

## 기호코딩 및 정보입자를 이용한 전방향 퍼지 집합 기반 뉴럴네트워크의 설계

이인태, 오성권, 김현기  
수원대학교 전기공학과

### Design of Feed-Forward Fuzzy Set-based Neural Networks Using Symbolic Encoding and Information Granulation

In-Tae Lee, Sung-Kwon Oh, Hyun-Ki Kim  
Department of Electrical Engineering, The University of Suwon

**Abstract** - 본 논문은 기호 코딩 및 정보입자를 이용한 유전자 알고리즘의 전방향 퍼지 집합 기반 뉴럴 네트워크 (Information Granules and Symbolic Encoding-based Fuzzy Set Polynomial Neural Networks ; IG and SE based FSPNN)의 모델 설계를 제안한다. 기존 퍼지 집합기반 다항식 뉴럴네트워크(FSPNN)의 구조 최적화를 위해 이진코딩을 사용하였다. 그러나 이진코딩에서 스트링의 길이가 길면 길수록 인접한 두 수 사이에 발생하는 금지한 비트 차이라는 해밍절벽이 발생하였다. 이에 제안된 모델에서는 해밍절벽의 문제를 해결하기 위해 기호코딩을 사용하였다. 제안된 모델은 각 입력에 대해 MFs의 개수 만큼 규칙을 생성하는 Fuzzy 집합기반 다항식 뉴럴네트워크(FSPNN)를 그대로 사용한다. 그리고 IG based gFSPNN의 평가을 위해 실험적 예제를 통하여 제안된 모델의 성능 및 근사화 능력의 우수함을 보인다.

#### 1. 서 론

본 논문에서 제안한 모델의 기본 모델이 되는 퍼지규칙 기반 자기구성 퍼지 다항식 뉴럴네트워크(Self-Organizing Fuzzy Polynomial Neural Networks ; SOFPNN)[1]은 FIS와 GMDH의 확장(Extension), 결합(Combination), 및 융합(Fusion)에 의해 설계되며 이는 퍼지 집합기반 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 퍼지 집합과 퍼지관계를 기반으로 한 FIS가 GMDH의 확장된 형태인 Self-Organizing Polynomial Neural Networks(SOPNN)[2]와의 융합으로 생성된 구조이다.

기본 모델로 사용된 FSPNN[3]은 유전자 알고리즘(Genetic Algorithms; GAs)[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 특성 까지는 모델을 구축하는데 반영되지는 못한다. 따라서 주어진 데이터의 특성을 해석하기 위하여 HCM 방법을 결합한 Information Granulation[5]기반 전화론적 최적 퍼지 집합 다항식 뉴럴네트워크 (Information Granules-based gFSPNN; IG based gFSPNN)를 제안한다.

본 논문의 평가를 위해 Mackey Glass 시계열] 데이터를 이용하여 제안된 모델의 타당성, 정확성 및 예측 성능 등을 기존 지능 모델들과 비교를 통해 그 우수성을 보인다.

#### 2. 정보 입자화

데이터 입자는 근접성, 유사성 또는 기능성 등의 기준에 의해 서로 결합된 물체(특히, 데이터 점)의 연결된 모임으로 간주되며, 기준보다 적은 계산적인 복잡성을 위해 잘 정의된 하위문제(모듈)들로 분할된다. 본 논문에서는 입력 출력 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. H CM 클러스터링에 의한 데이터 분류는 다음과 같다.

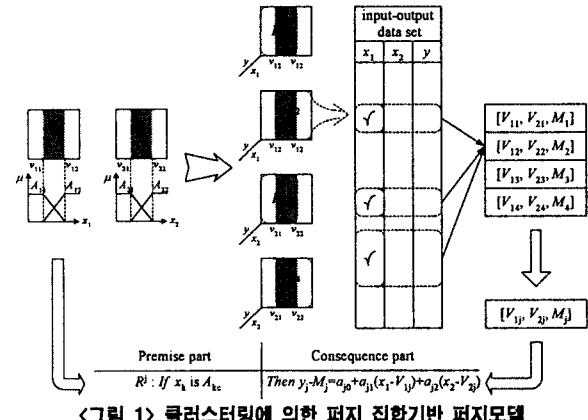
[단계 1] 클러스터 개수 ( $2 \leq c \leq n$ )를 결정하고, 소속행렬 U를 초기화한다.

[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

그림1은 HCM 클러스터링에 의한 2입력 1출력 시스템의 입력 출력 데이터 쌍을 가지고 퍼지 집합 기반 퍼지 모델(선형 퍼지추론)을 형성하는 과정을 보여준다.



