

論文2002-39TE-4-13

# 온 라인 CFCM 기반 적응 뉴로-퍼지 시스템에 의한 온도제어

## (Temperature Control by On-line CFCM-based Adaptive Neuro-Fuzzy System)

尹起厚\*, 郭根昌\*\*

(Kee-hoo Yoon, Keun-Chang Kwak)

## 요약

본 논문에서는 적응 제어 문제를 다루기 위해 CFCM 클러스터링과 퍼지 균등화 기법을 이용하여 새로운 적응 뉴로-퍼지 제어기를 설계하고자 한다. 먼저 오프라인에서 CFCM은 입력데이터의 성질과 출력 패턴의 성질까지도 고려한 퍼지 클러스터링 기법으로 적응 뉴로-퍼지 제어기의 구조동정을 수행한다. 파라미터 동정은 역전파 알고리즘과 RLSE(Recursive Least Square Estimate)을 이용한 하이브리드 학습을 수행한다. 온라인 학습에서는 시변특성으로 인해 전제부 및 결론부 파라미터를 실시간으로 계산된다. 시뮬레이션으로 온 라인 적응 뉴로-퍼지 제어 시스템의 성능을 입증하기 위해 목욕물 온도제어 시스템에 대해 다루고 전형적인 퍼지 제어기에 비해 오프 라인과 온 라인 설계 모두 좋은 성능을 보이고자 한다.

**Abstract**

In this paper, we propose a new method of adaptive neuro-fuzzy control using CFCM(Conditional Fuzzy c-means) clustering and fuzzy equalization method to deal with adaptive control problem. First, in the off-line design, CFCM clustering performs structure identification of adaptive neuro-fuzzy control with the homogeneous properties of the given input and output data. The parameter identification are established by hybrid learning using back-propagation algorithm and RLSE(Recursive Least Square Estimate). In the on-line design, the premise and consequent parameters are tuned to RLSE with forgetting factor due to a characteristic of time variant. Finally, we applied the proposed method to the water temperature control system and obtained better results than previous works such as fuzzy control.

**Keyword** : temperature control, CFCM clustering, adaptive neuro-fuzzy system

\* 正會員, 舟城大學 디지털情報制御學科

(Dept. of Digital Information Control, Juseong College)

\*\* 正會員, 忠北大學校 電氣工學科

(Dept. of Electrical Engineering, Chungbuk National University)

接受日字:2002年8月28日, 수정완료일:2002年12月2日

**I. 서 론**

전통적인 제어 이론은 보통 제어기를 설계하기 위해 수학적인 모델을 필요로 한다. 플랜트의 수학적인 모델링의 부정확성은 특히 비선형이며 복잡한 제어문제에 있어서 제어기의 성능을 약화시키고 있다. 최근에 좀더 효과적인 제어의 실현 가능성을 제시하기 위해 디층

퍼셉트론으로 이루어진 신경회로망을 근거로 한 신경 제어기(Neural Controller)<sup>[1]</sup>와 퍼지 제어기(Fuzzy Controller)<sup>[2]</sup>에 대한 연구가 진행되고 있다. 이 제어기들은 플랜트의 수학적인 모델을 필요로 하지 않는다는 점에서 전형적인 적응 제어 시스템(Adaptive Control System)에 대해 중요한 장점을 제공하고 있다.

퍼지 제어기는 산업공정 제어에 성공적으로 적용되어져 왔으며 제어대상에 대해서 잘 알고 있는 전문가로부터 얻어진 경험적인 지식을 이용하여 퍼지 규칙을 생성한다. 그러나 전문가가 복잡한 시스템을 다루기 위해 퍼지 제어기의 적당한 퍼지 규칙을 획득하는 경우에 체계적인 방법이 없기 때문에 여러 가지 어려움을 겪고 있다. 또한 신경회로망은 비선형 사상과 학습능력을 가진 지능적인 제어 시스템을 구축함에 있어 중요 한 도구로서 사용되어져 왔다.

그러나 주된 단점은 학습속도가 느리며 오프라인에서 학습될 때 만족스런 결과를 얻기에는 오랜 시간을 소요해야만 한다. 게다가 환경이 변함에 따라 적응하기 위해 온 라인에서 학습할 때 보통 과도 조정된(over-tuned) 현상을 나타내기 때문에 제어기의 성능을 약화 시킬 것이다.

따라서, 입력공간에서의 데이터뿐만 아니라 출력변수의 유사성에 관련된 패턴들의 동질성을 유지하도록 클러스터를 생성하는 CFCM(Conditional Fuzzy C-Means) 클러스터링<sup>[3]</sup>과 퍼지 균등화<sup>[4]</sup>에 의해 자동적인 퍼지 규칙생성과 뉴로-퍼지 시스템을 설계한다. 구축된 시스템은 제어기로 설계하기 위해 두 단계과정인 학습 단계(training phase)와 응용 단계(application phase)를 포함하고 있다. 학습 단계에서 온 라인 혹은 오프 라인 기법은 플랜트의 역 동력학(inverse dynamics)을 모델링하는데 사용되어진다. 플랜트의 역 동력학을 표현해서 얻어진 뉴로-퍼지 시스템은 응용 단계에서 제어 입력을 발생하도록 사용되며 이 두 단계는 동시적으로 수행되어진다<sup>[5]</sup>.

