

## EM 알고리즘에 의한 퍼지 규칙생성과 온도 제어 시스템의 설계 (A Fuzzy Rule Extraction by EM Algorithm and A Design of Temperature Control System)

오범진 · 박근창 · 유정웅\*

(Bum - Jin Oh · Keun - Chang Kwak · Jeong - Woong Ryu)

### 요 약

본 논문에서는 EM(Expectation-Maximization) 알고리즘을 이용한 자동적인 퍼지 규칙생성과 적응 뉴로-퍼지 제어기(Adaptive Neuro-Fuzzy Controller)의 설계를 제안한다. EM 알고리즘은 가우시안 혼합모델(Gaussian Mixture Model)의 최대우도추정(Maximum Likelihood Estimate)을 위해 사용되어지며 본 논문에서는 규칙생성을 위해 클러스터 중심을 추정한다. 추정된 클러스터는 ANFIS(Adaptive Neuro-Fuzzy Inference System)의 퍼지 규칙과 소속함수를 구축하는데 사용되어진다. 시뮬레이션으로 제안된 적응 뉴로-퍼지 제어기의 성능을 입증하기 위해 목욕물 온도 제어 시스템에 대해 다루고 기존 퍼지 제어기에 비해 적은 규칙의 수와 작은 값의 SAE(Sum of Absolute Error)으로 성능개선을 확인하였다.

### Abstract

This paper presents a fuzzy rule extraction method using EM(Expectation-Maximization) algorithm and a design method of adaptive neuro-fuzzy control. EM algorithm is used to estimate a maximum likelihood of a GMM(Gaussian Mixture Model) and cluster centers. The estimated clusters is used to automatically construct the fuzzy rules and membership functions for ANFIS(Adaptive Neuro-Fuzzy Inference System). Finally, we applied the proposed method to the water temperature control system and obtained better results with respect to the number of rules and SAE(Sum of Absolute Error) than previous techniques such as conventional fuzzy controller.

Key Words : Expectation-Maximization, Adaptive Neuro-Fuzzy Control, Gaussian Mixture Model, ANFIS

### 1. 서 론

전통적인 제어 이론은 보통 제어기를 설계하기 위

해 수학적 모델을 필요로 한다. 플랜트의 수학적 인 모델링의 부정확성은 특히 비선형이며 복잡한 제어 문제에 있어서 제어기의 성능을 악화시키고 있다. 전통적인 제어기술로는 쉽게 제어되지 않는 복잡하고 불확실하며 비선형성을 포함한 시스템에 대해 숙련가의 경험적 지식과 제어전문가의 지식의 정성적인 언어 형태를 이용한 퍼지 제어기(Fuzzy Controller)를 이용해서 쉽게 제어할 수 있다[1].

\* 주저자 : 충북대 전기전자 및 컴퓨터공학부 교수  
Tel : 043-261-2422, Fax : 043-261-3280  
E-mail : jwryu@vod.chungbuk.ac.kr  
접수일자 : 2002년 8월 17일  
1차심사 : 2002년 8월 21일  
심사완료 : 2002년 9월 4일

이러한 퍼지 제어기는 좋은 성능들을 보이고 있지만 설계한 제어기가 성능 시험에서 만족한 결과를 얻지 못할 경우 소속함수와 규칙들은 재조정되어지며 원하는 제어기 특성을 가지는 시스템이 되기 위해서 여러 번의 시행착오를 거쳐서 소속함수와 규칙이 선택되어진다[2]. 한편, 다른 방법으로 제어의 실현 가능성을 제시하기 위해 다층 퍼셉트론으로 이루어진 신경회로망을 근거로 한 신경 제어기(Neuro Controller)에 대한 연구가 진행되고 있다[3]. 신경회로망은 비선형 사상과 학습능력을 가진 지능적인 제어 시스템을 구축함에 있어 중요한 도구로서 사용되어져 왔다. 그러나 주된 단점은 학습속도가 느리며 오프라인에서 학습될 때 만족스런 결과를 얻기에는 오랜 시간을 소요해야만 한다.

