

# C-Means 클러스터링 기반의 Type-2 퍼지 논리 시스템을 이용한 비선형 모델 설계

## Design of Nonlinear Model Using Type-2 Fuzzy Logic System by Means of C-Means Clustering

백진열 · 이영일 · 오성권

Jin-Yeol Baek, Young-Il Lee and Sung-Kwun Oh

수원대학교 전기공학과

### 요 약

본 논문에서는 비선형 모델의 설계를 위해 Type-2 퍼지 논리 집합을 이용하여 불확실성 문제를 다룬다. 제안된 모델은 규칙의 전·후반부가 Type-2 퍼지 집합으로 주어진 Type-2 퍼지 논리 시스템을 설계하고 불확실성의 변화에 대한 비선형 모델의 성능을 해석한다. 여기서 규칙 전반부 멤버쉽 함수의 정점 선택은 C-means 클러스터링 알고리즘을 이용하고, 규칙 후반부 퍼지 집합의 정점 결정에는 경사 하강법(Gradient descent method)을 이용한 오류 역전파 알고리즘을 사용하여 학습한다. 또한, 제안된 모델에 관련된 파라미터는 입자 군집 최적화(Particle Swarm Optimization; PSO) 알고리즘으로 동조한다. 제안된 모델은 모의 데이터집합(Synthetic dataset), Mackey-Glass 시계열 공정 데이터를 적용하여 논증되고, 기존 Type-1 퍼지 논리 시스템과의 근사화 및 일반화 능력에 대하여 비교·토의한다.

키워드 : Type-2 퍼지 논리 시스템, 비선형 시스템 모델링, 퍼지추론 시스템, Mamdani 퍼지모델, 입자군집 최적화

### Abstract

This paper deal with uncertainty problem by using Type-2 fuzzy logic set for nonlinear system modeling. We design Type-2 fuzzy logic system in which the antecedent and the consequent part of rules are given as Type-2 fuzzy set and also analyze the performance of the ensuing nonlinear model with uncertainty. Here, the apexes of the antecedent membership functions of rules are decided by C-means clustering algorithm and the apexes of the consequent membership functions of rules are learned by using back-propagation based on gradient decent method. Also, the parameters related to the fuzzy model are optimized by means of particle swarm optimization. The proposed model is demonstrated with the aid of two representative numerical examples, such as mathematical synthetic data set and Mackey-Glass time series data set and also we discuss the approximation as well as generalization abilities for the model.

Key Words : Type-2 fuzzy logic system, Nonlinear system modeling, Fuzzy inference system, mamdani fuzzy modeling, Particle swarm optimization

### 1. 서 론

알려지지 않은 시스템의 입출력 데이터로 시스템을 파악하는 것은 피할 수 없는 어려운 문제이며, 동적 시스템에 대한 효율적인 제어 메커니즘의 설계에는 일반적으로 프로세서에 대한 경험이 필요하게 된다. 그러나 실 시스템은 비선형성, 파라미터의 변동, 모델링 오차 등의 복잡한 문제를 포함하고 있으며, 프로세서에 대한 충분한 지식과 정보의 결핍으로 일반적인 수학적 방법 적용에는 상당한 어려움이 있다. 따라서, 비선형 공정의 복잡성과 불확실성을 제어하기 위해 많은 연구가 계속되고 있으며, 퍼지 논리 시스템

은 수학적 방법으로 해결하지 못했던 문제들을 해결하며, 사람들의 자연적인 언어 체계를 표현하는 데 효과적이다.

퍼지 논리 시스템의 멤버쉽 함수와 규칙의 구조는 불확실성이 존재하는 언어적 정보 또는 수치적 데이터를 바탕으로 설계된다. 기존 Type-1 퍼지 논리 시스템의 멤버쉽 함수는 외부의 노이즈와 같은 불확실성을 표현하는데 한계가 있다. 그러나 Zadeh[1]에 의하여 소개된 Type-2 퍼지 집합에 기초한 Type-2 퍼지 논리 시스템은 이러한 불확실한 정보를 멤버쉽 함수로 표현함으로써 불확실성을 효율적으로 취급할 수 있다. Type-2 퍼지 논리 집합[2]은 Mendel등에 의하여 General Type-2 퍼지 논리 집합[3]과 Interval Type-2 퍼지 논리 집합[4]으로 구체화 되었으며, 현재 활발한 연구[5][6]가 진행 중이다.

