

# 진화론적으로 최적화된 FPN에 의한 자기구성 퍼지 다항식 뉴럴 네트워크의 최적 설계

## Optimal design of Self-Organizing Fuzzy Polynomial Neural Networks with evolutionarily optimized FPN

박호성\*, 오성권\*\*  
(Ho-Sung Park, Sung-Kwun Oh)

**Abstract** - In this paper, we propose a new architecture of Self-Organizing Fuzzy Polynomial Neural Networks (SOFPNN) by means of genetically optimized fuzzy polynomial neuron(FPN) and discuss its comprehensive design methodology involving mechanisms of genetic optimization, especially genetic algorithms(GAs). The conventional SOFPNNs hinges on an extended Group Method of Data Handling(GMDH) and exploits a fixed fuzzy inference type in each FPN of the SOFPNN as well as considers a fixed number of input nodes located in each layer. The design procedure applied in the construction of each layer of a SOFPNN deals with its structural optimization involving the selection of preferred nodes (or FPNs) with specific local characteristics (such as the number of input variables, the order of the polynomial of the consequent part of fuzzy rules, a collection of the specific subset of input variables, and the number of membership function) and addresses specific aspects of parametric optimization. Therefore, the proposed SOFPNN gives rise to a structurally optimized structure and comes with a substantial level of flexibility in comparison to the one we encounter in conventional SOFPNNs. To evaluate the performance of the genetically optimized SOFPNN, the model is experimented with using two time series data(gas furnace and chaotic time series).

**Key Words** : SOFPNN(Self-Organizing Fuzzy Polynomial Neural Networks), FPN(Fuzzy Polynomial Neuron), GMDH(Group Method of Data Handling), GAs(Genetic Algorithms)

### 1. 서론

현재 대부분의 시스템 공정들은 모델의 차원이 증가하면 서(즉, 변수들의 수가 증가) 이데 대한 시스템을 모델링하는 것 역시 어려운 과제이다. 특히, 시스템이 복잡하고 대규모의 구조인 경우에는 함수식으로 모델의 표현이 한정되지 않기 때문에 회귀 분석을 적용하는 경우가 늘고 있다. 그 중 한 가지 방법이 1950년대 후반 A. G. Ivakhnenko가 제안한 Group Method of Data Handling(GMDH) 알고리즘이다[1]. 그러나 GMDH는 비교적 간단한 시스템에 대해서 매우 복잡한 다항식을 생성하는 경우가 있으며, 2입력, 2차 회귀다항식의 형태로 복잡한 비선형 시스템을 표현하는데는 어느 정도 한계가 있다. 또한 시스템 입력변수가 3입력이하인 경우엔 효율적인 모델을 구축하기가 어렵다. GMDH의 이러한 단점을 극복하고자, Oh 등에 의해 자기구성 다항식 뉴럴 네트워크 (Self-Organizing Polynomial Neural Networks ; SOPNN) [2]와 자기구성 퍼지 다항식 뉴럴 네트워크(Self-Organizing Fuzzy Polynomial Neural Networks ; SOFPNN) [2, 3]가 제안되었다. 기존의 SOFPNN의 구조는 일반적인 다중 퍼셉트론 구조의 경우와 달리 미리 정해져 있지 않고 층이 진행하는 동안 모델 스스로 노드의 선택과 제거를 통해 최적의 네

트워크 구조를 생성할 수 있는 유연성을 가지고 있다. 그러나 성능을 향상시키기 위하여, 노드의 입력변수의 수, 규칙 후반부 다항식 차수, 입력변수 그리고 멤버쉽 함수의 수는 설계자의 경험 또는 반복적인 학습을 통해 선호된 네트워크 구조를 선택하였으나, 최적의 네트워크 구조를 구축하는데는 어려움이 내재되어 있었다.

본 논문에서는 기존의 SOFPNN을 최적화시키기 위해서 최적화 탐색 방법중의 하나인 유전자 알고리즘 [4, 5]을 이용하여 SOFPNN의 입력변수 수와 입력변수, 규칙 후반부 다항식의 차수 그리고 멤버쉽 함수의 수를 탐색하여 최적의 퍼지 다항식 뉴럴 네트워크를 구축한다.

