

## 다중모델기법을 이용한 비선형시스템의 퍼지모델링

이 철 희\* · 하 영 기\*\* · 서 선 학\*\*\*

### Fuzzy Modeling for Nonlinear System Using Multiple Model Method

Lee, Chul-Heui\* · Ha, Young-Ki\*\* · Seo, Seon-Hak\*\*\*

#### ABSTRACT

In this paper, a new approach to modeling of nonlinear systems using fuzzy theory is presented. To express the various and complex behavior of nonlinear system, we combine multiple model method with hierachical prioritized structure, and the mountain clustering technique is used in partitioning of system. TSK rule structure is adopted to form the fuzzy rules, and Back propagation algorithm is used for learning parameters in consequent parts of the rules. Also we soften the paradigm of Mamdani's inference mechanism by using Yager's S-OWA operators. Computer simulations are performed to verify the effectiveness of the proposed method.

#### 1. 서 론

물리계 대부분의 시스템은 비선형성을 포함하고 있으나 비선형성에 대한 수학적 모델링 및 취급이 까다롭기 때문에 선형시스템으로 근사화하여 모델링하고 제어기를 설계하는 경우가 많다.

즉 공칭점(동작점)부근에서 선형화하여 모델링하고 이에 대한 선형제어기를 설계하는 방법이다. 그러나 이러한 접근은 대상의 불확실성, 동작환경의 변화등에 효과적으로 대처하기가 쉽지 않다. 이를 해결하기 위하여 적응제어, 가변구조 시스템 제어, 다중모델기법등의 방법들이 사용되었으나 정량적 모델 확보의 어려움이 있다.

따라서 정량적 수학적 접근이 어려운 비선형 시스템에 대해서는 Zadeh의 부적합성의 원리에서 지

적하고 있는 것처럼 시스템의 정성적 특성을 이용하여 정량적 모델이 필요치 않으면서도 좋은 결과를 보여주고 있는 퍼지이론을 시스템의 모델링 및 제어에 활용하는 것이 더 바람직하다.

퍼지 모델링 및 제어에서는 "IF-THEN-" 형태의 언어적 규칙을 이용하여 시스템을 표현, 제어하게 되므로 정량적 모델이 필요치 않으며 다수의 규칙을 병렬형으로 나열한 규칙기반이 이용되므로 내재적으로 가변구조기법 또는 다중모델기법의 개념을 포함하고 있다고 볼 수 있다. 또한 규칙과 소속 함수의 설정과 관련한 학습능력의 부여로 적응기법의 기능도 구현이 가능하다. 이렇게 퍼지를 이용할 경우 입력변수의 퍼지화, 퍼지 규칙 기반의 생성, 소속함수와 언어변수의 설정, 추론 메카니즘과 비퍼지화 기법의 선정등이 필요하게 된다.

그런데 비선형성의 정도가 심하여 동작특성을 몇 가지 경우로 나누어 표현하는 것이 훨씬 좋은 결과를 보일 수 있는 경우에는 전체적인 퍼지 규칙기반을 단일화하여 표현하게 되면 규칙기반의 크기가 너무 커질뿐만 아니라 규칙간의 일관성유지도 어려워지고 추론시간도 오래걸리고 복잡해지는 등

\* 강원대학교 전기공학과 부교수

\*\* 강원대학교 전기공학과 석사과정

\*\*\* 강원대학교 전기공학과 박사과정

의 문제점을 보이게 된다. 따라서 동작특성에 따라 적절히 분할된 다중모델로 비선형 시스템을 표현하는 것이 좋다.

또한 다중모델기법[7][8]을 이용한 규칙기반의 구성에 있어서 동일한 모델의 규칙기반내 일자라도 비선형 시스템의 특성을 반영한 규칙들이 동일한 확신도를 가지고 있다고 볼 수 있으므로 규칙의 특정도를 고려한 규칙기반 구조가 필요하다.

따라서 본 논문에서는 시스템의 특성이나 환경변화에 따라 여러개의 모델을 설정하여 추정 및 제어를 구현하는 다중모델기법과 규칙의 특정도를 고려한 계층순위구조(Hierarchical Prioritized Structure)[10][21]를 퍼지모델링 및 제어에 결합시켜 효과적인 비선형 시스템의 모델링 및 제어방법을 제안하였다.

다중모델기법을 도입할 경우 최우선적인 문제는 모델의 분할인데 본 논문에서는 입출력 공간에서 관측데이터의 퍼지 클러스터링기법인 Mountain Clustering (MC)[22][25]기법을 사용하였다. 모델 분할에 이용된 Mountain Clustering(MC)기법은 기존의 FCM(Fuzzy C-Mean)과 같은 클러스터링 기법의 난점인 초기 클러스터중심의 설정등과 같은 문제가 필요없는 간단한 기법이며 단지 그리드 분할을 통한 마운틴 함수값의 계산을 통해서 클러스터 중심을 구할 수 있다.

