

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

The Design of Multi-FNN Model Using HCM Clustering and Genetic Algorithms and Its Applications to Nonlinear Process

박호성*, 오성권*, 김현기**

*원광대학교 전기전자공학부, 전라북도 익산시 신용동 344-2 ☎570-749

**수원대학교 전기전자정보통신공학부, 경기도 화성군 봉삼면 와우리 ☎445-743

Ho-Sung Park*, Sung-Kwun Oh*, and Hyun-Ki Kim**

*School of Electrical & Electronic Engineering, Wonkwang Univ., Iksan, KOREA

**School of Electrical Engineering, Suwon Univ., Whasung-gun, KOREA

ABSTRACT

In this paper, an optimal identification method using Multi-FNN(Fuzzy-Neural Networks) is proposed for modeling of nonlinear complex system. In order to control of nonlinear process with complexity and uncertainty of data, proposed model use a HCM clustering algorithm which carry out the input-output data preprocessing function and Genetic Algorithm which carry out optimization of model. The proposed Multi-FNN is based on Yamakawa's FNN and it uses simplified inference as fuzzy inference method and Error Back Propagation Algorithm as learning rules. HCM clustering method which carry out the data preprocessing function for system modeling, is utilized to determine the structure of Multi-FNN by means of the divisions of input-output space. Also, the parameters of Multi-FNN model such as apexes of membership function, learning rates and momentum coefficients are adjusted using genetic algorithms. Also, a performance index with a weighting factor is presented to achieve a sound balance between approximation and generalization abilities of the 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.

I. 서론

비선형 공정에 대한 복잡성과 불확실성을 제어하기 위해 인간의 언어적 논리를 수리적으로 취급하는 퍼지이론[1]과 인간의 두뇌가 이루고 있는 뉴런(neuron)들의 결합을 모델링한 신경망(Neural networks)을 상호 융합한 지능형 모델에 관하여 많은 연구가 진행되고 있다.

따라서 본 논문에서는 이러한 비선형 공정을 제어하기 위해 기존의 퍼지-뉴럴 네트워크 모델에 비해서 학습속도가 빠르고, 수렴특성이 매우 우수하다는 장점을 가진 Yamakawa[2]에 의해 제안된 퍼지-뉴럴 네트워크모델을 단일 FNN구조로 사용한 다중 FNN모델을 제안한다. 제안한 다중 FNN 모델은 시스템의 데이터 특성을 해석하는데 HCM 클러스터링 알고리즘을 이

용하여 입출력 데이터를 서로 유사한 특성을 가진 그룹으로 분류하는 전처리 과정을 수행함과 동시에 데이터 특성 분류에 따른 각 네트워크모델 구조의 최적화를 위해 유전자 알고리즘[3]을 이용하여 퍼지-뉴럴 네트워크의 멤버십 함수 정점과 학습률 그리고 모멘텀 계수를 최적으로 동조하여 다중 FNN 구조를 생성함으로써 단일 퍼지-뉴럴 네트워크모델의 한계성을 극복하고자 한다.

더 나아가 학습 데이터 및 테스트 데이터를 고려한 퍼지-뉴럴 네트워크 모델 성능 즉 근사화 및 일반화 능력 모두를 고려한 성능결과를 위해 하중 계수를 가진 합성 목적함수를 사용한다. 제안된 모델은 가스로 공정[4]과 비선형 함수를 이용한 수치 데이터[5]를 사용하여 성능을 평가하며, 기존 방법과 비교하여 우수한 모델을 구축할 수 있음을 보여준다.

II. 본문

2.1. 다중 FNN의 구조

본 논문에서 제안한 다중 퍼지-뉴럴 네트워크의 기본 모델은 그림 1에서 보여준 바와 같이 각 입력변수에 따른 퍼지 입력공간분할에 의한 기본 FNN[2]구조를 사용한다.