시뮬레이션으로 온 라인 적응 뉴로-퍼지 제어 시스템의 성능을 입증하기 위해 목욕물 온도제어 시스템<sup>[6~9]</sup>에 대해 다루고 다른 방법에 비해 오프 라인과 온 라인 설계 모두 좋은 성능을 보이고자 한다.

## II. 제안된 적응 뉴로-퍼지 제어기

제안된 적응 뉴로-퍼지 시스템을 구축하기 위해서는

두 가지 동정과정인 구조동정과 파라미터 동정이 필요하다. 구조 동정은 소속함수와 퍼지 규칙의 생성에 관련되어지고 파라미터 동정은 전제부 및 결론부 파라미터의 조정에 관련되어진다.

CFCM 클러스터링과 퍼지 균등화를 이용한 적응 뉴로-퍼지 시스템에서의 퍼지 규칙과 소속함수를 자동적으로 생성하는 구조동정에 대하여 다루고자 한다.

먼저, 퍼지 균등화는 임의의 전체공간  $X$ 가 주어져 있고 이 공간상에서 취득된 수치데이터가 있을 경우, 이들로부터 확률밀도함수를 구한 후 전체공간  $X$ 에서 이들을 적절히 표현 할 수 있는 소속함수들을 원하는 개수만큼 체계적으로 만들어 낼 수 있는 기법으로 Pedrycz에 의해 소개되었다. 이러한 퍼지 균등화 이론은 Zadeh 교수<sup>[10]</sup>에 의해 정의된 퍼지 사건의 개념에 기인한다. 기존의 확률개념에서 사용되는 사건(crisp event)의 개념에서는  $A$ 라는 사건과 이의 확률밀도함수  $p(x)$ 가 주어졌을 경우 사건  $A$ 의 확률은 식 (1)과 같이 구해진다.

$$P(A) = \int_A p(x) dx \quad (1)$$

그러나, 만약 사건  $A$ 에 대하여 확률밀도함수  $p(x)$ 와 더불어 소속함수  $A(x)$  값이 주어진 퍼지사건일 경우의 확률은 식 (2)와 같이 주어진다.

$$P(A) = \int_X A(x) p(x) dx \quad (2)$$

위와 같은 개념에 기초하여 전체공간  $X$ 에 대하여 확률밀도함수  $p(x)$ 가 주어져 있을 때, 이 공간을 퍼지 집합  $\{A_1, A_2, \dots, A_G\}$ 로 나누는 퍼지사건을 정의한다고 하자. 그러면, 이때, 가장 바람직한 분할 방법은 각각의 퍼지사건의 확률이 같도록 식 (3)과 같이 균등화하는 방법이다.

$$P(A_1) = P(A_2) = \dots = P(A_G) = \frac{1}{G} \quad (3)$$

위의 개념을 적용하면 <그림 1>과 같이 데이터가 많은 부분에서는 조밀한 소속함수의 값을 갖고 그 반대의 경우에는 드물게 소속함수의 배치를 갖게 되어 우리의 직관과도 잘 일치함을 알 수 있다.

위의 개념을 역으로 이용하면, 원하는 소속함수의 개수  $G$ 와 확률밀도함수  $p(x)$ 가 주어져 있을 경우 소속함수를 정할 수 있다. 본 장에서는 퍼지 응용에 널리

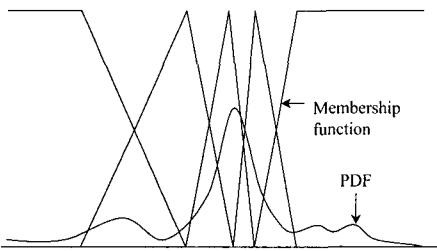


그림 1. 퍼지 균등화의 해석

Fig. 1. Idea of fuzzy equalization.

쓰이는 삼각퍼지 함수 모양을 사용하고 좌우의 소속함수와 1/2씩 겹치도록 하는 경우에 퍼지 균등화기법을 이용하여 소속함수를 자동으로 생성할 수 있다.

퍼지 균등화 기법을 이용한 소속함수 생성과정을 살펴보면 다음과 같다.

[단계 1]  $A$ 에서 소속함수의 수  $G$ 를 정한다.

[단계 2]  $X$ 의 최소 값으로 표시된  $x_{\min}$ 로부터 시작한다.

[단계 3] 적분의 이동 값을  $x_{\min}$ 에서  $X$ 의 최대 값으로 이동하면서 식 (4)와 같이 진행한다.

$$\int_{x_{\min}}^a A_1(x) p(x) dx = \frac{1}{2G} \quad (4)$$

이 적분 값이  $\frac{1}{2G}$ 에 도달하면 멈추고 그 값을  $a$ 라 한다.

