

정보 입자 기반 유전론적 퍼지 집합 다항식 뉴럴네트워크 설계와 다변수 시스템으로의 응용 The Design of Genetic Fuzzy Set Polynomial Neural networks based on Information Granules and Its Application of Multi-variables System

이인태, 오성권, 김현기, 서기성*

수원대학교 전기공학과

*서경대학교 전자공학과

In-Tae Lee, Sung-Kwun Oh, Hyun-Ki Kim, Ki-Sung Seo

Dept. of Electrical Engineering, The University of Suwon

*Dept. of Electronic Engineering, Seokyeong University

E-mail : ohsk@suwon.ac.kr

요 약

본 논문에서는 퍼지 뉴럴네트워크의 새로운 구조인 Fuzzy Set-based Polynomial Neural Networks(FSPNN)을 소개한다. 제안된 모델은 일반적인 최적화 방법과 정보 입자를 이용하여 네트워크를 설계한다. 최종 구조는 Fuzzy Set-based Polynomial Neuron(FSPN)을 기반으로 설계한 FPNN과 동일하다. 첫째로 FSPNs의 종합적인 설계방법(유전자 알고리즘을 이용한 최적 구조 탐색)에 대해 소개한다. FSPNN에 관계되는 입력변수의 개수, 후반부 다항식의 차수, 멤버쉽 함수의 수 그리고 입력변수 개수에 따른 입력변수를 유전자 알고리즘을 통하여 동조한다. 두 번째로, 입력 변수의 개별적인 퍼지 규칙 형성과 퍼지 공간 분할 및 삼각형 멤버쉽 함수의 초기 정점을 HCM 클러스터링을 통한 Information Granules로 정의한다. 또한 데이터 입자의 중심을 이용하여 후반부의 구조를 결정한다.

이 네트워크의 성능은 기존에 퍼지 또는 뉴로퍼지 모델링에서 실험된 모델링 표준치를 이용하여 평가한다.

1. 서론

본 논문에서 제안한 모델의 기본 모델이 되는 퍼지규칙 기반 자기구성 퍼지 다항식 뉴럴네트워크(Self-Organizing Fuzzy Polynomial Neural Networks ; SOFPNN)[1]는 FIS와 GMDH의 확장(Extension), 결합(Combination), 및 융합(Fusion)에 의해 설계되며 이는 퍼지 집합 기반 다항식 뉴럴네트워크(Fuzzy Set-based Polynomial Neural Networks; FSPNN)와 퍼지 관계 기반 다항식 뉴럴네트워크(Fuzzy Relation-based Polynomial Neural Networks; FRPNN)로 나뉘어 진다. 이것은 퍼지집합과 퍼지 관계를 기반으로 한 FIS가 GMDH의 확장된 형태인 SOPNN(Self-Organizing Polynomial

Neural Networks)[2]과의 융합으로 생성된 구조이다.

기본 모델로 사용된 FSPNN[7]은 유전자 알고리즘(Genetic Algorithms;GAs)[3, 4]을 사용하여 구조를 최적화시킨다. 이는 기존의 FSPNN 모델들이 선호된 네트워크 구조를 찾기 위해서 노드의 입력변수의 수와 규칙 후반부 다항식 차수 입력변수 그리고 선택된 멤버쉽 함수의 수를 설계자의 경험 또는 반복적인 학습을 통해서 얻을 수 있어서 최적의 네트워크 구조를 구축하는데 어려움이 내재되어 있었다. 따라서 객관적이고 신뢰성 있는 최적의 모델을 구축하기 위해서 유전자 알고리즘을 통해 모델(GAs_based FSPNN; gFSPNN)을 구축하였다. 비록 GAs를 통해 구조를 최적화 하였더라도 데이터의 특성까지는 모

델을 구축하는데 반영되지는 못한다. 따라서 주어진 데이터의 특성을 해석하기 위하여 HCM 방법을 결합한 Information Granulation[5]기반 진화론적 최적 퍼지 집합 다항식 뉴럴네트워크 (Information Granulation-based gFSPNN; IG_based gFRPNN)를 제안한다.

본 논문에서 제안된 IG_based gFSPNN의 성능 평가를 위해 Mackey-Glass 시계열 공정[6]을 사용하였다.

2. 데이터 입자

데이터 입자는 근접성, 유사성 또는 기능성 등의 기준에 의해 서로 결합된 물체(특히, 데이터 점)의 연결된 모임으로 간주되며, 기존보다 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.

본 논문에서는 데이터들간의 거리를 기준으로 근접한 정도를 측정하여 데이터를 특성별로 분류하는 HCM 클러스터링 알고리즘[4]을 이용한다. HCM 클러스터링에 의한 데이터 분류는 다음과 같다.