TSK형 규칙의 생성에는 전건부를 위한 퍼지공간 분할과 후건부 파라미터의 결정이 필요한데 퍼지 공간 분할에는 MC를 활용할 수 있으며, 후건부 파라미터의 결정에는 오차역전파 방법을 이용하였다.

추론메카니즘에는 계층순위구조에의한 단계적 추론이 가능하도록하고 여러가지 추론기법이 파라미터값의 조정을 통하여 하나의 프레임하에 가능하도록 Yager의 S-OWA연산자를 이용하여 유연성을 부여하였다.

## 2. 다중모델 계층순위구조 규칙 기반의 구성

### 2.1 다중모델기법

다중모델의 궁극적인 목적은 시스템의 특성이나 환경변화에 잘 대처하고 각 모델을 효율적으로 이용하기 위함이다. 또한 다중모델기법은 전체 시스템의 동특성 변화와 같은 요인의 영향을 적게 받는 장점을 가지고 있다.

그러나 이 경우 시스템을 몇 개의 모델로 분할

설정하고 이들 모델로부터 전체 시스템의 출력을 어떻게 결정할 것인가 하는 것이 문제가 된다.

본 논문에서는 모델의 분할 설정 문제는 입출력 데이터의 clustering을 통하여, 출력의 결정은 계층 순위구조에 의한 퍼지 추론 메카니즘을 통하여 해결하도록 하였다.

우선 입출력 공간에서 데이터의 특성의 유사성에 의해 clustering하여 다중 모델로 나누고 cluster중심을 각 모델(부시스템)의 공칭점으로 고려하여 각 부시스템에 대해 다음과 같이 TSK 형태의 규칙으로 시스템 특성을 모델링하게 된다.

IF  $x_1$  is  $A_{11}$ ...and  $x_n$  is  $A_{n1}$  THEN  $y = f_i(x_1, \dots, x_n)$

일반적으로 함수  $f_i$ 는 선형함수를 이용하게 된다. 이 경우 위의 규칙은 입출력 공간에서 시스템의 특성을 선형근사화한 것과 유사해진다. 따라서 최종적인 모델은 다수의 규칙에 의해 서로 선형 근사모델들의 집합 형태가 된다.

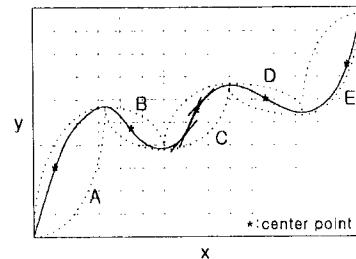


Fig. 1. Partitioning Of Model

그림 1은 다중모델분할 예를 간략히 도시화한 것으로 A, B, C, D, E의 다섯 개의 모델로 분할하였다. 각 모델에 있는 '\*'는 모델분할을 위해 구해진 클러스터 중심을 나타내며 공칭점으로 고려한다. 또한 모델 C에 있는 직선은 각 구간을 선형화하여 모델링하는 것을 보여주고 있다.

다중 모델을 얻기 위한 clustering 기법으로는 여러 가지 clustering 기법을 적용할 수 있으나 [2,3] 여기서는 뒤에서 설명하게 될 mountain clustering 기법을 적용한다.

모델분할에 있어서 또하나 고려해야 할 사항은 각 모델간의 경계가 되는 부분을 어떻게 처리하는가의 문제이다. 첫 번째 방법은 각 모델의 경계를 disjoint 하게 분할하는 것이다. 두 번째는 경계의 일정부분을 서로 overlap시키는 것으로 출력을 결정할 때 이부분을 따로 고려해 주어야 한다.

### 2.2 계층순위구조

그런데 규칙기반의 구축에 있어서 모든 규칙들이 동일한 신뢰도를 가질 경우 불만족스런 결과를 도출할 수 있다.

실제로 비선형 시스템의 경우 공통점에서는 정확한 특성이 주어질 수 있지만 그 부근에서는 선형으로 근사화된 결과만 주어지게 되므로 아주 특정한 규칙과 그렇지 않은 규칙들이 혼재하게 된다. 따라서 규칙들을 그 특정한 정도에 따라 몇 개의 레벨로 나누고 순위를 부여함으로써 계층적 구조를 갖게 하여 입력데이터의 레벨별 부합도에 맞추어 출력에 대한 기여도가 결정되게 하는 계층순위구조를 도입하는 것이 바람직하다.[8]

그림 2는 계층순위구조의 계층적 구조를 보여주고 있으며, 각 레벨의 출력은 전 레벨의 출력과 입력에 의해서 결정된다. 따라서 입력이  $x$ , 각 레벨의 룰의 집합을  $f_i$ 라 하면 출력  $y_i$ 는 다음의 형태로 나타낼 수 있다.

