

# 전역적 성능과 지역적 성능을 동시에 고려하는 TS 퍼지 모델링 : LMI를 이용한 풀이

곽기호, 박주영  
고려대학교 제어계측공학과

## Fuzzy modeling with emphasis on both global fitting and local interpretation : An LMI approach

Kiho Kwak, Jooyoung Park  
Dept. of Control and Instrumentation Engineering, Korea University

**Abstract** - TS 퍼지 모델은 복잡한 비선형 시스템을 효과적으로 표현할 수 있는 주요한 근사 모델 중 하나이다. TS 퍼지 모델링을 위한 기준의 학습 방법론들은 대부분 전역적 근사 오차를 최소화하는 것을 목적으로 하는데, 이러한 경우에는 결과로서 얻어지는 TS 퍼지 모델의 국소모델들이 근사 대상 시스템의 국소적 특성을 제대로 표현 할 수 없는 상황이 발생할 수 있다.

따라서 본 논문에서는 이러한 특성을 고려하여 새로운 학습 알고리즘을 제시함으로써 전역·지역적 성능을 동시에 향상시킬 수 있는 TS 퍼지 모델을 구하고자 한다. 모델을 구하는데 있어서는 LMI를 이용한 풀이를 이용한다. 그리고 간단한 예제를 통하여 그 성능을 입증한다.

### 1. 서 론

일반적으로 TS 퍼지 모델링이 널리 사용되는 이유 중 하나는, 몇 개의 간단한 규칙의 결합을 통하여 복잡한 비선형 시스템을 표현할 수 있다는 장점 때문이다. 그리고 [1][6]와 같은 학습 알고리즘을 통하여 실제 시스템을 정확하게 표현할 수 있는 TS 퍼지 모델을 구할 수 있다. 하지만 대부분의 알고리즘들은 다음과 같은 전역적 목적 함수  $J$ 를 최소화하는 방법으로 퍼지모델의 매개변수를 찾는 방법을 취한다.

$$J = \sum_{k=1}^N [y_d(k) - y_a(k)]^2 \quad (1)$$

이러한 형태의 알고리즘이 가질 수 있는 단점 중 하나는, 구해진 TS 퍼지 모델의 각 국소모델이 모델링하고자 하는 시스템의 지역적 특성을 적절히 반영하지 못하는 경우가 있다는 점이다[2].

본 논문에서는 최근에 퍼지체에 분야에서 응용이 다각도로 모색되고 있는 LMI(Linear Matrix Inequality) [3][5]을 이용하여 전역적 성능과 지역적 성능을 동시에 고려할 수 있는 TS 퍼지 모델링 방법을 제시하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 TS 퍼지 모델에 대해서 간단히 소개하고, 3장에서는 본 논문에서 제시하고자 하는 방법론에 대해서 설명한다. 그리고 4장에서는 제시한 방법을 모의 실험을 통하여 예시하고, 마지막으로 5장에서는 결론 및 추후 연구방향에 대해서 알아본다.

### 2. 기초 이론

Takagi와 Sugeno에 의해 제안된 TS 퍼지 모델은 비선형 시스템의 국소 선형 입력 출력 관계를 표현하는 퍼지 IF-THEN 규칙들로 표현된다[6]. 따라서 일반적인 TS 퍼지 모델의 IF-THEN 규칙은 다음과 같은 형식으로 주어진다

Rule i:

$$\begin{aligned} & \text{IF } x_1 \text{ is } M_{i1} \text{ and } \dots \text{ and } x_r \text{ is } M_{ir}, \\ & \text{THEN} \\ & y_i = b_{i0} + b_{i1}x_1 + \dots + b_{ir}x_r \text{ for } i = 1, 2, \dots, L \end{aligned} \quad (2)$$

여기서  $x_i$ 는 입력변수,  $y_i$ 는 국소 출력변수,  $L$ 은 rule의 개수.  $M_{ij}$ 는 소속함수  $M_{ij}(x_j)$ 에 의해 결정되는 퍼지집합이고, 그리고  $b_{ij}$ 는 매개변수이다.

