

CFCM과 퍼지 균등화를 이용한 퍼지 규칙의 자동 생성

An Automatic Fuzzy Rule Extraction using CFCM and Fuzzy Equalization Method

곽근창 · 이대종 · 유정웅 · 전명근

Keun-Chang Kwak, Dae-Jong Lee, Jeong-Woong Ryu and Myung-Geun Chun

충북대학교 전기전자공학부

요 약

본 논문에서는 여러 분야에서 널리 응용되고 있는 적응 뉴로-퍼지 시스템(ANFIS)에서의 효과적인 퍼지 규칙 생성 방법을 제안한다. 기존의 입력공간 그리드 분할을 이용한 ANFIS의 규칙 생성에 있어서는 얻어진 규칙의 수가 지수적으로 증가하는 단점이 있다. 이에, 본 연구에서는 조건부적인 FCM을 이용하여 입·출력 데이터의 특성을 잘 반영할 수 있는 클러스터를 구하고, 퍼지 균등화 방법을 적용하여 출력변수의 소속함수를 자동 생성하도록 하였다. 이렇게 함으로서 적은 규칙 수를 갖으면서도 효율적인 퍼지 규칙을 얻을 수 있도록 하였다. 이들 방법의 유용함을 보이하고자 트럭 후진제어와 Box-Jenkins의 가스료 데이터의 모델링에 적용하여 제안된 방법이 이전의 연구보다 좋은 결과를 보임을 알 수 있었다.

ABSTRACT

In this paper, an efficient fuzzy rule generation scheme for Adaptive Network-based Fuzzy Inference System(ANFIS) using the conditional fuzzyc-means(CFCM) and fuzzy equalization(FE) methods is proposed. Usually, the number of fuzzy rules exponentially increases by applying the grid partitioning of the input space, in conventional ANFIS approaches. Therefore, CFCM method is adopted to render the clusters which represent the given input and output fuzzy data and FE method is used to automatically construct the fuzzy membership functions. From this, one can systematically obtain a small size of fuzzy rules which shows satisfying performance for the given problems. Finally, we applied the proposed method to the truck backer-upper control and Box-Jenkins modeling problems and obtained a better performance than previous works.

1. 서 론

퍼지논리를 이용하여 주어진 시스템을 모델링하거나, 대상 플랜트가 원하는 동작을 하도록 제어를 하는 경우에, 가장 널리 쓰이는 방법은 모델링이나 제어대상에 대하여 가장 잘 알고 있는 전문가로부터 얻어진 경험적 지식을 이용해서 퍼지 규칙과 여기에 사용되는 소속함수를 결정하는 접근방법이 널리 쓰이고 있다[1]. 그러나 전문가의 지식은 적지 않은 경우 일관성이 없고 때론 불완전하며, 또한 인간의 직관과 경험에 의존하여 퍼지규칙을 획득하는 경우에 체계적이고 효율적인 방법이 없기 때문에 여러 가지 어려움을 겪고 있다.

이런 문제점을 해결하기 위해 수치적인 학습 데이터에 근거한 규칙 생성을 자동화하도록 다양한 연구가 시도되어 왔다. 대부분의 이러한 연구들은 인간의

사고과정에 포함된 애매함이나 불확실성을 극복하고 추론을 해내는 근사추론 능력을 모사하는 if-then 퍼지규칙을 가진 퍼지 시스템과 학습능력, 적응성, 병렬 처리 능력과 같은 뇌의 기능을 모사한 인공 신경회로 망과의 융합인 뉴로-퍼지 시스템에 기초하고 있다[2,3].

이러한 뉴로-퍼지 시스템을 이용한 대상시스템의 모델링을 시스템 동정(system identification)의 관점에서 보면, 구조동정(structure identification)과 파라미터 동정(parameter identification)을 포함하고 있다. 일반적으로 전달함수를 이용하여 시스템을 동정하는 경우 구조동정은 전달함수의 분모와 분자의 차수를 결정하는 문제이고 파라미터 동정은 각 분모와 분자에 해당되는 다항식의 계수를 구하는 문제에 해당된다. 뉴로-퍼지 시스템에서의 구조동정은 적당한 규칙과 소속함수의 수, 입력공간분할과 관련되어지고, 다른 한편으로, 파라미터 동정은 전제부 및 결론부 파라미터의 조정

이 논문은 정보통신부의 “정보통신 우수시범학교 지원사업”으로 연구되었습니다.