<그림 1> 클러스터링에 의한 퍼지 집합기반 퍼지모델

#### 3. IG based gFSPNN 설계

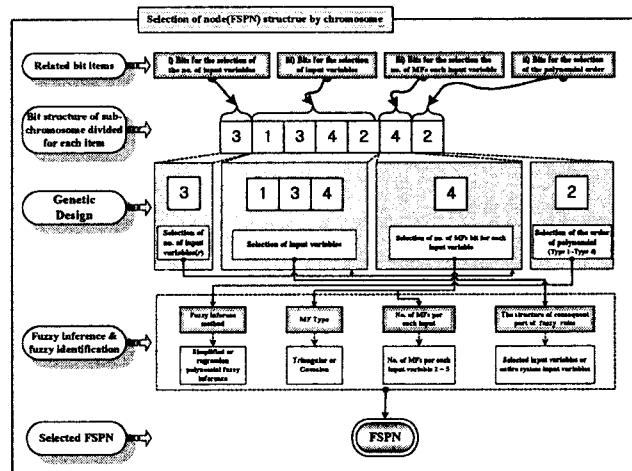
데이터 입자화 기반 유전자적 퍼지 다항식 뉴럴 네트워크의 최적화 설계 과정은 다음과 같다.

[단계 1] 출력변수 \$y\$와 시스템 입력변수 결정.

[단계 2] 입출력 테이터를 학습용과 평가용 테이터로 분할한다.

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

[단계 4] FPNN 모델을 구축하는데 기본 유닛인 FSPN을 유전자 알고리즘에서 각각의 염색체에 의한 구조 선택을 통해 최적 모델 구축



<그림 2> 염색체구조

#### [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  $x_k = [x_{1k}, x_{2k}, \dots, x_{mk}]^T$ ,  $y = [y_1, \dots, y_m]^T$ ,  $l$ 은 변수의 수 그리고  $m$ 은 데이터의 수로 가정한다.

데이터 집합  $X_k$ 를  $c$ (멤버쉽 함수의 수)의 클러스터(데이터 입자)로 분류 한다.

$$v_{kg} = \{v_{k1}, v_{k2}, \dots, v_{kc}\} \quad (1)$$

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

#### [단계 6] 후반부 동정

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.

[단계 7] 모델 구축, 테스트 그리고 노드의 선택

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

$$F_1 \leq F^* \quad (3)$$

[단계 9] 현재 층에서 보존된 노드의 출력들에서 다음 층의 새로운 입력들로,  $X_{lj}=Z_{lj}$ ,  $X_{2j}=Z_{2j}$ , ...,  $X_{Wj}=Z_{Wj}$ 으로 구성하고, [단계 4]로 간다(여기서,  $j=i+1$ ). 이 후, [단계 4]부터 [단계 9]까지를 반복한다.

#### 4. 실험 데이터를 통한 결과고찰

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.

$$\dot{x}(t) = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (4)$$

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.

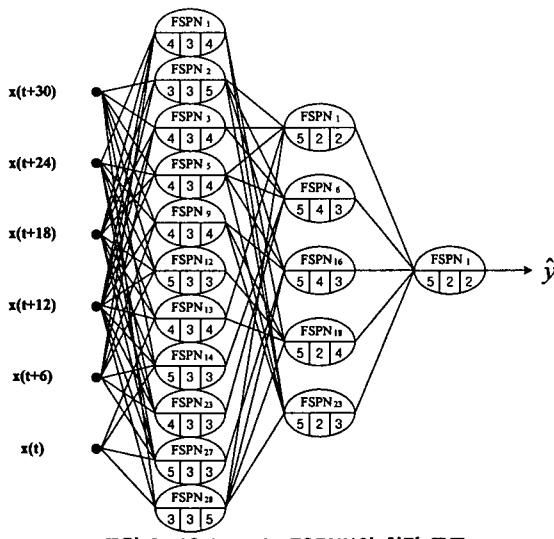
제안된 퍼지 모델을 설계하는데 있어서 시스템의 입출력을 6입력 1출력 [ $x(t+30)$ ,  $x(t+24)$ ,  $x(t+18)$ ,  $x(t+12)$ ,  $x(t+6)$ ,  $x(t)$ ;  $y(t+6)$ ]으로 선정하였다. 학습 데이터에 의한 근사화와 테스트 데이터에 의한 일반화 능력을 상호 고려한 합성 목적 함수를 이용하였다.  $\Theta$ 를 0.0으로 설정하여 일반화 능력에 초점을 맞추었다. 성능 지수는 RMSE (Root Mean Square Error)을 이용한다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (5)$$

다음 표 1은 유전자 알고리즘과 FSPNN의 초기설정값을 보여주고 있다.