이러한 문제점을 해결하기 위해 학습능력, 적응성, 결합극복능력을 가진 신경회로망과 인간의 사고과정에 포함된 애매함이나 불확실성을 극복하고 추론을 해내는 근사 추론능력을 모사하는 퍼지 규칙을 가진 퍼지 시스템을 융합한 적응 뉴로-퍼지 제어기(Adaptive Neuro-Fuzzy Controller)가 활발히 연구되어지고 있다[4]. 그러나 이러한 연구들은 입력공간을 그리드 분할하기 때문에 많은 규칙의 수가 필요하며 다변수 입력일 경우에는 규칙의 수가 지수적으로 증가하는 단점을 가지고 있다.

따라서, 본 논문에서는 입력공간을 스캐터 분할하여 적은 규칙으로도 좋은 성능을 보이기 위해 EM(Expectation-Maximization) 알고리즘[5]이 사용된다. 여기서 EM 알고리즘은 GMM(Gaussian Mixture Model)의 최대우도추정(Maximum Likelihood Estimate)을 위해 사용되어지며 본 논문에서는 클러스터 중심을 추정한다. 여기서 추정된 클러스터는 ANFIS(Adaptive Neuro-Fuzzy Inference System)[6]의 퍼지 규칙과 소속함수를 구축하는데 사용되어진다. 이렇게 함으로서 수치적인 데이터로부터 자동적인 퍼지 규칙생성과 적은 규칙으로도 좋은 제어기 성능을 보일 수 있다. 시뮬레이션으로 제안된 적응 뉴로-퍼지 제어기의 성능을 입증하기 위해 목욕물 온도 제어 시스템[7]에 대해 다루고 기존 퍼지 제어기에 비해 적은 규칙의 수와 작은 값의 SAE(Sum of Absolute Error)으로 성능개선을 확인하였다.

## 2. EM 기반 적응 뉴로-퍼지 제어기

제안된 제어기를 구축하기 위해서는 두 가지 동정 과정인 구조동정(Structure Identification)과 파라미터 동정(Parameter Identification)이 필요하다. 구조동정은 소속함수와 퍼지 규칙의 생성에 관련되어지고 파라미터 동정은 전제부 및 결론부 파라미터의 조정에 관련되어진다.

먼저 구조동정에 수행하기 위한 과정을 살펴보면 다음과 같다. GMM에서 확률밀도함수는 식(1)에 의해 주어진다.

$$p(x|\Phi) = \sum_{j=1}^c p(x|w_j, \Phi)P(w_j) \quad (1)$$

여기서  $w_j$ 는 성분들이고,  $P(w_j)$ 는 그것들의 사전 확률 혹은 혼합 파라미터들이다. 또한,  $c$ 는 가우시안 혼합의 수이며 본 논문에서는 클러스터 수와 같다. 그리고  $p(x|w_j, \Phi)$ 는 파라미터  $\Phi$ 의 벡터가 알려졌을 때 성분 밀도이다. 때때로  $\Phi$ 는 또한  $P(w_j)$ 를 포함한다. 샘플  $X = \{x_k\}_k^N$ 의 log 우도는 식(2)와 같다.

$$\begin{aligned} L(\Phi|x) &= \sum_k \log p(x_k|\Phi) \\ &= \sum_k \log \sum_j p(x_k|w_j, \Phi)P(w_j) \end{aligned} \quad (2)$$

이 식은 직접적인 해를 가지지 못한다. 따라서, EM(Expectation-Maximization) 알고리즘의 두 단계를 이용하여 위 문제를 해결할 수 있다.