[단계 4] 소속함수의 감소 부분에 퍼지 사건의 확률을 이식 (5)와 같도록  $A_1$ 의 지지 상환경계인  $b$ 를 결정한다.

$$\int_a^b A_1(x) p(x) dx = \frac{1}{2G} \quad (5)$$

[단계 5] 삼각 퍼지 집합( $A_2, A_3, A_4, \dots$ )에 대해서 식 (6)과 같이 퍼지 사건의 확률을 계산한다.

$$\sigma = \int_a^b A_2(x) p(x) dx \quad (6)$$

[단계 6] 퍼지 집합의 지지 상환경계를 결정하도록 식 (7)과 같이 소속함수의 감소부분을 최적화 한다(그림 2 참조).

$$\int_b^c A_2(x) p(x) dx = \frac{1}{G} - \sigma \quad (7)$$

[단계 7] 위와 같이 모든 퍼지 집합의 생성을 위해 [단계 5]~[단계 6]을 반복 수행한다.

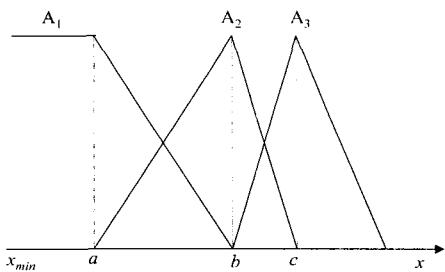
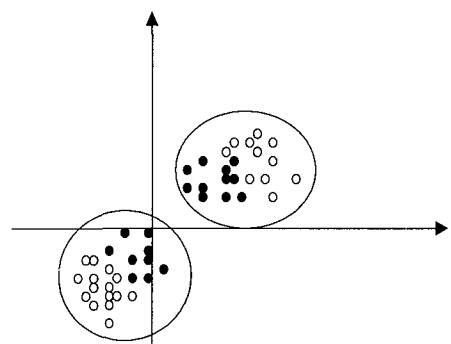
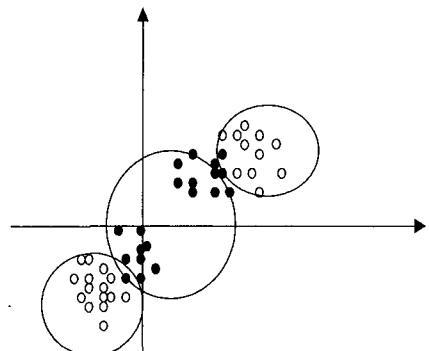


그림 2. 퍼지 균등화의 개념

Fig. 2. Concept of fuzzy equalization.



(a) FCM에서의 클러스터



(b) CFCM에서의 클러스터

그림 3. FCM과 CFCM에서의 클러스터의 비교

Fig. 3. Comparison of clusters in FCM and CFCM clustering algorithm.

한편, CFCM 클러스터링은 Pedrycz<sup>[5]</sup>에 의해 제제안된 방법으로 입력공간에서의 데이터뿐만 아니라 출력변수의 유사성에 관련된 패턴들의 동질성을 유지하도록 클러스터를 생성하는 퍼지 클러스터링 방법이다. <그림 3(a), (b)>는 입력공간  $x = [x_1 \ x_2]$ 에서 출력 데이터의 두 가지 클래스(흑, 백)에 대해 FCM과 CFCM 클러스터링의 클러스터 생성을 보여주고 있다. <그림

3(a)>는 전형적인 클러스터링 방법으로 출력 패턴의 성질을 고려하지 않고 단지 클러스터 중심과 입력 데이터 사이의 유clidean 거리를 사용해 두 개의 클러스터를 형성한다.

반면에 CFCM은 <그림 3(b)>에서 각 데이터가 분류된 것을 통하여 알 수 있듯이 입력 데이터의 성질뿐만 아니라 출력 패턴의 성질까지도 고려하기 때문에 최종적으로 세 개의 클러스터를 형성한다. 이를 정성적인 관점에서 보면 CFCM으로 얻어진 클러스터는 FCM에 의해 얻어진 클러스터보다 각각의 클러스터가 포함하는 데이터 사이의 유사성이 훨씬 좋음을 알 수 있다.

CFCM에 대해 간략히 기술하면 다음과 같다.

[단계1]  $m$  ( $1 < m < \infty$ )과 클러스터의 수  $c$  ( $2 \leq c \leq n$ )를 설정한다.

[단계2] 초기 분할 행렬  $U^{(0)}$ 와 역치  $\epsilon$ 를 설정하고 반복 지수 0에서  $p$ 까지 정한다.

여기서  $U = [u_{ij}]_{i=1 \dots c, j=1 \dots n}$

[단계3]  $U^{(p)}$ 와 식 (8)을 이용하여 각각의 클러스터 중심  $c_i^{(p)}$  ( $i = 1, 2, \dots, c$ )를 계산한다.