본 논문의 평가를 위해서 시계열 데이터인 가스로 공정 데이터[6]를 이용하여 제안된 모델의 타당성, 정확성 및 예측 성능 등을 기존 지능 모델들과 비교를 통해 그 우수성을 보인다.

### 2. 유전자 알고리즘을 이용한 SOFPNN 설계

이 장에서는 유전자 알고리즘을 이용한 퍼지 다항식 뉴럴 네트워크의 최적화 설계과정을 다룬다.

[단계 1] 출력변수  $y$ 에 관계하는  $n$ 개의 시스템 입력변수를 결정한다. 필요하면 데이터를 정규화한다.

[단계 2]  $N$ 개의 입출력 데이터를 학습용 데이터와 평가용 데이터로 분할한다.

[단계 3] GAs 기반 SOFPNN 구조를 구축하는데 있어서 기

\* 正會員 : 圓光大學 電氣電子情報工學部 專任講師 · 工博

\*\* 正會員 : 水原大學 電氣工學科 教授 · 工博

본적인 정보를 결정한다.

[단계 4] GAs 기반 SOFPNN 모델을 구축하는데 기본 유닛인 FPN 노드들을 유전자 알고리즘에서 각각의 염색체에 의한 구조 선택을 통해 최적 모델을 구축할 수가 있다.

[단계 4-1] 입력변수의 수 선택

[단계 4-2] 페지규칙 후반부 다항식 차수 선택

[단계 4-3] 입력변수 선택

[단계 4-4] 벤더쉽 함수의 수 선택

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

표 1. 페지규칙 후반부에서 회귀다항식의 서로 다른 형태

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

페지 추론 규칙과 파라미터 동정을 위한 매개변수 추정은 다음과 같다.

### i) 간략 추론

후반부가 단일의 상수함만을 가지는 것으로 이와 같은 추론법을 간략 추론법이라 한다.

$$R^i : \text{If } x_1 \text{ is } A_{j1} \text{ and } \dots \text{ and } x_n \text{ is } A_{jn} \text{ then } y_i = a_{ji} \quad (1)$$

i번째 데이터의 추론된 값은 다음과 같다.

$$\hat{y}_i = \frac{\sum_{j=1}^n w_j y_j}{\sum_{j=1}^n w_j} = \frac{\sum_{j=1}^n w_j a_{ji}}{\sum_{j=1}^n w_j} = \sum_{j=1}^n \hat{w}_j a_{ji} \quad (2)$$

$$w_j = A_{j1}(x_1) \wedge \dots \wedge A_{jn}(x_n)$$

여기서,  $i$ 는  $i(i=1, \dots, m)$ 번째 데이터,  $m$ 은 데이터 총 수이다. 후반부 파라미터  $a_{ji}$ 의 동정은 출력 데이터가 주어졌을 때 최소자승법에 의해 구해진다.

### ii) 회귀다항식 추론

후반부가 1, 2, 변형된 2차 다항식 형태로 표현된 것으로 회귀다항식 추론이라 한다. 이 경우의 페지 모델은 다음과 같은 형태를 가지는 구현 규칙들로 구성된다.

$$R^i : \text{If } x_1 \text{ is } A_{j1} \text{ and } \dots \text{ and } x_n \text{ is } A_{jn} \text{ then } y_i = f_i(x_1, \dots, x_n) \quad (3)$$

### [단계 5] 모델의 구축과 테스트 그리고 노드의 선택

Step 1) GAs 기반의 SOFPNN 모델 구축을 위한 유전자의 세대, Population 개수, 돌연변이율, 교배율, 그리고 염색체의 길이와 같은 유전자의 정보를 설정한다.

Step 2) 첫 번째 세대에서 설정된 population 개수만큼 염색체에 의한 노드(FPN)을 구축한다.

