

HCM과 유전자 알고리즘에 기반한 확장된 다중 FNN 모델 설계

박호성, 오성권

원광대학교 전기전자 및 정보공학부, 전라북도 익산시 신룡동 344-2 ☎570-749

Design of Extended Multi-FNNs model based on HCM and Genetic Algorithm

Ho-Sung Park and Sung-Kwon Oh

School of Electrical Electronic & Information Engineering, Wonkwang Univ., Iksan, KORI

Abstract - In this paper, the Multi-FNNs(Fuzzy-Neural Networks) architecture is identified and optimized using HCM(Hard C-Means) clustering method and genetic algorithms. The proposed Multi-FNNs architecture uses simplified inference and linear inference as fuzzy inference method and error back propagation algorithm as learning rules. Here, HCM clustering method, which is carried out for the process data preprocessing of system modeling, is utilized to determine the structure of Multi-FNNs according to the divisions of input-output space using I/O process data. Also, the parameters of Multi-FNNs model such as apexes of membership function, learning rates and momentum coefficients are adjusted using genetic algorithms. An aggregate performance index with a weighting factor is used 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 NOx emission process data of gas turbine power plant.

모델의 한계성을 극복하고자 한다. 더 나아가 학습 데이터 및 테스트 데이터를 고려한 퍼지-뉴럴네트워크 모델 성능 즉 근사화 및 일반화 능력 모두를 고려한 성능결과를 위해 하중 계수를 가진 합성 목적함수(4)를 사용한다. 모델의 성능지수는 데이터의 개수, 비선형성의 정도(입출력 데이터 분포)등에 의해 상호 의존성을 가진 근사화 및 예측의 정확도에 따라 차이가 나므로 하중계수의 선택과 조절을 통하여 공정시스템의 최적모델을 구축할 수 있다. 제안된 모델은 가스로 공정(5)과 가스터빈 발전소의 NOx 배출 공정 데이터(6)를 사용하여 성능을 평가하며, 기존 방법과 비교하여 우수한 모델을 구축할 수 있음을 보여준다.

2. 본 론

2.1 확장된 다중 FNN 구조

퍼지-뉴럴 네트워크 구조는 퍼지이론의 언어적 논리를 규칙의 형태로 표현할 수 있는 능력과 신경망의 오류 역전파 알고리즘을 사용한 학습기능이 서로 결합한 형태로서, 본 논문에서 제안한 확장된 다중 FNN의 기본 모델은 그림 1에서 보여준 바와 같이 다른 모델에 비해서 학습속도가 빠르고, 수렴특성이 매우 우수하며 후반부 추론을 간략 추론 방법을 이용한 FNN(2)구조를 후반부 추론방법을 선형 추론까지 확장한 FNN을 기본 모델로 사용한다.

1. 서 론

전통적인 선형 방정식 기반 근사화 이론은 현재 잘 개발되었으며 실제 문제에서 있어서도 성공적으로 실행되고 있는 반면에 비선형 함수 근사화와 같은 문제에서는 신경망과 퍼지 기술과 같은 방법을 적용하는 데 상당한 관심이 집중되고 있다[1]. 이와 같은 방법이 사용되는 주된 이유중의 하나가 정확한 수학적 모델들이 항상 존재하지 않을뿐더러 모든 복잡한 환경에 대해서도 유도할 수가 없기 때문이다. 이에 본 논문에서는 지능형 모델의 하나로 다른 퍼지-뉴럴 네트워크모델에 비해서 학습속도가 빠르고, 수렴특성이 매우 우수하며 후반부 추론은 간략 추론을 사용한 퍼지-뉴럴 네트워크(FNN) 모델(2)을 기반으로 하여 후반부 추론 방법을 선형 추론 방법으로 확장한 퍼지-뉴럴 네트워크 모델을 단일 FNN 모델로 이용한 확장된 다중 FNN 모델을 제안한다. 제안한 확장된 다중 FNN 모델은 시스템의 데이터 특성을 해석하는데 HCM 클러스터링 알고리즘을 이용하여 입출력 데이터를 서로 유사한 특성을 가진 그룹으로 분류하는 전처리 과정을 수행함과 동시에 데이터 특성 분류에 따른 각 퍼지-뉴럴 네트워크모델 구조의 최적화를 위해 유전자 알고리즘(3)을 이용하여 모델의 멤버십 함수 정점과 학습을 그리고 모멘텀 계수를 최적으로 동조하여 다중 FNN 구조를 생성함으로써 단일 퍼지-뉴럴 네트워크




