

라마키안 상호 적응에 의한 최적 COG 비퍼지화기 설계

An Optimal COG Defuzzifier Design Using Lamarckian Co-adaptation

김대진, 이한별
Daijin Kim, Han-Pyul Lee
동아대학교 컴퓨터공학과

요약

본 논문은 퍼지 논리 제어기(FLC)의 근사화 능력과 제어 성능을 동시에 향상시키는 정확한 무게 중심(Center Of Gravity; COG) 비퍼지화기를 제안한다. 본 논문은 비퍼지화 과정이 최적 선택의 한 과정이며 비퍼지화 방법의 적절한 선택이 FLC의 근사화 능력과 제어 성능을 크게 향상시킬 수 있다는 것을 전제로 하고 있다. 제안한 COG 비퍼지화기의 정확성은 출력 소속 함수를 여러 개의 설계 파라미터(중심, 폭, 변경자(modifier))로 나타내고 이들 설계 파라미터들을 학습과 진화의 Lamarckian 상호 적응에 의하여 갱신함으로써 얻어진다. 이러한 학습과 진화의 상호 적응은 학습하지 않는 경우 보다 빠르게 최적 COG 비퍼지화기를 얻도록 하며, 보다 넓은 범위의 탐색으로 최적해를 찾을 가능성을 높여 준다. 제안한 설계 방법은 목적 함수의 가중치를 조절하여 높은 근사화 능력, 높은 제어 성능, 또는 이들간의 균형된 성능을 갖는 다양한 특정 응용형(Application-specific) COG 비퍼지화기를 제공한다. 제안한 상호적응 COG 비퍼지화기의 설계 방법을 트럭 후진 주차 제어 문제에 적용하여, 각각 시스템 오차와 평균 추적 거리로 나타내어진 근사화 능력과 제어 성능을 기존의 COG 비퍼지화기와 비교한다.

Abstract

This paper proposes an optimal COG (Center of Gravity) defuzzification method that improves both the system's approximation behavior and the control performance of a fuzzy logic controller (FLC). The premise of this paper is that the defuzzification is a process of optimal selection and an appropriate selection of the defuzzification method can improve the approximation behavior and the control performance of the FLC greatly. The accuracy of the proposed COG defuzzifier is obtained by representing the output membership functions (MFs) with various design parameters such as the centers, widths, and modifiers of MFs and by adjusting these design parameters with Lamarckian co-adaptation of learning and evolution. This co-adaptation scheme allows to evolve much faster than the nonlearning case and gives a higher possibility of finding an optimal solution due to its wider searching capability. An application to the truck backer-upper control problem of the proposed co-adaptive design method of COG defuzzifier is presented. The approximation behavior and control performance of the proposed COG defuzzifier are compared with those of the conventionally simplified COG defuzzifier in terms of the system error and the average tracing distance, respectively.

I. 서론

퍼지 논리 제어기는 시스템의 특성이 복잡하여 기존의 정량적인 방법으로는 해석할 수 없거나, 얻어지는 정보가 정성적이며, 부정확하고 불확실한 경우에 있어서 기존의 제어기보다 우수한 제어결과를 나타낸다[1].

본 논문에서는 비퍼지화 문제를 최적 선

택의 한 과정으로 취급하고, 비퍼지화 방법의 적절한 선택은 FLC의 시스템 근사화 능력과 제어 성능을 모두 향상시킬 수 있다고 믿는다. 그러한 최적화를 실현하기 위하여, 비퍼지화기에 여러 자유 파라미터들을 도입하고 이들을 진화와 학습의 동시 적용에 의해 결정하는 라마키안 상호 적응 모델을 제시한다.