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (8)$$

[단계4]  $c^{(p)}$ 와 식 (9)을 이용하여 다음 번 분할 행렬  $U^{(p+1)}$ 을 구한다.

$$u_{ij} = \frac{f_j}{\sum_k (\frac{d_{ij}}{d_{kj}})^{2/(m-1)}} \quad (9)$$

여기서,  $f_j$ 는 생성된 클러스터에서  $x_j$ 의 포함정도를 말한다. 즉, 출력 변수에서 정의된 언어적인 형태가 퍼지 집합  $A$ , ( $A: R \rightarrow [0, 1]$ )로 표현되어 진다.  $f_j = A(y_j)$ ,  $j = 1, 2, \dots, n$ 은  $A$ 에서  $y_j$ 의 소속도로 표현된다.

[단계5] 식 (10)을 이용하여  $|J^{(p)} - J^{(p+1)}| \leq \epsilon$  을 만족한다면 멈추고, 그렇지 않으면 [단계 3]으로 가서  $p = p + 1$ 로 설정한다.

$$J = \sum_{j=1}^n \sum_{i=1}^c u_{ij}^m \|x_j - c_i\|^2 \quad (10)$$

이렇게 얻어진 클러스터는 적용 뉴로-퍼지 필터의 전체부 소속함수인 가우시안(gaussian) 소속함수의 중

심이 되고 확률적인 분포에 의해 폭이 정해진다. 전체부 소속함수가 결정된 후에 스캐터 분할에 의해 퍼지 규칙이 생성되어진다.

CFCM에 의해 구조동정이 수행된 후에 파라미터 동정은 Jang의 방법과 같이 역전파 알고리즘과 RLSE (Recursive Least Square Estimate)를 이용한 하이브리드 학습에 의해 전체부 및 결론부 파라미터가 구해진다.

온라인에서는 전체부 및 결론부 파라미터는 실시간으로 계산되어지며 결론부 파라미터는 다음 식과 같은 망각인자(forgetting factor)  $\lambda$ 를 갖는 순환적인 최소자승법을 사용한다.

$$\begin{aligned} X_{i+1} &= X_i + S_{i+1} a_{i+1} (b_{i+1}^T - a_{i+1}^T X_i) \\ S_{i+1} &= \frac{1}{\lambda} [S_i - \frac{S_i a_{i+1} a_{i+1}^T S_i}{\lambda + a_{i+1}^T S_i a_{i+1}}] \\ X^* &= X_p \end{aligned} \quad (11)$$

### III. 온라인 적용 뉴로-퍼지 제어기의 설계

제안된 뉴로-퍼지 시스템을 이용하여 제어기를 설계하기 위해서는 학습 단계(training phase)와 응용 단계(application phase)인 두 단계과정이 필요하며 그 과정을 살펴보면 다음과 같다.

우선 플랜트의 차수(상태변수의 수)는 알려져 있고 모든 상태변수는 측정 가능하다고 가정하면 식 (12)과 같이 표현되어질 수 있다.

$$x(k+1) = f(x(k), u(k)) \quad (12)$$

여기서  $x(k+1)$ 은  $k+1$ 에서 상태,  $x(k)$ 는  $k$ 에서 상태,  $u(k)$ 는  $k$ 에서의 제어 신호이다. 유사하게  $k+2$ 일 때의 상태는 식 (13)와 같이 표현되어진다.

$$\begin{aligned} x(k+2) &= f(x(k+1), u(k+1)) \\ &= f(f(x(k), u(k)), u(k+1)) \end{aligned} \quad (13)$$

일반적으로 플랜트의 차수가  $n$ 차라면 식 (14)와 같이 표현되어진다.

$$x(k+n) = F(x(k), U) \quad (14)$$

여기서  $F$ 는  $f$ 의 합성함수이며  $U$ 는  $[u(k), u(k+1), \dots, u(k+n-1)]$ 의 제어신호이다. 플랜트의 역 동력학

이 존재한다고 가정하면  $U$ 는  $x(k)$ 와  $x(k+n)$ 의 함수로서 식 (14)와 같이 표현된다.

$$U = G(x(k), x(k+n)) \quad (15)$$

역사상(inverse mapping)  $G$ 가 존재한다 할지라도 항상 분석적인 형태를 가지지 못하기 때문에 식 (16)과 같은 학습 데이터에 의해 역사상  $G$ 를 근사화하기 위해  $2n$ 개의 입력과  $n$ 개의 출력을 가지는 뉴로-퍼지 시스템을 구축한다.

$$[x(k)^T, x(k+n)^T; U^T] \quad (16)$$

<그림 4>는  $n=1$ 일 때 각각 플랜트, 학습단계와 응용단계의 블록 다이어그램을 나타내고 있다. <그림 4(a)>는 플랜트 출력  $x(k+1)$ 은 이전 상태인  $x(k)$ 와 입력  $u(k)$ 의 함수인 플랜트 블록을 보여주고 있다. 여