여기서 결과만을 살펴보면, 먼저 E-단계에서 사후 확률을 식(3)과 같이 계산한다.

$$P(w_j|x_k, \Phi) = \frac{p(x_k|w_j, \Phi)P(w_j)}{\sum_l p(x_k|w_l, \Phi)P(w_l)} \equiv h_{kj} \quad (3)$$

만약 성분밀도가 d-변량 가우시안이 되도록 선택하면,  $p(x|w_j, \Phi) \sim N_d(\mu_j, \Sigma_j)$ 은 식(4)와 같다.

$$p(x|w_j, \Phi) = \frac{1}{(2\pi)^{d/2} |\Sigma_j|^{1/2}} \exp\left[-\frac{1}{2}(x-\mu_j)^T \Sigma_j^{-1}(x-\mu_j)\right] \quad (4)$$

EM 알고리즘에 의한 퍼지 규칙생성과 온도 제어 시스템의 설계

그러면 식(3)은 식(5)로 표현되어질 수 있다.

$$h_{kj} = \frac{g_j |\Sigma_j|^{-1/2} \exp\left[-\frac{1}{2}(x_k - \mu_j)^T \Sigma_j^{-1} (x_k - \mu_j)\right]}{\sum_l g_l |\Sigma_l|^{-1/2} \exp\left[-\frac{1}{2}(x_k - \mu_l)^T \Sigma_l^{-1} (x_k - \mu_l)\right]} \quad (5)$$

단,  $g_j \equiv P(w_j)$

다음으로 M-단계는 성분 파라미터  $\theta$ 를 갱신한다.

$$\mu_j = \frac{\sum_k h_{kj} x_k}{\sum_k h_{kj}} \quad (6)$$

$$\Sigma_j = \frac{\sum_k h_{kj} (x_k - \mu_j)(x_k - \mu_j)^T}{\sum_k h_{kj}} \quad (7)$$

$$g_j = \frac{1}{n} \sum_k h_{kj} \quad (8)$$

벡터 양자화를 위해 사용되어질 때, 평균  $\mu_j$ 은 기준 벡터(혹은 클러스터 중심)에 대응된다.  $h_{kj}$ 는  $x_k$ 가 성분  $j$ 에 의해 발생되어지는 사후 확률이다. 여기서 초기 클러스터 중심은 Bezdek[8]에 의해 제안된 FCM(Fuzzy C-Means) 클러스터링이 적용되고 EM 알고리즘을 통해 최종적인 클러스터 중심을 얻는다.

FCM 클러스터링에 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(9)을 이용하여 각각의 클러스터 중심  $c_i^{(p)}(i=1, 2, \dots, c)$ 를 계산한다.

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (9)$$

[단계4]  $c^{(p)}$ 와 식(10)을 이용하여 다음 번 분할 행렬  $U^{(p+1)}$ 을 구한다.

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{kj}}\right)^{2/(m-1)}} \quad (10)$$

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

$$J = \sum_{j=1}^n \sum_{i=1}^c u_{ij}^m \|x_j - c_i\|^2 \quad (11)$$

따라서, 최종적으로 얻어진 각 클러스터는 시스템의 특성을 기술하는 TSK(Takagi-Sugeno-Kang) 형태의 퍼지 규칙으로 다음과 같이 나타내어진다.

$$R^i = \text{If } x \text{ is } A_i \text{ and } y \text{ is } B_i \\ \text{then } f_i = p_i x + q_i y + r_i \quad (12)$$

여기서  $x$ 와  $y$ 는 입력이고  $A_i, B_i$ 는 언어적인 레벨이며 소속함수는 식(13)과 같은 가우시안 소속함수를 사용한다.

$$\mu_{A_i}(x) = \exp\left\{-\left(\frac{x - c_i}{a_i}\right)^2\right\} \quad (13)$$

여기서  $\{a_i, c_i\}$ 는 전제부 파라미터이며,  $a_i$ 는 소속함수의 폭이고  $c_i$ 는 소속함수의 중심이다. 초기 폭인  $a_i$ 는 Yager[9]에 의해 사용된 식(14)으로 표현되어진다.

$$a_i = \sqrt{\frac{1}{2\beta}} \quad (14)$$

여기서  $\beta = \frac{4}{r}$  이고  $r$ 는 양의 수이다.

