

# 온도 제어 시스템을 위한 뉴로-퍼지 제어기의 설계

The Design of an Adaptive Neuro-Fuzzy Controller  
for a Temperature Control System

곽근창\*, 김성수\*\*, 이상혁\*\*\*, 유정웅\*  
충북대학교 전기공학과

Keun-Chang Kwak\*, Sung-Soo Kim\*\*, Sang-Hyunk Lee\*\*\*, Jeong-Woong Ryu\*

Department of Electrical Engineering

Chungbuk National University\*  
Woosuk University\*\*

Busan National University\*\*\*

## ABSTRACT

In this paper, an adaptive neuro-fuzzy controller using the conditional fuzzy c-means(CFCM) methods is proposed. Usually, the number of fuzzy rules exponentially increases by applying the grid partitioning of the input space, in conventional adaptive neuro-fuzzy inference system(ANFIS) approaches. In order to solve this problem, CFCM method is adopted to render the clusters which represent the given input and output data. Finally, we applied the proposed method to the water path temperature control system and obtained a better performance than previous works.

## I. 서론

전형적인 제어 이론은 제어기를 설계함에 있어 보통 수학적인 모델을 요구한다. 플랜트의 수학적 모델링에 대한 부정확성은 특히 비선형과 복잡한 제어문제에 있어서 제어기의 성능을 악화시킨다. 최근에 퍼지 논리 제어기와 다중신경회로망은 좀 더 효율적인 제어 실현을 가능화하도록 하였으며, 이 기법들은 플랜트의 수학적 모델을 요구하지 않는다. 퍼지 논리의 개념은 산업공정 제어에 성공적으로 적용되어 졌으며, 퍼지 if-then 규칙은 숙련가의 경험적 지식과 전문가의 지식을 정성적인 언어 형태로 표현하여 쉽게 제어할 수 있다[1]. 그러나, 경험적 지식이나 전문가적 지식은 종종

불완전하고 체계적이지 못하기 때문에 수치적인 입출력 데이터를 근거로 해서 자동적인 퍼지 규칙을 생성하도록 많은 연구들이 진행되어 왔다. 한편, 다중 신경회로망은 적응성, 학습 능력을 가지고 지능 제어 시스템을 발달시키도록 사용되어져 왔다. 그러나 다중 신경회로망의 주된 단점은 만족할만한 수렴을 하기에는 오랜시간이 소요된다는 점이다. 이런 문제점을 보완하기 위해 신경회로망과 퍼지 시스템의 융합인 뉴로-퍼지 시스템이 각광을 받고 있다 [2]. 이 시스템을 구조동정과 파라미터 동정과 정으로 나눌 때 구조동정에서 중요하게 다룰 부분은 입력공간을 분할하는 문제이다. 입력 공간을 분할하는 방법은 그리드, 트리, 스캐터 분할방법 등이 있으며, 그 중에 스캐터 분할은

입력공간이 다차원일 경우 수치적인 입력 데이터로부터 분할을 하여 클러스터를 생성하지만 대부분의 경우는 출력 데이터의 성질을 고려하지 않고 입력 데이터에 의해서만 클러스터를 생성하기 때문에 타당한 클러스터를 생성하지 못한다.

따라서, 본 논문에서는 Pedrycz[3]에 의해 제안된 조건부적인 퍼지 c-means 클러스터링 (Conditional Fuzzy c-means) 기법을 이용하여 Jang의 ANFIS(Adaptive Neuro-Fuzzy Inference System)[4]의 구조동정을 수행하도록 하였다. 이렇게 함으로서 ANFIS의 입력공간이 증가할 때 규칙의 수가 지수적으로 증가하는 문제점을 해결할 수 있고 CFCM에 의한 클러스터 생성으로 인해 타당한 규칙들을 자동적으로 생성할 수 있다. 제안된 방법은 목욕물 온도제어 시스템에 적용하여 이전의 논문에 비해 우수함과 유용성을 설명한다[5][6].

## II. 제안된 뉴로-퍼지 시스템

제안된 뉴로-퍼지 제어기에서 사용된 알고리즘을 간략히 살펴보면 다음과 같다. 먼저 구조동정에서 전형적인 FCM과 CFCM을 비교해보자.

