

FCM 알고리즘을 이용한 퍼지-뉴럴 네트워크 설계

윤기찬*, 박병준*, 오성권*, 이성환**

*원광대학교 전기전자공학부, **현대중공업(주) 기전 연구소

The Design of Fuzzy-Neural Networks using FCM Algorithms

Kichan Yoon*, Byoungjun Park*, Sungkwun Oh* and Sunghwan Lee**

*Div. of Electrical & Engineering, of Wonkwang Univ., **Mechatronics Research Institute, Hyundai Heavy I

Abstract - In this paper, we propose fuzzy-neural Networks(FNN) which is useful for identification algorithms. The proposed FNN model consists of two steps: the first step, which determines premise and consequent parameters approximately using FCM_RI method, the second step, which adjusts the premise and consequent parameters more precisely by gradient descent algorithm. The FCM_RI algorithm consists FCM clustering algorithm and Recursive least squared(RLS) method, this divides the input space more efficiently than convention methods by taking into consideration correlations between components of sample data. To evaluate the performance of the proposed FNN model, we use the time series data for gas furnace.

1. 서 론

퍼지논리는 1965년 Zadeh에 의해 창안된 “퍼지 집합” 이론을 이용하여 비선형적이고 복잡한 실 시스템의 특성을 해석하는데 적용함으로써 수학적 모델보다 좋은 결과를 가져왔다. 하지만 멤버쉽함수와 규칙을 결정하는데 많은 어려움을 가지고 있다. 즉 퍼지 논리에서 인간 전문가 혹은 시행착오법에 의해 퍼지 규칙을 생성하고, 퍼지 규칙을 적용적으로 생성할 수 있는 학습 기능이 없다. 이로 인하여 동적으로 변화하는 환경에서 적응적으로 대처할 수 있는 추론 시스템의 구성이 불가능하다. 이 문제를 해결하기 위해 학습능력을 가진 신경망의 융합이 시도하여 인간 전문가의 도움 없이 멤버쉽함수를 결정하거나 퍼지규칙을 찾고자 하는 방법이 다양하게 연구되어 왔다. 이들 대부분의 퍼지-뉴럴 네트워크모델은 찾고자 하는 퍼지 변수들의 일부를 신경회로망의 학습 연결 가중치로 표현하여 문제점을 해결하고자 하였다. 하지만 어떠한 미지의 데이터가 주어졌을 때 기존 모델은 그 미지의 데이터들간의 상관 관계를 고려하지 않고 각각 독립적으로 입력 공간을 분할함으로써 불필요하게 퍼지 규칙의 수가 증가하며 성능 또한 저하시키는 문제점을 가지고 있다. 이러한 문제점을 해결하기 위해 본 논문에서는 데이터들간의 상관 관계를 고려하여 전, 후반부 파라미터를 동정하는 퍼지-뉴럴 네트워크를 제안한다.

본 논문에서 제안하는 퍼지-뉴珥 네트워크는 하이브리드 알고리즘에 의해 전반부 및 후반부 파라미터를 찾는다. 하이브리드 알고리즘은 FCM_RI 알고리즘과 경사하강법으로 구성되어 있다. 즉, 다시 말해서 FCM_RI 알고리즘은 FCM 클러스터링 알고리즘과 Recursive least squared(RLS) 알고리즘으로 구성되어 있는데, 미지의 데이터는 공간 분할되며 각 영역에 대해서 가장 적합한 모델의 전, 후반부 파라미터에 대한 추정치를 구한다. 이렇게 얻어진 전반부와 후반부 파라미터들은 경사하강법에 의해 좀 더 정확하게 조정하여 모델링 오차를 줄이도록 한다.

제안된 모델은 가스로운 데이터를 이용하여 성능을 평가하여 기존 방법에 비해 우수한 모델을 구축할 수 있음을 보인다.