Step 3) 테스트 데이터를 이용해서 구해진 성능지수를 유전자 알고리즘의 적합도 함수로 계산하기 위해서 다음 식 (4)와 같이 변환하여 유전자 알고리즘의 적합도 함수로 사용한다.

$$F(\text{Fitness Function}) = 1/(1+EPI) \quad (4)$$

Step 4) 다음 세대의 생성을 위해서 구해진 개체구 정보와

적합도 값을 이용하여 선택연산, 교배, 돌연변이를 실행한다.

Step 5) 구해진 적합도 값을  $(F_1, F_2, \dots, F_z)$ 을 선호되는 적합도 값 순(내림차순)으로 정렬한다.

Step 6) 정렬된 적합도 값을 중복된 적합도 값을 제거하고 하나의 적합도 값으로 처리한다.

Step 7) 중복된 적합도 값을 하나로 처리한 후 설계자가 FPN 구조를 설계하기 전 결정한 노드의 제한된 개수 W개 만큼 선호되는 적합도 값을 선택한다.

Step 8) Step 7)에서 선택되어진 노드들을 다시 초기 population 번호 순서에 따른 오름차순으로 재정렬한다.

Step 9) 다음 세대에서의 엘리트 전략을 위해서 선택된 노드들 중에서 최적의 적합도 값을 가지는 노드를 선택한다.

Step 10) Step 4)에서 얻어진 정보를 가지고 다음 세대의 population을 생성한 후 Step 2)에서 Step 9)까지 반복한다.

Step 11) 이전 세대에서 구해진 적합도 값을 통해 현재 세대에서 구해진 적합도 값을 결합하여 다시 Step 5)부터 Step 8)까지 반복한다.

Step 12) 정해진 세대까지 Step 10)부터 Step 11)을 반복 실행한다.

[단계 6] [단계 5]의 현재 층에서 얻어진 최적 노드의 최대 적합도 값  $F_1$ 이 다음 부등식을 만족하는 경우에 알고리즘을 종료한다.

$$F_1 \leq F_* \quad (5)$$

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

$$E = -\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (6)$$

[단계 7] 현재 층에서 보존된 노드의 출력들( $z_{1i}, z_{2i}, \dots, z_{Wi}$ )에서 다음 층의 새로운 입력들( $x_{1i}, x_{2i}, \dots, x_{Wi}$ )로,  $x_{1j}=z_{1i}, x_{2j}=z_{2i}, \dots, x_{Wj}=z_{Wi}$ 으로 구성하고, [단계 4]로 간다(여기서,  $j=i+1$ ). 이 후, [단계 4]부터 [단계 7]까지를 반복한다. 알고리즘이 종료할 경우, 마지막 층의 최적 적합도 값  $F_*$ 을 얻은 노드의 다항식에 입력이 되는 전 층의 출력을 대입하고 동일한 조작을 제 1층까지 반복하여 최종 추정 모델  $\hat{y}$ 를 얻는다.

## 3. 실험 데이터를 통한 결과 고찰

제안된 모델의 성능을 테스트하기 위해서 시계열 가스로 공정 데이터[6]를 이용하였다.

표 2. GAs과 SOFPNN 정보

Parameters		1층 ~ 3층
GA	Maximum gen	150
	Total population size	100
	Selected population size	30
	Crossover rate	0.65
	Mutation rate	0.1
FPNN	String length	3+3+30+5
	Maximal no. of inputs to be selected(Max)	$1 \leq l \leq \text{Max}(2 \sim 4)$
	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 or 3

$l, T$  ; interger

• ; 규칙 후반부 다항식의 입력이 전체 시스템 입력이 사용된 경우

이 공정은 기존의 이용할 수 있는 데이터를 보다 풍부한 데이터들로 구성되어 있기 때문에 모델을 평가하는데 많은 도움이 된다. 표 2는 유전자염색체 정보와 퍼지 다항식 뉴럴 네트워크 구축을 위한 정보를 나타낸 것이다.

그림 1은 Max=3이고 삼각형 함수를 사용했을 때의 최적 네트워크를 보여준 것이다. 그림에서 노드들의 앞에 표시되어 있는 사각형은 유전자 알고리즘에 의해서 동조된 멤버쉽 함수의 수를 의미한다.