$\{p_i, q_i, r_i\}$ 는 결론부 파라미터는 식(15)와 같이 RLSE(Recursive Least Square Estimate)에 추정되어진다[6].

$$\theta_{i+1} = \theta_i + S_{i+1} a_{i+1} (b_{i+1}^T - a_{i+1}^T \theta_i)$$

$$S_{i+1} = S_i - \frac{S_i a_{i+1} a_{i+1}^T S_i}{1 + a_{i+1}^T S_i a_{i+1}} \quad i = 0, 1, \dots, P-1$$

$$\theta^* = \theta_p \quad (15)$$

여기서  $\theta_0 = 0$  이고  $S_0 = \lambda I$ 에서  $\lambda$ 는 양의 큰 수 이고  $I$ 는 항등 행렬이고  $\theta^*$ 는 추정하고자 하는 결론 부 파라미터이다. 그림 1은 EM 기반 뉴로-퍼지 제어를 보여주고 있으며 점선 영역은 EM 알고리즘에 의해 최종적으로 얻어진 가우시안 소속함수를 배치 하면 된다.




그림 1. 제안된 EM 기반 뉴로-퍼지 제어기  
Fig. 1. The proposed EM-based Neuro-Fuzzy Controller

### 3. 시뮬레이션 및 결과

본 논문에서 제안된 뉴로-퍼지 제어를 이용하여 목욕물 온도 제어 시스템에 대해 다루고자 한다. 여기서 다룬 시스템은 Yamato Science Inc. laboratory[6]에서 BP-5 model을 사용하였으며 이 제어 시스템의 목적은 목욕물 온도를 25~80℃사이의 특정 온도로 유지하도록 온 라인 제어를 구축하는 것이다. 제어하고자 하는 플랜트는 식(16)과 같이 표현되어진다.

$$y(k+1) = a(T_s)y(k) + \frac{b(T_s)}{1 + e^{0.5y(k)-r}} u(k) + [1 - a(T_s)]Y_0 \quad (16)$$

$$a(T_s) = e^{-aT_s} \quad (17)$$

$$b(T_s) = (\beta/a)(1 - e^{-aT_s}) \quad (18)$$

여기서 플랜트의 파라미터는  $\alpha = 1.00151e^{-4}$ ,  $\beta = 8.67973e^{-3}$ ,  $\gamma = 40$ ,  $Y_0 = 25^\circ\text{C}$ 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 온-라인 적응 뉴로-퍼지 제어를 설계하기 위해 기준 신호는  $0 \leq t \leq 40$ 분에 35℃,  $40 \leq t \leq 80$ 분에 50℃,  $80 \leq t \leq 120$ 분에 65℃,  $120 \leq t \leq 180$ 분에 80℃이다.

제안된 뉴로-퍼지 시스템을 이용하여 제어를 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(19)와 같이 표현되어질 수 있다.

$$x(k+1) = f(x(k), u(k)) \quad (19)$$

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(20)과 같이 표현되어진다.

$$x(k+2) = f(x(k+1), u(k+1)) = f(f(x(k), u(k)), u(k+1)) \quad (20)$$

일반적으로 플랜트의 차수가  $n$ 차라면 식(21)과 같이 표현되어진다.

$$x(k+n) = F(x(k), U) \quad (21)$$

여기서  $F$ 는  $f$ 의 합성함수이며  $U$ 는  $[u(k), u(k+1), \dots, u(k+n-1)]$ 의 제어신호이다. 플랜트의 역 동역학이 존재한다고 가정하면  $U$ 는  $x(k)$ 와  $x(k+n)$ 의 함수로서 식(22)와 같이 표현

EM 알고리즘에 의한 퍼지 규칙생성과 온도 제어 시스템의 설계

된다.

$$U = G(x(k), x(k+n)) \quad (22)$$

역사상(inverse mapping)  $G$ 가 존재한다 할지라도 항상 분석적인 형태를 가지지 못하기 때문에 식(23)과 같은 학습 데이터에 의해 역사상  $G$ 를 근사화하기 위해  $2n$ 개의 입력과  $n$ 개의 출력을 가지는 뉴로-퍼지 시스템을 구축한다.