II. 제안한 COG 비퍼지화기

비퍼지화 방법은 Max 방법, 최대 평균법(MOM), 그리고 무게 중심법(COG)[2]이 있다. 이들중 COG 방법이 가장 널리 사용된다. COG 비퍼지화기는 퍼지 집합 영역의 면적의 무게 중심값을 비퍼지화값으로 나타낸다. 이는 아래에 설명하는 것과 같이 거리의 자승의 소속함수에 의한 가중 평균으로 나타낸 목적 함수를 최소화하도록 결정된다[3]. 소속 함수에 의해서 가중된 한 비용 함수는 다음과 같다.

$$J(y_c) = \sum_{i=1}^n (y_i - y_c)^2 \mu_Y(y_i) \quad (1)$$

여기서 $y_c \in Y$ 와 n 은 각각 비퍼지화 비퍼지화 값과 출력 변수가 갖는 퍼지항의 개수이다. 비용 함수의 최소를 얻기 위해서 $J(y_c)$ 를 미분하여 y_c 에 대해 정리하면 아




그림 1. 기존의 COG 비퍼지화기의 오류

래와 같은 COG 비퍼지화값을 얻을 수 있다.

$$y_c = \frac{\sum_{i=1}^n y_i \mu_Y(y_i)}{\sum_{i=1}^n \mu_Y(y_i)} \quad (2)$$

여기서, y_c 는 단일 지지값(singleton)이고 소속 함수 $\mu_Y(y_i)$ 는 $y=y_i$ 에서 최대값을 갖는다. 그러나, 기존의 COG 비퍼지화기는 비퍼지화값 연산시 출력 단일 지지값과 단일 지지값에서의 절단된 소속 함수만을 고려하기 때문에 부정확한 비퍼지화값을 나타내는 단점이 있다.

그림 1은 기존의 COG 비퍼지화기의 오류를 예시해준다. 그림 1-(a)의 두 소속 함수들은 같은 크기의 폭을 갖는데 반해 그림 1-(b)의 두 소속 함수들은 다른 크기의 폭을 갖는다. 그리고, 양자 모두 같은 단일 지지값들을 갖는다. 기존의 COG 비퍼지화기가 비퍼지화값을 연산할 때 단일 지지값에서 소속 함수값들만 고려하기 때문에, 두 경우 모두 같은 비퍼지화 값을 나타낸다.

따라서, 기존의 COG 비퍼지화기는 소속 함수들의 서로 다른 폭을 반영하지 못하는 단점이 있다. 이 잘못을 수정하기 위하여, 본 논문에서는 다음과 같은 새로운 COG 비퍼지화 방법을 제안한다.

$$y_c = \frac{\sum_{i=1}^n A_i(y_i) \cdot y_i}{\sum_{i=1}^n A_i(y_i)} \quad (3)$$

여기서, n 은 이산 퍼지 항들의 수, y_i 는 i 번째 퍼지항의 단일 지지값, 그리고 $A_i(y_i)$ 는 i 번째 소속 함수값의 절단면 아




그림 2. 언어 변수 "Truth"의 다양한 변수 집합

래 면적으로 $A_i(y_i) = \mu_Y(y_i) \cdot s_i$ 로 정의된다. 여기서 s_i 는 i 번째 퍼지항의 폭이다. 더 나아가, very, more or less, or fairly와 같은 변경자를 사용하여 각 퍼지항의 의미를 확장할 수 있다[4]. 그림 2는 변경자에 의해 그 의미가 변경된 언어 변수 "Truth"의 여러 퍼지항을 보여준다. 여기에서,

$$\begin{aligned} \mu_{\text{very true}}(y) &= \mu_{\text{com}(\text{true})}(y) \\ &= (\mu_{\text{true}}(y))^2 \quad y \in [0,1] \\ \mu_{\text{fairly true}}(y) &= \mu_{\text{dil}(\text{true})}(y) \\ &= (\mu_{\text{true}}(y))^{\frac{1}{2}} \quad y \in [0,1] \end{aligned} \quad (4)$$

각 퍼지항이 서로 다른 변경자를 갖도록 하면, 제안한 COG 비퍼지화기가 비퍼지화값을 다음과 같이 연산하도록 확장할 수 있다.

$$y_c = \frac{\sum_{i=1}^n A_i^m(y_i) \cdot y_i}{\sum_{i=1}^n A_i^m(y_i)} \quad (5)$$

여기서, $A_i^m(y_i)$ 는 i 번째 소속 함수의 절단면 아래의 유효 면적으로 $A_i^m(y_i) = \mu_Y^m(y_i) \cdot s_i$ 로 정의되는데, m_i 는 i 번째 퍼지항의 변경자이다.

