

정보 입자 기반 퍼지 모델의 유전자적 최적화

Genetic Optimization of Information Granules-based Fuzzy Model

박건준*, 이동윤**, 오성권*

*수원대학교 전기공학과

**중부대학교 정보통신학과

Keon-Jun Park, Dong-Yoon Lee, Sung-Kwun Oh

Dept. of Electrical Engineering, The University of Suwon

Dept. of Information & Communications

E-mail : ohsk@suwon.ac.kr

요약

퍼지모델은 주로 경험적 방법에 의해 추출되기 때문에 보다 구체적이고 체계적인 방법에 의한 동정 및 최적화 될 필요성이 요구된다. 따라서 본 논문에서는 퍼지 모델의 전반부 및 후반부의 구조 동정과 파라미터 동정에 있어서 최적의 구조 및 파라미터를 찾기 위해 유전자 알고리즘을 이용한다. 초기 퍼지 모델을 설계하기 위해 유전자 알고리즘을 이용하여 입력 변수의 수, 선택될 입력 변수, 멤버쉽함수의 수, 그리고 후반부 형태를 결정한다. 구축된 퍼지 모델은 유전자 알고리즘에 의해 세대를 거듭하면서 전반부 파라미터를 자동 동조함으로써 최적의 퍼지 모델을 설계한다. 또한 구조 동정 및 파라미터 동정을 동시에 시행함으로서 정보 입자 기반 퍼지 모델의 유전자적 최적화를 도모한다. 마지막으로 제안된 퍼지 모델은 표준 모델로서 널리 사용되는 수치적인 예를 통하여 평가한다.

1. 서론

비선형적이고 복잡한 실 시스템의 특성을 해석하기 위해 1965년에 Zadeh[1]에 의해 창안된 “퍼지집합” 이론을 적용함으로써 수학적 모델보다 좋은 결과를 가져왔다. 설계할 시스템의 성능 및 기능의 요구조건에 따라 퍼지 모델은 애매 모호한 언어적 변수를 수치적으로 표시할 수 있어서 융통성 있는 시스템 설계를 가능하게 하고 시스템의 기능을 향상시키며 설계를 간단하게 해주는 장점이 있다. 그러나 데이터 특성에 맞는 퍼지 모델을 구축하는데 있어서는 전문가와 시행착오에 의존해야 하는 어려움이 있어 동적으로 변화하는 환경에서 적응적으로 대처할 수 있는 퍼지 모델을 구축하기가 힘들다. 이러한 문제를 해결하기 위한 방법으로 정보 입자(Information Granulation:IG)[2,3]에 대한 연구가 행해지고 있

다.

본 논문에서는 HCM 클러스터링 알고리즘[4]에 의한 정보 입자의 특성에 맞는 퍼지 모델을 설계하고 유전자 알고리즘[5]을 이용하여 퍼지 모델의 전반부 및 후반부의 구조와 파라미터를 최적으로 하이브리드 동정한다. 유전자 알고리즘을 이용하여 입력 변수의 수, 선택될 입력 변수, 멤버쉽함수의 수, 후반부 형태, 그리고 전반부 멤버쉽 파라미터를 결정한다. 구조 동정 및 파라미터 동정에 있어서 개별적이 아닌 동시에 시행함으로서 구조와 파라미터를 동시에 고려한 최적의 퍼지 모델을 설계한다. 제안된 정보 입자 기반 퍼지 모델의 평가를 위해 Mackey-Glass time series[6]를 모델링하여 기존 퍼지 모델과 비교 평가한다.

2. 정보 입자

정보 입자는 균접성, 유사성 또는 기능성 등의 기준에 의해 서로 결합된 물체(특히, 데이터 점)의 연결된 모임으로 간주되며, 기존보다 더 적은 계산적인 복잡성을 위해 잘 정의된 하위문제(모듈)들로 분할된다. 본 논문에서는 입출력 관계의 특성을 이용하여 모델링을 수행한다. 따라서 데이터의 특성을 파악하는 것이 매우 중요하다. 입출력 데이터의 특성을 찾아내기 위해 HCM 클러스터링 알고리즘[4]을 이용한다.