따라서 본 논문에서는 비선형 모델의 설계를 위해 Interval Type-2 퍼지 논리 집합을 이용한 Type-2 퍼지 논리 시스템을 설계하여 불확실성에 따른 비선형 모델의 성능을 비교한다. 여기서 규칙 전·후반부의 멤버쉽 함수로

접수일자 : 2008년 4월 4일

완료일자 : 2008년 6월 25일

이 논문은 2007년 및 2008년도 정부(교육과학기술부)의 재원으로 한국학술진흥재단의 지원을 받아 수행된 연구임 (KRF-2007-313-D00710 & KRF-2008-314-D00376)

Interval Type-2 퍼지 논리 집합을 사용하고, 전반부 멤버십 함수의 중심결정에는 C-means 클러스터링 알고리즘을, 후반부의 경우 경사하강법(Gradient descent method)에 의하여 학습한다. 또한 모델의 학습에 필요한 학습율, 모멘텀 계수 그리고 멤버십 함수의 불확실성을 결정하는 파라미터는 입자 군집 최적화(Particle Swarm Optimization)[7] 알고리즘으로 동정한다. 마지막으로 비선형 모델 평가에 대표적으로 사용되는 Mackey-Glass 시계열 데이터, 모의 데이터 집합을 제안된 모델에 적용하여 입력 데이터에 노이즈가 포함되었을 경우 불확실성에 따른 Type-2 퍼지 논리 시스템의 일반화 능력이 기존의 Type-1 퍼지 논리 시스템보다 우수함을 보인다.

## 2. Interval Type-2 퍼지 논리 시스템

### 2.1 Type-2 퍼지 논리 집합

기존 Type-1 퍼지 집합의 멤버십 grade는 crisp 값으로 이루어져 있다. 반면에 Type-2 퍼지 집합의 멤버십 grade는 Type-1 퍼지 집합으로 구성된다. 따라서 Type-2 퍼지 집합을 “퍼지 속의 퍼지 집합”이라고 부른다.

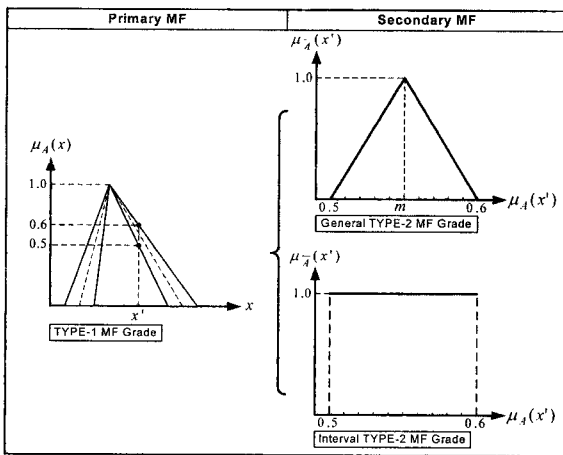


그림 1. Type-2 퍼지 논리 집합의 구성  
Fig 1. Composition of Type-2 fuzzy logic sets

그림 1은 Type-2 퍼지 집합의 두 가지 형태를 보여주고 있다. General Type-2 퍼지 논리 시스템은 Secondary MF grade가 퍼지 집합의 형태를 갖는다. 그러나 계산 과정이 복잡하고 Secondary 멤버십 함수의 구조를 결정하기 어렵다는 단점이 있다. 따라서 본 연구에서는 Secondary 멤버십 함수의 grade가 '1'의 값을 갖는 Interval Type-2 퍼지 논리 시스템을 다룬다. 식 (1)은 General Type-2 퍼지 논리 집합을, 식 (2)는 Interval Type-2 퍼지 논리 집합을 표현한 것이다.

$$\begin{aligned} \bar{A} &= \int_{x \in X} \mu \bar{A}(x) / x \\ &= \int_{x \in X} \left( \int_{u \in J_x} f_x(u) / u \right) / x \quad J_x \subseteq [0, 1] \end{aligned} \quad (1)$$

$f_x(u)$  : the secondary membership function

$J_x$  : the primary membership of  $x$  which is the domain of the secondary membership function

$$\bar{A} = \int_{x \in X} \left( \int_{u \in J_x} 1 / u \right) / x \quad (2)$$

### 2.2 Interval Type-2 퍼지 추론 시스템

그림 2는 Type-1 FLS과 Type-2 FLS을 비교한 그림이다. Type-2 FLS에서는 “Type-reducer”라는 새로운 연산이 필요함을 알 수 있다.