수정된 소속 함수 $\mu_Y^m(y_i)$ 를 사용하는 경우에서 유효 면적 $A_i^m(y_i)$ 의 정확한 식의 상세한 유도도는 [5]에 나타난다. 여기서,

$m_i > 1$ 인 경우 소속 함수를 수축시키고, $m_i < 1$ 인 경우 소속 함수를 팽창시킨다[6].




그림 3. 일반화된 소속 함수의 표현

유도 결과, $\mu_Y^m(y_i)$ (그림 3. 참조)의 절단면 아래의 유효 면적 $A_Y^e(y_i)$ 는 다음과 같이 주어진다.

$$A_Y^e(y_i) \equiv \mu_Y(y_i) \cdot s_i \left(1 - \frac{m_i}{m_i+1} \mu_Y^{\frac{1}{m_i}}(y_i) \right) \quad (6)$$

여기서, m_i , $\mu_Y(y_i)$, 그리고 s_i 는 각각 i 번째 소속 함수의 변경자, i 번째 퍼지항의 소속 함수, 그리고 i 번째 소속 함수의 폭이다. 주목할 것은

$$\begin{aligned} m_i \rightarrow 0 \text{ 이면 } A_Y^e(y_i) &\rightarrow \mu_Y(y_i) \cdot s_i \text{ 이고,} \\ m_i \rightarrow \infty \text{ 이면 } A_Y^e(y_i) &\rightarrow 0 \text{ 이다.} \end{aligned}$$

소속 함수 $\mu_Y^m(y_i)$ 의 절단면 아래의 유효 면적 $A_Y^e(y_i)$ 은 다음과 같이 해석될 수 있다. 항 $\mu_Y(y_i) \left(1 - \frac{m_i}{m_i+1} \mu_Y^{\frac{1}{m_i}}(y_i) \right)$ 을 유효 소속 함수값이라는 의미로 $\mu_Y^e(y_i)$ 이라고 하면, 면적(그림 3의 A_2 로 설명된)은 높이와 폭이 각각 $\mu_Y^e(y_i)$ 과 s_i 인 사각형 면적과 같다. 즉,

$$A_Y^e(y_i) = \mu_Y^e(y_i) \cdot s_i \quad (7)$$

비퍼지화값은 다음과 같이 계산된다.

$$\begin{aligned} y_c &= \frac{\sum_{i=1}^N A_Y^e(y_i) \cdot y_i}{\sum_{i=1}^N A_Y^e} \\ &= \frac{\sum_{i=1}^N \mu_Y(y_i) \cdot \left(1 - \frac{m_i}{m_i+1} \mu_Y^{\frac{1}{m_i}}(y_i) \right) \cdot s_i \cdot y_i}{\sum_{i=1}^N \mu_Y(y_i) \cdot \left(1 - \frac{m_i}{m_i+1} \mu_Y^{\frac{1}{m_i}}(y_i) \right) \cdot s_i} \quad (8) \end{aligned}$$

III. 경도 강하 배치 학습에 의한 최적 COG 비퍼지화기 결정

제안한 COG 비퍼지화기는 각각 i 번째 소속 함수의 중심, 폭, 변경자를 의미하는

세 개의 자유 파라미터 y_i, s_i 및 m_i 를 갖는다. 본 논문에서는 소속 함수가 모두 이동변 삼각형 형태를 갖는다고 가정한다. 이들 자유 파라미터들은 초기 파라미터 벡터 (y_0, s_0, m_0) 에서 시작하여 다차원 오차 표면

$E(y, s, m)$ 의 경도 즉, $\left(\frac{\partial E}{\partial y}, \frac{\partial E}{\partial s}, \frac{\partial E}{\partial m} \right)$ 을 계산한 후, 파라미터 벡터 (y, s, m) 의 다음 값으로 다차원 오차 표면을 따라서 음의 기울기 방향으로 이동하면서 얻는 경도 강하법에 의해 구할 수 있다[7].

