

mGA를 사용한 복잡한 비선형 시스템의 뉴로-퍼지 모델링

최종일* · 이연우* · 주영훈* · 박진배**
 * 군산대 전자정보공학부 · **연세대 전기 및 컴퓨터공학과

Neuro-Fuzzy Modeling of Complex Nonlinear System Using a mGA

Jong-il Choi* · Yeun-Woo Lee* · Young-Hoon Joo* · Jin-Bae Park**

*Dept. of Electronics & Info. Eng. Kunsan Univ. · **Dept. of Electric & Computer Eng. Yonsei Univ.

Abstract - In this paper we propose a Neuro-Fuzzy modeling method using mGA for complex nonlinear system. mGA has more effective and adaptive structure than sGA with respect to using the changeable-length string. This paper suggest a new coding method for applying the model's input and output data to the number of optimul rules of fuzzy models and the structure and parameter identifications of membership function simultaneously. The proposed method realize optimal fuzzy inference system using the learning ability of Neural network. For fine-tune of the identified parameter by mGA, back-propagation algorithm used for optimulize the parameter of fuzzy set. The proposed fuzzy modeling method is applied to a nonlinear system to prove the superiority of the proposed approach through compare with ANFIS.

1. 서 론

복잡하고 불확실한 비선형 시스템을 수학적으로 모델링하는 경우에는 비선형성의 고차 모델을 이용하거나 모델 근사화 방법을 이용한다. 하지만 만족할 만한 모델을 얻기는 어려우므로 if-then 규칙 형식으로 표현되는 퍼지 모델링 기법이 활발히 연구되어 왔다.

퍼지 모델링 방법의 주관심사는 전문가적 경험을 이용하여 미지의 시스템을 퍼지 규칙으로 정확히 묘사하는데 있다. 최근에는 모델링 기법을 향상시키기 위하여 전역 최적화 탐색 기법인 유전 알고리즘이나 신경 회로망과 같은 많은 혼합 기술이 이러한 문제를 다루는데 적용되어 왔다. Shimojima[1]는 새로운 종류의 GA와 혼합된 구조를 제안하였으며 그것은 유전 연산자들의 역전과 학습을 사용한 것이다. Horikawa[2]는 비선형 함수 근사치 문제를 위한 퍼지 모델의 역전과 학습에 의한 자동 동조 방법과 퍼지 뉴럴 네트워크의 세 가지 형식을 제안하였다. Jang[3]은 적응 네트워크 기반 퍼지 추론 시스템을 제안하였다. 이는 학습을 위해 역전과 알고리즘과 반복적인 최소제곱 방법을 사용하였다. Joo[4]는 퍼지 제어기의 구조 동정에 클러스터링 방법을 이용하고, 퍼지 규칙을 구성하고 있는 파라미터들은 유전·알고리즘을 이용하여 동정하였다. 그러나 기존의 여러 방법들에서는 제어기 구성요소 중 일부만을 동정한 형태였다.

본 논문에서는 메시 유전 알고리즘(messy genetic algorithm: mGA)을 사용한 뉴로-퍼지 모델링 기법을 제안한다. mGA는 D.Goldberg[5]에 의해 제안된 방법으로 Deb, Kargupta[6]등을 중심으로 발전되어 왔으며, [6]에서는 유전자 표현 메시 유전 알고리즘(gene expression messy genetic algorithm: GEMGA)을 제안하여 블랙박스 최적화 문제(black box optimization: BBO)에 응용하였다.

Chowdhury[7]는 mGA를 사용하여 도립 진자를 제어하여 정상상태 오차가 존재하지 않도록 하는데 성공하였다.

본 논문에서는 기존의 smGA(simple mGA)의 향상을 위해 퍼지 신경망의 학습 능력을 사용하여 퍼지 추론 시스템의 규칙뿐만 아니라 파라미터까지도 동시에 동정할 수 있는 새로운 염색체 암호화 방법을 제안하였다.

또한 제안된 방법은 퍼지 신경망의 학습을 통해 동정된 규칙과 파라미터를 오차 역전과 알고리즘을 사용하여 미세동조를 거쳐 시스템을 최적화 하게 되며, ANFIS[3]와의 비교를 통해 제안된 방법의 우수성을 입증하였다.