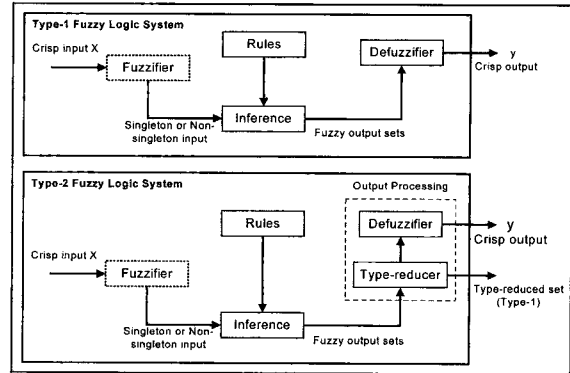


그림 2. Type-1 FLS와 Type-2 FLS 비교  
Fig 2. Comparison of Type-1 FLS and Type-2 FLS

#### 2.2.1 불확실성을 갖는 멤버십 함수의 설계

그림 3은 삼각형 형태의 Type-1 멤버십 함수와 Type-2 멤버십 함수를 비교한 그림으로 Type-2의 경우 정점을 기준으로 동일한 거리 만큼의 불확실성을 갖는다. 불확실성의 크기는 정점과 정점 사이 거리의 일정 비율 ( $\theta$ )만큼을 갖도록 하여 입력 데이터의 불확실성을 표현 할 수 있도록 설계하였으며, 모델의 최소 오차를 갖는  $\theta$ 는 PSO를 사용하여 탐색한다.




그림 3. Type-1 MF와 Type-2 MF의 비교  
Fig 3. Comparison of Type-1 MF and Type-2 MF

2.2.2 추론부 (Inference Engine)

Interval Type-2 퍼지 집합은 UMF(Upper Membership Function)과 LMF(Lower Membership Function)으로 구성되어 있으며, 이는 모든 계산 과정의 간소화에 중요한 역할을 한다. 멤버십 함수  $\mu_{F_k}(x_k)$ 에서  $\underline{\mu}_{F_k}(x_k)$ 와  $\overline{\mu}_{F_k}(x_k)$ 를  $\mu_{F_k}(x_k)$ 에 대한 Lower와 Upper 멤버십 함수라 하면, Secondary 멤버십 함수는 식 (3)으로 표현된다.

$$\mu_{F_k}(x_k) = \int_{w' \in [\underline{\mu}_{F_k}(x_k), \overline{\mu}_{F_k}(x_k)]} 1/w' \quad (3)$$

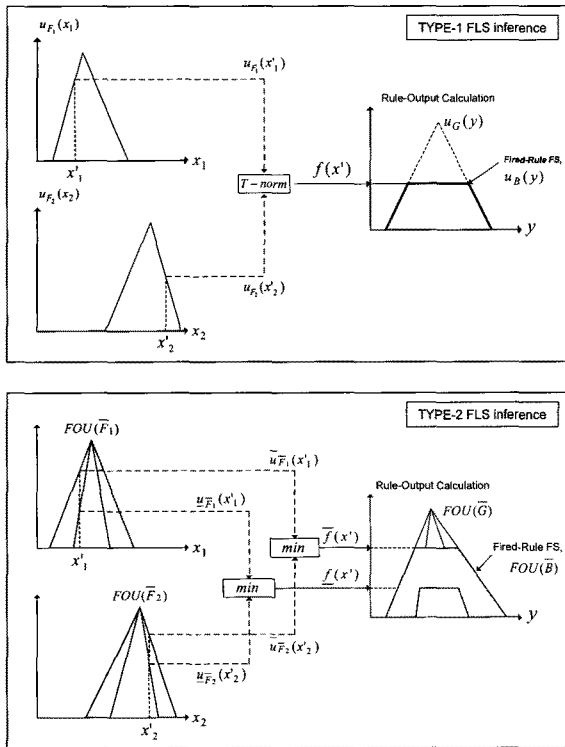


그림 4. Type-1 FLS와 Type-2 FLS의 추론 비교  
Fig 4. Comparison of Type-1 FLS inference and Type-2 FLS inference

입력에 대한  $l$  번째 규칙의 전반부 연산 결과는 식 (4)와 같다.

$$f'(x) = [\underline{f}'(x), \overline{f}'(x)] = [\underline{f}', \overline{f}'] \quad (4)$$

여기에서,

$$\underline{f}'(x) = \underline{\mu}_{F_1}(x_1) \star \dots \star \underline{\mu}_{F_p}(x_p) \quad (5)$$

$$\overline{f}'(x) = \overline{\mu}_{F_1}(x_1) \star \dots \star \overline{\mu}_{F_p}(x_p) \quad (6)$$