2. 퍼지-뉴珥 네트워크 모델

2.1 퍼지-뉴珥 네트워크 모델 구조

2입력 1출력을 가지고 각 입력변수에 대하여 2개의 규칙을 사용하는 퍼지-뉴珥 네트워크모델의 구조가 그림 1에 보인다. 본 논문에서 제안된 퍼지-뉴珥 네트워크 모델은 하이브리드 동정 방법에 의해 모델링 되어진다. 하이브리드 방법은 FCM_RI 동정 알고리즘과 경사하강법으로 구성되어 있다. 즉 FCM_RI 알고리즘을 이용하여 모델의 전반부와 후반부 파라미터를 조정되며, 이렇게 조정된 파라미터를 경사하강법을 이용하여 좀 더 정확하게 조정한다.

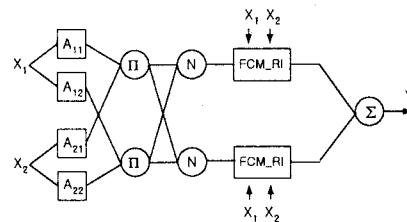


그림 1. 제안된 퍼지-뉴珥 네트워크 모델
Fig 1. Proposed fuzz-neural networks model

퍼지 규칙은 다음과 같은 선형 추론형태의 규칙 두개를 가진다

$$R^1 : \text{If } x_1 \text{ is } A_{11} \text{ and } x_2 \text{ is } A_{21} \\ \text{then } C_1 = c_{01} + c_{11}x_1 + c_{21}x_2 \quad (1)$$

$$R^2 : \text{If } x_1 \text{ is } A_{12} \text{ and } x_2 \text{ is } A_{22} \\ \text{then } C_2 = c_{02} + c_{12}x_1 + c_{22}x_2 \quad (2)$$

여기에서 클러스터 개수는 퍼지 규칙의 개수가 된다.

A_i 의 멤버쉽함수 값으로 입력 x 가 A_i 를 만족하는 정도를 나타내고, 식 (2)으로 표현되는 종형의 멤버쉽함수를 사용한다.

$$A_{ij} (a_{ij}, b_{ij}) = \exp \left\{ - \left(\frac{x_j - a_{ij}}{b_{ij}} \right)^2 \right\} \quad (2)$$

여기서, $\{a_{ij}, b_{ij}\}$ 는 파라미터 집합이다. 이러한 파라미터들은 FCM_RI 알고리즘과 경사하강법을 사용하여 조정된다. 파라미터 a_{ij} 는 멤버쉽함수의 중심값을, 파라미터 b_{ij} 는 폭을 의미한다. 멤버쉽함수는 평균과 표

준편차를 의미한다.

3. 하이브리드 알고리즘

3.1 FCM기반 Identification (FCM_RI)

본 논문에서 사용하는 FCM_RI 알고리즘은 FCM 클러스터링 알고리즘과 Recursive least squared 알고리즘을 결합한 형태이다. 기존의 FCM 클러스터링 알고리즘은 각 규칙들이 담당하게 될 클러스터의 형성에 부적절하며, 그 이유는 클러스터의 중심을 그 클러스터에 소속된 데이터의 하중 평균으로 계산하여 클러스터가 구형(hypersphere)으로 형성된다 이를, 페지 모델의 적용할 수 없으므로 변형된 FCM 클러스터링 알고리즘이 필요하다. 즉 본 논문에서 사용하는 FCM_RI 알고리즘은 주어진 데이터를 Recursive least squared(RLS) 알고리즘에 의해 필팅평면(fitting plane)을 구하여 클러스터의 중심으로 사용함으로써 클러스터가 하이퍼평면(hyperplane)으로 형성된다.