학습에 집합에 대하여 제안한 COG 비퍼지화기를 사용하는 FLC의 근사 오차를 E 라 하면, 이는 다음과 같이 계산된다.

$$\begin{aligned} E &= \frac{1}{2} \sum_{i=1}^N (y' - y_i)^2 \\ &= \frac{1}{2} \sum_{i=1}^N \left(y' - \sum_{j=1}^N \alpha_j^i \cdot y_j \right)^2 \quad (9) \end{aligned}$$

여기서 n 과 N 은 각각 출력 퍼지항의 수와 학습 샘플의 개수이다. 그리고

$$\alpha_j^i = \frac{\mu_Y(y_i) \cdot \left(1 - \frac{m_i}{m_i+1} \mu_Y^{\frac{1}{m_i}}(y_i) \right) \cdot s_i}{\sum_{j=1}^N \mu_Y(y_i) \cdot \left(1 - \frac{m_i}{m_i+1} \mu_Y^{\frac{1}{m_i}}(y_i) \right) \cdot s_i}$$

는 식을 단순화하기 위하여 사용하였다. 경도 강하법에 따르면, 세 파라미터들은 다음과 같이 갱신된다.

$$\begin{aligned} y_i(T+1) &= y_i(T) - \eta_i^y \frac{\partial E}{\partial y_i}, \\ s_i(T+1) &= s_i(T) - \eta_i^s \frac{\partial E}{\partial s_i}, \\ m_i(T+1) &= m_i(T) - \eta_i^m \frac{\partial E}{\partial m_i}. \quad (10) \end{aligned}$$

여기서, η_i^y, η_i^s 와 η_i^m 은 각각 i 번째 출력 퍼지항의 중심, 폭 그리고 변경자들의 학습율을 나타낸다. 세 개의 학습율 η_i^y, η_i^s 과

$$\eta_i^m \text{을 각각 } \eta_i^y = \frac{1}{\sum_{i=1}^N \alpha_i^y}, \eta_i^s = \frac{1}{\sum_{i=1}^N \beta_i^s} \text{ 과}$$

$$\eta_i^m = \frac{1}{\sum_{i=1}^N \gamma_i^m} \text{ 으로 정의하면, 위의 갱신 규칙은 다음과 같은 배치형 표현식을 갖는다.}$$

$$\begin{aligned} y_i(T+1) &= y_i(T) + \frac{\sum_{i=1}^N \alpha_i^y (y' - y_i^c)}{\sum_{i=1}^N \alpha_i^y}, \\ s_i(T+1) &= s_i(T) + \frac{\sum_{i=1}^N \beta_i^s (y' - y_i^c) (y_i - y_i^c)}{\sum_{i=1}^N \beta_i^s}, \end{aligned}$$

$$m_i(T+1) = m_i(T) + \frac{\sum_{i=1}^N \gamma_i'(y' - y_c')(y_i - y_c')}{\sum_{i=1}^N \gamma_i'} \quad (11)$$

IV. 진화에 의한 최적 COG 비퍼지화기 결정

일반적으로, 교사형 학습의 수렴은 설계 및 학습 파라미터들의 초기 선택에 많은 영향을 받는다. 따라서, 앞장의 학습에 의해 얻어진 FLC의 제어 성능이 최적이라고 할 수 없다. 이러한 단점을 극복하기 위하여, 많은 연구자들은 유전 알고리즘(GA)에 기초한 진화 기법을 사용하는 것을 제안하고 있다[8-9].

4.1 해개체 표현

출력 퍼지화의 수가 M 인 COG 비퍼지화기를 고려하면, 각 COG 비퍼지화기를 나타내는 해개체는 $3 \times M$ 의 연속된 실수로 표현되는데, 첫 번째 세 실수가 첫 번째 퍼지화의 중심, 폭, 변경자를 의미하도록 구성되어 있다.