★ is T-norm operator

따라서, 규칙  $l$  번째에 대한 fired interval set은 식(7)로 표현되며,

$$\mu_B(y) = \int_{b \in [\underline{f}' \star \underline{\mu}_{v(y)}, \overline{f}' \star \overline{\mu}_{v(y)}]} 1/b' \quad (7)$$

$$y \in Y$$

모델의 최종 출력 집합은 식 (8)로 정리된다.

$$\mu_B(y) = \int_{b \in \{(\underline{f}' \star \underline{\mu}_{v(y)}) \vee \dots \vee (\underline{f}' \star \underline{\mu}_{v(y)}), (\overline{f}' \star \overline{\mu}_{v(y)}) \vee \dots \vee (\overline{f}' \star \overline{\mu}_{v(y)})\}} 1/b' \quad (8)$$

2.3 Centroid of Set(COS) Type Reducer

식 (8)에서 얻어지는 모델의 출력은 Type-1 퍼지 로직 집합의 형태를 갖는다. 따라서 crsip한 출력값을 얻기 위해 "Type reduction"이라는 새로운 연산 과정이 필요하다. 본 논문에서는 규칙 후반부 멤버십 함수의 최소 가중 평균 무게 중심과 최대 가중 평균 무게 중심을 결정하는 COS type reducer를 사용한다. 여기서 Type-2 퍼지 논리 집합의 최대·최소 무게 중심 결정에는 Karnik와 Mendel이 제안한 KM 알고리즘[8]을 사용한다.

Step-1) : KM 알고리즘을 이용하여 각 규칙 후반부 멤버십 함수의 최소 무게 중심과 최대 무게 중심  $[y_l', y_r']$ 을 구한다.

Step-2) : 각 규칙에 대한 fired set,  $[f', \overline{f}']$ 을 구한다.

Step-3) : KM 알고리즘을 이용하여  $y_l'$ 의 최소 가중 평균 무게 중심(식 9)과  $y_r'$ 의 최대 가중 평균 무게 중심(식 10)을 구한다.

$$y_{l(x)} = \forall f' \in [\underline{f}', \overline{f}'] \left( \frac{\sum_{i=1}^M y_i' f_i'}{\sum_{i=1}^M f_i'} \right) \quad (9)$$

$$y_{r(x)} = \forall f' \in [\underline{f}', \overline{f}'] \left( \frac{\sum_{i=1}^M y_i' f_i'}{\sum_{i=1}^M f_i'} \right) \quad (10)$$

그림 5는 KM 알고리즘에 의한 Type-2 퍼지 집합에 존재하는 Type-1 퍼지 집합(embedded)의 최소 무게 중심과 최대 무게 중심 결정을 나타낸다.




그림 5. Type-2 퍼지 집합의 중심 결정  
Fig 5. Calculation center of Type-2 fuzzy sets

2.4 비 퍼지화기 (Defuzzifier)

식 (9)에 구한 모델의 최소 출력과 식(10)에서 얻은 모델 최대 출력의 평균을 취하여 최종 모델 출력을 얻는다.

$$\hat{y}(x) = \frac{y_l + y_r}{2} \quad (11)$$

2.5 멤버십 함수의 정점 결정 및 학습

규칙의 전반부 멤버십 함수의 정점 결정에는 데이터들

간의 euclidean distance를 기준으로 중심을 결정하는 C-means 클러스터링 알고리즘을 사용하고, 후반부의 경우 오류 역전파(BP; back-propagation) 알고리즘을 통하여 학습한다. 각 규칙 후반부 멤버십 함수의 최소 무게 중심 ( $y_p^j$ )과 최대 무게 중심 ( $y_r^j$ ) 동정을 위한 오차식 정의는 식 (12)로 표현되며, 전체 학습데이터에 대한 모델의 최소 오차를 얻기위해 학습이 이루어진다.

$$E_p = \frac{1}{2} (y_p - \hat{y}_p)^2 \quad (12)$$

여기서,  $E_p$ 는 p번째 데이터에 대한 모델의 오차이며, N 은 입력 데이터 수 이다.  $y_p$ 는 p번째 입력에 대한 원 출력 이며,  $\hat{y}_p$ 는 p번째 입력에 대해 추론된 모델의 결과로 식 (11)에 의한다.