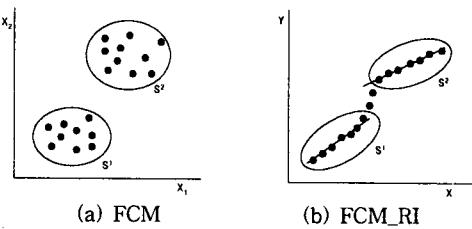


그림 2. 클러스터링 알고리즘
Fig. 2. Cluster Algorithm

후반부 파라미터가 FCM_RI 알고리즘에 의하여 결정되면, 전반부 파라미터는 $U(I)$ 의 1번쨰 클러스터 $C_i = X^T P_i$ 에서 (X_k, y_k) 의 멤버쉽인 μ_{ij} 를 이용하여 쉽게 얻을 수 있다. 종형 멤버쉽함수에 대한 수식 전개는 다음과 같다.

$$a_{ij} = \frac{\sum_{k=1}^n \mu_{ij} x_i}{\sum_{k=1}^n \mu_{ij}} \quad (3)$$

$$\frac{b_{ij}}{\sqrt{2}} = \sqrt{\frac{\sum_{k=1}^n \mu_{ij} (x_i - a_{ij})^2}{\sum_{k=1}^n \mu_{ij}}} \quad (4)$$

3.2 경사하강법(Gradient descent method)

FCM_PI 알고리즘으로 얻은 파라미터들은 페지-뉴럴 네트워크 모델링시 최적인 값으로 볼 수 없으므로 좀 더 정확하게 조정할 필요가 있다. 모델의 전반부 파라미터 동정은 다음과 같은 학습규칙에 의하여 정교하게 동조된다.

$j = l$ 일 때

$$\Delta a_{ij} = \beta \cdot 2 \cdot (y_p - \hat{y}_p) \cdot \left\{ \sum_{l=1}^m C_l \cdot \frac{\sum_{t=1}^n (w_t) - w_l}{\sum_{t=1}^n (w_t)^2} \right\} \cdot \prod_{k=1}^n A_k(x_k) \cdot \frac{\partial A^i}{\partial a_{ij}} \quad (5)$$

$$\Delta b_{ij} = \beta \cdot 2 \cdot (y_p - \hat{y}_p) \cdot \left\{ \sum_{l=1}^m C_l \cdot \frac{\sum_{t=1}^n (w_t) - w_l}{\sum_{t=1}^n (w_t)^2} \right\} \cdot \prod_{k=1}^n A_k(x_k) \cdot \frac{\partial A^i}{\partial b_{ij}} \quad (6)$$

$j \neq l$ 일 때

$$\Delta a_{ij} = \beta \cdot 2 \cdot (y_p - \hat{y}_p) \cdot \left\{ \sum_{l=1}^m C_l \cdot \frac{-w_l}{\sum_{t=1}^n (w_t)^2} \right\} \cdot \prod_{k=1}^n A_k(x_k) \cdot \frac{\partial A^i}{\partial a_{ij}} \quad (7)$$

$$\Delta b_{ij} = \beta \cdot 2 \cdot (y_p - \hat{y}_p) \cdot \left\{ \sum_{l=1}^m C_l \cdot \frac{-w_l}{\sum_{t=1}^n (w_t)^2} \right\} \cdot \prod_{k=1}^n A_k(x_k) \cdot \frac{\partial A^i}{\partial b_{ij}} \quad (8)$$

여기서 β 는 전반부의 학습율이고, y_p 는 바라는 출력이며, \hat{y}_p 는 페지모델의 출력이다.

페지-뉴럴 네트워크 모델의 후반부 동정은 다음과 같은 학습규칙에 의하여 정교하게 동조된다.

$$\Delta c_{ij} = \gamma \cdot (y_p - \hat{y}_p) \cdot \frac{1}{\sum_{t=1}^n w_t} \cdot w_t \cdot x_i \quad (9)$$

여기서 r 은 후반부의 학습율이다.

