

## mGA의 혼합된 구조를 사용한 퍼지모델 동정

이연우\*·주영호\*·박진배\*\*

\* 군산대학교 제어계측공학과 · \*\*연세대학교 전기공학과

## Fuzzy Model Identification Using A mGA Hybrid Scheme

Yeun-Woo Lee\* · Young-Hoon Joo\* · Jin-Bae Park\*\*

\*Dept. of Control &amp; Instrumentation Eng., Kunsan Univ. · \*\*Dept. of Electrical Eng., Yonsei Univ.

**Abstract** - In this paper, we propose a new fuzzy model identification method that can yield a successful fuzzy rule base for fundamental approximations. The method in this paper uses a set of input-output data and is based on a hybrid messy genetic algorithm (mGA) with a fine-tuning scheme. The mGA processes variable-length strings, while standard GAs work with a fixed-length coding scheme. For successfully identifying a complex nonlinear system, we first use the mGA, which coarsely optimizes the structure and the parameters of the fuzzy inference system, and then the gradient descent method which fine tunes the identified fuzzy model. In order to demonstrate the superiority and efficiency of the proposed scheme, we finally show its application to a nonlinear approximation.

## 1. 서 론

퍼지 제어 시스템은 인간의 생각과 자연적인 언어를 표현하는데 있어서 기존의 제어 시스템들보다 더 적합하다고 알려져 있다. 그러나, 퍼지 제어기는 제어기를 구성하고 있는 퍼지 제어의 규칙의 수와 몇몇 구성 요소들을 플랜트에 맞게 조정해야 한다. 이를 위해서, 퍼지 IF-THEN 규칙들의 언어적인 형태로 전문가의 지식을 표현하는 것이 필요하지만 전문가의 지식을 정확한 규칙으로 표현하기는 어려운 일이다. 또한, 전문가의 주관적인 경험에 의해 시행착오적인 방법으로 구성되는 제어기는 시스템의 복잡도가 증가하거나 돌발적인 상황에 처했을 경우 제어 성능이 떨어지기 쉬우며, 시스템의 구성요소가 최적의 값이라는 보장이 없으므로 신뢰도가 부족한 것이 사실이다. 이러한 문제들을 해결하기 위하여, 퍼지 추론 시스템들의 자동 동조에 대한 많은 연구가 이루어지고 있다 [5-10].

Horikawa[6]은 비선형 함수 근사치 문제를 위한 퍼지 모델의 역전파 학습에 의한 자동 동조 방법과 함께 퍼지 뉴럴 네트워크 세 가지 형식을 제안하였다. Jang[7]은 적용 네트워크 기반 퍼지 추론 시스템(ANFIS)을 제안하였으며, 학습을 위해 역전파 알고리즘과 반복최소제곱 방법을 사용하였다.

Joo[8, 9]는 퍼지 제어기의 구조 동정에 클러스터링 방법을 이용하고, 퍼지 규칙을 구성하고 있는 파라미터들은 유전 알고리즘을 이용하여 동정하였다. 그러나 기존의 여러 방법들에서 퍼지 제어기의 설계는 제어기의 구성요소 중 일부만을 동정한 형태였다. Shimojima[10]은 새로운 종류의 GA와 혼합된 구조를 제안하였는데, 그것은 유전 연산자들의 역전파 학습을 사용한 것이다.

mGA는 1989년 Goldberg[2]에 의해 제시된 방법으로 그 이후에 더욱 발전되어왔다. Kargupta[4]는 유전자 표현 메시 유전 알고리즘(gene expression messy genetic algorithm: GEMGA)을 제안하여 블랙박스

최적화 문제(black box optimization: BBO)에 응용하였다.

Hoffmann [3]은 메시 유전 알고리즘을 계층적 퍼지 추론 시스템의 규칙을 최적화 하는데 적용하여 이동 로봇의 최적 경로를 찾는데 응용하였다. 또한 Chowdhury [1]는 퍼지 신경망의 학습에 메시 유전 알고리즘을 사용하여 도로 진자 제어에 응용하였다.