그림 1. 기본 퍼지-뉴럴 네트워크의 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 간략 추론일 경우엔 다음과 같이 퍼지규칙을 이룬다.

$$R^i: \text{If } x_i \text{ is } A_{ij} \text{ then } y_{ij} = u_{ij} \quad (2)$$

식(2)의 최종 추론 결과는 식 (3)과 같이 표현된다.

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

선형 추론일 경우의 퍼지 규칙은 다음과 같다.

$$R^i: \text{IF } x_i \text{ is } A_{ij} \text{ Then } y_{ij} = u_{ij} + x_i w_{ij} \quad (4)$$

식(4)의 최종 추론 결과는 식 (5)와 같이 표현된다.

$$f_i(x_i) = \frac{\sum_{j=1}^n \mu_{ij}(x_i) \cdot (u_{ij} + x_i w_{ij})}{\sum_{j=1}^n \mu_{ij}(x_i)} \quad (5)$$

m 개의 입출력 데이터 쌍이 주어진 경우, 퍼지-뉴럴 네트워크의 최종 출력 오차는 식 (6)과 같이 된다.

$$E = \frac{1}{m} \sum_{p=1}^m (y_p - \hat{y}_p)^2 \quad (6)$$

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

본 논문에서는 HCM 클러스터링을 이용하여 데이터 각각의 거리를 기준으로 서로 유사한 특성을 가진 그룹으로 데이터를 분류하여 특성에 맞는 각각의 퍼지-뉴럴 네트워크를 구축하였다. HCM 클러스터링에 의해 분류된 전체 클러스터 수는 그림 2와 같이 다중구조를 가지는 퍼지-뉴럴 네트워크를 구성하기 위한 기본 모델의 수가 되고, 분류된 데이터 집합들은 각각 기본 모델의 입력이 되어 단일 퍼지-뉴럴 네트워크모델의 기능을 수행하게 된다.




그림 2. 확장된 다중 퍼지-뉴럴 네트워크의 구조

2.2 HCM 클러스터링 방법

클러스터링 알고리즘이란 데이터의 분류를 위해서 사용되는 것으로 데이터의 내부가 비슷한 패턴, 속성, 형태 등의 기준을 통해 데이터를 분류하여 내부의 구조를 찾아내는 것이다. 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 HCM 클러스터링에 의해 학습 데이터를 분류하고, 분류된 학습 데이터의 중심에 의해 테스트 데이터를 분류한다.

2.3 유전자 알고리즘

유전자 알고리즘은 자연 선택과 유전학에 기반으로 하는 확률적인 탐색방법으로써 탐색과 해의 가능영역을 균형있게 이용하기 위하여 생산, 교차, 돌연변이의 과정을 수행하는 일반성 있는 탐색법으로 비선형 최적화 이론에 탁월한 성능을 발휘하고 있다[3]. 기존의 다른 탐

색방법들과 달리 유전자 알고리즘은 해가 될 가능성이 있는 개체집단을 유지하면서 그들 모두가 동시에 최적값을 찾아가기 때문에 지역 극소에 빠질 위험을 어느 정도 해결할 수 있다는 점과 더불어 모델의 성능지수가 최소가 되는 전역 극소 영역을 찾는 능력을 갖고 있으며, 또한 기존의 방법들과는 달리 선형, 연속, 미분가능 등의 제한이 없기 때문에 다양한 분야에 별다른 제한 없이 적용할 수 있다는 장점을 가진다는 것이 중요한 특징이다.