$$y_i = f_i(x)$$

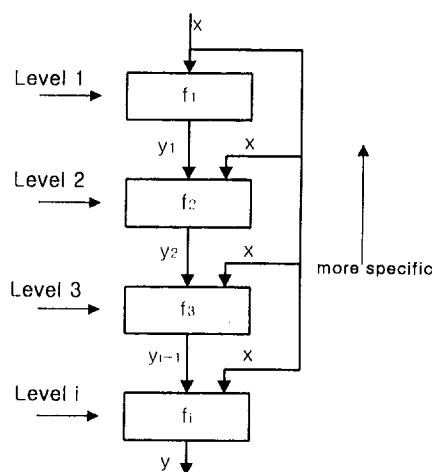


Fig. 2. Hierarchical Prioritized Structure(HPS)

또한 각 레벨에 위치하는 규칙은 위로 갈수록 특정도가 크다. 따라서 제일 상위 레벨에서 만족시키지 못한 부분은 하위레벨에서 보상하여 준다.

만약 각 레벨의 규칙들에 의한 출력값의 연산결과가  $B_i$ 라 하면 그 레벨의 출력  $y_i$ 는 아래와 같이 계산된다.

$$y_i = y_{i-1} \cup B_i$$

퍼지 clustering에 의해 다중모델로 표현된 비선형시스템의 각 모델의 계층순위구조 형태의 퍼지

규칙기반에서 제일 상위 레벨은 mountain clustering에 의해 얻어진 cluster 중심, 즉 그 부시스템의 공통점 또는 다른 몇 개의 특정 점에서 규정되는 시스템 특성을 표현한 퍼지규칙들로 구성되고, 하위 레벨로 내려갈수록 이들 특정점을 중심으로 한 구간을 확대시키며 얻은 TSK형태의 규칙들로 구성되며, 제일 하위 레벨들은 각 부시스템들 일부 또는 전부에 공통되는 규칙들에 의해 구성되도록 규칙을 생성시킨다. 따라서 특정한 규칙이 만족되지 않으면 계층순위구조에 의해 점점 시스템 전체에 보편적인 규칙들에 의해 출력을 결정하게 되는 특성을 지니게 된다.

### 2.3 Mountain Clustering

mountain clustering기법은 눈금(grid)분할에 기초한 cluster중심의 근사식별 기법으로서 다음과 같은 세단계로 나누어진다.

첫 단계에서는 초기화를 위하여 잠재적인 cluster 중심을 선정하는 단계로서 입출력 공간을 직선으로 적당하게 분할하여 생긴 눈금의 교차점을 잠재적인 cluster중심의 후보로 설정한다. 이때 입력과 출력 공간의 눈금분할은 등간격을 사용할 수도 있고 데이터의 특성에 따라 다르게 할 수도 있다. 두 번째 단계에서는 데이터를 이용해 모든 잠재적인 cluster 중심의 후보의 mountain 함수를 계산하여 첫 번째cluster 중심을 찾고, 마지막 단계로 선정된 cluster중심의 영향을 상쇄시키는 mountain 함수의 봉괴과정을 통하여 다른 cluster 중심을 찾아내는 과정을 축차적으로 진행하게 된다.

입출력 공간  $X \times Y$ 에서  $K$ 개의 데이터  $O_k(x_k, y_k)$ 가 주어지고  $N (=r_1 \times r_2)$ 개의 눈금 교차점  $N_{ij}(X_i, Y_j)$ 으로 분할한 경우를 생각하자. 교차점  $N_{ij}$ 에 대해 mountain 함수는 다음과 같이 정의된다.

$$M(N_{ij}) = \sum_{k=1}^K e^{-(\alpha d(N_{ij}, O_k))} \quad (1)$$

$$d(N_{ij}, O_k) = (X_i - x_k)^2 + (Y_j - y_k)^2 \quad (2)$$

위에서 알 수 있듯이 데이터가 교차점에 가까울수록 mountain함수에 큰값으로 기여하게 된다. 즉 mountain함수의 값이 클수록 cluster중심이 될 가능성이 커지게 된다. 따라서 mountain함수의 값이 가장 큰 교차점을 첫 번째 cluster 중심  $C_1^*$ 로 잡은 뒤 다음 cluster 중심을 구하기 위하여 원래의 mountain함수 값에서 각 교차점과  $C_1^*$  사이의 거리에 반비례하는 양을 빼주어  $C_1^*$ 에 의한 다른 교차점에 대한 영향을 감쇄시킨다. 이렇게 mountain 함수의 봉괴과정을 거친 새로운 mountain 함수를

$M_2$ 라고 하면

$$M_2(N_{ij}) = M_1(N_{ij}) - M_1^* e^{-\beta d(C_1, N_{ij})} \quad (3)$$

가장 큰  $M_2$ 값을 갖는 교차점을 두 번째 cluster 중심  $C_2^*$ 로 선정한다.

축차적으로 이 과정을 진행하게 되면 k번째에는 다음과 같이 된다.