과 관련되어진다. 그러나 구조동정에 대한 체계적인 방법이 없으므로 실제적인 문제에 적용하는 경우 많은 문제점을 발생시키고 있다[4]. 현재 널리 쓰이고 있는 입력 공간 분할 방법은 그리드분할, 트리분할, 스캐터 분할방법 등이 있다. 그리드분할 방법은 가장 직접적인 방법이지만 입력공간의 수가 증가할 때 규칙의 수가 지수적으로 증가하는 문제점을 가지고 있다[5,6]. 또한, 트리분할은 각각의 영역에 대응하는 결정트리에 따라 특정화되도록 입력공간을 분할하지만 그리드분할과 마찬가지로의 문제점을 가지고 있다[7,8]. 또 다른 자주 사용되는 스캐터분할은 출력패턴의 성질을 고려하지 않고 입력 데이터에 의해 클러스터가 생성되기 때문에 데이터 사이의 유사성에 문제점이 발생할 수 있다[9,10].

따라서, 본 논문에서는 입력데이터의 성질과 출력패턴의 성질까지도 고려한 적응적인 스캐터 분할에 근거한 퍼지 클러스터링 기법 가운데 하나인 CFCM (Conditional Fuzzy C-Means)[11,12]와 퍼지 균등화 (Fuzzy Equalization)[13] 방법을 이용하여 Jang[5]에 의해 제안된 적응 네트워크 기반 퍼지 추론 시스템 (ANFIS)에서의 퍼지규칙의 자동추출에 대하여 다룬다. 여기서, 기존의 CFCM에서는 출력변수의 소속함수를 균등하게 분포시켜 생성하였지만 본 논문에서는 확률적인 방법에 근거한 퍼지 균등화방법을 이용하여 자동으로 생성하도록 하였다. 이렇게 함으로서 ANFIS에서 입력공간의 그리드 분할로 인해 규칙의 수가 지수 함수적으로 증가하는 문제점을 해결할 수 있다.

이렇게 제안된 방법을 트릭 후진 제어[14-16]와 Box-Jenkins의 가스로 데이터의 모델링[17-21]에 적용하여 이전에 연구된 방법들에 비하여 좋은 결과를 얻음을 보이고자 한다.

2. CFCM 과 퍼지 균등화를 이용한 효과적 퍼지 규칙 생성

2.1 뉴로-퍼지 시스템의 구조동정

본 단원에서는 CFCM(Conditional Fuzzy C-Means) 과 퍼지 균등화 방법을 이용한 ANFIS에서의 퍼지 규칙과 소속함수의 수를 결정하는 구조동정에 대하여 다루고자 한다.

먼저, 퍼지 균등화는 임의의 전체공간 X 가 주어졌고 이 공간상에서 취득된 수치데이터가 있을 경우, 이들로부터 확률분포 함수를 구한 후 전체공간 X 에서 이들을 적절히 표현할 수 있는 소속함수들을 원하는 개수만큼 체계적으로 만들어 낼 수 있는 기법으로 Pedrycz[11]에 의해 소개되었다.

이러한 퍼지 균등화 이론은 Zadeh교수에 의해 정의된 퍼지 사건[22]의 개념에 기인한다. 기존의 확률개념에서 사용되는 사건(crisp event)의 개념에서는 A 라는 사건과 이의 확률분포함수 $p(x)$ 가 주어졌을 경우 사건 A 의 확률은 다음과 같이 구해진다.

$$P(A) = \int_A p(x)dx \tag{1}$$

그러나, 만약 사건 A 에 대하여 확률분포함수 $p(x)$ 와 더불어 가능성함수(소속함수) $A(x)$ 값이 주어진 퍼지 사건일 경우의 확률은 아래와 같이 주어진다.

$$P(A) = \int_X A(x)p(x)dx \tag{2}$$

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 다음과 같이 각각의 퍼지사건의 확률이 같도록 아래와 같이 균등화하는 방법이다[13].