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

2.4 합성 목적함수

입출력 데이터로 시스템을 모델링 할 때 가장 문제가 되는 것은 구축된 모델이 학습 데이터만을 사용한 모델로써 시스템을 구축하는 경우이다. 이에 본 논문에서는 주어진 학습 데이터를 이용하여 모델을 구축하고 테스트 데이터를 사용하여 모델을 평가하기 위하여 근사화 및 일반화의 상호 균형과 의존 능력을 가진 합성 목적 함수(성능지수)를 이용하여 최적 모델 구조를 생성한다. 이를 위해 하중계수를 가진 목적함수인 합성 성능지수로서 식 (7)과 같이 정의한다.

$$f(PI, E_PI) = \theta \times PI + (1 - \theta) \times E_PI \quad (7)$$

θ 는 PI 와 E_PI 에 대한 하중계수를 나타내고, PI 는 학습 데이터 성능지수, E_PI 는 테스트 데이터 성능지수를 나타낸다. 식 (7)과 같이 정의한 목적함수는 하중계수의 설정에 따라 다음과 같은 특징을 가진다.

$\alpha \in [0, 1]$ 에 대해서 $\theta = \alpha$ 이면 학습과 테스트 모두를 포함하고, α 의 선택은 모델의 근사화와 일반화 사이에서 상호 균형에 의한 최적화를 시도한다. 따라서 합성 성능지수는 모델 자체의 근사화 능력과 일반화 능력을 상호 고려한 목적함수의 형태로 적절한 하중계수 선정에 따라 최적 퍼지-뉴럴 네트워크모델을 구축할 수 있다.

3. 시뮬레이션 및 결과고찰

3.1 가스로 공정

제한된 모델의 성능을 평가하기 위해서 Box와 Jenkins[5]에 의해 사용된 가스로 시계열 데이터를 이용하였다. 가스로 시계열 데이터는 입출력 데이터인 가스 흐름율과 연소된 이산화탄소 농도의 가스로 공정으로부터 추출된다. 메탄가스 흐름율 ($X(t)$)은 실험에서 -2.5에서 2.5로 변하는 것을 사용하나 실제 공정에서의 메탄가스 흐름율 ($X_m(t)$)은 식 (8)에 의해 0.5에서 0.7로 변한다.

$$X_m(t) = 0.6 - 0.048 \times X(t) \quad (8)$$

입력($u(t)$)은 가스 흐름율이고 출력($y(t)$)은 이산화탄소 농도인 1입력 1출력의 가스로 시계열 데이터를 입력 $u(t-3)$, $y(t-1)$ 과 출력 $y(t)$ 의 2입력 1출력으로 설정하여 사용한다.

표 1에서는 HCM 클러스터링을 통해 얻은 클러스터 개수와 하중계수 θ 에 따른 확장된 다중 퍼지-뉴럴 네트워크 모델 후반부 추론방식에 따라서 간략 추론방법과 선형 추론방법을 각각 이용했을 때의 성능지수를 나타낸 것이다. 하중계수 θ 의 설정에 따라 FNN모델의 멤버십함수의 파라미터들과 학습율, 모멘텀 계수를 유전자 알고리즘에 의해 자동 동조함으로써 근사화 능력과 일반화 능력을 가진 최적 FNN모델의 성능지수를 구한 것이다.

표 1. 클러스터 개수에 따른 성능지수
(a) 간략 추론

입력	θ	단일 FNN		Multi-FNN							
				클러스터 2		클러스터 3		클러스터 4		클러스터 5	
		PI	E PI	PI	E PI	PI	E PI	PI	E PI	PI	E PI
u(t-3) y(t-1)	0.0	0.06	0.27	0.10	0.29	0.13	0.27	0.07	0.26	0.04	0.26
	0.25	0.07	0.27	0.05	0.29	0.03	0.28	0.04	0.27	0.03	0.26
	0.5	0.03	0.28	0.02	0.30	0.02	0.29	0.02	0.27	0.02	0.27
	0.75	0.02	0.30	0.02	0.31	0.02	0.30	0.01	0.28	0.01	0.29
	1.0	0.02	0.33	0.02	0.31	0.01	0.34	0.01	0.30	0.01	0.33