[단계 1] 클러스터 개수 ($2 \leq c \leq n$)를 결정하고, 소속행렬 U 를 초기화한다.

[단계 2] 각각의 클러스터에 대한 중심벡터를 구한다.

[단계 3] 각각의 클러스터 중심과 데이터와의 거리를 계산하여 새로운 소속행렬을 생성한다.

[단계 4] 만일 종료 조건을 만족한다면 종료하고, 그렇지 않으면 [단계 2]로 간다.

3. Fuzzy Set Polynomial Neuron

FSPN은 FSPNN의 가장 기본이 되는 처리 단위이다. FSPN은 퍼지 집합과 뉴럴 네트워크의 개념에 기초해서 자세히 설명된다. 그림 1과 같이 2개의 기본적인 기능 모듈로 구성되어 있다.

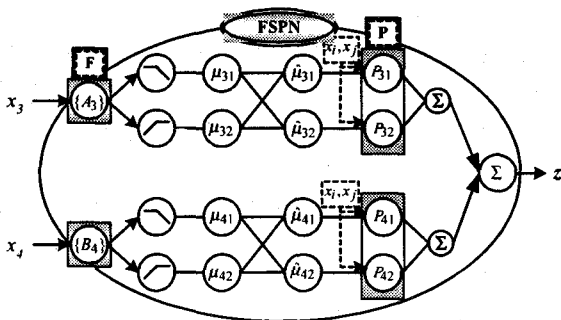


그림 1 FSPN 모듈의 일반적인 구조

그림 1은 입력변수가 2개이고 멤버십 함수가 각각 2인 경우를 보여주고 있다. FSPN은 FRPN과 다르게 입력변수들이 서로 관계하지 않고 각각 따로 연산을 한다. 따라서 FRPN처럼 각 입력에 대한 멤버십 함수의 수가 늘어나더라도 기아 급수적으로 규칙의 수가 증가하지 않아 후반부 파라미터 계산시간을 단축할 수 있다, 그림에서 "F" 로 표기되어진 것은 퍼지 집합의 집합체로써 입력 수의 변수들과 뉴론에 의해 실현된 처리 부분사이를 상호 연결해 준다. 그림에서 X_p 와 X_q 를 입력변수들로 표시한다. "P" 로 표기된 두 번째 모듈은 함수 기반 비선형(다항식) 처리에 관한 것이다.

4. IG-based gFSPNN 설계

데이터 입자화 기반 진화론적 퍼지 다항식 뉴럴 네트워크의 최적화 설계과정은 다음과 같다.

[단계 1] 출력변수 y 와 시스템 입력변수 결정.

[단계 2] 입출력 데이터를 학습용과 평가용 데이터로 분할한다.

[단계 3] gFSPNN의 퍼지 추론 방법 및 동정을 설계하는 부분과 모델의 구조를 결정하는 초기 정보를 결정한다.

[단계 4] gFSPNN 모델을 구축하는데 기본 유닛인 FPN 노드들을 유전자 알고리즘에서 각각의 염색체에 의한 구조 선택을 통해 최적 모델을 구축한다.

[단계 4-1] 입력변수의 수 선택

[단계 4-2] 퍼지규칙 후반부 다항식 차수 선택

[단계 4-3] 입력변수 선택

[단계 4-4] 멤버십 함수의 수 선택

[단계 4-1]부터 [단계 4-4]까지 수행해서 얻은 선택된 입력변수와 퍼지규칙 후반부 다항식 차수를 이용하여 퍼지 추론을 적용한다.

표 1 퍼지규칙 후반부 구조의 서로 다른 형태

입력수 차수	1	2	3
0(Type 1)	Constant		
1(Type 2)	Linear	Bilinear	Trilinear
2(Type 3)	Quadratic	Biquadratic	Triquadratic
2(Type 4)		Modified Biquadratic	Modified Triquadratic

[단계 5] 전반부 동정

HCM 클러스터링을 통한 데이터 입자에 의한 전반부 동정은 다음과 같다.

전체 데이터 집합 $U = \{x_1, x_2, \dots, x_l; y\}$ 이고, 여기서 $x_k = [x_{1k}, \dots, x_{mk}]^T$, $y = [y_1, \dots, y_m]^T$, l 은

변수의 수 그리고 m 은 데이터의 수로 가정한다. 데이터 집합 X_k 를 c 개(멤버쉽 함수의 수)의 클러스터(데이터 입자)로 분류한다.

$$v_{kg} = \{u_{k1}, u_{k1}, \dots, u_{kc}\} \quad (1)$$

여기서, $k=1, 2, \dots, l, g = 1, 2, \dots, c$. 중심 벡터 v_{kg} 를 멤버쉽함수의 정점으로 설정한다.