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

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

위의 개념을 역으로 이용하면, 원하는 소속함수의 갯수 G 와 확률분포함수 $p(x)$ 가 주어져 있을 경우 소속함수를 정할 수 있다. 본 논문에서는 퍼지 응용에 널리 쓰이는 삼각퍼지 함수 모양을 사용하고, 좌우의 소속함수와 1/2씩 겹치도록 하는 경우에 다음과 같이 퍼지 균등화기법을 이용하여 소속함수를 자동으로 만들어 내었다.




그림 1. 퍼지 균등화의 해석
Fig. 1. The idea of fuzzy equalization

[단계 1] A 에서 언어 변수의 갯수 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)과 같이 진행한다.

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

이 적분 값이 $1/2G$ 에 도달하면 멈추고 그 값을 a 라 한다.

[단계 4] 소속함수의 감소 부분에 퍼지 사건의 확률이 식(5)와 같도록 A_1 의 지지 상한경계인 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)와 같이 퍼지 사건의 확률을 계산한다.

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

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

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

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

한편, CFCM은 Pedrycz[11,12]에 의해 제안된 방법으로 입력공간에서의 데이터뿐만 아니라 출력변수의 유사성에 관련된 패턴들의 동질성을 유지하도록 클러스터를 생성하는 퍼지 클러스터링 기법이다.





그림 2. 퍼지 균등화의 개념
Fig. 2. The concept of fuzzy equalization

그림 3(a)와 (b)는 입력공간 $x = [x_1, x_2]$ 에서 출력 데이터의 두 가지 패턴(흑, 백)에 대해 FCM[9]과 CFCM의 클러스터 추정을 보여주고 있다. 그림 3(a)는 전형적인 클러스터링 방법으로 출력 패턴의 성질을 고려하지 않고 단지 클러스터 중심과 입력 데이터 사이의 유클리디언 거리를 사용해 두 개의 클러스터를 형성한다. 반면에 CFCM은 그림 3(b)에서 알 수 있듯이 각 데이터가 분류된 것을 통하여 알 수 있듯이 입력 데이터의 성질뿐만 아니라 출력 패턴의 성질까지도 고려하기 때문에 최종적으로 세 개의 클러스터로 형성한다. 이를 정성적인 관점에서 보면 CFCM으로 얻어진 클러스터는 FCM에 의해 얻어진 클러스터보다 각각의 클러스터가 포함하는 데이터 사이의 유사성이 훨씬 좋을 수 있다. CFCM에 대해 간략히 기술하면 다음과 같다.


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

[단계 2] 초기 분할 행렬 $U^{(0)}$ 와 역치 ϵ 를 설정하고 반복 지수 0에서 p 까지 정한다. 여기서 $U = [u_{ij}]_{i=1 \dots c, j=1 \dots n}$

[단계 3] $U(p)$ 와 식(8)을 이용하여 각각의 클러스터



(a) clusters in x_1-x_2 space



(b) clusters in x_1-x_2 space in with a conditional variable involved

그림 3. FCM과 CFCM에서 클러스터 비교
Fig. 3. The Comparison of clusters in FCM and CFCM

중심 $c_i^{(p)}(i=1, 2, \dots, c)$ 를 계산한다.

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

[단계 4] $c_i^{(p)}$ 와 식(9)을 이용하여 다음 번 분할 행렬 $U^{(p+1)}$ 을 구한다.

$$u_{ij} = \frac{f_j}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{kj}}\right)^{2/(m-1)}} \quad (9)$$

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 표현되어진다. 이것은 퍼지 균등화 알고리즘에 의해 계산되어진다.

그러면 $f_j = A(y_j), j=1, 2, \dots, n$ 은 A 에서 y_j 의 속속도로 표현된다.

[단계 5] $\|J^{(p)} - J^{(p+1)}\| \leq \epsilon$ 이 만족한다면 멈추고, 그렇지 않으면 [단계3]로 가서 $p=p+1$ 로 설정한다.