(b) 선형 추론

입력	θ	단일 FNN		Multi-FNN							
				클러스터 2		클러스터 3		클러스터 4		클러스터 5	
		PI	E PI	PI	E PI	PI	E PI	PI	E PI	PI	E PI
u(t-3) y(t-1)	0.0	0.12	0.25	0.05	0.25	0.11	0.25	0.04	0.27	0.04	0.26
	0.25	0.05	0.25	0.03	0.26	0.05	0.25	0.04	0.25	0.04	0.26
	0.5	0.04	0.26	0.03	0.26	0.03	0.27	0.02	0.28	0.02	0.28
	0.75	0.02	0.28	0.02	0.30	0.02	0.29	0.02	0.29	0.01	0.28
	1.0	0.02	0.33	0.02	0.33	0.01	0.31	0.01	0.36	0.01	0.33

표 1에서 보여지는 것처럼 가스로 공정과 같이 주어진 데이터가 균일한 구조를 가지고 비선형성 정도가 약한 데이터에서는 클러스터 분할에 따른 모델의 성능이 단일 모델의 성능보다는 우수하지만, 후반부 추론에서는 간략과 선형 추론 방법에 따른 성능의 우수성을 평가하기에는 미미함을 알 수 있다. 표 2는 동일한 데이터를 사용하여 성능 지수를 식 (6)에 의해 계산된 값으로 다른 동정된 모델과 성능비교를 나타낸다.

표 2. 기존 모델과 동정오차 비교

모델		PI	E PI
Fuzzy model[4] (Complex)	간략추론	0.024	0.328
	선형추론	0.021	0.364
Fuzzy model[7] (GA)	간략추론	0.022	0.333
FNN model[8]	GA	0.026	0.304
	HCM+GA	0.032	0.276
Our model	간략추론	$\theta=0.5$	0.025
		$\theta=1.0$	0.017
	선형추론	$\theta=0.5$	0.031
		$\theta=0.5$	0.017

3.2 가스터빈 발전소의 NOx 방출 공정 데이터

확장된 다중 FNN 모델의 성능을 평가하기 위해서 최근 가스 터빈 발전소에서 사용하는 입출력 변수 중에 입력으로 Tamb, COM, LPT, Pcd, Texh와 출력으로 NOx양을 이용하여 모델을 구축한다. 본 논문에서는 이러한 입출력 변수들을 이용하여 제안한 모델의 성능을 평가하기 위해서 각각의 변수들의 데이터에 대해 처음 130개 데이터는 학습 데이터로 사용하고 그 나머지 130개 데이터는 테스트 데이터로 사용하여 모델의 근사화와 일반화를 얻는다. NOx의 성능 평가를 위해서 성능지수식으로는 식 (6)을 이용한다. 표 3에서는 HCM 클러스터링을 통해 얻은 클러스터 개수와 하중계수 θ 에 따른 확장된 다중 퍼지-뉴럴 네트워크 모델을 후반부 추론방식에 따라서 간략 추론방법과 선형 추론방법을 각각 이용했을 때의 성능지수를 나타낸 것이다.

표 3. 클러스터 개수에 따른 성능지수

추론방법	θ	단일 FNN		Multi-FNN			
				클러스터 2		클러스터 3	
		PI	E PI	PI	E PI	PI	E PI
간략추론	0.0	7.249	11.06	3.605	6.966	3.331	5.327
	0.25	7.026	11.18	3.658	6.894	3.236	5.418
	0.5	7.043	11.26	3.476	6.827	3.009	5.447
	0.75	6.714	11.47	2.773	8.527	3.140	5.446
	1.0	6.686	11.57	2.542	13.13	3.037	6.159
선형추론	0.0	4.46	5.496	2.457	3.013	1.348	2.122
	0.25	3.910	5.776	1.832	3.019	1.165	2.049
	0.5	4.038	6.028	1.699	2.847	1.140	2.653
	0.75	3.620	5.560	1.642	3.727	1.054	3.078
	1.0	3.794	6.814	1.256	58.04	0.840	3.183