4.2 초기 해집단 생성

초기 해집단의 한 해개체 $C_r(r=1, 2, \dots, |P|)$, 여기서 $|P|$ 는 해집단의 크기)은 중심은 전체 영역을 걸쳐 균일하게 놓이도록, 폭은 가능하면 출력 변수상에 각 퍼지항이 공평하게 겹치도록, 변경자는 $[0.5, 2.0]$ 사이의 임의의 값을 갖도록 결정된다. 위 과정을 P 번 반복 수행하여 초기 해집단을 생성한다.

4.3 목적 함수

해개체의 우수성은 목적 함수에 의하여 평가된다. 본 논문에서는 목적 함수에 다음과 같은 두 가지 요인을 고려한다.

첫째로, 우수한 COG 비퍼지화기는 좋은 근사화 능력(즉 작은 근사화 오차)을 나타낸다. 이러한 요구는 $F_e(T) = \frac{1}{1+E(T)}$ 와 같이 목적 함수에 근사화 오차를 포함 시킴으로서 만족되어진다. 여기서 $E(T)$ 는 식 (9)에서 정의된 근사화 오차이다.

둘째로, 우수한 COG 비퍼지화기는 좋은 제어 성능을 보여 준다. 두 번째 요구인 우수한 제어 성능은 $F_p(T) = \frac{1}{1+d(T)}$ 와 같이 목적 함수에 평균 주행 거리를 포함 시킴으로서 만족된다.

위의 두 가지 고려 사항을 한 목적 함수에 통합시키면 목적 함수는 아래 식과 같이 나타난다.

$$F(T) = k_1 \cdot F_e(T) + k_2 \cdot F_p(T) \quad (12)$$

여기서, k_1 과 k_2 는 두 가지 설계 목적에

따라 다르게 가중되는 적당한 상수로서, $k_1 + k_2 = 1$ 를 만족한다.

4.4 유전 연산

COG 비퍼지화기들의 초기 해집단에서 주어진 제어 목적들에 맞는 최적 COG 비퍼지화기를 얻어내기 위해 적절한 유전 연산이 가해지면서 진화된다.

1) 재생

본 논문에서는 해개체들을 재생하기 위하여 elitism과 수정된 k -토너먼트 방법 [10]을 이용한다.

2) 교차

선택된 두 부모 개체와 대응하는 목적 함수값을 각각 C^1 과 C^2 및 F_1 과 F_2 라고 하고, 두 선택된 개체들의 i 번째 퍼지항들의 설계 파라미터를 각각 (y_i^1, s_i^1, m_i^1) 와 (y_i^2, s_i^2, m_i^2) 라고 하자. 그러면, 교차 연산을 적용하여 생성된 새로운 개체 C^∞ 의 설계 파라미터 $(y_i^\infty, s_i^\infty, m_i^\infty)$ 은 아래 식에 의해서 얻어진다.

$$\begin{aligned} y_i^\infty &= \frac{F_1 \cdot y_i^1 + F_2 \cdot y_i^2}{F_1 + F_2} \\ s_i^\infty &= \frac{F_1 \cdot s_i^1 + F_2 \cdot s_i^2}{F_1 + F_2} \\ m_i^\infty &= \frac{F_1 \cdot m_i^1 + F_2 \cdot m_i^2}{F_1 + F_2} \end{aligned} \quad (13)$$

3) 돌연 변이

한 돌연 변이점 (y_i, s_i, m_i) 를 임의로 선택한다. 다음, 돌연변이된 해개체 C^{mu} 의 설계 파라미터값 $(y_i^{mu}, s_i^{mu}, w_i^{mu})$ 은 다음 식에 의하여 연산된다.

$$\begin{aligned} y_i^{mu} &= y_i + \text{random}(-\Delta y, \Delta y) \\ s_i^{mu} &= s_i + \text{random}(-\Delta s, \Delta s) \end{aligned}$$

$$m_i^{mu} = \begin{cases} \frac{1}{2} \cdot (1 - m_i) + 1 & \text{if } m_i \geq 1 \\ 2 \cdot (1 - m_i) + 1 & \text{if } m_i < 1 \end{cases} \quad (14)$$

여기서, Δy^{mu} 와 Δs^{mu} 는 각각 돌연 변이들의 중심값 및 폭의 최대 변동량이다. 변경자 m_i^{mu} 는 원래값 m_i 를 1.0에 대해 반전(turn over)된 값으로 변이된다.