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

2.2 뉴로-퍼지 시스템의 파라미터 동정

구조식별이 CFCM과 퍼지 균등화에 의해 결정된 후에 파라미터 동정은 Jang[5]의 방법과 같이 최소자승법(Least Square Estimate)과 역전파 알고리즘(Back Propagation)을 이용한 하이브리드 학습에 의해 수행되어진다. 여기서 ANFIS 모델링과 학습 메카니즘을 간략히 살펴보자[24]. 먼저 아래와 같은 두 개의 Sugeno-Takagi 형태의 퍼지 규칙을 갖는 추론시스템에 대해 생각해보자.


$$\begin{aligned} R^1: & \text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1x + q_1y + r_1 \\ R^2: & \text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f_2 = p_2x + q_2y + r_2 \end{aligned} \quad (11)$$

여기서 x 와 y 는 입력이고 A_i, B_i 는 언어적 변수이며 $\{p_i, q_i, r_i\}$ 는 결론부 파라미터이다. 위와 같은 규칙에 대해 적응네트워크 기반 퍼지 시스템의 구조는 그림 4와 같이 나타낼 수 있다.


위와 같은 적응네트워크 기반 퍼지 시스템에 대하여 학습절차는 다음과 같다.

먼저, 전체부 소속함수로 다음과 같은 가우시안 소속함수를 선택하였다.

$$\mu_{A_i}(x) = \exp\left\{-\left(\frac{x-c_i}{a_i}\right)^2\right\} \quad (12)$$



(a) Fuzzy reasoning



(b) Equivalent ANFIS (type-3 ANFIS)

그림 4. Sugeno-Takagi의 추론시스템과 ANFIS의 구조
Fig. 4. Sugeno-Takagi Fuzzy Reasoning Process and ANFIS

여기서 $\{a_i, c_i\}$ 는 전제부 파라미터이며, a_i 는 소속함수의 폭이고 c_i 는 소속함수의 중심이다. 전제부 파라미터에 관한 학습 알고리즘을 위해 유도하기 위해 최소화하기 위한 목적함수는 다음과 같다.

$$E = \frac{1}{2}(y^* - y_d)^2 \tag{13}$$

여기서 y_d 는 입력벡터 $x = [x, y]^T$ 에 대한 원하는 데이터 출력이고 y^* 는 퍼지 모델의 출력이다. 소속함수의 모양이 전제부 파라미터에 의해 정의되어지기 때문에 목적함수 E 는 결론부 파라미터가 고정된다면 $\{a_i, c_i\}$ 의 파라미터로 결정되어진다. 목적함수 E 의 값을 감소시키기 위해서는 전제부 파라미터에 대해서 아래와 같이 최대경사법에 의해 반복적으로 이루어진다.

$$a_i^j(t+1) = a_i^j(t) - \eta \frac{\partial E}{\partial a_i^j}$$

$$c_i^j(t+1) = c_i^j(t) - \eta \frac{\partial E}{\partial c_i^j} \tag{14}$$

다른 한편으로, 결론부 파라미터는 최소자승법에 의해 추정되어진다.

정리하면, 전방향 경로에서는 최소자승법으로 후방향 경로에서는 역전과 알고리즘으로 전제부 및 결론부 파라미터를 조정하여 실제 데이터 출력과 퍼지모델 출력사이의 오차를 최소화하는 것이다.

3. 시뮬레이션 및 결과

본 논문에서 제안된 CFCM과 퍼지 균등화에 근거한 ANFIS를 이용하여 트럭 후진제어와 Box-Jenkins의 가스르 데이터의 모델링에 적용하여 이전에 연구된 방법들에 비하여 보다 나은 결과를 얻을 수 있음을 보이고자 한다.

3.1 트럭 후진 제어

트럭 후진 제어문제는 비선형 문제를 신경회로망이나 퍼지 시스템과 같은 지능 시스템을 이용하여 성공적으로 제어할 수 있는 대표적인 예라고 할 수 있다. Nguyen와 Widrow[14]은 다층신경회로망으로 이루어져 있는 제어기와 에뮬레이터 네트워크를 가지고 트럭 후진 제어 문제를 해결할 수 있다는 것을 보여주었다. 제어기 네트워크는 트럭의 현재 위치에 대해 원하는 조향각을 출력하고, 이와 직렬로 연결되어 있는 에뮬레이터 네트워크는 제어기 네트워크로부터 조향

각이 주어지면 이를 이용하여 트럭을 일정한 거리만큼 후진시키는 역할을 한다. 그러나, 이러한 신경회로망을 이용한 방법의 경우 충분히 학습되지 않았을 경우에 종종 극단적으로 나쁜 수렴특성을 보여주어 성공적이지 못한 궤적을 만든다[23].