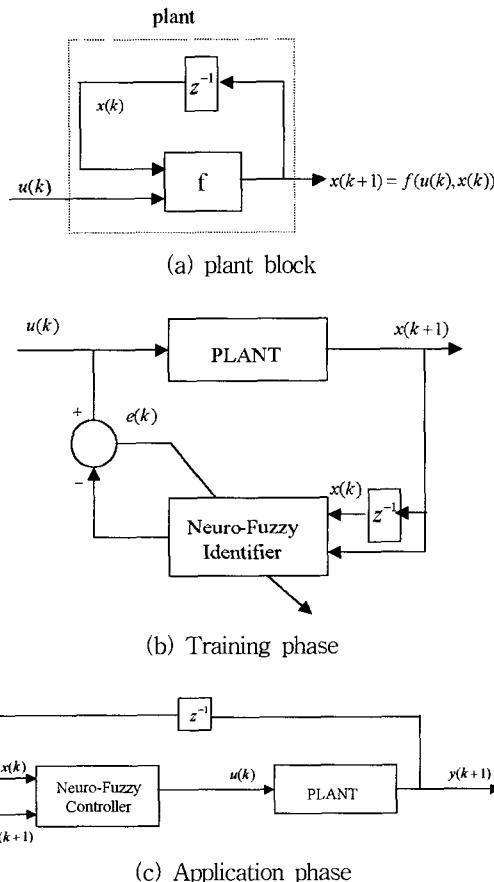


그림 4. 역 학습방법을 위한 블록 다이어그램  
Fig. 4. Block diagram for the inverse learning method.

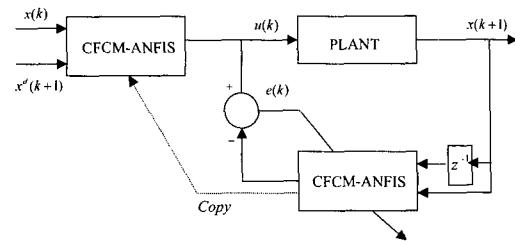


그림 5. 온 라인 역 학습을 위한 블록 다이어그램  
Fig. 5. Block diagram for on-line inverse learning.

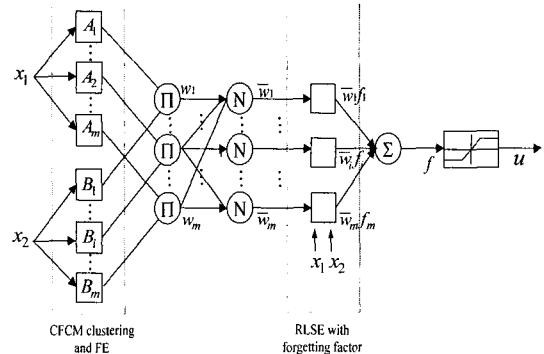


그림 6. 적응제어를 위한 CFCM기반 뉴로-퍼지 제어기  
Fig. 6. Architecture of CFCM-based Neuro Fuzzy Controller.

기서  $z^{-1}$ 은 단위 시간 지연을 나타내는 블록이다. <그림 4(b)>는 학습 단계동안 블록 다이어그램이고 <그림 4(c)>는 응용 단계동안 블록 다이어그램이다.

뉴로-퍼지 제어기는 현 상태  $x(k)$ 와 원하는 미래 상태  $x_d(k+n)$ 가 주어지면 식 (17)과 같이 추정된  $\hat{U}$ 를 발생시켜준다.

$$\hat{U} = \hat{G}(x(k), x_d(k+n)) \quad (17)$$

<그림 5>는 시변 특성을 갖는 시스템을 다루기 위해  $n=1$ 일 때 온 라인 학습에 대한 블록 다이어그램이다. <그림 6>은 <그림 5>의 CFCM 기반 뉴로-퍼지 식별기와 제어기에 대한 구조를 나타내고 있다. 이 구조는 두 개의 입력과  $m$ 개의 퍼지 규칙을 가지고 있으며, 마지막 층은 일정한 범위 내의 제어입력을 발생하도록 설정하였다.

#### IV. 시뮬레이션 및 결과

본 논문에서 제안된 뉴로-퍼지 제어기를 이용하여 목욕물 온도 제어 시스템(water bath temperature

control system)에 대해 다루고자 한다. 여기서 다룬 시스템은 Yamato Science Inc. laboratory<sup>[7]</sup>에서 BP-5 model을 사용하였으며 이 제어 시스템의 목적은 목욕 물 온도를 25~80°C 사이의 특정 온도로 유지하도록 온라인 제어기를 구축하는 것이다. 제어하고자 하는 플랜트는 식 (18)과 같이 표현되어진다.

$$y(k+1) = a(T_s)y(k) + \frac{b(T_s)}{1 + e^{0.5y(k)-r}} u(k) + [1 - a(T_s)]Y_0 \quad (18)$$

$$a(T_s) = e^{-\alpha T_s} \quad (19)$$

$$b(T_s) = (\beta/\alpha)(1 - e^{-\alpha T_s}) \quad (20)$$

여기서 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 [V]사이로 제한되고 샘플링 시간  $T_s$ 는 60초이다. 원하는 기준 신호에 따라 물 온도를 제어할 온라인 적응 뉴로-퍼지 제어기를 설계하기 위해 기준 신호는  $0 \leq t \leq 40$ 분에  $35^\circ\text{C}$ ,  $40 \leq t \leq 80$ 분에  $50^\circ\text{C}$ ,  $80 \leq t \leq 120$ 분에  $65^\circ\text{C}$ ,  $120 \leq t \leq 180$ 분에  $80^\circ\text{C}$ 이다.