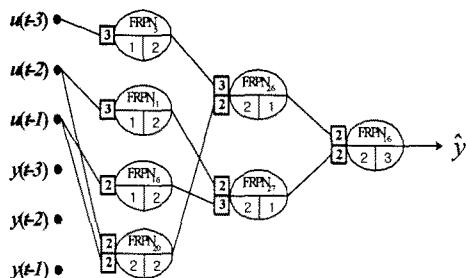


그림 1. 최적 SOFPNN 구조

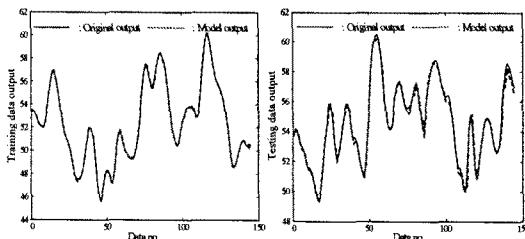


그림 2. 가스로 공정 데이터의 출력값과 모델의 출력값

표 3. 기존의 모델과 동정오차비교

Model	PÍ	PÍs	EPIs
Box and Jenkins's model[6]	0.710		
Oh and Pedrycz's model[7]		0.020	0.271
Kim et al.'s model[8]		0.034	0.244
FPNN [9]	CASEI G 5th layer	0.016	0.116
	CASEII G 5th layer	0.012	0.125
Our model	T 3rd layer	0.011	0.114
	G	0.014	0.126
	T	0.011	0.116
	G	0.006	0.120

T : Triangular , G : Gaussian-like

#### 4. 결론

본 논문에서는 유전자 알고리즘을 이용한 전화론적 최적 FPN에 의한 자기구성 퍼지 다항식 뉴럴 네트워크의 효율적인 설계방법을 제안하였다. 기존의 SOFPNN 구조는 성능을 향상시키는데 크게 영향을 미치는 네트워크 층, 노드내의 입력변수의 수, 퍼지규칙 후반부 다항식의 차수, 고정된 입력변수 선택 그리고 멤버쉽 함수의 수를 설계자의 경험에 의해서

결정함으로써 객관적이고 주어진 데이터의 특성에 맞는 최적의 모델을 구축하는데 어려움이 있었다. 이러한 SOFPNN 모델 구조의 한계를 극복하고자 본 연구에서는 최적화 방법인 유전자 알고리즘을 이용하여 파라미터를 선택하여 모델 구축에 있어서 유연성과 정확성을 가지며 더욱 정확한 예측 능력을 가진 최적화된 SOFPNN 모델 구조를 구축할 수가 있었다.

#### 감사의 글

본 연구는 산업자원부의 지원에 의하여 기초전력연구원(R-2003-B-274) 주관으로 수행된 과제임.

#### 참 고 문 헌

- [1] A. G. Ivakhnenko, "Polynomial theory of complex systems", IEEE Trans. on Systems, Man and Cybernetics, Vol. SMC-1, pp. 364-378, 1971.
- [2] S. K. Oh and W. Pedrycz, "The design of self-organizing Polynomial Neural Networks", Information Science, Vol. 141, pp. 237-258, 2002.
- [3] 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.
- [4] Holland, J. H., Adaptation In Natural and Artificial Systems, The University of Michigan Press, Ann Arbor. 1975.
- [5] 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.
- [6] D. E. Box and G. M. Jenkins, Time Series Analysis, Forcasting and Control, California: Holden Day, 1976.
- [7] S. K. Oh and W. Pedrycz, "Identification of Fuzzy Systems by means of an Auto-Tuning Algorithm and Its Application to Nonlinear Systems", Fuzzy sets and Systems, Vol. 115, No. 2, pp. 205-230, 2000.
- [8] E. T. Kim, et al, "A simple identified Sugeno-type fuzzy model via double clustering", Information Science, Vol. 110, pp. 25-39, 1998.
- [9] H. S. Park, S. K. Oh, and Y. W. Yoon, "A New Modeling Approach to Fuzzy-Neural Networks Architecture", Journal of Control, Automation and Systems Engineering, Vol. 7, No. 8, pp. 664-674, Aug., 2001.