[단계 6] 후반부 동정

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

j 번째 규칙의 퍼지 공간에 속한 데이터 집합을 찾는다. j 번째 규칙의 퍼지 공간에 속한 입력 데이터 쌍을 찾는다. 앞서 찾은 입력 데이터의 쌍으로부터 그에 대응하는 출력 데이터를 찾는다.

각 규칙에서 산술 평균에 의한 데이터 집합의 중심 벡터 V_j 를 계산한다.

$$V_j = \{V_{1j}, V_{2j}, \dots, V_{kj}; M_j\} \quad (2)$$

여기서, $k=1, 2, \dots, l, j=1, 2, \dots, n$. V_{kj} 와 M_j 는 각각 입력 데이터와 출력 데이터의 중심값이다.

예를 들어, 2차식 퍼지추론은 후반부가 2차식 함수의 다항식 형태를 가지면, 퍼지 집합 뉴럴 네트워크는 식 (3)와 같은 구현 규칙으로 구성된다.

$$R^j : \text{If } x_k \text{ is } A_{kc} \text{ then } y_j - M_j = f_j(x_1, \dots, x_k) \quad (3)$$

$$f_j(x_1, \dots, x_k) = a_0 + a_{1j}(x_1 - V_{1j}) + \dots + a_{jk}(x_k - V_{kj}) + a_{j(k+1)}(x_1 - V_{1j})^2 + \dots + a_{j(2k)}(x_k - V_{kj})^2 + a_{j(2k+1)}(x_1 - V_{1j})(x_2 - V_{2j}) + \dots + a_{j(k+2)(k+1)/2}(x_{k-1} - V_{(k-1)j})(x_k - V_{kj}) \quad (4)$$

퍼지 추론에 의해 추론된 값 y^* 은 식 (6)과 같다.

$$y^* = \frac{\sum_{j=1}^n w_{ji} y_j}{\sum_{j=1}^n w_{ji}} = \sum_{j=1}^n \hat{w}_{ji} (f_j(x_1, \dots, x_k) + M_j) \quad (5)$$

후반부 파라미터는 최소자승법에 의해 결정된다.

[단계 7] 모델 구축과 테스트 그리고 노드의 선택

Step 1) gFSPNN 모델 구축을 위한 유전자의 세대, Population 개수, 돌연변이를, 교배율, 그리고 염색체의 길이와 같은 유전자의 정보를 설정한다.

Step 2) 테스트 데이터를 이용해서 구해진 성능지수를 유전자 알고리즘의 적합도 함수로 계산하기 위해서 다음 식 (6)와 같이 변환하여 유전자 알고리즘의 적합도 함수로 사용한다.

$$F(\text{Fitness Function}) = 1/(1+EPI) \quad (6)$$

Step 3) 다음 세대의 생성을 위해서 구해진 개체군 정보와 적합도 값들을 이용하여 선택연산, 교배, 돌연변이를 실행한다.

Step 4) 내림 차순으로 정렬된 적합도 값들 중에서 중복된 적합도 값들은 제거한다.

Step 5) 중복된 적합도 값들을 하나로 처리한 후 설계자가 노드의 제한된 개수 W 개만큼 선호되는 적합도 값들을 선택한다.

Step 6) Step 5)에서 선택되었던 노드들을 다시 초기 population 번호 순서에 따른 오름차순으로 재정렬한다.

Step 7) 다음세대에서의 엘리트 전략을 위해서 선택된 노드들 중 최적의 적합도 값을 가지는 노드를 선택한다.

Step 8) Step 3)에서 얻어진 정보를 가지고 다음 세대의 population을 생성한 후 Step 2)에서 Step 7)까지 반복한다. 여기서 생성된 적합도 값들 중에서 가장 낮은 적합도 값을 가진 노드를 이전 세대의 최적의 적합도 값을 가진 노드로 대체하는 엘리트 전략을 실행한다.

Step 10) 이전 세대에서 구해진 적합도 값들과 현재 세대에서 구해진 적합도 값들을 결합하여 다시 Step 4)부터 Step 7)까지 반복하고 정해진 세대까지 반복 실행한다.

[단계 8] [단계 7]의 현재 층에서 얻어진 최적 노드의 최대 적합도 값 F_1 이 다음 부등식을 만족하는 경우에 알고리즘을 종료한다.

$$F_l \leq F_* \quad (7)$$

단, F_* 는 이전 층의 최적 노드인 최대 적합도 값이다. 본 논문에서의 모델의 성능지수식으로 다음 식을 이용하였다.