V. 최적 COG 비퍼지화기 설계를 위한 라마키안 상호 적응

본 연구에서 제안한 라마키안 상호 적응 방법은 다음과 같다.

각 개체가 T 번째 세대에서 자신의 목적 함수값 $F_i(T)$ 를 가진다고 가정하자. 일생

동안, 각 개체의 파라미터는 3장에서 기술된 제안한 강도 강하 배치 학습에 의해 갱신된다. 각 개체는 서로 다른 초기 파라미터들의 선택에 의하여 각기 다른 학습 환경 하에서 다르게 학습되어진다. 각 개체가 T 번째 세대에서 학습을 수행한 후 목적 함수값 $F_i(T)$ 를 갖는다고 가정한다. 어떤 해개체는 학습을 수행한 후에 더 좋은 목적 함수값을 가지며(예를 들면, $F_i'(T) > F_i(T)$), 다른 해개체는 그렇지 못할 수 있다. 본 연구에서는 다음과 같이 우생적 해개체 선택을 적용하여 학습된 설계 파라미터 (y_i', s_i', m_i') 은 더 나은 목적 함수값을 갖는 해개체의 설계 파라미터들을 취한다.

$$(y_i', s_i', m_i') = \begin{cases} (y_i, s_i, m_i) & \text{if } F_i'(T) > F_i(T) \\ (y_i', s_i', m_i') & \text{if } F_i'(T) > F_i(T) \end{cases} \quad (15)$$

여기서 (y_i, s_i, m_i) 과 (y_i', s_i', m_i') 는 각각 학습 전과 학습 후의 설계 파라미터 쌍이다. 위의 식은 학습에 의하여 나빠진 설계 파라미터는 학습은 되었지만 선택되지는 않는다는 것을 의미한다.

학습을 하지 않고 단지 진화만을 고려할 때, 설계 파라미터는 학습에 의하여 변하지 않는다. 그래서, 학습된 설계 파라미터 (y_i', s_i', m_i') 은 학습하기 전의 설계 파라미터들 (y_i, s_i, m_i) 과 같다. 각 개체는 학습된 후에 4장에서 기술된 진화 기법에 의하여 갱신된다. 이것은 학습과 진화가 수행 설계 파라미터 $(y_i^{t+e}, s_i^{t+e}, m_i^{t+e})$ 를 만드는데, 이것은 다음 세대 즉 $(T+1)$ 번째 세대에서 설계 파라미터가 된다.

VI. 실험 결과 및 분석

제안한 COG 비퍼지화기 설계 방법을 트럭 후진 주차 제어 문제에 적용하여 근사화 능력과 제어 성능을 각각 근사화 오차와 평균 주행 거리를 이용하여 기존의 COG 비퍼지화기의 그것과 비교한다.

트럭의 위치는 (x, y, ϕ) 에 의해 결정된다. 단, 여기에서 ϕ 는 트럭 진행 방향과 x 축 간의 각도이며, 트럭의 후진 주행 제어는 ϕ 와 핸들의 축 간의 각도인 θ 에 의해 결정된다. 트럭이 움직이는 운동 방정식은 아래와 같이 나타내어진다[11].

$$\begin{aligned} x(t+1) &= x(t) + \cos[\phi(t) + \theta(t)] + \sin[\theta(t)]\sin[\phi(t)] \\ y(t+1) &= y(t) + \cos[\phi(t) + \theta(t)] - \sin[\theta(t)]\sin[\phi(t)] \\ \phi(t+1) &= \phi(t) - \sin^{-1}\left[2\sin\left(\frac{\theta(t)}{b}\right)\right] \end{aligned} \quad (16)$$

여기서 b 는 트럭의 길이이다. 본논문에서는 $b=4$ 로 하였다.