그리고 TS 퍼지모델의 일반적인 추론 방법에 의하면 모델의 전체 출력은 다음과 같다.

$$y = \frac{\sum_{i=0}^L w_i y_i}{\sum_{i=0}^L w_i} = \frac{\sum_{i=0}^L w_i (b_{i0} + b_{i1}x_1 + \dots + b_{ir}x_r)}{\sum_{i=0}^L w_i} \quad (3)$$

여기서  $w_i$ 는 Rule i의 하중함수(Weight Function)이고 다음과 같이 정의된다.

$$\begin{aligned} w_i &= M_{i1}(x_1) \times M_{i2}(x_2) \times \dots \times M_{ir}(x_r) \\ &= \prod_{j=1}^r M_{ij}(x_j) \end{aligned} \quad (4)$$

또  $\sum_{i=1}^L w_i(x) > 0$ ,  $\forall t > 0$ 을 항상 만족함을 가정하고 하중 함수를

$$h_i(x) \triangleq \frac{w_i(x)}{\sum_{i=1}^L w_i(x)} \quad (5)$$

으로 정규화하면, TS 퍼지모델의 전체 출력은 다음과 같이 바꿔 쓸 수 있다.

$$y = \sum_{i=0}^L h_i(b_{i0} + b_{i1}x_1 + \dots + b_{ir}x_r) \quad (6)$$

$$h_i(x) \geq 0, \quad i = 1, \dots, r,$$

$$\sum_{i=1}^r h_i(x) = 1, \quad \forall t \geq 0$$

### 3. 전역적 학습(Global Learning)과 지역적 학습(Local Learning) : LMI를 이용한 풀이

전역적 학습을 위한 알고리즘은 (1)에서 제시한 목적함수(Objective Function)  $J_G$ 를 최소화하는 매개변수를

찾는 것이다. 여기서  $y_d(k)$ 는 실제 시스템의 출력,  $y_a(k)$ 는 모델링한 시스템의 출력이고, 그리고  $N$ 은 학습에 사용된 데이터의 개수이다. 그리고 (1)은 전역적 학습의 목적함수로서 다음과 같이 다시 쓸 수 있다[2].

$$J_C = (y_d - Xb)^T (y_d - Xb) \quad (7)$$

여기서

$$\begin{aligned} y_d &= [y_d(1) \ y_d(2) \ \cdots \ y_d(N)]^T \in \mathbb{R}^N \\ X &= \left[ \begin{array}{cccc} \omega_1(1) & \omega_1(1)x_1(1) & \cdots & \omega_1(1)x_r(1) \\ \omega_1(2) & \omega_1(2)x_1(2) & \cdots & \omega_1(2)x_r(2) \\ \vdots & \vdots & \ddots & \vdots \\ \omega_1(N) & \omega_1(N)x_1(N) & \cdots & \omega_1(N)x_r(N) \end{array} \right] \in \mathbb{R}^{N \times (r+1)} \\ b &= [b_{10} \ b_{11} \ \cdots \ b_{1r} \ \cdots \ b_{L0} \ b_{L1} \ \cdots \ b_{Lr}]^T \in \mathbb{R}^{((r+1) \times L)} \end{aligned}$$

이다. 그리고 목적함수를 최소화하는 매개 변수  $b$ 를 구하기 위하여 다음을 만족하는 중간변수  $a(k)$ 를 이용할 수 있다.

$$(y_d(k) - y_a(k))^2 < a(k) \quad (8)$$

이 식은 다음과 동치임에 주목하자.

$$G(k) = \begin{bmatrix} a(k) & [y_d(k) - X(k)b]^T \\ [y_d(k) - X(k)b] & 1 \end{bmatrix} > 0 \quad (9)$$

여기서  $X(k)$ 는 행렬  $X$ 의  $k$ 번째 행이다.