우선 첫 단계인 학습 단계에서 뉴로-퍼지 식별기를 구축하기 위해 학습 데이터는 식 (18)을 이용하여 [ $y(k)$ ,  $y(k+1)$ :  $u(k)$ ] 형태의 50개 학습 데이터를 얻었다. <그림 7>은 퍼지 균등화에 의해 생성된 출력 변수  $u(k)$ 의 소속함수이다. 퍼지 균등화에 의해 생성된 각 소속함수마다 클러스터의 수를 두 개부터 증가하면서 CFCM 클러스터링을 수행한 결과 <그림 8>과 같이 성능지표가 8개인 경우에 제일 작은 값을 나타내고 있다. 따라서, 각 소속마다 두 개의 클러스터를 생성 시켜 총 8개의 클러스터 중심, 즉 퍼지 규칙을 생성하였다. <그림 9>는 학습데이터와 CFCM 클러스터링에 의해 생성된 클러스터 중심을 나타내고 있다.

CFCM 클러스터링에 의해 전제부 파라미터가 생성되고 RLSE를 이용하여 초기 뉴로-퍼지 식별기의 결론부 파라미터를 추정한다. <그림 10>은 실제 출력과 10epoch동안 학습한 후 뉴로-퍼지 식별기의 추론 값의 결과를 보여주고 있다. 그림에서 알 수 있듯이 원하는 출력 값을 잘 추종하고 있음을 알 수 있다. <그림 4(c)>와 같은 제어기로 하여 시뮬레이션 한 결과 <그림 10>과 같이 원하는 기준 온도를 잘 추종하고 있음을 알 수 있다. <그림 12>는 <그림 11>의 기준 온도를 추종하기 위해 추론한 제어 신호  $u$ 를 나타내고 있다.

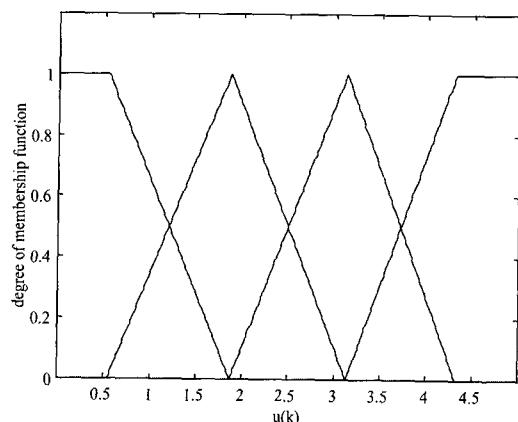


그림 7. 퍼지 균등화에 의해 얻어진 소속함수

Fig. 7. Membership function obtained by fuzzy equalization.

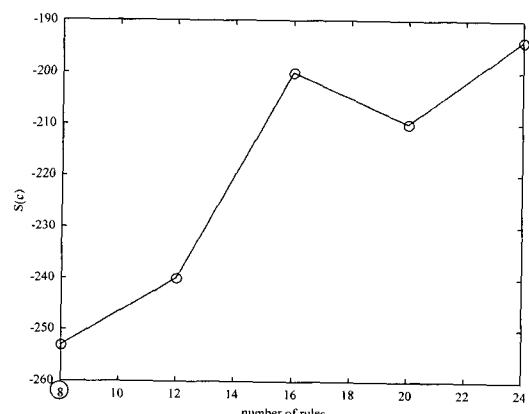


그림 8. 목욕물 온도 시스템에서 성능지표의 특성

Fig. 8. Behavior of performance criterion in water bath temperature system.

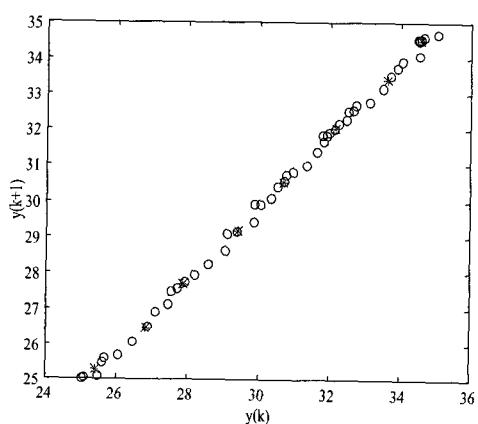


그림 9. 입력데이터('o')분포와 클러스터들('\*')

Fig. 9. Input data('o') distribution and clusters('\*').