FCM 클러스터링은 Bezdek에 의해 제안된 알고리즘으로서 각각의 데이터와 클러스터 중심 사이의 직선 거리로 나타내는 목적함수가 최소화되도록 클러스터 중심을 추정하는 반복적인 알고리즘이다. FCM 클러스터링 방법의 목적함수는 다음과 같다.

$$J = \sum_{k=1}^c \sum_{i=1}^n u_{ik}^m \|x_k - c_i\|^2 \quad (1)$$

이 클러스터링 방법은 입력 데이터만을 고려하므로 다른 패턴의 성질을 가지는 출력 데이터가 같이 분류될 수 있다.

그림 1은 입력공간  $x = [x_1 \ x_2]$ 에서 출력 데이터의 두 패턴(흑, 백)에 FCM과 CFCM의 클러스터 추정을 보여주고 있다. 그림 1(a)는 단지 클러스터 중심과 데이터 사이의 직선 거리를 이용해 두 개의 클러스터를 형성한다. 반면에 그림 1(b)는 출력 패턴의 같은 성질을 유지하기 위해 세 개의 클러스터로 형성한다. 그림에

서 알 수 있듯이 후자의 방법으로 얻어진 클러스터는 전자의 방법보다 각각의 클러스터가 포함하는 데이터 사이의 유사성이 훨씬 좋음을 알 수 있다.

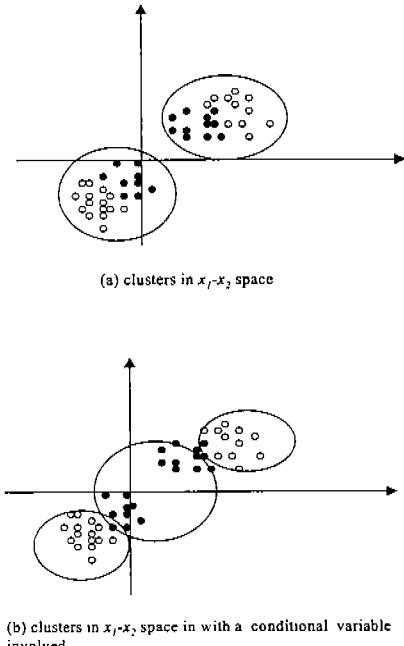


그림 1. FCM과 CFCM과의 비교

CFCM 클러스터링 알고리즘의 수행순서를 살펴보면 다음과 같다.

- [단계 1] 클러스터 수  $c$  ( $2 \leq c \leq N$ )와 가중치  $m$  ( $1 < m < \infty$ )을 정의한다.
- [단계 2] 0과 1사이에 임의의 값으로 소속함수 행렬의 초기치  $U^{(0)}$ 를 설정하고 클러스터의 값을 초기화한다. 소속도 행렬에 의한 조건을 수 정하고 다음 집합을 정의한다.

$$\begin{aligned} \sum_{i=1}^c u_{ik} &= f_k, \quad k=1 \cdots N, \quad i=1 \cdots c \\ U(f) &= \left\{ u_{ik} \in [0, 1] \mid \sum_{i=1}^c u_{ik} = f_k \forall k \text{ and } 0 < \sum_{k=1}^N u_{ik} < N \forall i \right\} \end{aligned} \quad (2)$$

- [단계 3] 각각의 클러스터 중심  $c_i^{(p)}$ 를 계산한다.

$$\begin{aligned} u_{ik} &= \frac{f_k}{\sum_{j=1}^c \left( \frac{\|x_k - c_j\|}{\|x_k - c_i\|} \right)^{2/(m-1)}} \\ c_i &= \frac{\sum_{k=1}^N u_{ik}^m x_k}{\sum_{k=1}^N u_{ik}^m} \end{aligned} \quad (3)$$

[단계 4]  $c^{(p)}$ 와 목적함수를 이용하여 다음 목적함수  $J^{(p+1)}$ 을 구하고 역치  $\varepsilon (\varepsilon > 0)$ 를 정의하여  $\|J^{(p)} - J^{(p+1)}\| \leq \varepsilon$ 이 만족할 때까지 [단계 3] ~ [단계 4]를 반복한다.

이렇게 얻어진 클러스터는 ANFIS의 2층의 가우시안 소속함수를 생성하여 스캐터 분할에 의해 퍼지 규칙이 생성된다.

### III. 시뮬레이션 및 결과

CFCM 클러스터링을 이용한 온-라인 뉴로-퍼지 제어기의 성능을 입증하기 위해 목록을 온도 제어 시스템에 적용한다. 그림 2는  $n=1$  일 때, 온-라인 학습에 대한 블록 다이어그램이다.

