasting and Control", 2nd ed. Holden Day, San Francisco, CA, 1976.
- [8] G. Kang and M. Sugeno, "Fuzzy modeling", *Trans. SICE*, Vol. 23, No. 6, pp. 106-108, 1987(in Japanese).
- [9] 오성권, 김동원, 박병준, "다항식 뉴럴네트워크 구조의 최적 설계에 관한 연구", *대한전기학회논문지*, 제 49권, 제3호, pp. 145-156, 2000년 3월.
- [10] 박병준, 오성권, 안태천, 김현기, "유전자 알고리즘과 하중값을 이용한 퍼지 시스템의 최적화", *대한전기학회논문지*, 제48A권, 제6호, pp. 789-799, 1999년 6월.
- [11] 오성권, 박병준, 박춘성, "적응 퍼지-뉴럴 네트워크를 이용한 비선형 공정의 온-라인 모델링", *대한전기학회논문지*, 제48A권, 제10호, pp. 1293-1302, 1999년 10월.
- [12] 오성권, 윤기찬, 김현기, "유전자 알고리즘과 합성 성능지수에 의한 퍼지-뉴럴 네트워크 구조의 최적 설계", *제어 · 자동화 · 시스템공학회*, 제6권, 제3호, pp.273-283, 2000년 3월.
- [13] 菅野道夫(譯: 박민용, 최항식), "퍼지제어 시스템",


大英社, pp. 143-158, 1990.

- [14] 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.
- [15] 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.



박호성 (Ho-Sung Park)

1999년 : 원광대 제어계측공학과 졸업.
1999년~현재 : 동 대학교 제어계측공학과 석사과정
주관심분야 : 시스템자동화, 퍼지이론 및 신경회로망 응용, 지능형 모델링 및 제어 등



오성권 (Sung-Kwon Oh)

1981년 : 연세대학교 전기공학과 졸업
1983년~1989년 : 금성산전연구소(선임 연구원)
1993년 : 연세대 대학원 전기공학과 졸업(공학)
1996년~1997년 : 캐나다 Manitoba대학 전기 및 컴퓨터공학과 Post-Doc

1993년~현재 : 원광대 제어계측공학과 부교수
주관심분야 : 시스템자동화, 퍼지이론 및 신경회로망 응용, 지능형 모델링 및 제어 등



안태천 (Tae-Chon Ahn)

1978년 : 연세대학교 전기공학과 졸업
1980년 : 동 대학원 전기공학과 졸업(석사)
1986년 : 동 대학원 졸업(공학)
1987년~1988년 : 스웨덴 Uppsala 대학 제어 및 시스템 공학과 Post-Doc
1994년~1995년 : 미국 Georgia 공대 전기 및 컴퓨터공학부 교환교수

1981년~현재 : 원광대 제어계측공학과 교수
주관심분야 : 적응제어, 신호처리, 지능형 모델링 및 제어 등