경사하강법에 의한 다항식 계수의 학습은 식 (12)로 표현 되는 오차가 최소가 되도록 식 (13)과 같이 l번째 규칙의 최소 무게 중심 변화분  $\Delta y_p^j$ 을 이용하여 현재의 최소 무게 중심을 갱신한다. 최대 무게 중심 학습은 식 (14)에 의하여 수행한다.

$$y_l^j(new) = y_l^j(present) + \Delta y_l^j + \alpha \cdot \Delta y_l^j(old) \quad (13)$$

$$y_r^j(new) = y_r^j(present) + \Delta y_r^j + \alpha \cdot \Delta y_r^j(old) \quad (14)$$

여기서,  $\alpha$ 는 모멘텀 계수로 변화분에 관성을 부여함으로써, 학습의 아주 얇은 지역 극소에 빠지는 것을 방지해 주고 학습 속도를 개선해 주는 효과가 있다[9].  $E_p$ 와  $y_l^j$ 사이의 관계를 Chain rule로 나타내면 식 (15)와 같으며, 식 (15)의 우변항은 식 (16-18)로 정리된다.

$$\Delta y_p^j = -n \cdot \frac{\partial E_p}{\partial y_p^j} = -n \cdot \left( \frac{\partial E_p}{\partial \hat{y}_p} \right) \cdot \left( \frac{\partial \hat{y}_p}{\partial y_p^j} \right) \cdot \left( \frac{\partial y_p^j}{\partial y_p^j} \right) \quad (15)$$

$$\frac{\partial E_p}{\partial \hat{y}_p} = \frac{\partial}{\partial \hat{y}_p} \left( \frac{(y_p - \hat{y}_p)^2}{2} \right) = -(y_p - \hat{y}_p) \quad (16)$$

$$\frac{\partial \hat{y}_p}{\partial y_p^j} = \frac{\partial}{\partial y_p^j} \left( \frac{y_l^j + y_r^j}{2} \right) = \frac{1}{2} \quad (17)$$

$$\frac{\partial y_l^j}{\partial y_l^j} = \frac{\partial}{\partial y_l^j} \left( \frac{\sum_{i=1}^M f_i^j y_i^j}{\sum_{i=1}^M f_i^j} \right) = \frac{\partial}{\partial y_l^j} \left( \frac{\sum_{i=1}^L \bar{f}^i y_i^j + \sum_{j=L+1}^M f^j y_l^j}{\sum_{i=1}^L \bar{f}^i + \sum_{j=L+1}^M f^j} \right) \quad (18)$$

$$= \frac{\partial}{\partial y_l^j} \left( \sum_{i=1}^M y_i^j p_i^j(x) \right) = p_l^j(x)$$

$$p_l^j(x) = \frac{h_l^j}{\sum_{i=1}^L \bar{f}^i + \sum_{i=L+1}^M f^i}$$

$$h_l^j = \begin{cases} \bar{f}^i & i = 1, \dots, L(x) \\ f^i & i = L(x) + 1, \dots, M \end{cases}$$

식 (16-18)에 의하여 l번째 규칙의 최소 무게 중심 변화 분  $\Delta y_p^j$ 은 식 (19)로 정리된다.

$$\Delta y_p^j = \frac{1}{2} \cdot n \cdot (y_p - \hat{y}_p) \cdot \frac{h_l^j}{\sum_{i=1}^L \bar{f}^i + \sum_{i=L+1}^M f^i} \quad (19)$$

위와 동일한 절차를 통하여 l번째 규칙의 최대 무게 중심

변화분  $\Delta y_r^j$ 은 식 (20)로 표현된다.

$$\Delta y_r^j = \frac{1}{2} \cdot n \cdot (y_p - \hat{y}_p) \cdot \frac{h_r^j}{\sum_{i=1}^L \bar{f}^i + \sum_{i=R(x)+1}^M f^i} \quad (20)$$

$$where, \quad h_r^j = \begin{cases} f^i & i = 1, \dots, R(x) \\ \bar{f}^i & i = R(x) + 1, \dots, M \end{cases}$$

여기에서,  $y_l^j$ 은 모델의 최소 출력을,  $y_r^j$ 은 최대 출력을 나타내고,  $y_p^j$ 은 l번째 규칙 후반부 멤버십 함수의 최소 무게 중심이며,  $y_r^j$ 은 최대 무게 중심이다. 또한, 모델의 학습에 필요한 학습률  $\eta$ 와 모멘텀 계수  $\alpha$  그리고 멤버십 함수의 불확실성( $\theta$ )을 결정하는 파라미터들은 입자 군집 최적화(PSO) 알고리즘으로 최적의 값을 탐색하도록 하였다. 탐색 초기 파라미터 값은 표 1과 같다.