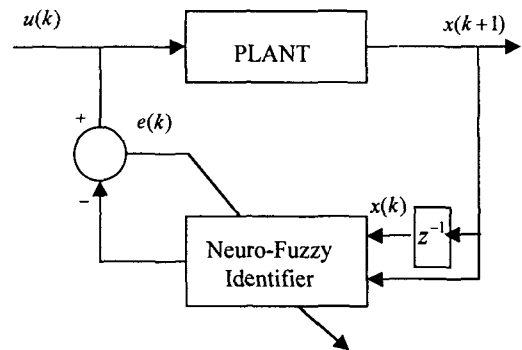
$$[x(k)^T, x(k+n)^T; U^T] \quad (23)$$

그림 2는  $n=1$ 일 때 각각 플랜트, 학습단계와 응용단계의 블록 다이어그램을 나타내고 있다. 그림 2(a)는 플랜트 출력  $x(k+1)$ 은 이전 상태인  $x(k)$ 와 입력  $u(k)$ 의 함수인 플랜트 블록을 보여주고 있다. 여기서  $z^{-1}$ 은 단위 시간 지연을 나타내는 블록이다. 그림 2(b)는 학습 단계동안 블록 다이어그램이고 그림 2(c)는 응용 단계동안 블록 다이어그램이다.


뉴로-퍼지 제어기는 현 상태  $x(k)$ 와 원하는 미래 상태  $x_d(k+n)$ 가 주어지면 식(24)와 같이 추정된  $\hat{U}$ 를 발생시켜준다.

$$\hat{U} = \hat{G}(x(k), x_d(k+n)) \quad (24)$$

우선 첫 단계인 학습 단계에서 뉴로-퍼지 식별기를 구축하기 위해 학습 데이터는 식(23)을 이용하여  $[y(k), y(k+1): u(k)]$  형태의 50개 학습 데이터를 얻었다. 클러스터 수를 증가함에 따라 6개인 경우에 제일 좋은 초기 성능을 보였으며 그림 3은 입력 데



(b) Training phase



(c) Application phase

그림 2. 역 학습방법을 위한 블록 다이어그램  
Fig. 2. Block diagram for the inverse learning method





그림 3. 입력 데이터분포와 추정된 클러스터들  
Fig. 3. Input data distribution and estimated clusters



(a) plant block

이터 분포와 EM 알고리즘에 의해 얻어진 클러스터 중심을 나타내고 있다. 또한 그림 4는 데이터 분포에 따른 밀도를 컨투어로 나타내고 있다. 그림 5는 실제 출력과 뉴로-퍼지 식별기의 추론 값의 결과를 보여주고 있다. 그림에서 알 수 있듯이 원하는 출력 값

을 잘 추종하고 있음을 알 수 있다.




그림 4. 입력데이터에 대한 밀도  
Fig. 4. Density for input data

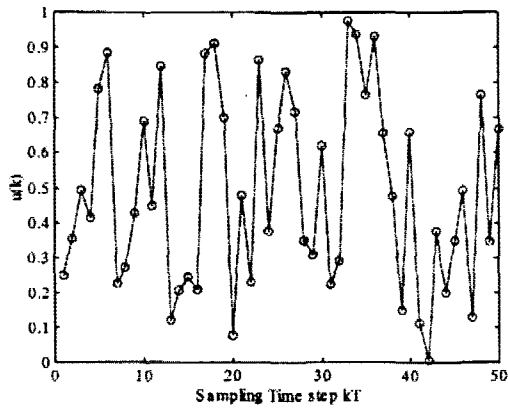


그림 5. 제안된 뉴로-퍼지 식별기에 대한 학습 결과  
Fig. 5. Result of learning by the proposed method