트럭 주차 제어 문제는 주어진 공간 내




그림 4. 여러 모의 실험의 근사화 오차




그림 5. 여러 모의 실험의 평균 주행 거리

의 $\{0 \leq x \leq 20, -90^\circ \leq \phi \leq 270^\circ\}$ 임의의 초기 위치 (x_0, ϕ_0) 에서 가능하면 신속·정확하게 주차대 $(x=10, \phi=90^\circ)$ 쪽으로 후진하도록 바퀴 각도 θ ($-40 \leq \theta \leq 40$)를 제어하는 것이 요구된다. 본 논문에서는 Wang과 Mendel[12]이 사용한 퍼지 제어기의 입력력 변수를 이용한다.

Wang의 COG 비퍼지화기는 고정된 것이지만, 본 연구에서 제안한 COG 비퍼지화기 설계 방법은 여러 가지 방법에 의해 설계 파라미터들을 조절할 수 있다. 본 연구에서 수행한 시뮬레이션은 다음 세 가지 각기 다른 면 - (1) 고려하는 설계 파라미터들의 서로 다른 조합, (2) 설계 파라미터들의 서로 다른 갱신 방법, 그리고 (3) 목적 함수의 서로 다른 가중치-을 고려하여 수행하였다.

그림 4와 5는 아래와 같은 7 가지 다른 형태의 모의 실험 결과 얻어진 근사화 능력과 제어 성능을 각각 보여 준다.

1. SIM1 : $F = F_1$ 이고 진화만에 의한 적용,
2. SIM1-1 : $F = F_1$ 이고 라마키안 상호 적용,
3. SIM2 : $F = \frac{F_1}{2} + \frac{F_2}{2}$ 이고

진화만에 의한 적용,

4. SIM2-1 : $F = \frac{F_1}{2} + \frac{F_2}{2}$ 이고

라마키안 상호 적용,

5. SIM3 : $F = F_2$ 이고 진화만에 의한 적용,

6. WANG(y) : MF의 중심만 변화 가능한 Wang의 FLC,

7. WANG(y,s) : MF의 중심, 폭이 변화 가능한 Wang의 FLC,

이 그림으로부터, (1) 근사화 오차는 설계 파라미터들이 목적 함수가 $F = F_1$ 인 조건 하에서 조정될 때 가장 적으며, (2) 모의 실험 SIM1과 SIM1-1의 경우에서 근사화 오차가 주어진 파라미터 갱신 방법에서 설계 파라미터 변수 조합이 (y,s,m) , (y,s) , 그리고 (y) 를 갖는 COG 비퍼지화기의 순서대로 적으며, (3) Wang의 FLC는 7개의 다른 FLC들 중에서 비교적 작은 근사화 오차를 보여 주며, 근사화 오차는 설계 파라미터 변수의 선택 (즉, (y) 또는 (y,s))에 민감하지 않고, (4) SIM3의 근사화 능력은 가장 나쁘게 나타났는데 그 이유는 SIM3의 설계 목적이 짧은 주행 거리를 얻도록 설계되어 있기 때문이며, (5) 평균 주행 거리는 설계 파라미터들이 목적 함수가 $F = F_2$ 인 조건하에서 조정될 때 가장 짧으며, (6) 모의 실험 SIM3의 경우 평균 주행 거리는 주어진 파라미터 갱신 방법에서 설계 파라미터 변수 조합이 (y,s,m) , (y,s) , 그리고 (y) 를 갖는 COG 비퍼지화기의 순서대로 짧으며, (7) Wang의 FLC는 7개의 다른 FLCs 중에서 비교적 긴 평균 주행 거리를 보여 주며, 평균 주행 거리는 설계 파라미터 변수 조합이 (y) 와 (y,s) 의 경우에 각각 14.73cm와 14.41cm로 나타나는 것처럼 설계 파라미터 변수의 선택에 다소 민감하며, (8) 모의 실험 SIM2와 SIM2-1은 근사화 능력과 제어 성능 모두에서 균형된 성능들을 보여 준다.