한편, Kong과 Kosko[16]는 전형적인 퍼지 추론 시스템을 이용하여 이 문제를 해결할 수 있다는 것을 보여 주었다. 그러나 여기서 사용된 퍼지 시스템은 입력공간을 그리드 분할함으로서 많은 규칙이 생성되며, 전문가의 경험이나 공학적인 상식에 의한 지식을 미리 가지고 있지 않은 경우에는 퍼지 규칙의 생성이 어려운 단점이 있다. 또한, Wang[15]은 수치적인 입력 출력 데이터와 언어적인 규칙을 동시에 사용하여 규칙 생성을 제안하였다. 그러나 Kosko방법과 마찬가지로 그리드 분할 방법으로 인해 많은 규칙이 생성되는 문제를 안고 있다.

앞서 언급된 트럭 후진 제어 문제는 그림 5와 같이 한정된 주차공간에서 임의의 위치에서 원하는 주차위치에 후진하여 주차시키는 것을 목표로 하고 있다. 본 논문의 모의 실험에 사용된 트럭의 다이어그램과 주차 영역은 그림 5와 같으며 이때의 트럭의 근사화된 모델 운동식은 다음과 같은 것을 이용하였다[15].

$$x(k+1) = x(k) + v \cdot t \cdot \cos[\psi(k)]$$

$$y(k+1) = y(k) + v \cdot t \cdot \sin[\psi(k)]$$

$$\psi(k+1) = \psi(k) + v \cdot t / l \cdot \tan[\theta(k)] \tag{15}$$

여기서, 후진속도 v 와 시간 스텝은 각각 -5 m/s 와 0.5 sec 이며, 트럭길이 l 은 4 m 로 가정하고 이때, 각 변수의 범위는 다음과 같이 설정하였다.

$$-40 \leq x \leq 40, 0 \leq y \leq 50, -90 \leq \psi \leq 270, -45 \leq \theta \leq 45 \tag{16}$$

입력변수는 x 축 좌표의 거리와 수평축에 대한 트럭 각 ψ 이며 출력변수는 조향각 θ 로 하고 트럭과 주차위치 사이의 충분한 거리유지를 가정해서 y 축 좌표의




그림 5. 트럭의 다이어그램과 주차공간
Fig. 5. Truck diagram and parking space

거리는 무시하였다[15,16].

제안된 뉴로-퍼지 시스템에서 사용되는 출력이 학습 데이터에 편중되지 않고 새로운 데이터에 대해서도 타당한 결과를 내는 모델인가를 평가하기 위해 그림 6과 같이 700개 데이터는 모델 형성에 학습 데이터로 사용하였고 나머지 700개의 데이터는 모델 검증에 검증 데이터로 나누어 사용하였다.

학습 데이터 중 출력 변수인 조향각 데이터에 대한 히스토그램은 그림 7에 나타내어지며, 앞서 언급한 퍼지 균등화 방법을 적용한 후에 그림 8에서 나타난 것처럼 4개의 퍼지 집합을 얻었다.

출력 변수 θ 에 대해 얻어진 각각의 퍼지 집합 (T_1, T_2, T_3, T_4)에서 각각 두 개씩의 클러스터를 CFCM 알고리즘에 의해 발생시켜 총 8개의 TSK 퍼지 규칙을 갖는 뉴로-퍼지 시스템을 구축하였다. 구축된 뉴로-퍼지 시스템을 가지고 10개의 임의의 초기 상

태로부터 시뮬레이션을 한 결과 이상적인 궤적을 따라 정확하게 주차하고 있음을 그림 9에서 보여주고 있다.

표 1에서 알 수 있듯이 제안된 방법은 기존의 방법에 비해서 적은 수의 규칙과 파라미터를 가지고 트럭 후진 제어를 행할 수 있음을 알 수 있었다. 또한, ANFIS와 제안된 방법을 비교해 본 결과 학습데이터에 대한 평균 조향각 오차는 각각 0.101, 0.119[rad]으로 비슷한 결과를 보였으나 검증데이터에 대한 평균 조향각 오차는 각각 0.432, 0.147[rad]으로 차이가 남을 알 수 있는데, 이는 ANFIS의 많은 규칙으로 인해 과도적합의 문제점을 보이는 반면, 제안된 방법에서는 이러한 문제가 없음을 알 수 있다.