1.  $M_k^* = \text{Max}\{M_k(N_{ij})\}$  를 구한다.
2.  $M_k^*$ 에 대응되는 교차점을 k번째 cluster 중심  $C_k^*$ 로 둔다.
3.  $M_{k+1}(N_{ij}) = M_k(N_{ij}) - M_k^* e^{-\beta d(C_k^*, N_{ij})}$  를 구한다.

mountain 함수의 붕괴는  $M_{k+1}^* < \delta$  를 만족할 때까지 진행된다.

#### 2.4 파라미터 학습

다중모델기법과 계층순위구조를 결합한 형태로 비선형 시스템을 퍼지모델링하게 되면 남는 문제는 퍼지 입출력 공간의 분할과 소속함수의 설정, TSK형태 규칙의 후건부 함수  $f_i$ 의 계수 파라미터의 결정 등이다. 공간의 분할에는 앞절의 mountain clustering 또는 퍼지 C-means 등과 같은 퍼지 clustering기법이나, 신경망이나 유전알고리즘 등을 이용할 수 있고, 소속함수의 학습과  $f_i$ 의 계수 파라미터의 결정에도 신경망이나 유전알고리즘 등을 적용하면 된다.[2,3]

많은 경우에 신경망을 이용한 학습 등에 이용되는 Back propagation을 적용하여 파라미터 학습을 시킬 수 있다. TSK형 규칙이 아래와 같을 경우에

IF  $u_1$  is  $B_{i1}$  AND ... AND  $u_r$  is  $B_{ir}$   
THEN  
 $y_i = b_{io} + b_{i1}u_1 + \dots + b_{ir}u_r, \quad i(=1, m)$

TSK의 출력은 다음과 같다.

$$y = \frac{\sum_{i=1}^m \tau_i (b_{io} + b_{i1}u_1 + \dots + b_{ir}u_r)}{\sum_{i=1}^m \tau_i} \quad (4)$$

$$\tau_i (= B_{i1}(u_1) \wedge B_{i2}(u_2) \wedge \dots \wedge B_{ir}(u_r))$$

$$= \exp\left(-\frac{1}{2} \sum_{j=1}^r \left(\frac{u_j - x_{ij}^*}{\sigma_{ij}}\right)^2\right)$$

$$B_{ij}(u_j) = \exp\left(-\frac{1}{2} \left(\frac{u_j - x_{ij}^*}{\sigma_{ij}}\right)^2\right)$$

전건부 멤버쉽 함수가 Gaussian형태를 갖고 MIN 연산자를 곱연산자로 바꾸면 아래와 같은 식이 된다.

$$y = \frac{\sum_{i=1}^m \left[ \exp\left(-\left(\frac{1}{2} \sum_{j=1}^r \left(\frac{u_j - x_{ij}^*}{\sigma_{ij}}\right)^2\right)\right] (b_{io} + b_{i1}u_1 + \dots + b_{ir}u_r)}{\sum_{i=1}^m \left[ \exp\left(-\left(\frac{1}{2} \sum_{j=1}^r \left(\frac{u_j - x_{ij}^*}{\sigma_{ij}}\right)^2\right)\right]\right]} \quad (5)$$

$$v_i = \frac{\tau_i}{\sum_{i=1}^m \tau_i} = \frac{\left[ \exp\left(-\left(\frac{1}{2} \sum_{j=1}^r \left(\frac{u_j - x_{ij}^*}{\sigma_{ij}}\right)^2\right)\right]\right]}{\sum_{i=1}^m \left[ \exp\left(-\left(\frac{1}{2} \sum_{j=1}^r \left(\frac{u_j - x_{ij}^*}{\sigma_{ij}}\right)^2\right)\right]\right]} \quad (6)$$

학습시켜야 할 파라미터는  $x_{ij}^*$ ,  $\sigma_{ij}$ ,  $b_{io}, \dots, b_{ij}$ 이며, 퍼지모델의 출력( $y$ )과 현재출력( $y_k$ )사이의 에러를 구하여 최소화하는 것이 목적이므로 각 파라미터의 학습은 아래와 같이 진행된다.

Backpropagation 파라미터 학습식은 다음식에 의하여 개선된다.

$$b_{io}(k+1) = b_{io}(k) - \alpha \frac{\partial E_k}{\partial b_{io}} \quad (6)$$

여기에서  $E_k$ 는 아래와 같다.

$$E_k = \frac{1}{2} (y - y_k)^2$$

$$= \frac{1}{2} \left( \sum_{i=1}^m v_i (b_{io} + b_{i1}u_1 + \dots + b_{ir}u_r) - y_k \right)^2 \quad (7)$$

따라서  $b_{io}$ 의 학습식은 아래와 같다.

$$b_{io}(k+1) = b_{io}(k) - \alpha v_i e \quad (8)$$

이와 마찬가지로  $b_{ij}$ 는 아래와 같은 식으로부터 구할 수 있다.