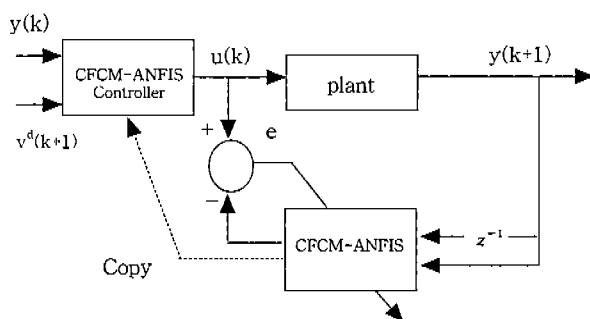


그림 2. 온-라인 학습에 대한 블록다이어그램

여기서,  $z^{-1}$ 는  $i$ 만큼의 지연을 나타낸다. 제어하고자 하는 플랜트는 다음과 같이 표현되어 진다.

$$y(k+1) = a(T_s)y(k) + \frac{b(T_s)}{1 + e^{0.5y(k)-r}} u(k) + [1 - a(T_s)] Y_0 \quad (4)$$

여기서,  $a(T_s) = e^{-\alpha T_s}$ ,  $b(T_s) = (\beta/\alpha)(1 - e^{-\alpha T_s})$

이고 플랜트의 파라미터는  $\alpha = 1.00151e^{-4}$ ,  $\beta = 8.67973e^{-3}$ ,  $r = 40$ ,  $Y_0 = 25^\circ\text{C}$ 로 고정된다.

플랜트 입력  $u(k)$ 는 0과 5 볼트 사이로 제한되고 샘플링 시간  $T_s$ 는 60초이다. 가능한 기준 신호에 따라 물 온도를 제어할 온-라인 적응 뉴로-퍼지 제어기를 설계하기 위해 기준 신호는  $0 \leq t \leq 40$ 분에  $35^\circ$ ,  $40 \leq t \leq 80$ 분에  $50^\circ$ ,  $80 \leq t \leq 120$ 분에  $65^\circ$ ,  $120 \leq t \leq 180$ 분에  $80^\circ$ 이다.

시스템을 학습하기 위한 학습 데이터는

$[y(k), y(k+1); u(k)]$  형태의 50개 학습 데이터 쌍을 찾기 위해 식 (4)을 사용한다. 그림 3은 학습 데이터와 CFCM에 의한 클러스터의 분포를 나타낸다. 이 클러스터는 시스템을 특징으로 하는 퍼지 규칙으로 사용된다.

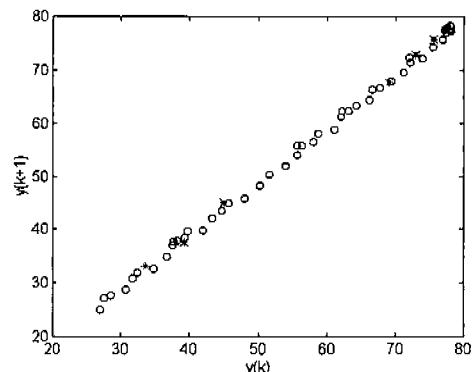


그림 3. 학습 데이터(○)와 클러스터(\*)의 분포

그림 4는 실제 출력과 모델의 추론 값의 결과를 보인다. 그러나 오프-라인 학습에 기초한 시뮬레이션 결과가 좋은 성능을 가질지라도 시변 동적 플랜트를 가지는 육조 제어 시스템은 불안정할 수도 있다. 따라서, 오프-라인 학습과 온-라인 학습을 병행할 필요성이 있다. 온-라인 학습에서 사용된 파라미터는  $\eta_c = \eta_o = 0.1$ 이고 결과 파라미터는  $\lambda = 0.99$ 인 RLSE로 조정한다.

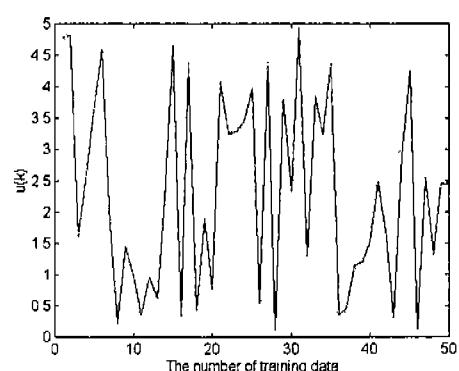


그림 4. 오프-라인 학습의 결과

그림 5에서 알 수 있듯이 원하는 목표값에 안정하게 도달하고 있음을 보인다. 이때 온-라인 학습 동안 결론부 파라미터 변동은 그림 6에서

보이고 있다. 그림 7은 일반적인 퍼지 제어기로서 온도가 높아짐에 따라 불완전하게 됨을 알 수 있다.