본 논문에서는 상기에서 언급한 방법의 향상을 위해 mGA와 경사법을 혼합한 구조를 사용한 퍼지모델 동정 방법을 제안한다. 제안한 방법은 mGA를 이용하여 퍼지 시스템의 구조와 파라미터를 동정하고, 그 동정된 모델을 경사법을 이용하여 파라미터의 미세 동조를 하는 방법이다. 마지막으로, 복잡한 비선형 시스템에서의 모의 실험 결과를 통하여 제안된 방법의 우수함을 입증한다.

## 2. 본 론

## 2.1 퍼지모델

퍼지모델은 복잡하고 정의되지 않은, 그리고 불확실한 실세계 시스템의 언어적인 표현을 제공하며, 이는 양식화된 수학적 모델링을 하지 않더라도 만족스러운 결과를 가져다준다. 퍼지 모델링은 입출력 데이터 또는 숙련된 전문가의 지식을 주어진 퍼지모델에 기반하여 구성하는 것이다. 그림 1은 퍼지모델의 일반적인 구조를 보여준다.

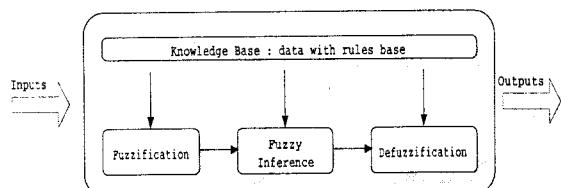


그림 1 퍼지 모델의 일반적인 구조

본 논문에서는 동정될 모델로 Takagi-Sugeno 퍼지 모델을 사용한다. 사용된 TS 퍼지모델의  $i$ 번째 규칙은 식 (1)과 같다.

$$\text{Plant Rule } i : \text{If } x_1(t) \text{ is } A_1^i \text{ and } \dots \text{ and } x_n(t) \text{ is } A_n^i, \text{ THEN } y \text{ is } w_i \quad (i = 1, 2, \dots, r) \quad (1)$$

여기서, Rule  $i$ 는  $i$ 번째 퍼지 규칙을 나타내며,  $A_j^i$  ( $j = 1, 2, \dots, n$ )는 퍼지 집합,  $x_j(t)$  ( $j = 1, 2, \dots, n$ )는 입력변수,  $y$ 는 출력변수,  $w_i$ 는 퍼지 싱글톤으로 실수이며,  $r$ 은 규칙들의 총 개수이다. 본 논문에서는 이등변 삼각형 소속함수를 사용하였으며, 식 (2)로 표현된다.

$$\Lambda_j^i(x_j; a_{ij}, b_{ij}) = \max(\min(\frac{2x_j - 2a_{ij} + b_{ij}}{b_{ij}}, \frac{2a_{ij} + b_{ij} - 2x_j}{b_{ij}}), 0) \quad (2)$$

여기에서  $a_{ij}$ 와  $b_{ij}$ 는 각각 이등변삼각형의 중심점과 폭을 나타낸다.

출력값을 구하는 비퍼지화 방법은 무게 중심법으로 구하며 이는 다음 식으로 표현된다.

$$y^* = \frac{\sum_{i=1}^r \mu_i(x(t)) w_i}{\sum_{i=1}^r \mu_i(x(t))} \quad (3)$$

$$\mu_i(x(t)) = \prod_{j=1}^n \Lambda_j^i(x_j(t)) \quad (4)$$

$\Lambda_j^i(x_j(t))$ 는  $\Lambda_j^i$ 에 대한  $x_j(t)$ 의 소속 정도이다.