표 3에서 볼 수 있듯이 가스로 공정보다 데이터가 균일하지 않고 NOx 데이터와 같이 비선형성이 강한 데이터일수록 본 논문에서 제안한 확장된 다중 퍼지-뉴럴 네트워크 모델이 효과적임을 알 수 있다. 또한 후반부 추론에 있어서도 간략 추론 방법을 이용하는 것보다 선형 추론방법을 이용했을 때 더욱 효과적인 다중 퍼지-뉴럴 네트워크 모델을 구축할 수 있다.

4. 결 론

본 논문에서는 확장된 다중 퍼지-뉴럴 네트워크 모델을 이용하여 비선형적이고 복잡한 실 시스템 데이터를 해석하고 데이터 특성을 따른 체계적이고 효율적인 모델을 구축하였다. 제안된 모델은 초기 다중 구조를 가지는 모델의 수를 HCM 클러스터링 알고리즘으로 결정함으로써 기존 모델들의 단점인 데이터의 특성을 고려하지 않고 모델을 구축하는 것에서 벗어나 주어진 데이터의 특성을 반영하였고, 각각의 퍼지-뉴럴 네트워크의 멤버십 함수 파라미터 정점들과 학습율, 모멘텀 계수를 유전자 알고리즘으로 동조하여 더욱 정밀한 최적의 모델을 구축하였다. 시뮬레이션 및 결과 고찰에서 볼 수 있듯이 본 논문에서 제안한 알고리즘은 비선형성이 상대적으로 약하고 비교적 균일하게 분포된 데이터 구조에서는 뚜렷한 성능향상을 나타내지 못하지만, 비선형성이 강하며 균일하지 않고 분산된 구조와 입출력 데이터 수가 적은 경우에는 학습 및 테스트 성능이 향상된 모델을 구축할 수 있었다. 또한 하중 계수를 가지는 목적함수 의해 FNN 모델의 근사화 및 일반화사이에서 최적 성능결과에 대한 해석을 시도함으로써 FNN모델의 근사화와 일반화 사이의 상호 연계를 통한 최적화 향상을 제시하였다.

감사의 글

본 논문은 2001년 에너지 관리공단의 에너지기술 학술진흥 사업 연구비에 의하여 지원하였음.

(참 고 문 헌)

- [1] J. H. Nie and T. H. Lee, Rule-based modeling: Fast construction and optimal manipulation, IEEE Trans. Syst., Man, Cybern. Part A, vol.26, pp. 728-738, Nov, 1996.
- [2] T. Yamakawa, "A New Effective Learning Algorithm for a Neo Fuzzy Neuron Model", 5th IFSA World Congress, pp. 1017-1020, 1993.
- [3] D. E. Goldberg, "Genetic Algorithm in search, Optimization & Machine Learning", Addison wesley, 1989.
- [4] 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.
- [5] Box and Jenkins, "Time Series Analysis, Forecasting and Control", Holden Day, San Francisco, CA.
- [6] G. Vachtsevanos, V. Ramani, T. W. Hwang, "Prediction of Gas Turbine NOx Emissions using Polynomial Neural Network", Technical Report, Georgia Institute of Technology, Atlanta, 1995.
- [7] B.-J. Park, W. Pedrycz and S.-K. Oh, "Identification of Fuzzy Models with the Aid of Evolutionary Data Granulation", *IEE Proceedings-CTA*, Vol. 148, Issue 05, pp. 406-418, 2001.
- [8] 오성권, 윤기찬, 김현기, "유전자 알고리즘과 합성 성능지수에 의한 퍼지-뉴럴 네트워크 구조의 최적 설계", 제어자동화시스템공학회, 제6권, 제3호, pp.273-283, 2000.
- [9] 오성권, "퍼지모델 및 제어이론과 프로그램", 기다리출판사, 1999.