본 논문에서는 데이터들간의 거리를 기준으로 균접한 정도를 측정하여 데이터를 특성별로 분류하는 HCM 클러스터링 알고리즘[4]을 이용한다.

3. 정보 입자 기반 퍼지 모델

3.1 전반부 동정

퍼지 모델링에서 전반부 동정, 즉 구조 동정 및 파라미터 동정은 비선형 시스템을 표현하는데 있어서 매우 중요하다. 기존의 방법은 멤버쉽 함수를 입력 변수의 최소값과 최대값 사이에서 임의의 개수로 등분하여 일률적으로 정의하였으나 이는 데이터들이 가지고 있는 특성을 제대로 반영하지 못하는 단점이 있다. 그래서 전반부 파라미터 동정을 위해 HCM 클러스터링에 의해 초기 멤버쉽함수의 정점을 동정한다.

HCM 클러스터링을 통한 정보 입자에 의한 전반부 동정은 다음과 같다.

전체 데이터 집합 $\mathbf{U} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_l ; \mathbf{y}\}$ 이고, 여기서 $\mathbf{x}_k = [x_{1k}, \dots, x_{mk}]^T$, $\mathbf{y} = [y_1, \dots, y_m]^T$, l 은 변수의 수 그리고 m 은 데이터의 수로 가정한다.

[단계 1] 전체 데이터 집합 \mathbf{U} 를 각각의 입력 데이터와 출력 데이터의 데이터 집합 \mathbf{X}_k 로 배열한다.

$$\mathbf{X}_k = [\mathbf{x}_k ; \mathbf{y}] \quad (1)$$

여기서, \mathbf{X}_k 는 k 번째 입력 데이터와 출력 데이터의 데이터 집합이고, $k=1, 2, \dots, l$ 이다.

[단계 2] 데이터 집합 \mathbf{X}_k 로부터 중심 벡터 \mathbf{v}_{kg} 를 구하기 위해 HCM 클러스터링을 시행한다.

[단계 2-1] 데이터 집합 \mathbf{X}_k 를 c 개의 클러스터(정보 입자)로 분류한다.

[단계 2-2] 각 클러스터의 중심 벡터 \mathbf{v}_{kg} 를 계산한다.

$$\mathbf{v}_{kg} = \{v_{k1}, v_{k2}, \dots, v_{kc}\} \quad (2)$$

[단계 3] 중심 벡터 \mathbf{v}_{kg} 로 해당하는 입력의 개별적인 퍼지 공간을 분할하고 각 클러스터에 Small, Big과 같은 언어적 변수를 할당한다.

[단계 4] 중심 벡터 \mathbf{v}_{kg} 를 멤버쉽함수의 초기 정점으로 설정한다.

3.2 후반부 동정

퍼지 모델의 후반부 동정도 전반부와 마찬가지로 구조 동정과 파라미터 동정으로 나뉘어진다. 정보 입자에 따른 다항식 함수의 초기값을 가지고 구조를 동정한다.

[단계 1] j 번째 규칙의 퍼지 공간에 속한 데이터 집합을 찾는다.

[단계 1-1] 각 입력 변수의 분할 매트릭스로부터 각 클러스터(정보 입자)에 포함된 입력 데이터를 찾는다.

[단계 1-2] j 번째 규칙의 퍼지 공간에 속한 입력 데이터 쌍을 찾는다.

[단계 1-3] 앞서 찾은 입력 데이터의 쌍으로부터 그에 대응하는 출력 데이터를 찾는다.

[단계 2] 각 규칙에서 산술 평균에 의한 데이터 집합의 중심 벡터 \mathbf{V}_j 를 계산한다.

$$\mathbf{V}_j = \{V_{1j}, V_{2j}, \dots, V_{kj} ; M_j\} \quad (3)$$

여기서, V_{kj} 와 M_j 는 각각 입출력 데이터의 중심 값이다.

[단계 3] 중심 벡터 \mathbf{V}_j 를 후반부 다항식 함수의 초기값으로 설정한다.