목적함수(1)을 최소화하는 문제는 다음의 EVP(Eigen value Problem)문제를 풀면 얻을 수 있다[3].

$$\begin{aligned} \text{minimize } & \sum_{i=1}^N a(i) \\ \text{subject to } & \end{aligned} \quad (10)$$

$$\text{block-diag}[G(1) \ G(2) \ \cdots \ G(N)] > 0$$

따라서 식(10)에서 구한 매개변수는 전역적 성능만 고려하여 얻어지는 해가된다. 지역적 성능을 고려하는 데에는 일반적으로 다음과 같은 목적함수를 사용한다.

$$J_L = \sum_{i=1}^L \sum_{k=1}^N \omega_i(k) [y_d(k) - y_a(k)]^2 \quad (11)$$

이것은 다시

$$\begin{aligned} J_L &= \sum_{i=1}^L (y_d - X_i b_i)^T W_i (y_d - X_i b_i) \\ &= \sum_{i=1}^L (W_i^{1/2} y_d - W_i^{1/2} X_i b_i)^T (W_i^{1/2} y_d - W_i^{1/2} X_i b_i) \end{aligned} \quad (12)$$

이 되고, 여기서

$$\begin{aligned} W_i &= \text{diag}[\omega_i(1) \ \omega_i(2) \ \cdots \ \omega_i(N)] \in \mathbb{R}^{N \times N} \\ b_i &= [b_{i0} \ b_{i1} \ \cdots \ b_{ir}]^T \in \mathbb{R}^{(r+1)}$$

$$X_i = \begin{bmatrix} \omega_i(1) & \omega_i(1)x_1(1) & \cdots & \omega_i(1)x_r(1) \\ \omega_i(2) & \omega_i(2)x_1(2) & \cdots & \omega_i(2)x_r(2) \\ \vdots & \vdots & \ddots & \vdots \\ \omega_i(N) & \omega_i(N)x_1(N) & \cdots & \omega_i(N)x_r(N) \end{bmatrix} \in \mathbb{R}^{N \times (r+1)}, \quad i = 1, 2, \dots, L$$

가 된다. 따라서 목적함수  $J_L$ 을  $\beta$  미만으로 유지하기 위하여 부등식이 필요하다.

$$(W^{1/2} y_d - W^{1/2} X' b)^T (W^{1/2} y_d - W^{1/2} X' b) < \beta \quad (13)$$

여기서

$$y_d = [y_d \ y_d \ \cdots \ y_d]^T \in \mathbb{R}^{N \times N}$$

$$X' = \text{diag}[X_1 \ X_2 \ \cdots \ X_L] \in \mathbb{R}^{(N \times L) \times [(r+1) \times L]}$$

$$W = \text{diag}[W_1 \ W_2 \ \cdots \ W_L] \in \mathbb{R}^{(N \times L) \times (N \times L)}$$

$$b = [b_1 \ b_2 \ \cdots \ b_L]^T \in \mathbb{R}^{(r+1) \times L}$$

이다. 그리고 식(13)은 다음과 같이 선형행렬부등식의 형태로 표현이 가능하다.

$$\begin{bmatrix} \beta & [W^{1/2} y_d - W^{1/2} X' b]^T \\ [W^{1/2} y_d - W^{1/2} X' b] & 1 \end{bmatrix} > 0 \quad (14)$$

하지만 전역적 학습을 통하여 얻어지는 매개변수와 지역적 학습을 통하여 얻어지는 매개변수는 결국 전역적 특성과 지역적 특성을 동시에 만족시키지는 못한다. 따라서 본 논문에서 LMI를 이용하여 두 가지 특성을 동시에 만족시키는 방법을 다음과 같이 제안한다[4].

$$\text{minimize } \sum_{i=1}^N a(i) \quad (15)$$

subject to

$$\text{block-diag}[G(1) \ G(2) \ \cdots \ G(N)] > 0,$$

$$(W^{1/2} y_d - W^{1/2} X' b)^T (W^{1/2} y_d - W^{1/2} X' b) < \varepsilon$$

#### 4. 모의 실험

본 논문에서 제시하고자 하는 방법을 보이기 위하여 먼저 간단한 예제[2]에 대해서 TS 퍼지 모델을 구해보았다. Fig.1은 일반적인 학습을 통하여 모델을 구해보았는데 3개의 국소 모델 중 2와 3은 시스템의 국소적 특성을 정확하게 반영하지 못하고 있다. 따라서 본 논문에서 제시하는 방법을 적용한 결과, Fig.2와 같이 전역 및 지역적 성능이 모두 만족되는 TS 퍼지 모델이 구해졌다.