그림 6. 학습데이터와 검증데이터의 분포
Fig. 6. The training data and checking data




그림 8. 퍼지 균등화에 의해 얻어진 소속함수
Fig. 8. The membership function by fuzzy equalization




그림 7. 조향각 θ 에 대한 히스토그램
Fig. 7. The histogram for the steering angle, θ




그림 9. CFCM-FE based ANFIS를 이용한 트럭의 궤적
Fig. 9. The truck trajectory using CFCM and FE-based ANFIS

표 1. RMSE와 규칙 수의 비교
Table 1. The comparison of RMSE and rule numbers

	규칙 수	파라미터 수
Wang[15]	27	85
Kosko[16]	35	85
ANFIS	25	132
CFCM FE-based ANFIS	8	56

3.2 Box와 Jenkins의 가스로 데이터의 모델링

Box-Jenkins 가스로 데이터를 이용한 비선형 시스템 식별을 하기 위해 본 논문에서 제안한 뉴로-퍼지 시스템을 적용한다. 여기서는 가스로에서의 가스 흐름을 $u(t)$ 와 이산화탄소 농도 $y(t)$ 시계열 데이터인 296 $\{y(t), u(t)\}$ 개의 쌍이 사용된다. 본 논문에서는 이전의 다른 논문과 비교하기 위해 입력을 $y(t-1)$ 과 $u(t-4)$ 으로 선택하고 출력 변수는 $y(t)$ 를 선택하였다.

학습 데이터 중 출력 변수인 $y(t)$ 데이터의 히스토그램은 그림 10에 나타내어지며 히스토그램으로서 주어진 확률적인 분포를 근거로 하여 퍼지 균등화 알고리즘을 적용한 후에 그림 11에서 나타낸 것처럼 3개의 퍼지 집합을 얻었다.

출력 변수 $y(t)$ 에 대해 얻어진 각각의 퍼지 집합 (T_1, T_2, T_3)에서 CFCM에 의해 각각 두 개의 클러스터를 발생시켜 총 6개의 TSK 퍼지 규칙을 갖는 뉴로-퍼지 시스템을 구축하였다. CFCM과 퍼지 균등화를 이용한 클러스터 분포는 그림 12에서 보여주고 있다. 그림에서 알 수 있는 바와 같이 입력 데이터의 성질뿐만 아니라 출력 패턴의 성질까지도 고려하기 때문에 각각의 클러스터가 포함하는 데이터 사이의 유

사성이 좋음을 알 수 있었다.

위와 같은 6개의 규칙을 이용하여 Jang[5]의 방법에 따라, 하이브리드 학습을 통해 최종적으로 얻어진 전제부의 소속함수와 결론부 파라미터는 각각 그림 13

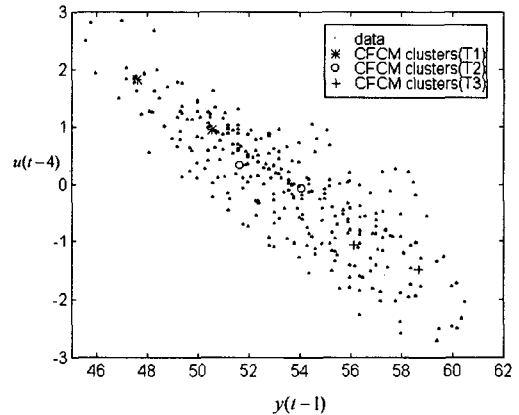


그림 12. CFCM과 FE을 이용한 클러스터 분포
Fig. 12. Distribution of clusters using CFCM and FE




그림 10. $y(t)$ 에 대한 히스토그램
Fig. 10. The histogram for the output variable $y(t)$




그림 11. 퍼지 균등화에 의해 얻어진 소속함수
Fig. 11. The membership function by fuzzy equalization