그림 2(b)와 같이 얻어진 뉴로-퍼지 식별기를 그림 2(c)의 뉴로-퍼지 제어기로 수행하여 시뮬레이션 한 결과 그림 6과 같이 원하는 기준 온도를 잘 추종하고 있음을 알 수 있다. 그림 7는 뉴로-퍼지 제어기에서 추론된 제어 신호  $u$ 를 나타내고 있다. 여기서 추론된  $u$ 값은 0에서 5의 값으로 제한하였다. 이때 100epoch 까지 학습하여 얻어진 전제부 소속함수와 결론부 파라미터를 그림 8과 표 1에 나타내었다.

제안된 방법과 비교를 위해 기존의 퍼지 제어기를 이용하여 적용할 경우 Mamdani 형태의 제어기로 그림 9와 같이 각 입력과 출력변수를 7개의 소속함수로

분할하였으며, 표2와 같이 25개의 퍼지 규칙을 사용하였다. 그림 10과 11은 각각 원하는 기준온도의 추정과 제어 입력에 대해서 나타내고 있으며 그림에서 알 수 있듯이 채터링 현상이 일어남을 볼 수 있었다.

표 3에서 온수 제어에 대한 결과로 온도 추종 성능을 정량적으로 표현하기 위해 절대오차의 합인 SAE(Sum of Absolute Error)와 퍼지 규칙의 수를 살펴보면 제안된 EM 기반 뉴로-퍼지 제어기는 적은 규칙으로도 퍼지 제어기에 비해 좋은 성능을 보임을 알 수 있었다.




그림 6. 오프 라인 역 학습에 대한 성능(제안된 제어기)  
(... : 기준신호, — : 플랜트 출력)

Fig. 6. Regulation performance for off-line inverse learning (the proposed controller)  
(... : Reference signal, — : Plant output)






그림 7. 제안된 뉴로-퍼지제어기에 의해 얻어진 제어 입력  
Fig. 7. Control input obtained by the proposed neuro-fuzzy controller

EM 알고리즘에 의한 퍼지 규칙생성과 온도 제어 시스템의 설계



(a) 입력  $y(k)$ 에 대한 소속함수



(b) 입력  $y(k+1)$ 에 대한 소속함수

그림 8. 학습에 의해 얻어진 전제부 소속함수  
Fig. 8. Premise membership function obtained by hybrid learning

표 1. 학습에 의해 얻어진 결론부 파라미터  
Table 1. Consequent parameters obtained by hybrid learning

	$p$	$q$	$r$
$R^1$	4.63	-4.643	0.5684
$R^2$	4.464	-4.54	3.552
$R^3$	4.60	-4.596	-0.1308
$R^4$	4.774	-4.825	4.019
$R^5$	4.435	-4.312	-6.778
$R^6$	4.931	-4.803	-9.339




그림 9. 입력변수와 출력변수에 대한 소속함수  
Fig. 9. Membership function for the input and output variable

표 2. 기존 퍼지 제어기의 퍼지 규칙  
Table 2. Fuzzy rules of conventional fuzzy controller

		Error, e(t)						
		NL	NM	NS	ZE	PS	PM	PL
Chang error c(t)	PL				PL	PL	PL	PL
	PM				PM	PM	PM	PL
	PS			PS	PS	PS	PM	PL
	ZE	NL	NM	NS	ZE	PS	PM	PL
	NS			NS	NS	NS		
	NM				NM			
	NL				NL			




그림 10. 오프 라인 역 학습에 대한 성능  
Fig. 10. Regulation performance for off-line inverse learning (fuzzy controller)




그림 11. 기존 퍼지제어기에 의해 얻어진 제어입력  
Fig. 11. Control input produced by conventional fuzzy controller