VII. 결론

본 논문은 소속 함수들이 중심, 폭, 그리고 변경자가 조정되는 새로운 형태의 COG 비퍼지화기를 제안했다. 본 연구에서는 이들 설계 파라미터를 가능한 한 정밀하게 조정함으로써 보다 정확한 제어를 달성할 수 있었다. 이들 설계 파라미터들을 동시에 조정하고자 경도 강하 배치 학습법을 유도하였다. 그리고, 본 연구에서는 라마키안 상호 적용과 같은 생물학적으로 개념에 바탕을 둔 새로운 설계 기법을 제안하였다.

본 연구에서는 좋은 근사화 능력과 좋은 제어 성능과 같은 두 가지 설계 목적은 적은(많은) 근사화 오차가 긴(짧은) 평균 주행 거리를 나타내는 것처럼 목적 함수에서로 상반되는 결과를 나타낸다는 사실을 발견하였다. 그럼에도 불구하고, 제안한 설

계 방법은 목적 함수의 가중치 상수인 k_1 과 k_2 를 적절하게 제어함으로써, 좋은 근사화 능력, 좋은 제어 성능, 또는 이들 간의 균형된 성능을 나타내는 다양한 설계 목적들을 만족시키는 많은 유용한 COG 비퍼지화기들을 제공해 주는 장점이 있다.

참고 문헌

- [1] E. H. Mandani, "Application of Fuzzy Algorithm for Control of Simple Dynamic Plant," *IEEE Proc. Control and Science*, vol. 121, no. 12, pp. 1585-1588, 1974.
- [2] C.C. Lee, "Fuzzy Logic in Control Systems: Part II," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 20, no. 2, pp. 404-435, 1990.
- [3] S. Mabuchi, "A Proposal for Defuzzification Strategy by the Concept of Sensitivity Analysis," *Fuzzy Sets and Systems*, vol. 55, no. 1, pp. 1-14, 1993.
- [4] H.-J. Zimmermann, *Fuzzy Set Theory and Its Application*, Kluwer Academic Publishers, 1991.
- [5] Daijin Kim and In-Hyun Cho, "An Accurate and Cost-effective COG Defuzzifier without the Multiplier and the Divider," *Fuzzy Sets and Systems*, In print, 1997.
- [6] T.A. Runkler and M. Glesner, "A Set of Axioms for Defuzzification Strategies Towards a Theory of Rational Defuzzification Operators," *Second IEEE International Conference on Fuzzy Systems*, vol. 2, pp. 1161-1166, 1993.
- [7] H.-S. Rhee and K.-W. Oh, "A Design and Analysis of Objective Function-based Unsupervised Neural Networks for Fuzzy Clustering," *Neural Processing Letters*, vol. 4, no. 2, pp. 83-95, 1996.
- [8] Charles L. Karr and Edward J. Gentry, "Fuzzy Control of pH Using Genetic Algorithms," *IEEE Transactions on Fuzzy Systems*, vol. 1, no. 1, February 1993.
- [9] Philip Thrift, "Fuzzy Logic Synthesis with Genetic Algorithms," *Proceedings of The Fourth International Conference on Genetic Algorithms*, pp. 509-513, 1991.
- [10] David E. Goldberg and Kalyanmoy Deb, "A Comparative Analysis of Selection Schemes Used in Genetic Algorithms," Ed. Gregory J. E.

Rawlins, *Fundamental of Genetic Algorithms*, Morgan Kaufmann Publisher, San Mateo, 1991, pp. 69-93.

- [11] Li-Xin Wang And Jerry M. Mendel, "Generating Fuzzy Rules from Numerical Data with Applications," *USC-SIPI Report*, no. 169, 1991.
- [12] Li-Xin Wang and Jerry M. Mendel, "Generating Fuzzy Rules by Learning from Examples, *IEEE Transactions on System, Man, and Cybernetics*," vol. 22, no. 6, pp. 1414-1427, 1992.