표 2. 학습 후의 결론부 파라미터
Table 2. The consequent parameter after learning

	p_i	q_i	r_i
Rule 1	1.1798	1.3459	-12.8825
Rule 2	0.2710	-2.1233	39.1296
Rule 3	-2.3281	6.5240	185.3158
Rule 4	-1.8930	-1.3355	143.0843
Rule 5	-0.7031	1.1281	96.6051
Rule 6	0.2995	1.0186	45.3538





그림 13. 학습 후의 전제부 소속함수
Fig. 13. The premise membership function after learning




그림 14. CFCM FE-based ANFIS의 추론 값과 실제 데이터 출력과의 비교

Fig. 14. The comparisons of CFCM and FE-based ANFIS inference and desired output value

표 3. 규칙 수와 오차의 비교

Table 3. The comparison of rule numbers and mean square error

	입력수	규칙수	평균제곱오차
Box and Jenkins[17]	6	.	0.71
Tong[18]	2	19	0.469
Pedrycz[19]	2	20	0.320
Xu[20]	2	25	0.328
Sugeno[1]	3	6	0.190
Joo[21]	2	6	0.166
CFCM FE-based ANFIS	2	6	0.117

과 표 2에 나타난 바와 같이 전체부 파라미터는 총 24개가 사용되어지고 결론부 파라미터는 총 18개가 사용되어졌다.

그림 14는 제안된 방법을 이용하여 모델의 추론 값과 원하는 데이터 출력력을 비교하고 있다. 그림에서 알 수 있듯이 적은 오차를 보이면서 가스로 데이터가 예측하고 있음을 알 수 있다.

표 3은 시뮬레이션 결과로 모델에 대한 규칙 수와 오차를 비교한 결과이며 제안된 방법인 CFCM-FE에 근거한 ANFIS가 이전의 다른 논문들에 비해 적은 규칙의 수와 입력 수를 가지면서도 작은 오차를 보임을 알 수 있었다.

4. 결 론

전문가의 지식은 종종 일관성이 없고 불완전하기 때

문에 이로부터 퍼지규칙을 획득하는 경우에 여러 가지 어려움을 겪고 있다. 이런 문제점을 해결하기 위해서 뉴로-퍼지 시스템에 기초하여 수치적인 학습 데이터에 근거한 규칙을 자동 생성하도록 하는 다양한 연구가 시도되어 왔다. 그러한 이러한 모델링 방법들 역시 구조식별에 대한 체계적인 방법이 없으므로 현재 널리 쓰이고 있는 그리드 분할 방법의 경우 입력공간의 수가 증가할 때 규칙의 수가 지수적으로 증가하는 문제점을 가지고 있다.

이런 문제점을 해결하기 위해 본 논문에서는 적용적인 스캐터 분할에 근거한 적용 뉴로-퍼지 시스템에서의 퍼지 규칙의 자동생성을 다루었다. 이를 위하여 먼저 기존의 FCM 기법을 확장하여 출력 데이터의 특성을 반영하도록 고안된 CFCM 기법을 적용하여 ANFIS에서 구조동정을 수행하도록 채택하였다. 이로부터 전형적인 ANFIS에서 입력공간의 그리드 분할로 인해 규칙의 수가 지수함수적으로 증가하는 문제점을 해결 할 수 있었다. 이때, 퍼지 균등화 기법을 이용하여 출력변수의 퍼지 소속함수를 자동적으로 생성하도록 하였다.

위의 방법을 모델링 기법의 적용 예로 널리 쓰이는 트릭 후진 제어와 Box-Jenkins의 가스로 데이터에 적용하여 실험해 본 결과 이전의 다른 논문에 비해 적은 규칙과 파라미터로 좋은 모델링 특성을 보임을 알 수 있었다. 따라서, 제안된 방법은 언어적인 집합과 수치적인 데이터로부터 퍼지 규칙을 자동 생성하는 것이 요구되는 다양한 분야에 유용하게 적용될 수 있으리라 생각된다.

참고문헌

- [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] 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.
- [3] C. T. Lin, C. S. G. Lee, "Neural Fuzzy Systems : A Neuro-Fuzzy Synergism to Intelligent Systems", Prentice Hall, 1996.
- [4] C. C. Wong, C. C. Chen, "A clustering-based method for fuzzy modeling", *IEICE Trans. Inf. and Syst.*, Vol. E82-D, No. 6, pp. 1058-1065, 1999.
- [5] 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.
- [6] C. T. Lin, C. S. G. Lee, "Reinforcement structure parameter learning forneural network-based fuzzy logic control system", *IEEE Trans. on Fuzzy System*,

Vol. 2, No. 1, pp. 46-63, 1994.