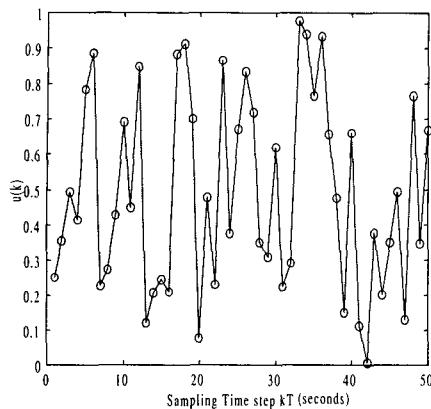


그림 10. 제안된 뉴로-퍼지 식별기에 대한 오프 라인 학습의 결과

Fig. 10. Result of off-line learning for the proposed neuro-fuzzy identifier.

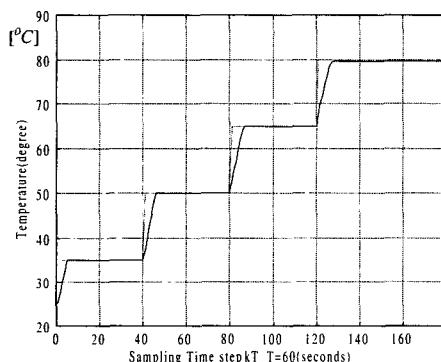


그림 11. 오프 라인 역 학습에 대한 성능

Fig. 11. Regulation performance for off-line inverse learning.

(… : Reference signal, — : Plant output)

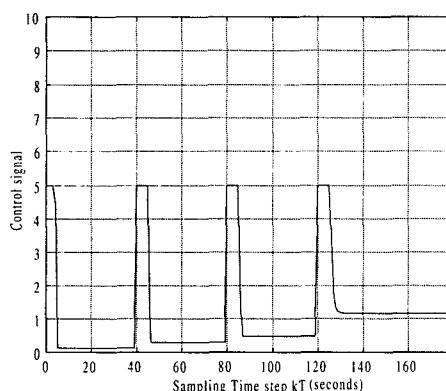


그림 12. 제안된 뉴로-퍼지 제어기에 의해 얻어진 제어 입력

Fig. 12. Control input obtained by the proposed neuro-fuzzy controller.

그러나 오프 라인 학습에 기초한 시뮬레이션 결과가 좋은 성능을 가질지라도 시변 동적 플랜트를 가지는 온도 제어 시스템은 불안정할 수가 있다. 따라서, <그림 5>와 같이 오프라인 학습과 온라인 학습을 병행할 필요성이 있다. 온라인 학습에서 사용된 파라미터는 학습률 0.1,  $\lambda = 0.97$ 을 이용하여 시뮬레이션을 수행하였다.

<그림 13>은 온라인 상에서 원하는 기준온도에 잘 추종하고 있음을 보여주고 있다. 제안된 방법과 비교를 위해 기존의 퍼지 제어기를 이용하여 적용할 경우 Mamdani 형태의 제어기로 각 입력공간을 5개의 소속 함수를 이용하여 그리드 분할하기 때문에 25개의 퍼지 규칙을 사용한다. <그림 14>는 제어 입력에 채터링 현상이 일어남을 알 수 있으며 <그림 15>에서 온라인 학습을 이용한 일반적인 퍼지 제어기는 제안된 방법보

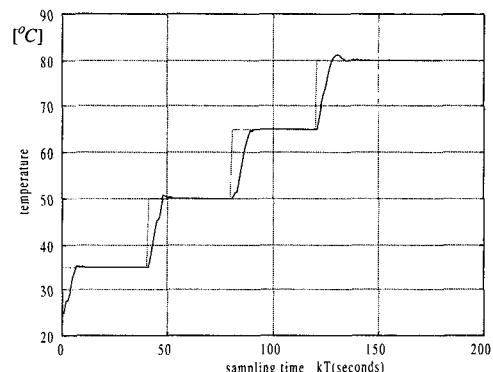


그림 13. 온라인 역 학습에 대한 성능

Fig. 13. Regulation performance for on-line inverse learning.

(CFCM-ANFIS)(… : Reference signal, — : Plant output)

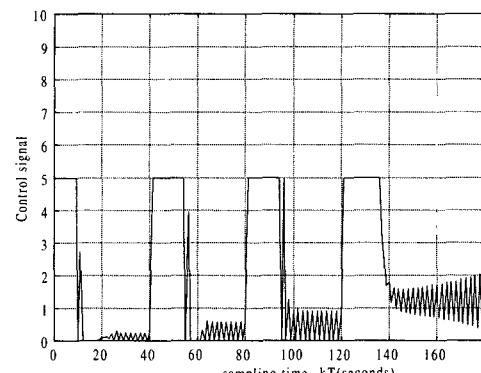


그림 14. 전형적인 퍼지제어기에 의해 얻어진 제어입력

Fig. 14. Control input produced by conventional fuzzy controller.