표 1. 모델링을 위한 초기 파라미터들  
Table 1. Initial parameters for modeling

구분	파라미터	값
PSO	세대 수	10
	Swarm 크기	30
	최대 이동 속도 ( $v_{max}$ )	탐색공간의 20%
	관성 계수 [ $w_{min}$ $w_{max}$ ]	[0.4 0.9]
	가속 상수 ( $c_1, c_2$ )	2.0 2.0
	탐색 공간	$\theta$
$n$		[0.0 1.0]
$\alpha$		[0.0 1.0]
BP	학습 횟수	100

### 3. 시뮬레이션 및 결과 고찰

제안된 모델의 근사화 성능과 일반화 성능을 평가하기 위한 지표로 식 (21)의 mean square error(MSE)와 식 (22)의 root mean square error(RMSE)를 사용하였다.

$$PI \text{ or } EPI = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (21)$$

$$PI \text{ or } EPI = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (22)$$

여기서 PI(Performance Index)는 학습데이터에 대한 성능지수, EPI(Evaluated Performance Index)는 테스트 데이터에 대한 성능지수, m은 데이터 수를 나타낸다.

#### 3.1 Synthetic dataset

제안된 모델의 평가에 이용될 2입력 1출력의 비선형 함수는 식 (23)으로 표현되는 2입력의 수학적 함수를 적용하였다.

$$z = 1.91.35 + e^{x_2} e^{-x_1} \sin(13(x_2 - 0.6)^2) \sin(7x_1) \quad (23)$$

$$0 \leq x_1, x_2 \leq 1$$

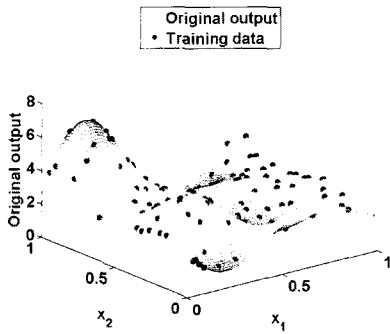


그림 6. 2입력 1출력의 비선형 함수  
Fig 6. Nonlinear function with 2 inputs and 1 output

식 (23)의 함수로부터 그림 6에 보인 200개의 데이터를 랜덤하게 발생시켜 그 중 140개를 학습데이터로 사용하였으며, 나머지 60개의 데이터를 테스트 데이터로 사용하였다. 또한, 랜덤하게 얻은 200개의 입력 데이터 집합에서 그림 7의 화이트 가우시안 노이즈를 갖는 데이터를 입력으로 사용하여 제안된 모델의 노이즈에 대한 유연성을 평가한다.

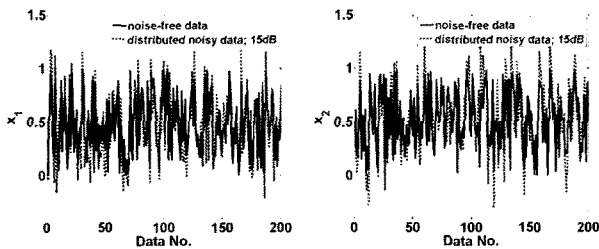


그림 7. 오리지널 Synthetic 데이터와 노이즈를 갖는 Synthetic 데이터  
Fig 7. Original synthetic input data set and input data set that have noise

표 2는 식 (23)에서 랜덤하게 발생된 200개의 noise-free data와 15dB의 화이트 가우시안 노이즈를 갖는 입력  $x_1$ 과  $x_2$ 를 제안된 모델에 적용했을 경우 각 모델에 대한 성능 비교를 나타낸다. 여기서, 각 모델은 입력마다 3개의 멤버쉽을 사용함으로써 9개의 규칙을 갖는 모델을 설계하였으며, 성능지수는 식 (21)의 mean square error에 의한다.

표 2. Synthetic 데이터에 의한 실험 결과  
Table 2. Experiment result by synthetic data set

모델 입력	모델 타입	PI	EPI	파라미터		
				$\theta$	$\eta$	$\alpha$
noise-free data	Type-1	0.6122	0.4858	-	0.0226	0.9830
	Type-2	0.4818	0.4327	0.4150	0.2118	0.3451
distributed noisy data	Type-1	0.8771	1.1994	-	0.4209	0.6107
	Type-2	0.7984	1.1561	0.3952	0.6528	0.4508

표 2의 실험 결과로부터 기존 Type-1 모델보다 제안된 Interval Type-2 모델의 근사화 성능 및 일반화 성능이 우수함을 알 수 있다. 여기서, 오리지널 데이터 집합 뿐만 아니라, 노이즈에 의해 훼손된 데이터를 사용하여 실험했을 때에도 근사화 및 일반화 성능에서 적은 오차를 보여줌으로서

기존의 Type-1 모델보다 노이즈에 유연함을 알 수 있다.