$$b_{ij}(k+1) = b_{ij}(k) - \alpha v_i e u, \quad (9)$$

또한  $x_{ij}$ ,  $\sigma_{ij}$ 값도 아래와 같이 구할 수 있다.

$$\begin{aligned} x_{ij}^*(k+1) &= x_{ij}^*(k) - \alpha \frac{\partial E_k}{\partial x_{ij}^*} \\ &= x_{ij}^*(k) - \alpha v_i(b_{i0} + b_{i1}u_1 + \dots + b_{ir}u_r - y) e^{-\frac{(u_i - x_{ij}^*(k))^2}{\sigma_{ij}^2(k)}} \end{aligned} \quad (10)$$

$$\begin{aligned} \sigma_{ij}(k+1) &= \sigma_{ij}(k) - \alpha \frac{\partial E_k}{\partial \sigma_{ij}} \\ &= \sigma_{ij}(k) - \alpha v_i(b_{i0} + b_{i1}u_1 + \dots + b_{ir}u_r - y) e^{-\frac{(u_i - x_{ij}^*(k))^2}{\sigma_{ij}^2(k)}} \end{aligned} \quad (11)$$

윗식에서  $\alpha$ 는 학습률(learning rate)을 나타내며, 보통  $0 \leq \alpha \leq 1$  사이의 값을 갖는다. 학습률을 잘못 선택하면 수렴하지 않거나 훈련하는데 시간이 너무 오래 걸릴 수 있으므로 잘 선택해야 한다.

실제 학습시  $x_{ij}^*$ ,  $\sigma_{ij}$ ,  $b_{i0}, \dots, b_{ir}$ 의 초기 값은 각각 초기 클러스터 중심의  $x$ 좌표값,  $\sigma_{ij} = \sqrt{\frac{1}{2\beta}}$ , 후진부 합수의 파라미터들은 0을 이용한다. 여기서  $\beta$ 는 MC에서 이용되는 값이다.

위의 학습과정을 순차적인 블록도를 이용하여 나타내면 아래와 같다.

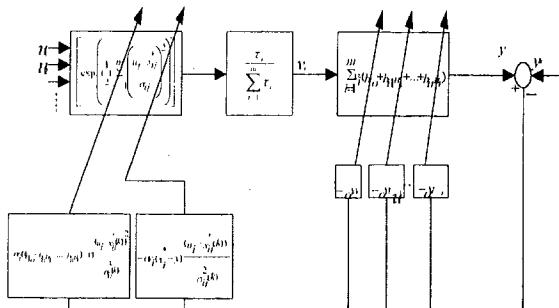


Fig. 3. Block Diagram Of Backpropagation

### 3. 유연구조 추론 메카니즘

2장에서 설명한 다중모델기법과 계층순위구조를 결합한 퍼지 모델링은 비선형 시스템의 퍼지제어기를 구성하기 위한 퍼지 규칙기반의 구성에 활용된다. 퍼지 규칙기반이 구해지면 퍼지추론과 비퍼지화 과정을 거쳐 출력을 발생하게 된다. 퍼지규칙기반의 구축에 계층순위구조를 적용하였으므로 추론과정도 달라지게 된다.

보통의 퍼지제어기와는 달리 모든 규칙에 대해

추론이 진행된 후에 비퍼지화 과정을 거쳐서 제어기의 출력이 결정되는 것이 아니라 규칙기반의 각 레벨별로 출력의 값이 순차적으로 결정되어 제일 하위 단계를 거치면 시스템의 전체 출력이 나오게 된다.

i번째 레벨의 j번째 규칙의 점화수준을  $\tau_{ij}$ 라고 하면

$$\tau_{ij} = \bigwedge \mu_{A_j^k}(x_k) \quad (12)$$

i번째 레벨의  $n_i$ 개의 규칙에 의한 출력  $T_i$ 는 다음과 같이 된다.

$$T_i = \bigcup_{j=1}^{n_i} \tau_{ij} \wedge f_{ij} \quad (13)$$

그러면 i번째 레벨의 최종적인 출력은 그 전 레벨의 출력과  $T_i$ 로부터 데이터 입력의 부합도를 고려하여 구해지게 된다.

i번째 레벨의 출력  $V_i$ 가  $G_i$ 로 주어질 때 이에 대한 입력 데이터의 부합도를  $g_i$ 라 하고 다음과 같이 정의하자.

$$g_i = \max \mu_{G_i}(y) = Possibility(G_i) \quad (14)$$

그러면 i번째 레벨의 출력  $G_i$ 는

$$G_i(y) = (T_i(y) \wedge low(g_i)) \vee G_{i-1}(y) \quad (15)$$

위에서 볼 수 있듯이 입력데이터의 부합도  $g_i$ 가 i번째 레벨의 전체 출력에 대한 기여도를 규정하게 된다. 그러므로 이를 적절히 반영할 수 있도록 식 (15)의 low함수로는 다음의 형태를 사용할 수 있다.

$$low(g_i) = 1 - g_i \quad (16)$$

그러면 만약  $g_i$ 가 1이 될 경우 식(15)로부터 다음 레벨부터는 전혀 출력에 기여하지 못함을 알 수 있다.