그림 1. 기본 퍼지-뉴럴 네트워크 구조

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.

$$\begin{aligned} R^1 : & \text{IF } x_i \text{ is } A_{i1} \text{ Then } y_{i1} = w_{i1} \\ & \vdots \\ R^j : & \text{IF } x_i \text{ is } A_{ij} \text{ Then } y_{ij} = w_{ij} \\ & \vdots \\ R^n : & \text{IF } x_i \text{ is } A_{in} \text{ Then } y_{in} = w_{in} \end{aligned} \quad (2)$$

기존의 퍼지-뉴럴 네트워크 모델들에서 사용하였던 HCM 클러스터링은 시스템의 입력 공간의 분할을 통하여 초기 멤버십함수의 파라미터를 결정하기 위해 사용되었으나[8], 이는 데이터의 특성에 맞는 모델을 구축하지는 못하였다. 따라서 본 논문에서는 HCM 클러스터링을 이용하여 서로 유사한 특성을 가진 그룹으로 데이터를 분류하여 특성에 맞는 각각의 퍼지-뉴럴 네트워크를 그림 2와 같이 구축하였다.




그림 2. 다중 퍼지-뉴럴 네트워크의 구조

2.2 HCM 클러스터링 알고리즘

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 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 초기화

$$M_c = \left\{ U \mid u_{ij} \in \{0, 1\}, \sum_{k=1}^n u_{ik} = 1, 0 < \sum_{k=1}^n u_{ik} < n \right\} \quad (3)$$

[단계 2] 클러스터의 중심벡터를 구한다.

$$v_{ij} = \frac{\sum_{k=1}^n u_{ik} \cdot x_{kj}}{\sum_{k=1}^n u_{ik}} \quad (4)$$

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

$$d_{ik} = d(x_k - V_i) = \|x_k - V_i\| = \left[\sum_{j=1}^n (x_{kj} - v_{ij})^2 \right]^{1/2} \quad (5)$$

$$u_{ik}^{(r+1)} = \begin{cases} 1 & d_{ik}^{(r)} = \min \{d_{jk}^{(r)}\} \text{ for all } j \in c \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

[단계 4] 만일 식 (7)을 만족하면 종료하고, 그렇지 않으면 $r = r+1$ 로 놓고 [단계 2]로 간다.

$$\|U^{(r+1)} - U^{(r)}\| \leq \epsilon \text{ (tolerance level)} \quad (7)$$

2.3 유전자 알고리즘

유전자 알고리즘은 자연 선택과 유전학에 기반으로 하는 확률적인 탐색방법으로써 비선형 최적화 이론에 탁월한 성능을 발휘하고 있다 [3]. 또한 기존의 방법과는 달리 미분에 대한 제한이 없고, 지역극소가 존재하더라도 문제없이 적용 가능하기 때문에 다양한 분야에 별다른 제한없이 적용될 수 있다는 장점을 가진다.

그림 3은 유전자 알고리즘의 수행과정을 보여준다

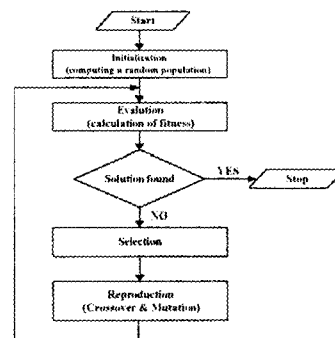


그림 3. 유전자 알고리즘의 수행과정

본 논문에서는 다중 퍼지-뉴럴 네트워크 각각의 모델에 대한 멤버십함수의 정점과 학습을, 모멘텀계수를 최적으로 설정해 주기 위하여 유전자 알고리즘을 이용하여 모델의 최적화 과정을 수행하게 된다.

2.4 합성 성능지수

본 논문에서는 주어진 학습 데이터를 이용하여 퍼지-뉴럴 네트워크 모델을 구축하고 테스트 데이터를 사용하여 모델을 평가하기 위하여 합성 목적 함수(성능지수)를 이용하여 상호 연계된 최적 모델 구조를 생성한다. 이를 위해 하중계수를 가진 목적함수인 합성 성능지수로써 식 (8)과 같이 정의한다.

$$f(PI, E_PI) = \theta \times PI + (1 - \theta) \times E_PI \quad (8)$$

θ 는 PI 와 E_PI 에 대한 하중계수를 나타내고, PI 는 학습 데이터, E_PI 는 테스트 데이터에 대한 성능지수를 나타낸다. 목적함수는 하중계수의 설정에 따라 다음과 같은 특징을 가진다.