표 3. 제안된 제어기의 성능비교  
Table 3. Performance comparison of the proposed controller

	제안된 시스템	기존 퍼지 시스템
SAE	162.5	206.4
퍼지 규칙의 수	6개	25개

### 5. 결론

본 논문에서는 EM 알고리즘을 이용한 자동적인 퍼지 규칙생성과 적응 뉴로-퍼지 제어기의 설계 방법을 제안하였다. EM 알고리즘은 가우시안 혼합모델의 최대우도추정을 위해 사용되어지며 본 논문에서는 규칙생성을 위해 클러스터 중심을 추정하였다. 표 3에서 알 수 있는 바와 같이 기존 퍼지 제어기는 입력 공간을 그리드 분할하기 때문에 25개의 규칙이 생성되는 반면 제안된 방법은 클러스터링 기법을 사용하기 때문에 6개의 적은 규칙이 사용되었으며 절대오차의 합인 SAE가 작은 값을 보이며서 원하는 온도에 추정함을 알 수 있었다. 본 논문에서 제안된 방법은 수치적인 입출력데이터로부터 자동적인 퍼지 규칙을 생성할 수 있으므로 퍼지 시스템, 뉴로-퍼지 시스템을 구축할 때 유용하게 사용되어질 수 있다. 또한 제

조명 · 전기설비학회논문지 제16권 제5호, 2002년 9월

어뿐만 아니라 비선형 시스템 모델링, 패턴분류, 데이터 마이닝, 시계열 예측 등에 적용되어질 수 있다.

### Reference

- (1) M. Sugeno, T. Yasukawa, "A fuzzy-logic based approach to qualitative modeling", IEEE Trans. on Fuzzy Systems, Vol. 3, No. 1, pp. 7-31, 1993.
- (2) K. M. Passino, S. Yurkovich, Fuzzy Control, Addison Wesley, 1997.
- (3) J. A. K. Suykens, et al, Artificial Neural Networks for Modelling and Control of Non-Linear Systems, Kluwer Academic Publishers, 1996.
- (4) J. S. R. Jang, C. T. Sun, E. Mizutani, Neuro-Fuzzy and Soft Computing : A Computational Approach to Learning and Machine Intelligence, Prentice Hall, 1997.
- (5) E. Alpaydin, "Soft vector quantization and the EM algorithm", Neural Networks, Vol. 11, pp. 467-477, 1998.
- (6) J. S. R. Jang, ANFIS: Adaptive-Networks-based Fuzzy Inference System", IEEE Trans. on System, Man, and Cybern., Vol. 23, No. 3, pp. 665-685, 1993.
- (7) 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.
- (8) J. Bezdek, R. Hathaway, M. Sabin and W. Tucker, Convergence Theory for Fuzzy C-Means : Counter Examples and Repairs, CRC Press, Chap. 8, 1987.
- (9) R. R. Yager, D. P. Filev, "Generation of fuzzy rules by mountain clustering", Journal of Intelligent and fuzzy system", Vol. 2, pp. 209-219, 1994.

### ◇ 저자소개 ◇

#### 오 범 진 (吳範鎭)

1953년 12월 18일생, 1982년 숭실대학교 전기공학과 졸업, 1984년 동대학원 전기공학과 졸업(석사), 2001년 충북대학교 전기공학과 박사수료, 1984년~현재 국립한밭대학교 전자공학과 겸임교수.

#### 곽 근 창 (郭根昌)

1971년 6월 23일생, 1996년 충북대학교 전기공학과 졸업, 1998년 동대학원 전기공학과 졸업(석사), 2002년 동대학원 전기공학과 졸업(박사), 2002년~현재 충북대학교 BK21사업단 연구원.

#### 유 정 웅 (柳正雄)

1941년 1월 20일생, 1965년 한양대학교 전기공학과 졸업, 1976년 단국대학교 전기공학과 졸업(석사), 1987년 동대학원 전자공학과 졸업(박사), 1979년~현재 충북대학교 전기전자및컴퓨터공학과 교수.