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

[단계 9] 현재 층에서 보존된 노드의 출력들에서 다음 층의 새로운 입력들로, $x_{1j}=z_{1i}, x_{2j}=z_{2i}, \dots, x_{wj}=z_{wi}$ 으로 구성하고, [단계 4]로 간다(여기서, $j=i+1$). 이 후, [단계 4]부터 [단계 9]까지를 반복한다. 알고리즘이 종료할 경우, 마지막 층의 최적 적합도 값 F_* 을 얻은 노드의 다항식에 입력이 되는 전 층의 출력을 대입하고 동일한 조작을 제 3 층까지 반복하여 최종 추정 모델 \hat{y} 를 얻는다.

5. 실험 데이터를 통한 결과 고찰

제안된 모델의 성능을 테스트하기 위해서 Mackey-Glass 시계열 공정[6]을 사용하였다. Mackey-Glass 시계열은 예측 알고리즘의 성능 평가를 위한 대표적인 예로서 사용되는 데이터이

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



(a) Training data (b) Testing data

그림 2 가우시안 멤버쉽 함수일때 성능지수에 따른 최적화 과정

그림 2는 최대 선택될 수 있는 입력변수의 수가 5이며 시스템 입력을 모두 후반부 다항식에 사용하였을 때의 그림이다. 여기에서 정보 입자화를 사용한 모델이 보다 빠르게 최적 해에 수렴함을 볼 수 있다.

표 2 기존모델과의 성능지수 비교

Model	PI	P2	EPI
Wang's model [8]	0.044		
ANFIS [9]	0.013		
FNN [10]		0.0016	0.0015
Our model	Max=5	T	2.28×10^{-4}
		G	2.22×10^{-4}
		T (T)	1.20×10^{-4}
		G (G)	1.20×10^{-4}

T : Triangular, G : Gaussian-like
T: 후반부 다항식에 시스템 입력을 사용

표 3은 Mackey_Class 시계열 데이터를 사용하여 성능지수를 식 (8)에 의해 계산한 값이다. Max=5일때 그리고 후반부 구조가 가우시안 멤버쉽 함수일 때 성능이 우수함을 보인다. 또한 기존의 gFSPNN보다 IG-based FSPNN이 데이터의 특성을 고려하여 모델을 설계해 보다 최적화 됨을 알 수 있다.

6. 결론

본 논문에서는 IG-based gFSPNN 모델을 제안하였다. 기존의 gFSPNN 모델의 구조는 성능을 향상시키는데 영향을 미치는 입력변수의 수와 그에 따른 입력변수, 퍼지 규칙 후반부 다항식 그리고 멤버쉽 함수의 수를 설계자의 경험이 아닌 객관적 최적화 방법인 유전자 알고리즘을 이용하여 구조를 선택하였다. 하지만 데이터의 특성을 고려하지 않아 모델 데이터 특성에 맞게 설계가 어려웠다. 따라서 HCM 클러스터링을 통한

데이터 입자에 의한 gFSPNN 모델을 설계하는 것이 결과적으로 다변수 공정 모델 구축에 있어서 유연성과 정확성을 가지며 또한 데이터 특성에 맞는 모델을 설계에 유용함을 보인다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초전력 연구원(I-2004-0-074-0-00) 주관으로 수행된 과제임.

7. 참고문헌

- [1] S.-K. Oh and W. Pedrycz, "Fuzzy Polynomial Neuron-Based Self-Organizing Neural Networks", *Int. J. of General Systems*, Vol. 32, No. 3, pp. 237-250, May, 2003.
- [2] S.-K. Oh and W. Pedrycz, "The design of self-organizing Polynomial Neural Networks", *Information Science*, Vol. 141, pp. 237-258, 2002.
- [3] Holland, J. H., *Adaptation In Natural and Artificial Systems*, The University of Michigan Press, Ann Arbour. 1975.
- [4] K. De Jong. Are genetic algorithms function optimizers? In Proc. of PPSN II (Parallel Problem Solving from Nature), pages 3-13, Amsterdam, North Holland, 1992.
- [5] W. Pderycya and G. Vukovich, "Granular neural networks," *Neurocomputing*, Vol. 36, pp. 205-224, 2001.
- [6] M. C. Mackey and L. Glass, "Oscillation and chaos in physiological control systems", *Science*, Vol. 197, pp. 287-289, 1977
- [7] S.-K. Oh, S.-B. Roh, D.-H Park, Y.-K Kim "FSPN-based Genetically Optimized Fuzzy Polynomial Neural Networks", *ICCSA 2005*, LNCS 3483, pp. 858-866, 2005.
- [8] L. X. Wang, J. M. Mendel, "Generating fuzzy rule from numerical data with applications", *IEEE Trans. System, Man, Cybern.*, Vol. 22, No. 3, PP. 665-685, 1993
- [9] J. S. Jang, "ANFIS: Adaptive-Network-based Fuzzy Inference System", *IEEE Trans. System, Man, 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.