2. 퍼지-신경망

2.1 퍼지 모델

본 논문에서 사용된 퍼지 모델로는 다음의 식(1)의 IF-THEN 구조를 갖는 퍼지 모델을 사용하였다.

$$\text{RULE } i: \text{If } X_1 \text{ is } A_1^i \text{ and } X_n \text{ is } A_n^i \text{ Then } O_i \text{ is } \omega_i \quad (1) \\ (i=1, 2, 3, \dots n)$$

여기에서 RULE i 는 i 번째 퍼지 규칙, O_i 는 i 번째 규칙의 출력, n 는 규칙수를 나타낸다. 그림 1은 본 논문에서 사용된 가우시안(gaussian) 소속함수의 모양을 나타낸다.

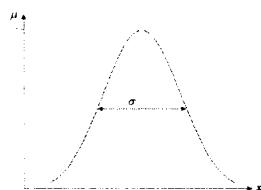


그림 1. 가우시안 소속함수

그림 1의 가우시안 소속함수는 식(2)로 표현된다.

$$\text{gaussian}(x_i; c_i, \sigma_i) = e^{-\frac{1}{2}\left(\frac{x_i - c_i}{\sigma_i}\right)^2} \quad (2) \\ (i=1, 2, 3, \dots n)$$

여기에서 x_i 는 입력 데이터, c_i 는 소속함수의 중심, σ_i 는 소속함수의 너비이다.

2.2 퍼지 신경망의 구조

본 논문에서는 Horikawa[8]가 제안한 퍼지 신경망 타입 III 형태의 퍼지 신경망을 사용하였으며, 각 층은 다음과 같이 설명된다.

입력 층에서는 입력 x_1, x_2 그리고 소속함수의 파라메

터 중심(c_{ij})과 너비(σ_{ij})를 규칙 층으로 보낸다. 입력 데이터와 규칙층의 결선 강도는 1이고 바이어스로 연결된 입력 노드와 규칙층 사이의 결선 강도는 각각 소속함수의 중심과 너비를 결정한다.

규칙 층에서는 입력 층에서 받은 입력 데이터와 소속함수의 파라미터로 퍼지 추론 과정은 sum-product로 소속정도는 T-norm에 의해 결합되게 된다. 본 논문에서는 2입력 1 출력 시스템을 사용하였으므로 식(3)과 같이 표현할 수 있다.

$$f(x, c, \sigma) = g_1(x_1, c_1, \sigma_1) \cdot g_2(x_2, c_2, \sigma_2) \quad (3)$$

$$= \exp\left(-\frac{(x_1 - c_1)^2}{\sigma_1^2} - \frac{(x_2 - c_2)^2}{\sigma_2^2}\right)$$

정규화 층에서는 다중 신경 회로망과 달리 은닉층과 출력층 사이에 정규화층이 존재한다. 이는 출력층에서 비퍼지화하는 과정의 예비단계이며, 두 개의 노드로 나누어 하나는 규칙층과의 결선 강도를 1로 하여 단지 규칙층 출력의 합을 구하고 다른 노드는 결선 강도와 규칙층 출력의 곱을 합한다. 그것은 다음의 식(4)와 식(5)에 의해 계산된다.

$$\Sigma_1 = \sum_{j=1}^J \omega_{1j} f_j(x, c, \sigma) \quad (4)$$

$$\Sigma_2 = \sum_{j=1}^J f_j(x, c, \sigma) \quad (5)$$

출력 층은 비퍼지화하는 단계로 정규화 층의 Σ_1 과 Σ_2 를 입력으로 받아 출력으로 Σ_1 / Σ_2 를 내보낸다. 이렇게 추론된 출력은 원래의 출력 데이터와 비교하여 오차 역전과 알고리즘에 의해 각 결선 강도를 갱신하게 된다.

3. mGA의 구조 및 암호화

3.1 mGA 스트링의 구조 및 연산자

mGA는 GA의 변형된 형태로 가변 스트링을 사용함으로써 더 순용적인 스트링 구조를 갖는다. 또한 GA에서의 교차 연산자 대신 다른 자르기와 붙이기(cut)와 불이기(splice) 연산자가 사용된다. 그림 2는 mGA의 진화시에 나누어지는 개체군을 나타낸 것이다.

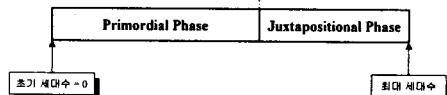


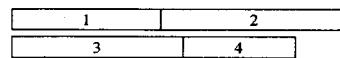
그림 2. 개체군 변형 표

그림 2에서와 같이 mGA의 개체군은 원시상(primitive phase)과 병치상(juxtapositional phase)으로 불리우는 두 개의 상으로 이루어진다. 원시상에서는 선택연산자를 사용하여 개체군의 많은 후보 스트링 중에서 진화시킬 개체를 선별하기만 하며, 일정 세대 이후에 개체군의 크기는 고정된다. 병치상에서는 보통의 유전알고리즘에서 사용하는 들연변이 연산자와 교차연산자 대신 자르기와 붙이기 연산자를 사용하여 개체들을 진화시킨다. sGA(simple GA)의 교차연산자는 교배될 두 부모의 동일한 위치에서 교차점을 갖지만 mGA는 서로 다른 위치의 교차점을 갖을 수 있다.