후반부 구조로는 구조 1(간략 퍼지추론), 구조 2(선형 퍼지추론)와 구조 3(2차식 퍼지추론), 그리고 구조 4(변형된 2차식 퍼지추론)를 이용한다. 본 논문에서는 유전자 알고리즘에 의해 선택된 구조 3을 설명한다.

2차식 퍼지추론은 후반부가 2차식 함수의 다항식 형태를 가지며, 정보 입자 기반 퍼지 모델은 식 (4)와 같은 구현 규칙으로 구성된다.

$$R^j : \text{If } x_1 \text{ is } A_{1c} \text{ and } \dots \text{ and } x_k \text{ is } A_{kc} \text{ then } y_j - M_j = f_j(x_1, \dots, x_k) \quad (4)$$

$$\begin{aligned} f_j(x_1, \dots, x_k) = & a_{j0} + a_{j1}(x_1 - V_{1j}) + \dots + a_{jk}(x_k - V_{kj}) \\ & + a_{j(k+1)}(x_1 - V_{1j})^2 + \dots + a_{j(2k)}(x_k - V_{kj})^2 \\ & + a_{j(2k+1)}(x_1 - V_{1j})(x_2 - V_{2j}) + \dots \\ & + a_{j((k+2)(k+1)/2)}(x_{k-1} - V_{(k-1)j})(x_k - V_{kj}) \end{aligned} \quad (5)$$

퍼지 추론에 의해 추론된 값 y^* 은 식 (6)과 같다.

$$y^* = \frac{\sum_{j=1}^n w_{ji} y_j}{\sum_{j=1}^n w_{ji}} = \sum_{j=1}^n \hat{w}_{ji} (f_j(x_1, \dots, x_k) + M_j) \quad (6)$$

후반부 파라미터는 최소자승법에 의해 결정된다.

4. 퍼지 모델의 유전자적 최적화

유전자 알고리즘[5]은 자연 선택과 유전학에 기반으로 하는 확률적인 탐색방법으로써 탐색과 해의 가능영역들을 균형 있게 이용하기 위하여 생산, 교배, 돌연변이의 과정을 수행하는 일반성 있는 탐색법으로 비선형 최적화 이론에 탁월한

성능을 발휘하고 있다. 기존의 다른 탐색방법들과 달리 유전자 알고리즘은 해가 될 가능성이 있는 개체집단을 유지하면서 그들 모두가 동시에 최적값을 찾아나가기 때문에 지역 극소에 빠질 위험을 어느 정도 해결할 수 있다는 점과 더불어 모델의 성능지수가 최소가 되는 전역 극소 영역을 찾는 능력을 갖고 있다.

본 논문에서 제안된 퍼지 모델의 설계를 위해 유전자 알고리즘을 이용하여 구조 및 파라미터를 최적으로 동정한다. 퍼지 규칙의 전반부에서, 구조 동정은 입력 변수의 수와 선택되는 입력 변수 그리고 멤버쉽함수의 수를 결정하고, 퍼지 규칙의 후반부에서, 구조 동정은 다항식 함수의 구조를 결정하여 초기 모델을 설계한다. 그리고 전반부 멤버쉽 파라미터를 최적으로 동정한다. 구조 동정 및 파라미터 동정에 있어서 개별적이 아닌 동시에 시행함으로서 구조와 파라미터를 동시에 고려한 최적의 퍼지 모델을 설계한다.

5. 실험 데이터를 통한 결과 고찰

Predicting Chaotic(Mackey-Glass time series) 시계열 공정은 예측 알고리즘의 성능 평가를 위한 대표적인 예로서 사용되는 시계열이다[6]. 다음 식과 같은 비선형 동력학 방정식에 의해 생성된다.

$$\dot{x}(t) = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (7)$$

기존의 방법들과 비교를 위해 미래값 $x(t+6)$ 의 예측 성능을 알아본다. 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.