#### IV. 결 론

본 논문에서는 목욕물 온도제어 시스템을 다루기 위해 적응 뉴로-퍼지 제어기를 설계하였다. 먼저, 오프라인 학습에 대해서는 일반적인 역 학습기법이 사용되어지고 얻어진 입출력 데이터는 CFCM에 근거한 적응 뉴로-퍼지 제어기를 구축한다. 여기서 CFCM은 출력 패턴의 성질을 고려하기 때문에 기존의 퍼지 클러스터링 보다 타당한 클러스터와 규칙이 생성되었다. 온라인 학습에서는 전제부 및 결론부 파라미터가 온라인으로 역전파 알고리즘(BP)과 순환적인 최소자승법(RLSE)에 의해 조정 및 추정되었다.

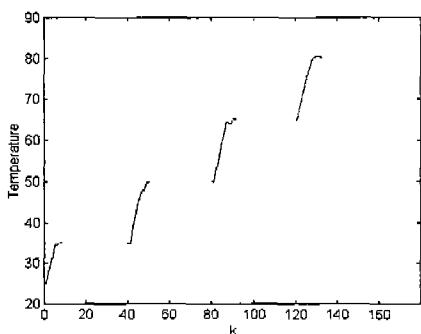


그림 5. 온-라인 학습에 대한 결과  
원하는 온도(+)와 제어된 온도(-)

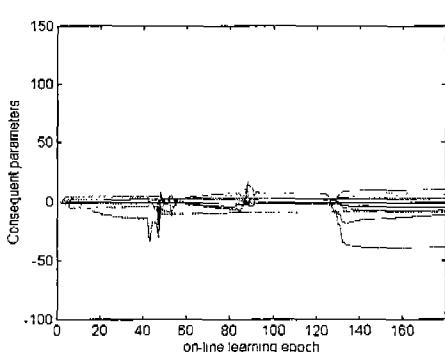


그림 6. 온-라인 학습시 결론부  
파라미터 변화

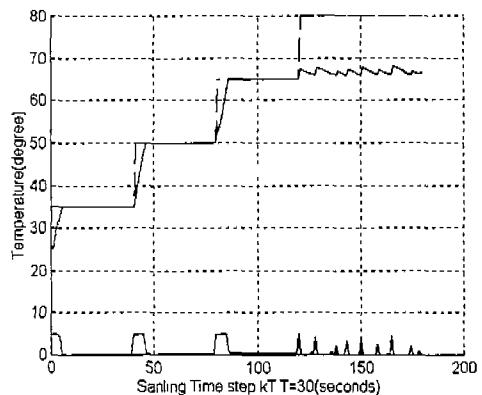


그림 7. 퍼지 제어기의 시뮬레이션 결과

#### 참고문헌

- [1] M. Sugeno, T. Yasukawa, "A Fuzzy-logic based Approach to Qualitative Modeling", IEEE Trans. Fuzzy Systems, Vol. 1, No. 1, pp. 7-31, 1993.
- [2] C. T. Lin, C. S. G. Lee, "Neural Fuzzy Systems", Prentice Hall, 1996.
- [3] W. Pedrycz, "Conditional fuzzy Clustering in the design of Radial Basis function Neural Networks", Proc. IEEE Trans. on Neural Networks, Vol. 9, pp. 601-612, 1998.
- [4] J. S. R. Jang, "ANFIS : Adaptive-Network based Fuzzy Inference System", IEEE Trans. System Man Cybernetics, Vol. 23, No. 3, pp. 665-685, 1993.
- [5] J. Tanomaru, S. Omatsu, "Process control by on-line trained neural controllers", IEEE Trans. Indust. Electrons, Vol. 39, pp. 511-521, 1992.
- [6] C. F. Juang, C. T. Lin, "An on-line self-constructing neural fuzzy inference network and its applications", IEEE Trans. on Fuzzy Systems, Vol. 6, No. 1, pp. 12-32, 1998.