〈표 1〉 GAs과 FSPNN정보

	Parameters	1층~3층
GAs	Maximum gen	300
	Total population size	150
	Selected population size	30
	Crossover rate	0.65
	Mutation rate	0.1
	String length	1+Max+2
FSPNN	Maximal no. of inputs to be selected (Max)	$1 \leq l \leq \text{Max}(2-5)$
	polynomial Type(Type T) of the consequent part of rules	$1 \leq T \leq 4$
	Membership Function(MFs) type	Gaussian Triangular
	No. of MFs per each input	2 ~ 5

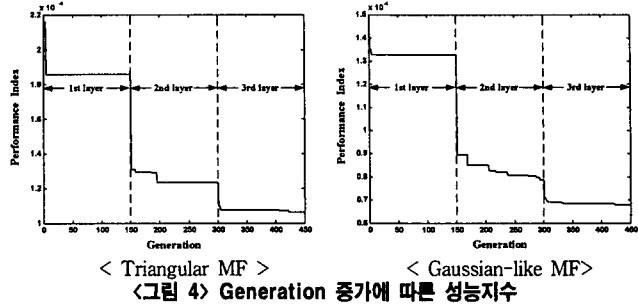


〈그림 3〉 IG based gFSPNN의 최적 구조

그림 3은 Mackey-Glass time series에 대한 최적 구조를 보여주고 있다. 이 구조는 Max=5이며 가우시안 멤버십 함수를 사용하고 후반부 구조에 시스템 입력 모두를 사용할 때 얻어지는 최적 구조이다. 노드의 세 개의 숫자가 의미하는 것은 (FSPN:4,3,4)를 예로 설명하면 먼저 FSPN1은 첫 번째

노드를 나타내고, 4,3,4는 입력의 수, 다항식의 차수, 멤버십함수의 수를 나타낸다.

그림 4는 후반부 다항식에 전체입력을 사용하여 Max=5일 때 삼각형과 가우시안 멤버십 함수에 따른 세대별 모델의 성능지수를 보여주고 있다.



〈그림 4〉 Generation 중간에 따른 성능지수

표 2는 기존의 퍼지모델과 동정 오차를 비교하여 보여준다. 제안된 퍼지 모델이 기존의 퍼지 모델보다 성능이 향상된 것을 알 수 있다.

〈표 2〉 GAs과 FSPNN정보

Model	PI	PI	EPI
Wang's model [6]	0.044		
ANFIS [7]	0.013		
FNN [8]		0.0016	0.0015
Our model	T	0.00031	0.00042
	G	0.00021	0.00024
	T(T')	4.49e-5	0.00011
	G(T')	4.49e-5	6.76e-5
	T	7.57e-5	0.00015
	G	0.00123	0.00121
Max=5	T (T')	4.65e-5	0.00010
	G (T')	2.65e-5	6.76e-5

#### 5. 결 론

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 멤버십 함수의 수를 설계자의 경험에 아닌 객관적 최적화 방법인 유전자 알고리즘을 이용하여 구조를 선택하였다. 하지만 데이터의 특성을 고려하지 않아 모델 데이터 특성에 맞게 설계가 어려웠다. 또한 유전자 알고리즘에서 2진코딩으로 인한 염색체의 길이에 따른 해밍절벽의 문제가 내재되어 있었다. 이에 본 논문에서는 HCM 클러스터링을 통한 데이터 특성을 고려하여 gFSPNN 모델을 설계하였고, 해밍절벽의 문제를 이진코딩에서 기호코딩으로 교체하여 극복하였다. 결과적으로 다변수 공정 모델 구축에 있어서 유연성과 정확성을 가지며 또한 데이터 특성에 맞는 모델을 설계 하는데 유용함을 보인다.

#### 감사의 글

이 논문은 경기지방·중소기업청의 연구비 지원에 의한 2005년도 수원대학교 산학연 컨소시엄 사업에 의해 수행된 과제임.

#### 참 고 문 헌

- S.-K. Oh and W. Pedrycz, "Fuzzy Polynomial Neuron-Based Self-Organizing Neural Networks", Int. J. of General Systems, Vol. 32, No. 3, p. 237-250, May, 2003.
- S.-K. Oh and W. Pedrycz, "The design of self-organizing Polynomial Neural Networks", Information Science, Vol. 141, pp. 237-258, 2002.
- 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.
- Holland, J. H., Adaptation In Natural and Artificial Systems, The University of Michigan Press, Ann Arbor, 1975.
- W. Pedrycz and G. Vukovich, "Granular neural networks," Neurocomputing, Vol. 36, pp. 205-224, 2001.
- 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.
- J. S. Jang, "ANFIS: Adaptive-Network-based Fuzzy Inference System", IEEE Trans. System, Man, Cybern., Vol. 23 No. 3, pp 665-685, 1993
- L. P. Maguire, B. Roche, T. M. McGinnity, L. J. McDaid, "Predicting a chaotic time series using a fuzzy neural network", Information Science s, Vol. 112, pp. 125-136, 1998.