각 레벨의 식 (13),(15)에 사용되는 퍼지 연산자들은 Mamdani의 최대최소법 등 일반적인 방법을 활용할 수 있는데, Yager의 S-OWA연산자를 이용, 완화시킴으로써 유연성을 갖는 퍼지 추론이 가능하다.[9]

규칙 aggregation의 완화에는 다음과 같이 정의되는 S-OWA-OR 연산자를 사용할 수 있다.

$$\vee_i a_i = (1-\beta) \frac{1}{m} \sum_{i=1}^m a_i + \beta a_{\max}, \quad 0 \leq \beta \leq 1 \quad (17)$$

S-OWA-OR연산자는 OR정도가  $\beta$ 에 종속적인 orlike aggregation으로서,  $\beta$ 값의 선정에 따라 유연한 추론 결과를 얻을 수 있다.  $\beta=1$ 인 경우, 순수한 Max연산자가 되어 Mamdani의 추론 방법과 동일하게 된다.

규칙 점화의 완화에는 다음과 같이 정의되는 S-OWA-AND 연산자를 사용할 수 있다.

$$\wedge_i a_i = (1-\alpha) \frac{1}{m} \sum_{i=1}^m a_i + \alpha a_{\min}, \quad 0 \leq \alpha \leq 1 \quad (18)$$

S-OWA-AND 연산자는 AND정도가  $\alpha$ 에 종속적인 andlike aggregation으로서,  $\alpha$ 값의 선정에 따라 유연하게 규칙의 점화수준을 결정할 수 있다.  $\alpha=1$ 인 경우, 순수한 Min연산자가 되어 Mamdani의 추론방법과 동일하게 된다.

전-후건부 결합의 완화에는 다음과 같이 정의되는 S-OWA-PRODUCT 연산자를 사용할 수 있다

$$\prod_i a_i = (1-\gamma) \frac{1}{m} \sum_{i=1}^m a_i + \gamma \prod_i a_i, \quad 0 \leq \gamma \leq 1 \quad (19)$$

(14)에서 보면  $\gamma$ 에 의해 입력 퍼지 cell과 출력 퍼지 집합의 결합 정도가 제어된다.  $\gamma=1$ 의 경우 최소가 되며,  $\gamma=0$ 의 경우 최대가 된다. Mamdani 추론법에 해당되는  $\gamma$ 값은 간단한 과정을 거쳐 쉽게 계산할 수 있다.

## 4. 모의실험 및 결과

### 4.1 모델링

본 논문에서는 아래와 같은 비선형식을 이용하여 수치적인 모의실험을 수행하였으며 noise는 표준 편차 0.05이다.

$$y = \frac{x^3 + x^2}{x^6 + x^4 + 3} + \text{noise}$$

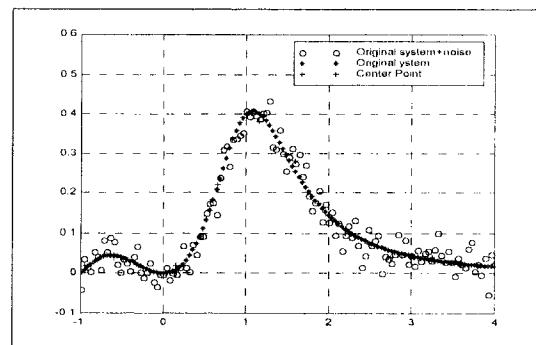


Fig. 4. Cluster Center Points

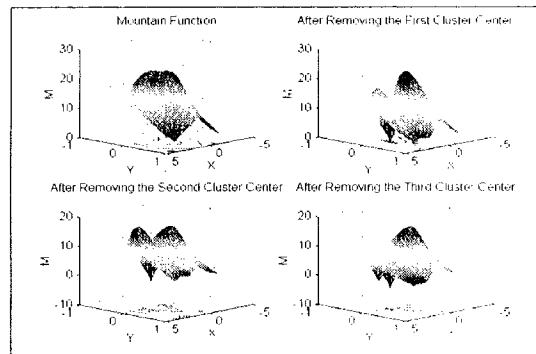


Fig. 5. Mountain Function

그림 4.에서 횡축은 x를 종축은 y를 나타낸다. 그리고 '+'기호는 클러스터링에 의해서 구해진 중심점이다. 그림 5.는 마운틴 클러스터링을 수행하면서 구해진 마운틴 함수를 도시한 것으로 두번째 그림을 자세히 보면 첫번째 함수값이 가장 커었던 좌표점이 가장 작아지는 것을 알 수 있다. 역시 세번째, 네번째 그림도 마찬가지이다.