제안된 퍼지 모델을 설계하는데 있어서 시스템의 입출력을 6입력 1출력 [$x(t+30)$, $x(t+24)$, $x(t+18)$ $x(t+12)$ $x(t+6)$ $x(t)$; $y(t+6)$]으로 선정하였다. 학습 데이터에 의한 근사화와 테스트 데이터에 의한 일반화 능력을 상호 고려한 합성 목적 함수를 이용하였다. θ 를 0.0으로 설정하여 일반화 능력에 초점을 맞추었다. 성능 지수는 RMSE (Root Mean Square Error)을 이용한다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (8)$$

입력데이터의 Min_Max값을 이용한 퍼지 모델과 제안된 정보 입자 기반 퍼지 모델을 설계하기 위해 두 가지 퍼지 모델에 대해 6입력 시스템을 4입력 시스템으로 설정하였다. 주어진 시스템으로부터 입력 변수와 멤버쉽함수의 수 그리고 후반부 구조 및 전반부 파라미터를 유전자 알고리

즘을 이용하여 결정하였다.

Max_Min 기반 퍼지 모델의 경우 입력 변수는 $x(t-30)$, $x(t-18)$, $x(t-12)$, $x(t)$ 이 선택되었고, 멤버쉽함수의 수는 각 입력 변수에 대해 2개이고, 후반부 구조는 구조 3이 결정되었으며, 정보 입자 기반 퍼지 모델 경우에는 입력 변수가 Max_Min 기반 퍼지 모델과 같이 선택되었고, 멤버쉽함수의 수는 각 입력 변수에 대해 2개, 2개, 3개, 2개이고, 후반부 구조는 구조 3이 결정되었다. 표 1은 Max_Min 기반 퍼지 모델과 정보 입자 기반 퍼지 모델의 구조와 그에 따른 성능지수를 보여준다.

표 1 Max_Min 기반 퍼지 모델과 정보 입자 기반 퍼지 모델의 성능지수 ($\theta=0.0$)

Model	input variable	No. of MFs	Type	PI	E_Pi
Max/Min_FIS	$x(t-30)$ $x(t-18)$ $x(t-12)$ $x(t)$	2x2x2x2	Type 3	0.0001	0.0002
IG_FIS	$x(t-30)$ $x(t-18)$ $x(t-12)$ $x(t)$	2x2x3x2	Type 3	$6.15e^{-5}$	0.0001

그림 1은 표 1에서 정보 입자 기반 퍼지 모델에 대한 동정된 멤버쉽 파라미터를 보여준다.

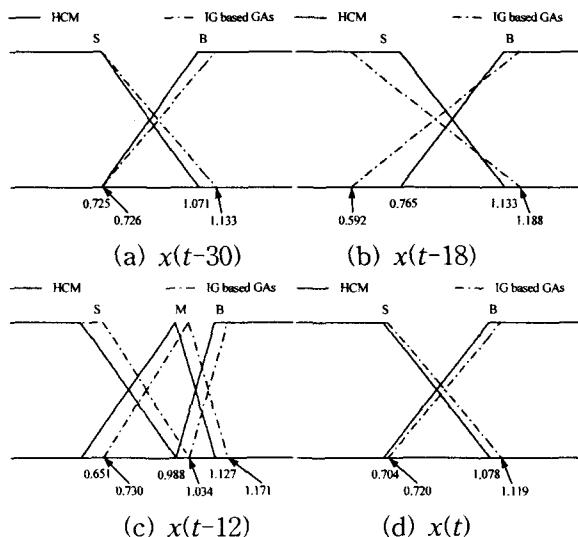


그림 1 동정된 멤버쉽 파라미터(IG_FIS)

그림 2는 제안된 퍼지 모델에 대한 성능지수를 보여주며, 세대 초기부터 좋은 성능을 나타냄을 알 수 있다.

표 2는 기존의 퍼지모델과 동정 오차를 비교하여 보여준다. 제안된 퍼지 모델이 기존의 퍼지

모델보다 성능이 향상된 것을 알 수 있다.