그림 3은 병치상에서 수행되는 자르기와 붙이기 연산과정을 나타낸 것이다. 자르기 연산은 두 부모개체에서 무작위로 선택된 위치에서 스트링을 자르며, 무작위로 잘라진 스트링은 붙이기 연산자에 의해 두 스트링을 잇는다. 따라서 생성되는 후손 스트링은 이전의 스트링의

길이와 다르게 변경된다. 이때 자르기 확률 p_c 와 붙이기 확률 p_s 는 GA에서의 교배율과 돌연변이율로 적용된다.

Cut Operation



Splice Operation

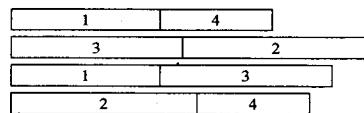


그림 3. 자르기와 붙이기 연산

그림 3의 경우 네 가지 종류의 스트링이 생성될 수 있으며 최종 적용 시에는 그 중 2개의 스트링만을 선택하여 사용하게 된다.

3.2 mGA 암호화

본 논문에서는 효과적인 시스템 모델링을 위해 기존의 mGA 암호화 기법을 변경하였다. 제안된 암호화 기법은 시스템의 구조와 파라미터를 동시에 동정할 수 있는 장점을 갖는다. 그림 4는 제안된 암호화 방법의 예를 나타낸 것이다.

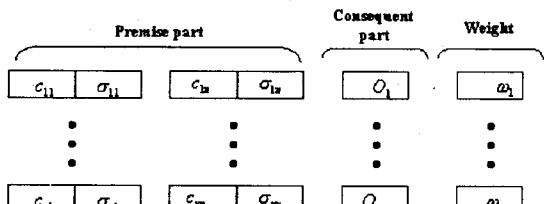


그림 4. 제안된 스트링의 구조

제안된 mGA의 암호화 구조는 일반적인 mGA의 암호화 구조보다 더 순용적이며, mGA를 사용하여 퍼지-신경망의 구조 및 파라미터를 동정한 후 오차 역전과 알고리즘을 사용하여 미세동조를 수행하게 된다.

4. 모의실험 및 결과고찰

mGA를 사용한 뉴로-퍼지 모델링 방법의 효과적이고, 유용함을 보이기 위해 본 논문에서는 Mackey-Glass 혼돈 시계열 데이터를 사용하여 기존의 모델링 기법과 비교하였으며, 식(6)의 미분지연방정식으로 표현된다.

$$\dot{x}(t) = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (6)$$

여기에서 실험 목적은 시간 t 까지 시계열의 과거 값을 사용하여 이후 $t+P$ 인 순간의 값을 예측하는 것이다. 이러한 예측의 일반적인 방법은 Δ 의 일정한 간격을 가진 시계열을 D 점부터 사상을 생성하는 것이다. 즉, $[x(t-(D-1)\Delta), \dots, x(t-\Delta), x(t)]$ 에서 미래값 $x(t+P)$ 를 예측하는 것이다. 본 논문에서는 $D=4$, $\Delta=P=6$ 으로 사용하였다.

모의 실험을 위해 방정식의 해는 4차 Runge-Kutta 방법을 이용한 수치 해석적 풀이로부터 얻었으며, time step은 0.1[sec]이고, 초기 조건 $x(0)$ 는 1.2, t 는 17이 사용되었다. 식(7)은 데이터를 추출하는데 사용된 식을 보여준다.

$$[x(t-18), x(t-12), x(t-6), x(t); x(t+6)] \quad (7)$$

식(7)에서 t 는 601에서 1201이며, 이를 중 400개의 입출력 쌍들이 학습용 데이터이고, 나머지 200개의 입출력 쌍들은 동정화된 모델을 확인하기 위한 데이터로 사용되었다. 출력값을 구하는 비퍼지화 방법은 무게 중심법을 사용하였으며, mGA 뉴로-퍼지 구조 동정을 위한 초기 파라미터로써 초기 개체군의 크기 300, 원시상과 병치상의 세대수 400, 자르기 확률 0.2, 붙이기 확률 1.0, 돌연변이율 0.2, λ 는 0.9, 미세동조시 반복되는 세대수는 1000이다.

