

병렬구조 FNN과 비선형 시스템으로의 응용

박호성, 윤기찬, 오성권

원광대학교 전기전자공학부, 전라북도 익산시 신륵동 344-2 ☎570-749

Fuzzy-Neural Networks with Parallel Structure and Its Application to Nonlinear Systems

Ho-Sung Park, Ki-Chan Yoon and Sung-Kwun Oh

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

Abstract - In this paper, we propose an optimal design method of Fuzzy-Neural Networks model with parallel structure for complex and nonlinear systems. The proposed model is consists of a multiple number of FNN connected in parallel. The proposed FNNs with parallel structure is based on Yamakawa's FNN and it uses simplified inference as fuzzy inference method and Error Back Propagation Algorithm as learning rules. We use a HCM clustering and GAs to identify the structure and the parameters of the proposed model. 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.

1. 서 론

최근, 제어, 의사 결정 혹은 패턴 인식 등등의 여러 분야에서 쉽게 접하는 비선형성과 불확실성 및 상당히 복잡한 구조를 갖는 시스템에 대한 모델링 기법이 기존의 수학적 모델을 사용한 기법으로부터 인간의 언어 및 사고에 관련된 애매함을 수리적으로 취급이 가능하도록 하는 퍼지이론(1)과 인간의 두뇌가 이루고 있는 뉴런(neuron)들의 결합을 모델링한 신경망의 상호 융합한 지능형 모델로 대치되고 있다. 이에 본 논문에서는 지능형 모델의 하나로 다른 퍼지-뉴럴 네트워크모델에 비해서 학습속도가 빠르고, 수렴특성이 매우 우수하다는 장점을 가진 Yamakawa(2)에 의해 제안된 퍼지-뉴럴 네트워크 모델을 단일 FNN 구조로 사용한 병렬구조를 가진 FNN 모델을 제안한다. 제안한 병렬구조를 가진 FNN 모델은 시스템의 데이터 특성을 해석하기 위해 HCM 클러스터링 방법을 이용하여 입출력 데이터를 서로 유사한 특성을 가진 그룹으로 분류하는 전처리 과정을 수행하고, 분류된 그룹은 병렬구조를 가진 FNN 각각의 모델에 입력이 되어 출력하게 된다. 또한 데이터 특성 분류에 따른 각 네트워크모델 구조의 최적화를 위해 GAs(3)를 이용한 병렬구조를 가진 FNN 구조를 생성함으로써 단일 퍼지-뉴럴 네트워크모델의 한계성을 극복하고자 한다.

더 나아가 학습 데이터 및 테스트 데이터를 고려한 퍼지-뉴럴 네트워크 모델 성능 측 근사화 및 일반화 능력 모두를 고려한 성능결과를 위해 하중 계수를 가진 합성 목적함수를 사용하여 공정시스템의 최적모델을 구축하고자 한다. 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.

2. 본 론

2.1 병렬구조 FNN의 구조

퍼지-뉴럴 네트워크 구조는 퍼지이론의 언어적 논리를 규칙의 형태로 표현할 수 있는 능력과 신경망의 오류 역전파 알고리즘을 사용한 학습기능이 서로 결합한 형태로써, 본 논문에서 제안한 병렬구조 퍼지-뉴럴 네트워크의 기본 모델은 그림 1에서 보여준 바와 같이 다른 모델에 비해서 학습속도가 빠르고, 수렴특성이 매우 우수하다는 장점을 가진 각 입력변수에 따른 퍼지 입력공간분할에 의한 기본 FNN(2)구조를 사용한다.




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 퍼지규칙을 이루고 있으며 그 규칙은 식 (2)와 같은 간략추론 방법을 이용한다.

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

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 병렬구조를 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. 병렬구조 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 가능영역들을 균형있게 이용하기 위하여 생산, 교차, 돌연변이의 과정을 수행하는 일반성 있는 탐색법으로 비선형 최적화 이론에 탁월한 성능을 발휘하고 있다[3]. 기존의 다른 탐색방법들과 달리 유전자 알고리즘은 해가 될 가능성이 있는 개체집단을 유지하면서 그들 모두가 동시에 최적값을 찾아나가기 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 (3)과 같이 정의한다.

$$f(PI, E_PI) = \theta \times PI + (1 - \theta) \times E_PI \quad (3)$$

θ 는 PI 와 E_PI 에 대한 하중계수를 나타내고, PI 는 학습 데이터 성능지수, E_PI 는 테스트 데이터 성능지수를 나타낸다. 식 (3)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 네트워크 모델을 구축할 수 있다.