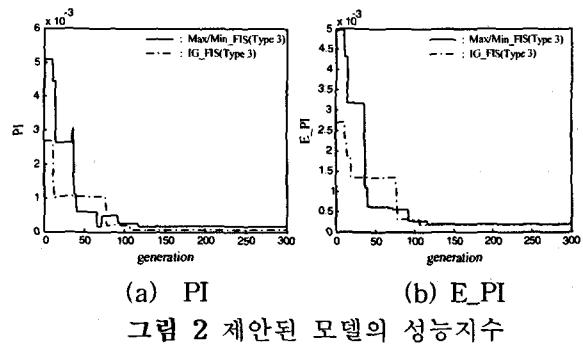


표 2 기존 퍼지모델과 동정 에러 비교

Model	rules	P _I	P _{II}	E-P _I	NDEI
Wang's model[7]	7	0.004			
	23	0.013			
	31	0.010			
Cascaded-correlation NN[8]					0.06
Backpropagation MLP[8]					0.02
6th-order polynomial[8]					0.04
ANFIS[9]			0.0016	0.0015	0.007
FNN model[10]			0.014	0.009	
Recurrent neural network[11]		0.0138			
Our model	32		6.15e ⁻⁵	0.0001	0.004

6. 결론

비선형 공정에 대해 체계적이고 효율적인 모델을 얻기 위하여 정보 입자 기반 퍼지 모델의 유전자적 최적화를 제안하였다. HCM 클러스터링 알고리즘에 의한 정보 입자는 퍼지규칙의 전,후반부에 각각 사용될 멤버쉽함수의 초기 정점 및 다항식 함수의 초기값과 같은 퍼지 모델의 초기 파라미터를 결정하였고, 초기 파라미터는 유전자 알고리즘에 의해 구조 및 파라미터를 동시에 탐색함으로써 효과적으로 동조하였다. 결과적으로 제안된 퍼지 모델은 입출력 데이터의 특징을 모델에 반영하기 위해 클러스터링 알고리즘을 사용하여 퍼지 입력 공간을 정의하였고, 또한 후반부 다항식 함수에 의한 정보 입자 기반 구조 동정 및 파라미터 동정을 수행하였다. 제안한 모델은 입출력 특징을 이용함으로써 복잡하고 비선형이 강한 공정에 기존의 퍼지 모델들 보다 성능이 향상된 퍼지 모델을 설계할 수 있었다.

7. 참고문헌

- [1] L. A Zadeh, "Fuzzy sets," Inf. Control 8, pp.338-353, 1965.

[2] _____, "Fuzzy logic = Computng with words," IEEE Trans. Fuzzy Syst., Vol. 4, No. 2, pp. 103-111, 1996.

[3] W.Pderyca and G. Vukovich, "Granular neural networks," Neurocomputing, Vol. 36, pp. 205-224, 2001.

[4] P. R. Krishnaiah and L. N. Kanal, editors. Classification, pattern recognition, and reduction of dimensionality, volume 2 of Handbook of Statistics. North-Holland, Amsterdam, 1982.

[5] D. E. Goldberg, "Genetic Algorithm in search, Optimization & Machine Learning," Addison wesley, 1989.

[6] M.C. Mackey and L. Glass, "Oscillation and chaos in physiological control systems," Science, 197, pp 287-289, July 1977.

[7] L. X. Wang, J. M. Mendel, "Generating fuzzy rules from numerical data with applications," IEEE Trans. Systems, Man, Cybern., Vol. 22, No. 6, pp. 1414-1427, 1992.

[8] R. S. Crowder III, "Predicting the Mackey-Glass time series with cascade-correlation learning," In D. Touretzky, G. Hinton, and T. Sejnowski, editors, Proceedings of the 1990 Connectionist Models Summer School, pp. 117-123, Carnegie Mellon University, 1990.

[9] J. S. R. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference System," IEEE Trans. System, Man, and Cybern., Vol. 23, No. 3, pp. 665-685, 1993.

[10] L. P. Maguire, B. Roche, T. M. McGinnity, L. J. McDaid, "Predicting a chaotic time series using a fuzzy neural network," Information Sciences, Vol. 112, pp. 125-136, 1998.

[11] C. James Li, T. -Y. Huang, "Automatic structure and parameter training methods for modeling of mechanical systems by recurrent neural networks," Applied Mathematical Modeling, Vol. 23, pp. 933-944, 1999.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초전력연구원(R-2004-B-274) 주관으로 수행된 과제임.