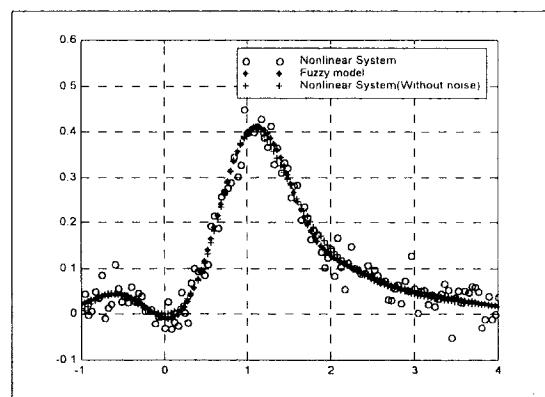


Fig. 6. The Result Of Fuzzy Modeling

그림 6.은 파라미터 학습 후 모델링한 결과이며 노이즈가 포함된 데이터로부터 원래의 시스템을 잘 모델링함을 알 수 있다.

#### 4.2 Inverted Pendulum Control

Pendulum의 구조는 아래와 같으며 본 논문에서 수치적인 모의실험을 수행하였다. 또한 제어상의 한계로 인하여 Pole의 각변화는  $0\sim0.8[\text{rad}]$  으로 제한 하였으며 각속도의 범위는  $0\sim0.5[\text{rad/s}]$  이다.

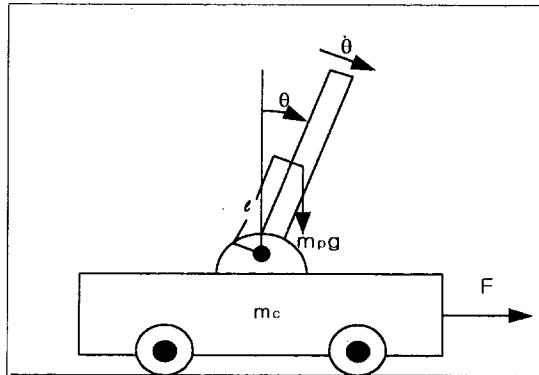


Fig. 7. Inverted Pendulum System

$$g : 9.8 \text{ [m/s}^2\text{]} \quad (\text{중력 가속도})$$

$$m_c : 0.9 \text{ [kg]} \quad (\text{차의 무게})$$

$$m_p : 0.1 \text{ [kg]} \quad (\text{폴의 무게})$$

$$l : 0.5 \text{ [m]} \quad (\text{폴의 절반길이})$$

$$F : \text{[N]} \quad (\text{차에 가해지는 힘})$$

그림 8은 제어규칙을 생성하기 위하여 경계값이 주어졌을 때 미방을 풀이하는 방법인 Shooting Method를 이용하여 얻은 제어규칙이다. 또한 두 번째 그림은 첫번째에서 얻은 규칙을 모델링한 결과이다.

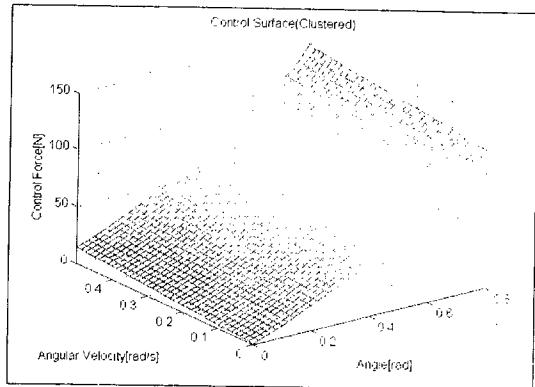


Fig. 9. Control Surface(Clustered)

모델링을 통하여 얻은 제어규칙을 이용하여 모의 실험한 결과는 아래와 같다.