## 2.2 메시 유전 알고리즘

기존의 유전 알고리즘은 선택(selection), 재결합(crossover), 돌연변이(mutatuation)의 유전 연산자를 가지며, 전체 해 공간을 탐색하는 최적화 방법이다. 그러나, 풀고자하는 해의 집합인 염색체는 세대가 바뀌어도 고정된 길이를 갖는 단점을 갖는다. 이러한 단점을 보완하기 위해 본 논문에서는 mGA를 사용한다. mGA는 탐색과정 중 다루기 어려운 빌딩 블록과 스키마 이론에 관련된 최적화 방법을 이용한 형태에 의해 서로 결합한다 [2]. 일반적으로 GA는 고정된 스트링을 사용하지만, mGA는 가변 스트링을 사용한다. 또한, mGA는 교차 연산자 대신 다루기 쉬운 자르기와 붙이기(cut and splice) 연산자가 사용된다. 그림 2에 mGA의 진화시에 나누어지는 개체군의 모양을 보여준다.

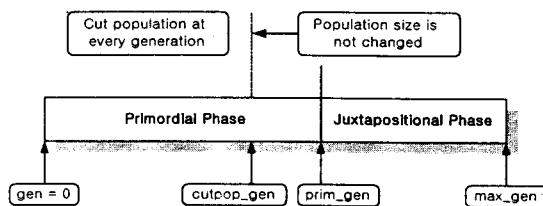


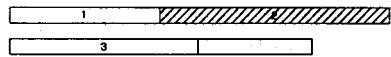
그림 2 대표적인 개체군 변형 표

그림 2에서 알 수 있듯이 mGA의 개체군은 원시상(primordial phase)과 병치상(juxtapositional phase)이라는 두 개의 상으로 이루어진다. 원시상에서는 선택 연산자를 사용하여 개체군의 많은 후보 스트링 중에서 진화시킬 개체를 선별하기만 한다. 즉, 이 단계에서는 진화를 하지 않고 선택 과정만 반복하므로 개체군의 크기는 선택 연산과 동시에 감소하게 된다. 이것은 일정한 세대를 거친 후에는 개체군의 크기는 고정된다. 병치상에서는 보통의 유전 알고리즘에서 사용하는 돌연변이 연산자와 교차 연산자 대신 자르기와 붙이기 연산자를 사용하여 개체들을 진화시킨다. 일반적인 GA의 교차연산자는 교배될 두 부모의 동일한 위치에서 교차점을 갖지만 mGA는 서로 다른 위치의 교차점을 갖을 수 있다. 그리고, 교배는 자르기와 붙이기 연산자를 이용한다. 그림 3은 mGA에서의 자르기, 붙이기 연산자들의 연산과정을 보여준다.

자르기 연산자는 두 부모 개체에서 무작위로 선택된 위치에 교차점을 갖는다. 붙이기 연산자는 이전에 무작위로 선택되어 잘라진 두 스트링을 갖는다. 이때, 자르기와 붙이기 연산자는 보통 교차연산자와 비슷한 방법으로 두 부모 스트링에 동시에 적용된다. 그림 3은 두 부

모 스트링으로부터 내 가지 종류의 후손 스트링이 생성됨을 보인다. 최종 적용시에는 그중 2개의 스트링만을 선택하여 사용하게 된다. 자르기 연산자는  $p_c$ 의 확률을 가지고 무작위로 선택된 위치에서 스트링을 자르고, 붙이기 연산자는 고정된 확률  $p_s$ 에 따라 무작위로 선택된 순서에 의해 두 개의 스트링을 잇는다.

cut operation



splice operation

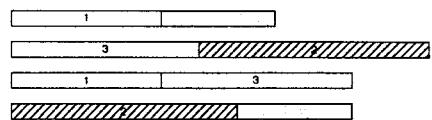


그림 3 자르기와 붙이기 연산자

본 논문에서는, 일반적인 mGA를 퍼지 시스템 모델링에 이용하기 위해 염색체의 암호화 기법을 변경하였다. 즉, 하나의 유전 인자는 세 개의 요소로 나누어 구성된다. 그러므로, 파라메터 행렬에서  $p$ 값을 갖는  $(i, j, p)$ 번째 성분은 유전인자  $\{(i, j, p)\}$ 로 나타낼 수 있다. 그림 4는 본 논문에서 제안한 파라메터 행렬의 예를 도시한 그림이다.