- 첫째, $\theta = 1$ 이면 학습 데이터를 기초로 최적화
- 둘째, $\theta = 0$ 이면 학습 데이터를 이용하여 모델링한 후 테스트 데이터를 기초로 최적화된다.
- 셋째, $\theta = 0.5$ 이면 학습과 테스트 모두 같은 비중을 가지고 평가한다.
- 넷째, $\alpha \in [0, 1]$ 에 대해서 $\theta = \alpha$ 이면 학습과 테스트 모두를 포함하고, α 의 선택은 모델의 근사화와 일반화 사이에서 상호 균형에 의한 최적화를 시도한다.


III. 시뮬레이션

3.1 가스로 공정

제한된 다중 퍼지-뉴럴 네트워크의 성능을 평가하기 위해서 Box와 Jenkins[4]에 의해 사용된 가스로 시계열 데이터를 이용한다. 입력 ($u(t)$)은 가스 흐름율이고 출력($y(t)$)은 이산화탄소 농도인 1입력 1출력의 가스로 시계열 데이터 296쌍을 시뮬레이션 하기 위해 균일한 입출력 분포구조를 가지는 입력 $u(t-3)$, $y(t-1)$ 과 출력 $y(t)$ 의 2입력 1출력으로 설정하여 사용한다. 성능 평가 기준인 PI (Performance Index)는 식 (9)와 같은 형태인 MSE (Mean Squared Error)를 이용한다.

$$PI = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (9)$$

그림 4는 가스로 데이터를 HCM 클러스터링으로 분류했을 때, 4개의 클러스터로 입출력 데이터를 분할한 것이다.



(a) 학습 데이터 (b) 테스트 데이터
그림 4. HCM 방법에 의해 분류된 가스로 데이터

표 1에서는 HCM 클러스터링을 통해 얻은 클러스터 개수와 하중계수 θ 에 따른 다중 퍼지-뉴럴 네트워크 모델의 성능지수를 나타낸다.

표 1. 클러스터 개수에 따른 성능지수

입력	θ	단일 FNN		다중 FNN							
		PI	E_PI	클러스터 2		클러스터 3		클러스터 4		클러스터 5	
$u(t-3)$ $y(t-1)$	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

그림 5는 표 1에서 나타난 단일 FNN과 다중 FNN의 각 클러스터 개수와 하중계수 θ 에 따른 학습 및 테스트 입출력 데이터군에 의한 각 모델의 성능지수를 그래프로 표시한 것이다.




그림 5. 하중계수 θ 에 따른 다중 FNN의 성능지수

표 2는 동일한 데이터를 사용하여 성능 지수를 식 (9)에 의해 계산된 값으로 다른 동정된 모델과 성능비교를 나타낸다. 표에서 볼 수 있듯이 본 논문에서 제안한 방법이 데이터의 특성을 반영함으로써 좀 더 최적화된 모델을 구축할 수 있다.

표 2. 기존 모델과 동정오차 비교

모델		PI	E_PI
Fuzzy model[6] (Complex)	Simplified	0.024	0.328
	Linear	0.021	0.364
Fuzzy model[7] (GA)	Simplified	0.022	0.333
FNN model[8]	GA	0.026	0.304
	HCM+GA	0.032	0.276
Our model	$\theta = 0.5$	0.025	0.274
	$\theta = 1.0$	0.017	0.309

3.2 수치 데이터

제안한 모델의 적용 및 유용성을 비교 평가하기 위해 식 (10)로 표현되어 지는 비선형 함수에 의해서 얻어진 40개의 입출력 데이터 쌍을 사용해서 모델의 성능을 평가하였다[5].

$$y = (1 + x_1^{0.5} + x_2^{-1} + x_3^{-1.5})^2 \quad (10)$$

비선형 함수에 대한 성능지수는 식 (11)과 같이 API(Average Percentage Error)를 이용하였다.

$$PI = \frac{1}{m} \sum_{i=1}^m \frac{|y_i - \hat{y}_i|}{y_i} \times 100(\%) \quad (11)$$

표 3에서는 비선형 함수에 의해 얻어진 데이터를 클러스터 개수에 따른 다중 퍼지-뉴럴 네트워크 모델의 성능지수를 나타낸 것이다.