흔든 시계열 시스템의 퍼지 모델을 위해 200개의 입출력 데이터 집합을 추출하고, 그것을 mGA의 뉴로-퍼지 동정 알고리즘에 적용하였으며, 학습된 데이터쌍은 0과 1사이에서 정량화 되며, mGA의 순위 선택 작업을 위해 처음에 무작위로 초기 모판을 선택한다. 또한 비용함수로는 평균 제곱 오차(Mean Square Error: MSE)를 사용하였다.

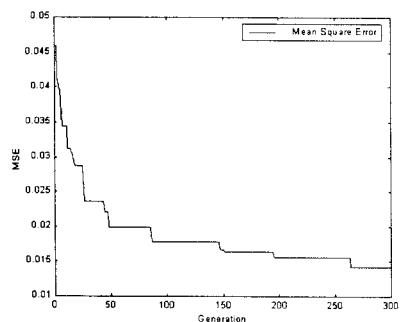


그림 5 동정 단계에서의 MSE 변화

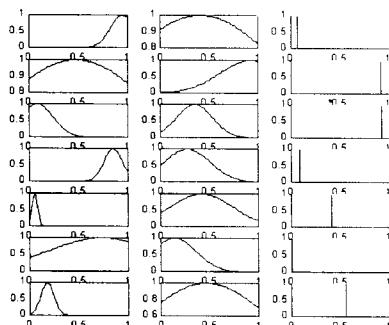


그림 6 동정된 퍼지 규칙들의 소속함수

그림 5는 동정 단계에서의 MSE값의 변화를 나타낸 것이고, 그림 6은 제안된 방법에 의해 동정된 퍼지 규칙들의 소속함수를 나타낸 것이다.

mGA를 사용한 뉴로-퍼지 모델링 결과 7개의 퍼지 규칙을 얻었으며, 이러한 규칙들은 오차 역전파 알고리즘에 따라 학습시킨 결과 0.0105의 오차값을 얻을 수 있었다. 그리고 ANFIS[3]에 의한 오차값은 0.007, 전체 규칙수는 17개로 제안된 방법에 비해 오차값은 낮은 수치이나, 현저한 규칙 수의 차이가 나타남을 알 수 있었다. 따라서 제안된 방법은 기존의 방법들에 비해 적은 수의 규칙으로 우수한 모델링 성능을 나타냄을 알 수 있다.

3. 결 론

본 논문에서는 mGA를 이용한 퍼지-신경망 모델링 방법을 제안하였다. 제안된 방법은 mGA를 사용하여 퍼지-신경망의 학습 능력을 이용하여 소속함수의 구조 및 파라미터들을 동정한 후, 신경망의 국소 학습 방법인 오차 역전파 알고리즘을 이용하여 동정된 모델을 미세동조 하는 방법이다. 기존의 유전알고리즘은 고정된 스트링을 이용하지만 mGA는 가변길이 스트링을 사용하므로 유동적인 암호화 표현이 가능하며, 본 논문에서는 소속함수의 구조 및 파라미터를 동시에 동정하기 위해 열색체의 새로운 암호화 방법을 개발하였다. 또한 제안된 방법의 우수성을 입증하기 위해 Mackey-Glass 흔든 시계열 시스템의 퍼지 신경망 모델의 동정 결과를 ANFIS와 비교를 통하여 제안된 방법의 우수성을 입증하였다.

(참 고 문 헌)

- [1] 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.
- [2] 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.
- [3] J. S. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference Systems", *IEEE Trans. System, Man and Cybernetics*, Vol. 23, No. 3, pp. 665-684, 1993.
- [4] 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
- [5] D. E. Goldberg, B. Korb, and K. Deb, "Messy Genetic Algorithms: Motivation, Analysis, and First Results", *Complex Systems*, Vol. 3, No. 5, pp. 493-530, 1989.
- [6] H. Kargupta, "The Gene Expression Messy Genetic Algorithm", Proc. of IEEE Int. Conf. on Evolutionary Computation, Nagoya, Japan, 1996
- [7] M. Chowdhury and Y. Li, "Messy Genetic Algorithm Based New Learning Method for Structurally Optimized Neurofuzzy Controllers", Proc. IEEE Int. Conf. on Industrial Tech., Dec. 1996.
- [8] Shin-ichi Horikawa, Takeshi Furuhashi, and Yoshiki Uchikawa "On Fuzzy Modeling Using Fuzzy Neural Networks with the Back-Propagation Algorithm", *IEEE Transactions on Neural Networks*, Vol. 3, No. 5, September 1992.