	Premise part			Consequent part			Weight	
	1	2	3	4	5	6	7	8
1	0.0362	0.0335	1.023	1.0395	0.7046	1.1623	0.0936	
2	0.5426	1	1.3533	1.1749	0.6778	0.9010	0.5778	0

그림 4 퍼지 추론 시스템의 파라메터 행렬의 예

제안된 mGA의 암호화 구조는 일반적인 mGA 구조보다 더 순응성 있는 구조를 갖는다. 본 논문에서 제안한 염색체의 구조는 퍼지 시스템의 구조 동정 뿐만 아니라 멤버쉽 함수의 파라미터 동정도 동시에 할 수 있는 장점을 갖는다. 마지막으로, mGA에 의해 동정된 퍼지 모델은 일정한 학습률을 갖는 경사법을 이용하여 미세 동조하여 최적인 퍼지 모델을 구한다.

## 3. 모의실험

제안된 퍼지 모델링 방법의 우수성을 입증하기 위해 우리는 [5]에서 논의되었던 복잡한 비선형 함수의 퍼지 모델링에 응용한다. 식 (5)는 사용된 비선형 시스템의 수학적 모델을 나타낸다.

$$z = 3(1-x)^2 e^{-x^2-(x+1)^2} - 10\left(\frac{x}{5} - x^3 - y^5\right) e^{-x^2-y^2} - \frac{1}{3} e^{-(x+1)^2-y^2} \quad (1 \leq x, y \leq 5) \quad (5)$$

식 (5)는 두 개의 입력과 하나의 출력을 가지며, 입력의 범위는 1과 5사이의 실수로 하였다. 이 비선형 시스

템의 퍼지 모델을 위해 50개의 입출력 데이터 집합을 무작위로 추출하고 그것을 mGA의 혼합된 동정 알고리즘에 적용하였다. 학습된 데이터 쌍은 0과 1사이에서 정량화 되며, 식 6과 같이 표현된다.

$$\begin{aligned}\hat{x} &= \frac{x - x_{\min}}{x_{\max} - x_{\min}} & (x_{\min} = 1.0, x_{\max} = 5.0) \\ \hat{y} &= \frac{y - y_{\min}}{y_{\max} - y_{\min}} & (y_{\min} = 1.0, y_{\max} = 5.0) \\ \hat{z} &= \frac{z - z_{\min}}{z_{\max} - z_{\min}} & (z_{\min} = 0, z_{\max} = 1.6822)\end{aligned}\quad (6)$$

mGA의 순위 선택 작업을 위해 우리는 처음에 무작위로 초기 모판을 선택한다. 비용함수로는 평균 제곱 오차 (mean square error, MSE)를 사용한다. 또한, 소속 함수의 초기 폭은  $[0, W]$  공간의 무작위 실수들이다.

$$W = \frac{2(X_{\max} - X_{\min})}{R} \quad (7)$$

식 (7)에서  $X_{\max}$ 과  $X_{\min}$ 는 입력공간의 계이고,  $R$ 은 퍼지 규칙의 초기 수이다. mGA의 혼합된 구조 동정을 위한 초기 파라미터들로써 초기 개체군의 크기 500, 원시상과 병치상에서의 세대수 200, 자르기 확률 0.2, 붙이기 확률 1.0, 돌연변이율 0.2,  $\lambda$ 는 0.9, 반복되는 세대수는 1000이다. 그리고, 미세조정 단계에서의 학습율  $K_a$ ,  $K_b$ ,  $K_c$ 와  $K_u$ 는 각각  $10^{-3}$ 을 사용하였다.