3. 시뮬레이션

3.1 가스로 공정

제안된 모델의 성능을 평가하기 위해서 Box와 Jenkins[4]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 (4)에 의해 0.5에서 0.7로 변한다.

$$X_m(t) = 0.6 - 0.048 \times X(t) \quad (4)$$

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. 성능지수 (PI)는 식 (5)와 같이 MSE(Mean Squared Error)를 이용한다.

$$PI = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (5)$$

표 1에서는 HCM 클러스터링을 통해 얻은 클러스터 개수와 하중계수 θ 에 따른 병렬구조 퍼지-뉴럴 네트워크 모델의 성능지수를 나타낸다. 각 입력에 따른 멤버십함수를 3개로 하여, 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

입력	θ	단일 FNN		병렬구조 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	0.062	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 3은 표 1에서 나타난 단일 FNN과 병렬구조 FNN의 각 클러스터 개수와 하중계수 θ 에 따른 학습 및 테스트 입출력 데이터군에 의한 각 모델의 성능지수를 그래프로 표시한 것이다.




그림 3. 하중계수 θ 에 따른 병렬구조 FNN의 성능지수

표 2는 동일한 데이터를 사용하여 성능 지수를 식 (5)에 의해 계산된 값으로 다른 동정된 모델과 성능비교를 나타낸다.

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

3.1 비선형 함수

제안한 모델의 적용 및 유용성을 비교 평가하기 위해 식 (6)으로 표현되어지는 비선형 함수에 의해서 얻어진 40개의 입출력 데이터 쌍을 사용해서 처음 20개의 데이터는 학습 데이터로 나머지 20개 데이터는 테스트 데이터로 사용하여 모델의 성능을 평가하였다[5].

$$y = (1 + x_1^{0.5} + x_2^{-1} + x_3^{-1.5})^2 \quad (6)$$

비선형 함수에 대한 성능지수는 식 (7)과 같이 API(Average Percentage Error)를 이용하였다.

$$PI = \frac{1}{m} \sum_{i=1}^m \frac{|y_i - \hat{y}_i|}{y_i} \times 100(\%) \quad (7)$$

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

표 3. 클러스터 개수에 따른 성능지수

θ	단일 FNN		병렬구조 FNN									
			클러스터 2		클러스터 3		클러스터 4		클러스터 5			
	PI	E_PI	PI	E_PI	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	0.936	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		

여기서, 그림 4는 표3에서 나타난 단일 FNN과 병렬구조 FNN의 클러스터 개수와 하중계수 θ 에 따른 학습 데이터와 테스트 데이터 각각의 성능지수를 그림으로 그려 놓은 것이다.




그림 4. 하중계수 θ 에 따른 병렬구조 FNN의 성능지수

표 4는 다른 동정된 모델과 성능비교를 나타낸다.

표 4. 기존 모델과 동정오차 비교

모델		PI	E PI
선형 모델(9)		12.7	11.1
Sugeno's model(5)	model I	1.5	2.1
	model II	1.1	3.6
Shin-ichi's model(10)	Type I	0.84	1.22
	Type 2	0.73	1.28
Our model	$\theta=0.5$	0.813	0.994
	$\theta=1.0$	0.700	1.304

4. 결 론

본 논문에서는 비선형적이고 복잡한 실 시스템의 데이터 특성을 해석하고 데이터의 특성에 따른 체계적이고 효율적인 모델을 구축하기 위하여 병렬구조를 가지는 퍼지-뉴럴 네트워크를 제안한다. 제안된 모델은 기존 모델들의 단점인 데이터의 특성을 고려하지 않고 모델을 구축하는 것에서 벗어나 HCM 클러스터링 알고리즘을 이용하여 데이터의 특성에 맞는 최적의 병렬구조 퍼지-뉴럴 네트워크 모델의 구축하였다. 또한 모델의 최적화를 위하여 유전자 알고리즘과 하중계수를 가진 합성 목적함수를 사용한다. 시뮬레이션을 통해서 알 수 있듯이 제안된 방법은 비선형 시스템의 입출력 데이터를 분석하여 데이터 상호간의 연관성을 찾아 몇 개의 병렬구조를 이루어 전체적으로 적용력을 가진 강인한 구조를 생성하는 장점이 있음을 알 수 있었다.

감사의 글

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

(참 고 문 헌)

- [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, San Francisco, 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.*, Vol. 115, issue 2, pp. 205-230, Jul, 2000.
- [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*, 제6권, 제3호, pp.273-283, 2000.
- [9] 菅野道夫(譯: 박민용, 최항식), "퍼지제어 시스템", pp. 143-158, 大英社, 1990.
- [10] 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.