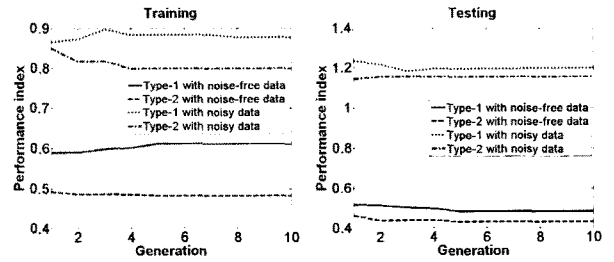


그림 8. 세대수 증가에 따른 모델 오차  
Fig 8. The model error by generation increase

그림 8은 세대수 증가에 따른 각 모델의 근사화 성능과 일반화 성능을 나타낸다.

### 3.2 Mackey-Glass time series dataset

Mackey-Glass 시계열 공정 데이터는 예측 알고리즘의 성능 평가를 위한 대표적인 예로서 사용되는 데이터이다 [10]. 특히 Mackey-Glass 시계열 공정은 비선형 시스템으로부터 발생되는 카오스 신호의 일종으로 신호의 복잡성으로 인해 랜덤 시계열(Random Time Series)처럼 보일 수 있으나 식 (24)와 같은 비선형 동역학 방정식에 의해 생성된다.

$$x(t) = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (24)$$

이 시계열의 미래값 예측은 많은 연구 결과에 대한 성능 평가의 척도가 되고 있다. 기존의 방법들과 비교를 위해 논문에서는 미래값  $x(t+6)$ 의 예측 성능을 알아본다. Mackey-Glass 시계열 공정 데이터는  $x(t)$ 로부터 입출력 데이터 쌍 1000개를 구하였다. 여기서 데이터 발생 초기에는 과도영역(Transient Region)이 존재하므로  $t=118$ 에서  $t=1117$ 까지 1000개의 데이터를 추출하였다. 제안된 모델의 학습을 위해  $x(118)$ 부터  $x(617)$ 까지 500개의 시계열 데이터를 사용하였고, 예측 성능의 평가를 위해  $x(618)$ 부터  $x(1117)$ 까지 500개의 시계열 데이터를 예측치와 비교하였다. 표 2는 본 논문에서 사용된 입출력 관계를 표로 나타낸 것이다.

표 3. Mackey-Glass 시스템 입력변수  
Table 3. Mackey-Glass system's input vector formats

입출력 관계	Input and Output
4입력 1출력	$[x(t-18), x(t-12), x(t-6), x(t); x(t+6)]$

이전의 결과 마찬가지로, 노이즈에 대한 모델의 성능을 평가하기 위해 화이트 가우시안 노이즈를 갖는 시스템을 사용하여 실험하였다.

그림 9는 오리지널 입력 데이터와 노이즈가 포함된 입력 데이터에 의한 출력을 나타낸다.




그림 9. 오리지널 데이터와 노이즈를 갖는 데이터  
Fig 9. Original data and distributed noisy data

표 3은 Mackey-Glass 시계열 데이터에 대한 실험 결과를 보여준다. 여기서, 각 입력변수마다 2개의 멤버십을 사용하여 16개의 규칙으로 구성된 모델을 설계하였으며, 성능지수는 식 (22)의 root mean square error에 의한다.

임의의 데이터 집합에 의한 실험과 동일한 실험 결과를 표 3을 통하여 볼 수 있다. 표 3으로부터 알 수 있듯이 오리지널 시스템 입력(noise-free data)을 사용했을 경우 기존의 Type-1 모델보다 제안된 Interval Type-2 모델이 적은 오차를 보였을 뿐 만 아니라, 노이즈가 포함된 데이터를 사용하였을 때에도 근사화 성능은 물론 일반화 성능에서도 실제 출력과 비교하여 적은 오차를 보였다. 그림 10은 노이즈를 갖는 데이터를 제안된 모델에 적용하여 얻은 모델의 출력을 나타낸다.