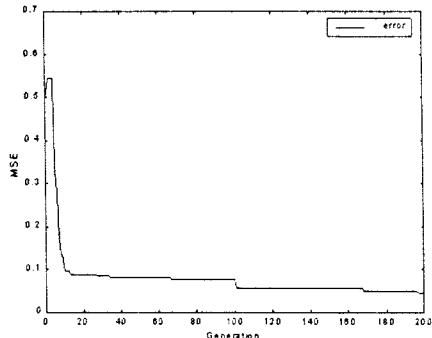


그림 5 mGA 동정 단계에서 최소 제곱 에러의 변화

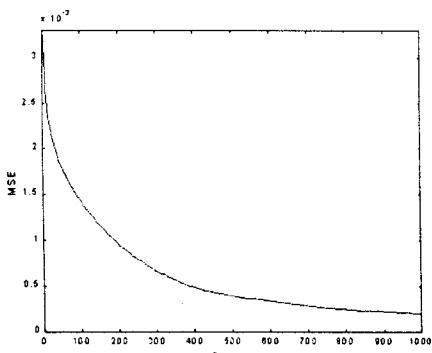


그림 6 미세 조정 단계에서 최소 제곱 오차의 변화

그림 5는 mGA 최적화 과정 동안에 MSE의 변화를 보여주며, 퍼지 모델링 결과 발생한 MSE는 0.003282이다. 그림 5에서 보여주듯이 MSE는 초기 단계에서 매우 효과적으로 감소한다. 제안된 방법의 모의실험 결과 규칙의 수는 10개, MSE는 0.000193으로 우수한 성능을 얻을 수 있었다.

## 4. 결 론

본 논문에서는 혼합된 mGA를 이용하여 복잡한 비선형 시스템의 퍼지 모델링을 구하는 방법을 제안하였다. 제안한 방법은 두 단계로 구성된다. 먼저, 비선형 시스템의 입출력 데이터를 사용하여 제안된 mGA 방법에 의해 퍼지 모델의 구조와 파라미터 동정을 구한 후, 경사법을 사용하여 파라미터를 미세 조정하는 방법이다. 제안한 방법은 복잡한 비선형 시스템의 퍼지 모델 동정에 응용하여 그 우수성을 증명하였다.

## (참 고 문 현)

- [1] M. Chowdhury and Y. Li, "Messy Genetic Algorithm Based New Learning Method for Structurally Optimized Neurofuzzy Controllers", Proc. IEEE Int. Conf. on Industrial Tech., 1996.
- [2] K. Deb and D.E. Goldberg, mGA in C: A Messy Genetic Algorithm in C, IlliGAL Report NO. 91008, 1991.
- [3] F. Hoffmann and G. Pfister, "A New Learning Method for the Design of Hierarchical Fuzzy Controllers Using Messy Genetic Algorithms", Proc. IFSA'95, 1995.
- [4] H. Kargupta, "The Gene Expression Messy Genetic Algorithm", Proc. of IEEE Int. Conf. on Evolutionary Computation, 1996.
- [5] J.-S.R. JANG, "Derivative-Free Optimization", Neuro-Fuzzy and Soft Computing, A Computational Approach to Learning and Machine Intelligence, pp. 179-180, 1996.
- [6] S. Horikawa, T. Furuhashi and Y. Uchikawa, On Fuzzy Modeling Using Fuzzy Neural Networks with the Back-Propagation Algorithm, IEEE Trans. On Neural Networks, Vol. 3, No. 5, pp. 801-806, 1992.
- [7] J. S. Jang, ANFIS: Adaptive-Network-Based Fuzzy Inference Systems, IEEE Trans. System, Man and Cybernetics, Vol. 23, No. 3, pp. 665-684, 1993.
- [8] Y. H. Joo, H. S. Hwang, K. B. Kim and K. B. Woo, "Fuzzy System Modeling and Its Application to Mobile Robot Control", Fuzzy Logic and Its Applications to Engineering, Information Sciences, and Intelligent Systems, Kluwer Academic Publishers, pp. 147-156, 1995.
- [9] Y. H. Joo, H. S. Hwang, K. B. Kim and K. B. Woo, "Fuzzy System Modeling by Fuzzy Partition and GA Hybrid Schemes", Fuzzy Sets and Systems, Vol. 86, No. 3, pp. 279-288, 1997.
- [10] K. Shimojima, T. Fukuda and Y. Hasegawa, Self-Tuning Fuzzy Modeling with Adaptive Membership Function, Rules, and Hierarchical Structure Based on Genetic Algorithm, Fuzzy Sets and Systems, Vol. 71, pp. 295-309, 1995.