3. 시뮬레이션

제안된 FNN모델링을 Box와 Jenkins가 사용한 가스로 시계열 데이터를 이용하여, 입출력 데이터인 가스 흐름율과 연소된 이산화탄소 농도의 가스로 공정을 FNN모델링한다. 메탄 가스 흐름율($X(t)$)은 실험에서 -2.5에서 2.5로 변하는 것을 사용하나 실제 공정에서 메탄 가스 흐름율($X_m(t)$)은 식(10)에 의해 0.5에서 0.7로 변한다.

$$X_m(t) = 0.060 - 0.048 \times X(t) \quad (10)$$

1입력 1출력의 가스로 시계열 입출력 데이터 296쌍을 시뮬레이션을 위해 $u(t-3)$ 과 $y(t-1)$ 을, 출력으로 $y(t)$ 를 사용하는 2입력 1출력으로 설정하여 사용한다. 성능평가 기준은 PI(Performance Index)중에서 오차의 제곱에 대한 평균을 구하는 식 (11)과 같은 형태인 MSE를 사용한다.

$$PI = \frac{1}{n} \cdot \sum_{s=1}^n (y_s - \hat{y}_s)^2 \quad (11)$$

표 1은 하이브리드 알고리즘의 모든 과정을 거친 전반부 파라미터이다.

표 1. 전반부 파라미터

	a_{1j}	b_{1j}	a_{2j}	b_{2j}
R^1	0.621	0.147	52.301	5.368
R^2	0.589	0.072	52.290	4.402
R^3	0.653	0.134	52.623	4.771

식 (12)은 하이브리드 알고리즘의 모든 과정을 거친 퍼지 모델링 결과이다.

$$\begin{aligned}
 R^1 : & \text{If } x_1 \text{ is } A_{11} \text{ and } x_2 \text{ is } A_{21} \\
 & \text{then } C_1 = 1.411 + 18.257 x_1 + 0.766 x_2 \\
 R^2 : & \text{If } x_2 \text{ is } A_{12} \text{ and } x_2 \text{ is } A_{22} \\
 & \text{then } C_1 = 2.552 - 30.582 x_1 - 0.606 x_2 \\
 R^3 : & \text{If } x_1 \text{ is } A_{13} \text{ and } x_2 \text{ is } A_{23} \\
 & \text{then } C_1 = -0.832 - 23.985 x_1 - 0.745 x_2
 \end{aligned} \quad (12)$$

그림 3은 제안된 모델의 출력과 실 데이터의 출력과의 비교를 나타낸다.

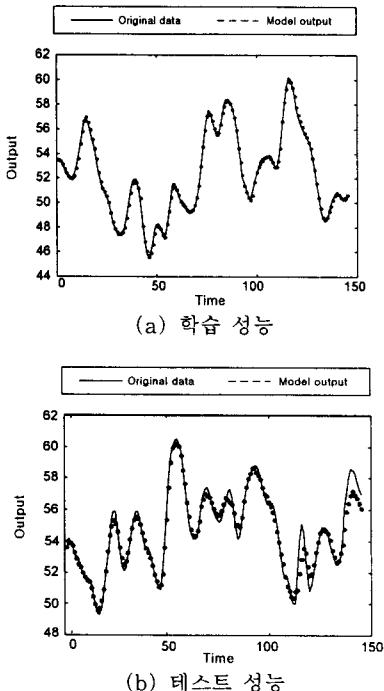


그림 3. Fuzzy모델의 출력과 실 데이터 출력의 비교.

Fig 3. Comparison of original data and output data for Fuzzy.

표 2는 동일한 데이터를 사용하여 성능 지수를 식 (11)에 의해 계산된 값으로 다른 모델과의 성능 비교를 나타낸다.

표 2. 기존 모델과 성능 지수 비교

Type	Performance		Total No. of rules
	PI	E_PI	
Oh's Fuzzy Model[12] (Complex)	0.022	0.326	4
	0.021	0.364	6
Oh's Fuzzy Model[13] (HCM + GA)	0.026	0.272	4
	0.020	0.264	6
Proposed FNN	0.025	0.295	3

3. 결 론

기존 퍼지모델은 그 미지의 데이터들간의 상관 관계를 고려하지 않고 입력 공간을 분할하는 문제점을 가지고 있었다.