표 3. 클러스터 개수에 따른 성능지수

θ	단일 FNN		다중 FNN									
	PI	E_PI	클러스터 2		클러스터 3		클러스터 4		클러스터 5			
			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 6은 표3에서 나타난 단일 FNN과 다중 FNN의 클러스터 개수와 하중계수 θ 에 따른 학습 데이터와 테스트 데이터 각각의 성능지수를 그림으로 그려 놓은 것이다.




그림 6. 하중계수 θ 에 따른 다중 FNN의 성능지수

표 4는 동일한 데이터를 사용하여 성능 지수를 식 (11)에 의해 계산된 값으로 다른 동정된 모델과 성능비교를 나타낸다.

표 4. 기존 모델과 동정오차 비교

모델	PI	E PI	
선형 모델[9]	12.7	11.1	
GMDH[10]	4.7	5.7	
Sugeno's model[5]	model I	1.5	2.1
	model II	1.1	3.6
Shin-ichi's model[11]	Type I	0.84	1.22
	Type 2	0.73	1.28
Our model	$\theta = 0.5$	0.813	0.994
	$\theta = 0.75$	0.720	1.158
	$\theta = 1.0$	0.700	1.304

표 4에서도 볼 수 있듯이 기존의 모델들과 달리 제안된 모델은 데이터의 특성을 반영함으로써 보다 우수한 모델을 구축할 수 있음을 보인다.

IV. 결론

본 논문에서는 비선형적이고 복잡한 실 시스템의 데이터 특성을 해석하고 데이터의 특성에 따른 체계적이고 효율적인 모델을 구축하기 위

하여 HCM 클러스터링을 사용하여 퍼지-뉴럴 네트워크모델의 병렬구조로써 다중 퍼지-뉴럴 네트워크를 제안한다. HCM 클러스터링 알고리즘을 이용하여 데이터의 특성에 맞는 최적의 다중 퍼지-뉴럴 네트워크 모델의 구축하였으며, 모델의 최적화를 위하여 유전자 알고리즘과 하중계수를 가진 합성 목적함수를 사용한다. 이 제안된 방법은 비선형 시스템의 입출력 데이터를 분석하여 데이터 상호간의 연관성을 찾아 몇 개의 병렬구조를 이루어 전체적으로 적응력을 가진 강인한 구조를 생성하는 장점이 있다.

감사의 글

이 논문은 1998년도 한국학술진흥재단의 연구비에 의하여 지원되었음(KRF-98-001-01048).

V. 참고문헌

- [1] L. A Zadeh, "Fuzzy sets", *Inf. Control* 8, 338-353, 1965.
- [2] 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.
- [3] David E. Goldberg, "Genetic Algorithm in search, Optimization & Machine Learning", Addison wesley.
- [4] Box and Jenkins, "Time Series Analysis, Forecasting and Control", Holden Day, SanFrancisco, CA.
- [5] G. Kand and M. Sugeno, "Fuzzy modeling", *Trans. SICE*, vol. 23, No. 6, pp.106-108, 1987(in Japanese).
- [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.*, 2000. (To appear)
- [7] 박병준, 오성권, 안태천, 김현기, "유전자 알고리즘과 하중값을 이용한 퍼지 시스템의 최적화", *대한전기학회논문지*, 제48A권, 제6호, pp. 789-799, 1999년 6월.
- [8] 오성권, 윤기찬, 김현기, "유전자 알고리즘과 합성 성능지수에 의한 퍼지-뉴럴 네트워크 구조의 최적 설계", *제어·자동화·시스템공학회*, 2000.
- [9] 菅野道夫(譯: 박민용, 최항식), "퍼지제어 시스템", pp. 143-158, 大英社, 1990.
- [10] 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.
- [11] 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.
- [12] 오성권, "퍼지모델 및 제어이론과 프로그램", 기다리출판사, 1999년 3월.