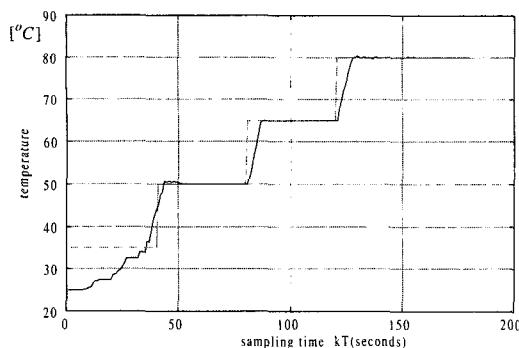


그림 15. 온 라인 역 학습에 대한 성능(퍼지제어기)  
Fig. 15. Regulation performance for on-line inverse learning(fuzzy controller).

표 1. 온도제어시스템에서 성능비교(절대오차  
합)

Fig. 1. Performance comparision of tempera-  
ture control system(SAE).

	제안된 방법	퍼지 시스템
SAE(오프라인)	163.8	206.4
SAE(온라인)	185.2	244.3

다 불안정하다는 것을 알 수 있었다.

<표 1>은 온수 제어에 대한 결과로 온도 추종 성능을 정량적으로 표현하기 위해 절대오차의 합인 SAE(Sum of Absolute Error)를 나타내고 있다. 표에서 알 수 있는 바와 같이 다른 방법에 비해 오프라인과 온 라인 모두 좋은 성능을 보임을 알 수 있었다.

## V. 결 론

본 논문에서는 입력데이터의 성질과 출력패턴의 성질까지도 고려한 CFCM 클러스터링과 퍼지 균등화 기법에 의한 온라인 적용 뉴로-퍼지 제어기를 설계하는 방법을 제안하였다. 먼저, CFCM 클러스터링은 오프라인에서 적용 뉴로-퍼지 제어기의 구조동정을 수행하고 파라미터 동정은 하이브리드 학습을 수행하였다. 온라인에서는 오프라인에서 구축된 제어기를 가지고 실시간으로 학습하였다. 제안된 적용 뉴로-퍼지 제어기를 가지고 목욕물 온도 제어 시스템에 시뮬레이션을 해 본 결과 전형적인 퍼지 제어기보다 오프라인과 온라인 모두 우수한 성능과 유용성을 보이고 있음을 알 수 있

었다. 제안된 방법은 제어뿐만 아니라 패턴분류, 적응신호처리 등 여러 다양한 분야에 적용이 가능하리라 생각된다.

## 참 고 문 헌

- [1] J. A. K. Suykens, et al, Artificial Neural Networks for Modelling and Control of Non-Linear Systems, Kluwer Academic Publishers, Chap. 4, pp. 83~116, 1996.
- [2] K. M Passino, S. Yurkovich, Fuzzy Control, Addison Wesley, Chap. 2, pp. 21~110, 1997.
- [3] W. Pedrycz, "Conditional fuzzy clustering in the design of radial basis function neural networks," IEEE Trans. on Neural Networks, vol. 9, no. 4, pp. 601~612, 1998.
- [4] W. Pedrycz, "Fuzzy equalization in the construction of fuzzy sets", Fuzzy Sets and System, Vol. 2001, pp. 329~335, 2001.
- [5] J. S. R. Jang, C. T. Sun, E. Mizutani, Neuro-Fuzzy and Soft Computing : A Computational Approach to Learning and Machine Intelligence, Prentice Hall, Chap.17, pp. 453~479, 1997.
- [6] J. Tanomaru, S. Omatsu, "Process control by on-line trained neural controllers", IEEE Trans. Indust. Electrons, Vol. 39, pp. 511~521, 1992.
- [7] M. Khalid, S. Omatsu, "A neural network controller for a temperature control system", IEE Control Systems, pp. 58~64, 1992.
- [8] M. Khalid, S. Omatsu, "Temperature regulation with neural networks and alternative control schemes", IEEE Trans. on Neural Networks, Vol. 6, No. 3, 1995.
- [9] C. T. Lin, C. F. Juang, C. P. Li, "Water bath temperature control with a neural fuzzy inference network", Fuzzy Sets and Systems, Vol. 111, pp. 285~306, 2000.
- [10] L. A. Zadeh, "Probability Measures of fuzzy events," J. Math. Analysis and Application, Vol. 22, pp. 421~427, 1968.

## 저자소개



尹起厚(正會員)

1979년 : 충북대학교 전기공학과 졸업(공학사). 1982년 : 성균관대학교 대학원 전기공학과 졸업(공학석사). 1998년 8월 : 충북대학교 대학원 전자공학과 박사과정 수료  
 1989년 10월 ~ 1992년 2월 : 순천제일대학 전자과 전임강사. 1992년 3월 ~ 현재 : 주성대학 디지털정보제어공학과 부교수. <주관심분야 : 데이터통신 및 이동통신, 신호처리 등>



郭根昌(正會員)

1996년 : 충북대학교 전기공학과 졸업(공학사). 1998년 : 충북대학교 대학원 전기공학과 졸업(공학석사). 2002년 2월 : 충북대학교 전기공학과 졸업(공학박사). 2002년 3월 ~ 현재 : 충북대학교 BK21사업단 연구원. <주관심분야 : 지능시스템, 패턴분류, 생체인식>