다음 예제에서는

$$y = \frac{\sin(x)}{x} \quad (16)$$

를 중심이  $x_i = -8, -6, -4, -2, 0, 2, 4, 6$ , 그리고 8인 9개의 삼각 소속함수를 갖는 TS 퍼지 모델로 근사하는 문제를 식(15)을 사용하여 다루어 보았다. 그 결과 Fig.3에서 보여진 바와 같이, 각 국소모델들의 성능과 전체 모델의 성능이 비교적 우수함을 알 수 있다.

본 논문의 관점을 풀 경우, 우리는 여러 가지 방법으로 TS 퍼지 모델의 전역적 성능과 지역적 성능을 동시에 고려해 줄 수 있다. 이러한 방법들 중 하나로 전역적 오차(1)을  $\varepsilon$  미만으로 유지시키면서 지역적 성능 관련 오

차(11)을 최소화하는 방법도 시뮬레이션 해보았는데, 결과는 Fig. 4와 같았다.

## 5. 결 론

지금까지 우리는 전역 및 지역적 성능을 동시에 보장할 수 있는 TS 퍼지 모델을 얻기 위하여 LMI를 이용한 학습 알고리즘을 제시하였다. 그리고 간단한 비선형 함수에 대해서 제시한 방법을 적용해 본 결과, 일반적인 학습 알고리즘에서 잘 보장하지 못했던 지역적 성능이 개선됨을 알 수 있었다. 그리고 본 모의 실험에서는 전역적 성능을 제한한 후 지역적 성능을 최적화시키는 방법도 고려해 보았다.

추후에 연구해야 할 방향으로서는, 더 복잡한 비선형 함수에 대해서 제시한 방법을 적용하는 것이다. 그리고 모델링 및 제어기 설계를 통합적으로 수행할 수 있는 LMI 기반 Tool의 설계 및 개발 등을 들 수 있다.

### (참 고 문 헌)

- [1] J.Shing, and R.Jang, "ANFIS:Adaptive-Network-Based Fuzzy Inference System", IEEE Transactions on Systems, Man and Cybernetics, Vol.23, 665-685,1993.
- [2] John Yen, Liang Wang, and C.W.Gillespie, "Improving the Interpretability of TSK Fuzzy Models by Combining Learning and Local Learning", IEEE Transactions on Fuzzy Systems, Vol.6, 530-537, 1998.
- [3] K.Tanaka, T.Hori, K.Yamafuji, and H.Wang, "An Integrated Algorithm of Fuzzy Modeling and Controller Design for Nonlinear Systems", IEEE International Fuzzy systems conference proceedings, II887-II892,1999.
- [4] P.Gahinet, A.Nemirovski, A.J.Laub, and M.Chilali, LMI Control Toolbox(MathWorks Inc, Natick, MA, 1995).
- [5] S.Boyd, L.ElGhaoui, E.Feron, and V.Balakrishnan, Linear Matrix Inequalities in Systems and Control Theory, SIAM Studies in Applied Mathematics, Vol.15 (SIAM, Philadelphia, 1994).
- [6] T.Takagi, and M.Sugeno, "Fuzzy Identification of Systems and Its Applications to Modeling and Control", IEEE Transactions on Sys, Man and Cybernetics, Vol. SMC-15, 116-132,1985.




Fig.1. 전역적 성능만을 고려한 TS 모델




Fig.2. 본 논문의 방법론으로 구한 TS 모델




Fig.3. 본 논문의 방법론으로 구한 TS 모델  
( $\epsilon = 0.35$ )




Fig.4. 전역적 성능을 제약조건으로, 목적함수로 지역적 성능을 가지는 방법으로 구한 TS 모델  
( $\epsilon = 0.05$ )