표 4. Mackey Glass 데이터에 의한 실험 결과  
Table 4. Experiment result by Mackey-Glass data set

모델 입력	모델 타입	PI	EPI	파라미터		
				$\theta$	$\eta$	$\alpha$
noise free data	Type 1	0.0617	0.0606	-	0.0880	0.2864
	Type 2	0.0469	0.0467	0.3441	0.3428	0.5815
distributed noisy data	Type-1	0.1036	0.0967	-	0.0297	0.3028
	Type-2	0.0984	0.0938	0.3676	0.1738	0.0000

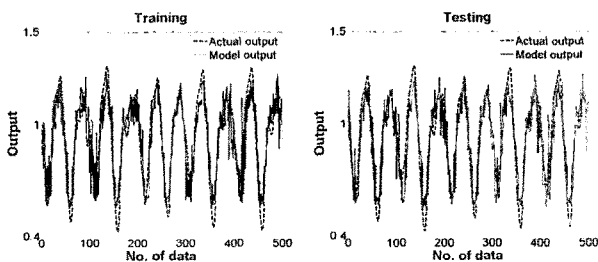


그림 10. 실제출력과 Interval Type-2 모델 출력 비교  
Fig 10. Comparison of actual output and model output of Interval Type-2

#### 4. 결 론

본 논문은 데이터의 불확성을 멤버십 함수로 표현 할 수 있는 Interval Type-2 퍼지 로직 시스템을 설계하고, 실제 노이즈를 갖는 비선형 실험 데이터를 사용하여 Type 2 퍼지 로직 시스템의 우수성을 증명 하였다. 따라서, 노이즈에 취약한 실제 공정에서 보다 유연한 적용을 기대 할 수 있겠다.

#### 참 고 문 헌

- [1] L. A Zadeh, "The concept of a linguistic variable and its application to approximate reasoning-1", *Information Sciences*, vol. 8, pp. 199-249, 1975.
- [2] J. M. Mendel, "Uncertain Rule-Based Fuzzy Logic System: Introduction and New Directions", Prentice-Hall, Upper-Saddle River, Nj, 2001.
- [3] J. M. Mendel, "Advances in type-2 fuzzy sets and systems", *Information Sciences*, vol. 177, pp. 84-110, 2007.
- [4] J. M. Mendel, R. I. John, and F. Lui, "Interval type-2 fuzzy logic system made simple", *IEEE Trans. on Fuzzy System*, vol. 14, pp. 808-821, Dec. 2006.
- [5] S. Coupland and R. I. John, "Towards more efficient type-2 fuzzy logic system", *Proc. IEEE FUZZ Conf.*, pp. 236-241, Reno, NV, May 2005.
- [6] J. T. Starczewski, "A triangular type-2 fuzzy logic system", *Proc. IEEE-FUZZ 2006*, pp. 7231-7238, Vancouver, CA, July 2006.
- [7] J. Kennedy, "Minds and cultures: Particle Swarm implications. Socially Intelligent Agents", *Paper from the 1997 AAI Fall Symposium*, 1997.
- [8] N. N. Karnik and J. M. Mendel, "Centroid of a type-2 fuzzy set", *Information Sciences*, vol. 132, pp. 195-200, 2001.
- [9] Richard O. Duda, Peter E. Hart, David G. Stork, "Pattern Classification : Second Edition", John Wiley&Sons, INC., 2000.
- [10] M. C. Mackey and L. Glass, "Oscillation and chaos in physiological control systems", *Science* 197:287-289, 1977.

#### 저 자 소개



백진열 (Jin-Yeol Baek)  
 2007년 : 수원대 전기전자공학과 졸업.  
 2007년~현재 : 동 대학원 전기공학과 석사과정.  
 관심분야 : 퍼지 추론 시스템, 신경회로망, 최적화이론, 마이크로프로세서 등.

Phone : (031) 222-6544  
 E-mail : qorwlsdud@suwon.ac.kr



이영일(Young-II Lee)

1980년: 연세대학교 전자공학과 졸업.  
1996년: 퍼듀 대학원 전기공학과 졸업  
(공학박사).  
1997년~현재: 수원대학교 전기공학과  
교수.

관심분야 : 전력시스템, 전자회로 및 퍼지시스템 등.

Phone : (031) 220-2584

E-mail : leeyi@suwon.ac.kr



오성권(Sung-Kwun Oh)

1981년: 연세대학교 전기공학과 졸업.  
1983년: 동 대학원 전기공학과 졸업  
(공학석사)  
1983~1989년: 금성산전연구소  
(선임연구원).

1993년: 연세대 대학원 전기공학과 졸업  
(공학박사).

1996~1997년: 캐나다 Manitoba대학 전기 및 컴퓨터공학과 Post-Doc.

1993~2005년: 원광대 전기전자 및 정보공학부 교수.

2005년~현재: 수원대 전기공학과 교수.

2002년~현재: 대한전기학회, 한국지능시스템학회 및 제어  
자동화시스템 공학회 편집위원.

관심분야 : 시스템 자동화, 퍼지이론, 신경회로망 응용 및  
제어, 컴퓨터 지능 등.

Phone : (031) 229-8162

E-mail : ohsk@suwon.ac.kr