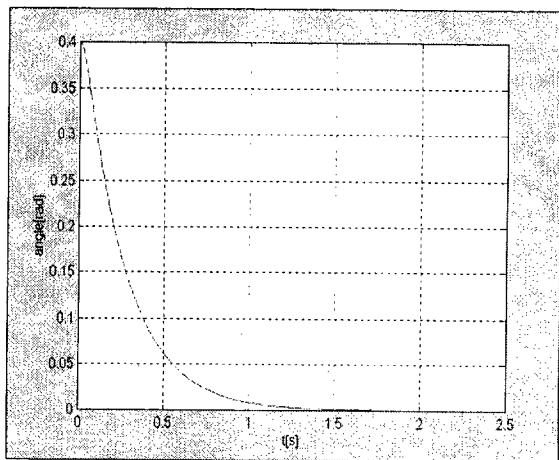


Fig. 10. Angle Of Pole

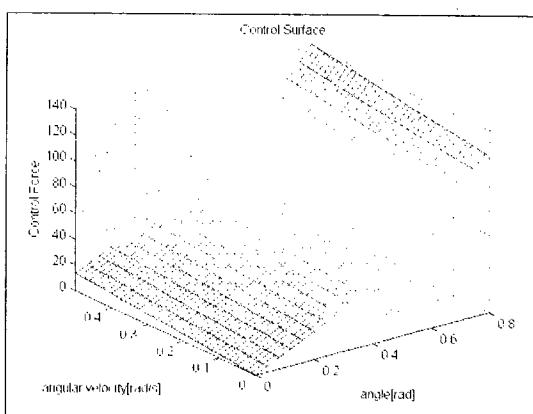


Fig. 8. Control Surface

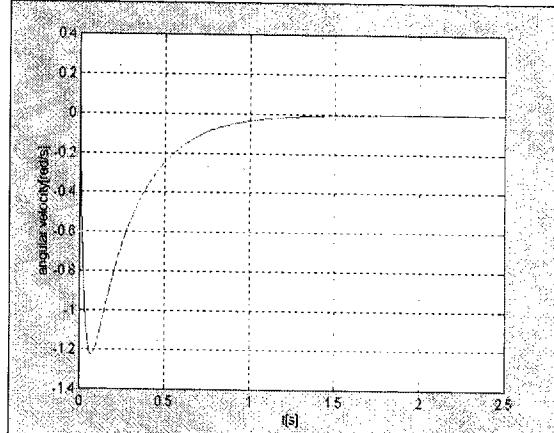


Fig. 11. Angular Velocity of Pole

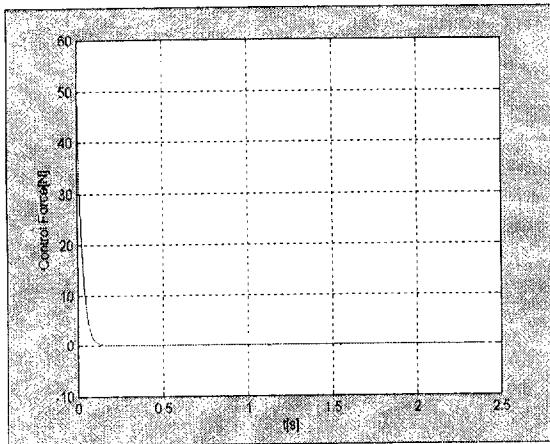


Fig. 12. Control Force

위의 결과에서 알 수 있듯이 모델링을 통하여 구득한 제어 결과를 이용하여 Pendulum의 제어를 잘 수행함을 알 수 있다. 또한 속응성에 있어서 약간의 문제점을 가지고 있지만, 이것은 모델링에서의 문제보다는 제어알고리즘상의 문제다.

## 5. 결 론

비선형 시스템은 대상의 불확실성, 동작환경의 변화 등 동작 특성의 복잡성으로 인해 모델링 및 제어가 까다롭다. 따라서 본 논문에서는 시스템의 특성이나 환경 변화에 따라 여려개의 모델을 설정하여 추정 및 제어를 구현하는 다중 모델기법을 계층순위구조와 결합시켜 효과적인 비선형 시스템의 퍼지 모델링 및 제어방법을 제안하였다. 또한 퍼지제어기의 추론 메카니즘을 Yager의 S-OWA 연산자들을 이용하여 유연성을 지니도록 완화하여 비선형 시스템의 다양성과 복잡성에 잘 대처할 수 있도록 하였다. 본 논문에서 제안된 방법은 정량적 접근이 어려운 비선형 시스템의 모델링 및 제어에 효과적으로 이용될 수 있을 것이다.

## 참 고 문 현

- [1] J.E. Slotine and W. Li, *Applied Nonlinear Control*, Prentice Hall, Englewood Cliffs, NJ, 1991
- [2] R.R. Yager and D.P. Filev, *Essentials of Fuzzy Modeling and Control*, John Wiley and Sons, New York, 1994

[3] C.T. Lin and C.S.G. Lee, *Neural Fuzzy Systems*, Prentice Hall PTR, Upper Saddle River, NJ, 1996

[4] M. Sugeno and T. Yasukawa, "A Fuzzy Logic Based Approach to Qualitative Modeling", *IEEE Trans. Fuzzy Systems*, Vol.1 pp.7-31, 1993

[5] W. Pedrycz, "Fuzzy Multimodels", *IEEE Trans. Fuzzy Systems*, Vol.4, pp.139-148, 1996

[6] W. Pedrycz, "Fuzzy Modeling: Fundamentals, Construction and Evaluation", *Fuzzy Sets and Systems*, Vol.41, pp.1-15, 1991

[7] D.G. Lainiotis, "Partitioning: A Unifying Framework for Adaptive Systems, I: Estimation", *IEEE Proc.* Vol.64, pp.1126-1143, 1976

[8] R.R. Yager, "On a hierarchical Structure for Fuzzy Modeling and Control", *IEEE Trans. Syst. Man, Cybern.*, Vol.23, pp.1189-1197, 1993

[9] 이철희, R.R. Yager, "유연성을 갖는 퍼지 추론 및 비퍼지화" 제어계측연구회 학술발표대회 논문집, 대한전기학회·전자공학회, pp.82-87, 1995