본 논문에서는 이 같은 문제점을 해결하기 위해 하이브리드 알고리즘을 이용하였다. FCM_RI 알고리즘으로 데이터의 특성을 파악하여 전, 후반부 파라미터의 동정하고, 경사하강법에 의해 더욱 세밀하게 조정하였다. 시뮬레이션 결과에서 알 수 있듯이 본 논문에서 제안된 모델이 최적화 알고리즘을 사용한 다른 모델보다 비슷한 성능이나 향상된 성능을 얻을 수 있다. 또한 적은 퍼지 규칙을 사용하면서도 쉽게 파라미터를 설정할 수 있었다.

감사의 글

본 연구는 한국과학재단 목적기초연구 (과제번호 : 2000-1-30300-009-3) 지원으로 수행되었음

(참 고 문 헌)

- [1] L. A. Zadeh, "Fuzzy sets", *Inf. Control* 8, 338-353, 1965
- [2] J. C. Bazdek and S. K. Pal, "Fuzzy Models For Pattern Recognition: Methods that Search for Structures in Data," *IEEE Press*.
- [3] E. Czogala and W. Pedrycz, "On identification in fuzzy systems and its applications in control problems", *Fuzzy Sets Syst.*, Vol 6, pp.73-83, 1981.
- [4] W. Pedrycz, "An identification algorithm in fuzzy relational system", *Fuzzy Sets Syst.*, Vol.13, pp.153-167, 1984.
- [5] T. Takagi and M. Sugeno, "Fuzzy Identification of Systems and its application to modeling and control", *IEEE Trans. Systems Man Cybernet*, Vol. 15, No. 1, pp.116-132, 1985
- [6] M.A. Ismail, "Soft Clustering Algorithm and Validity of Solutions", *Fuzzy Computing Theory, Hardware and Applications*, edited by M. M. Gupta, North Holland, pp.445-471, 1988.
- [7] M. Sugeno and T. Yasukawa, "Linguistic modeling based on numerical data", *IFSA'91 Brussels, Computer, Management & System Science*, PP.264-267, 1991.
- [8] K. Tanaka and M. Sugeno, "Stability Analysis and design of fuzzy control systems", *Fuzzy Sets Syst.*, Vol. 45, pp.136-156, 1992
- [9] M. Sugeno and T. Yasukawa, "A Fuzzy-Logic-Based Approach to Qualitative Modeling", *IEEE Trans. Fuzzy Systems*, Vol. 1, No. 1, pp.7-31, 1993.
- [10] A.F. Gomez-Skarmeta, M. Delgado and M.A. Vila, "About the use of fuzzy clustering techniques for fuzzy model identification", *Fuzzy Sets Syst.*, Vol. 106, pp. 179-188, 1999.
- [11] E. kim, M. Park, S. Ji and M. Park, "A new approach to fuzzy modeling", *IEEE Trans. Fuzzy Systems*, Vol. 5, No. 3, pp.328-337, 1997
- [12] 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 Syst.*, Vol.115, issue 2, pp. 205-230, Jul. 2000
- [13] 박병준, 오성권, 안태천, 김현기, "유전자 알고리즘과 학습률을 이용한 퍼지 시스템의 최적화", 대한전기학회 논문집 제 48권 A편 제 6호, pp. 789-799, 1999.
- [14] 오성권, 박춘성, 박병준, "적용 퍼지-뉴럴 네트워크를 이용한 비선형 공정의 온-라인 모델링", 대한전기학회, 48권 제 10호, pp.1293-1302, 1999.
- [15] 박호성, 박병준, 오성권, "HCM을 이용한 퍼지 모델의 On-Line 동정", 대한전기학회 학술대회 논문집 G, pp.2929-2931, Jul. 20, 1999.