[7] J. S. R. Jang, "Structure determination in fuzzy modeling : A fuzzy CART approach", Proc. of IEEE international conference on fuzzy systems, (Orlando, Florida), 1994.

[8] C. T. Sun, "Rule-based structure identification in an adaptive-network-based fuzzy inference system", *IEEE Trans. on Fuzzy System*, Vol. 2, No. 1, pp. 64-73, 1994.

[9] J. C. Bezdek, "Pattern Recognition with Fuzzy Objective Function Algorithms", Plenum Press, New York, 1981.

[10] S. Chiu, "Fuzzy model identification based on cluster estimation", *Journal of Intelligent Fuzzy System*. Vol. 2, No. 3, 1994.

[11] W. Pedrycz, "Conditional fuzzy c-means", *Pattern Recognition Letter*, Vol. 17, pp. 625-632, 1996.

[12] 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.

[13] W. Pedrycz, G. Vukovich, "Data-based design of fuzzy sets", 한국퍼지 및지능 시스템학회 논문지, 제9권, 3호, pp. 255-263, 1999.

[14] D. Nguyen, B. Widrow, "An example of self-learning in neural networks", in *Proceeding IJCNN-89*, Vol. 2, pp. 357-363, 1989.

[15] L. X. Wang, J. M. Mendel, "Generating fuzzy rules by learning from examples", *IEEE Trans. on System, Man, and Cybern.*, Vol. 22, No. 6, pp. 1414-1427, 1992.

[16] S. G. Kong, B. Kosko, "Comparison of fuzzy and neural truck backer upper control system", *Proceedings IJCNN-90*, Vol. 3, pp. 349-358, 1990.

[17] G. E. P. Box, G. M. Jenkins, "Time Series Analysis, For ecasting and Control", San Francisco, CA: Holden Day, 1970.

[18] R. M. Tong, "The evaluation of fuzzy models derived from experimental data", *Fuzzy Sets and Systems*, Vol. 4, pp. 1-12, 1980.

[19] W. Pedrycz, "An identification algorithm in fuzzy relational systems", *Fuzzy Sets and Systems*, Vol. 13, pp. 153-167, 1984.

[20] C. W. Xu, Y. Z. Lu, "Fuzzy model identification and self-learning for dynamics systems", *IEEE Trans. on System, Man, and Cybern.*, Vol. 17, pp. 683-689, 1987.

[21] Y. H. Joo, H. S. Hwang, K. B. Kim, K. B. Woo, "Fuzzy system modeling by fuzzy partition and GA hybrid schemes", *Fuzzy Sets and Systems*, Vol. 86, pp. 279-288, 1997.

[22] L. A. Zadeh, "Probability measures of fuzzy events", *J. Math. Analysis and Application*, Vol. 22, pp. 421-427, 1968.

[23] 공성곤, 김민수, "적응퍼지제어", 제어자동화 시스템 공학회지, 제1권, 3호, pp. 101-108, 1995.

[24] 객근창, 한태환, 유정웅, 전명근, "정수장 응집제 주입공정의 적응네트워크기반 퍼지 시스템 모델링", 한국퍼지 및 지능 시스템학회 논문지, 제9권, 3호, pp. 313-322, 1999.



객 근 창 (Keun Chang Kwak)

1996년 : 충북대 공대 전기공학과 졸업
 1998년 : 충북대 대학원 전기공학과 졸업(석사)
 1998년~현재 : 충북대 대학원 박사과정 재학중



이 대 종 (Dae Jong Lee)

1995년 : 충북대 공대 전기공학과 졸업
 1997년 : 충북대 대학원 전기공학과 졸업(석사)
 1998년~현재 : 충북대 대학원 박사과정 재학중 전기안전시험연구원



유 정 웅 (Jeong Woong Ryu)

제 9권 3호 참조
 현재 : 충북대학교 전기전자공학부 교수

전 명 근 (Myung Geun Chun)

제 9권 3호 참조
 현재 : 충북대학교 전기전자공학부 교수