

Evolutionary Data Granulation 기반으로한 퍼지 집합 다항식 뉴럴 네트워크에 관한연구

A Study on Fuzzy Set-based Polynomial Neural Networks Based on Evolutionary Data Granulation

노석범, 안태천, 오성권
원광대학교 전기전자및정보공학부

Seok-Beom Roh, and Tae-chon Ahn, Sung-Kwun Oh
School of Electrical and Electronic Engineering, Wonkwang Univesity
E-mail : ohsk@wonkwang.ac.kr

요 약

In this paper, we introduce a new Fuzzy Polynomial Neural Networks (FPNNs)-like structure whose neuron is based on the Fuzzy Set-based Fuzzy Inference System (FS-FIS) and is different from that of FPNNs based on the Fuzzy relation-based Fuzzy Inference System (FR-FIS) and discuss the ability of the new FPNNs-like structure named Fuzzy Set-based Polynomial Neural Networks (FSPNN). The premise parts of their fuzzy rules are not identical, while the consequent parts of the both Networks (such as FPNN and FSPNN) are identical. This difference results from the angle of a viewpoint of partition of input space of system. In other word, from a point of view of FS-FIS, the input variables are mutually independent under input space of system, while from a viewpoint of FR-FIS they are related each other. The proposed design procedure for networks architecture involves the selection of appropriate nodes with specific local characteristics such as the number of input variables, the order of the polynomial that is constant, linear, quadratic, or modified quadratic functions being viewed as the consequent part of fuzzy rules, and a collection of the specific subset of input variables. On the parameter optimization phase, we adopt Information Granulation (IG) based on HCM clustering algorithm and a standard least square method-based learning. Through the consecutive process of such structural and parametric optimization, an optimized and flexible fuzzy neural network is generated in a dynamic fashion. To evaluate the performance of the genetically optimized FSPNN (gFSPNN), the model is experimented with using the time series dataset of gas furnace process.

1. 서론

비선형 실 시스템의 동적 분석을 표현하는데 있어서의 수학적 모델들은 많은 입·출력 변수들 사이에서 모델을 구축하는 변수들과 모델 구조의 선택에 많은 문제를 가지고 있다. 이러한 문제를 풀기 위해, 시스템의 입력과 출력사이의 비선형 관계를 체계적으로 설계하기 위한 분석적인 기술로 A. G. Ivakhnenko는 Group Method of Data Handling(GMDH) 알고리즘을 소개하였다[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. GMDH의 이러한 단점을 극복하고자, Oh 등에 의해

자기구성 다항식 뉴럴 네트워크(Self-Organizing Polynomial Neural Networks) [2]와 자기구성 퍼지 다항식 뉴럴 네트워크(Self-Organizing Fuzzy Polynomial Neural Networks) [3]가 제안되었다. 그러나 기존 SOPNN 구조는 성능을 향상시키기 위해서, 노드의 입력변수의 수와 규칙 후반부 다항식 차수 그리고 입력변수는 설계자의 경험 또는 반복적인 학습을 통해 선호된 네트워크 구조를 선택하였으나, 최적의 네트워크 구조를 구축하는 데는 어려움이 내재되어 있었다. 따라서 모델 구축에 있어서 객관적이고 신뢰성이 있는 최적 모델 구조를 구축하기 위해 노드의 입력변수의 수와 이에 해당되는 입력변수의 선택 그리고 규칙 후반부 다항식 차수의 최적 선택이 요구되

어진다. 본 논문에서는 고급 자기구성 퍼지 다항식 뉴럴네트워크(SOFSPNN)을 최적화시키기 위해서 유전자 알고리즘[4, 5]을 이용하여 고급 자기구성 퍼지 다항식 뉴럴 네트워크의 입력변수의 수와 이에 해당되는 입력변수 그리고 규칙 후반부 다항식의 차수를 탐색하여 최적의 자기구성 퍼지 다항식 뉴럴 네트워크를 구축한다. 또한 SOFSPNN와 같은 구조이지만 노드에 FPN 대신 퍼지 집합 기반 다항식 뉴런(FSPN)을 적용한 SOFSPNN을 제안 하였다. 또한 HCM방법을 이용한 Information Granulation을 이용하여 개선된 성능을 가진 퍼지 규칙과 이러한 퍼지 규칙을 가진 시스템의 파라미터의 추정을 위한 최소자승법을 소개한다.

본 논문의 평가를 위해서 Box와 Jenkins가 사용한 가스로 입출력 데이터[6]을 이용하여 제안된 모델의 타당성, 정확성 및 예측 성능 등을 기존 지능 모델들과 비교를 통해 그 우수성을 보인다.

2. 퍼지 집합 기반 다항식 뉴런(FSPN)

FSPN은 Yamakawa가 제안한 퍼지 뉴럴 네트워크를 BP 학습이 아닌 LMS 알고리즘을 통해 학습시키는 네트워크이며 퍼지 규칙은 다음과 같다.

$$R^{11} : \text{If } x_1 \text{ is } A_{11} \text{ then } y_{11} = P_{11}$$

$$R^{1j} : \text{If } x_1 \text{ is } A_{1j} \text{ then } y_{1j} = P_{1j}$$

$$R^{n1} : \text{If } x_n \text{ is } A_{n1} \text{ then } y_{n1} = P_{n1}$$

$$R^{nj} : \text{If } x_n \text{ is } A_{nj} \text{ then } y_{nj} = P_{nj}$$

FSPN의 구조는 아래그림과 같다

여기서,

$$P_{ij} = a_{ij}^0 + a_{ij}^1 \cdot (x_1 - v_{ij}^1) + a_{ij}^2 \cdot (x_2 - v_{ij}^2) + \dots + a_{ij}^n \cdot (x_n - v_{ij}^n)$$

이고 v_{ij}^k 는 I번째 입력을 기준으로 HCM을 사용하여 clustering 한 j번째 cluster의 x_k 의 중심값이다.

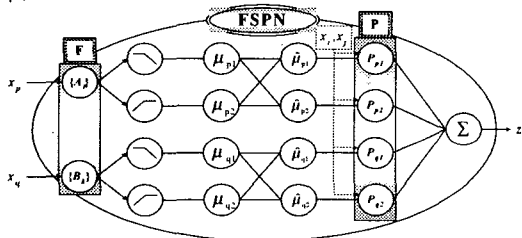


그림1. FSPN의 구조

3. GA 기반 고급 자기구성 퍼지 다항식 뉴럴 네트워크 설계

본 장에서는 기존의 자기구성 퍼지 다항식 뉴럴 네트워크를 유전자 알고리즘을 이용하여 고급 자기구성 퍼지 다항식 뉴럴 네트워크 구조를 최

적화하는 알고리즘 및 설계절차를 다룬다.

[단계 1] 출력변수 y에 관계하는 n개의 시스템 입력변수(x_1, x_2, \dots, x_n)를 결정한다.

[단계 2] N개의 입출력 데이터 (x_i, y_i)= $(x_{1i}, x_{2i}, \dots, x_{ni}, y_i)$, $i=1, 2, \dots, N$ 을 학습용 데이터와 평가용 데이터로 분할한다.

[단계 3] SOFSPNN 구조를 구축하는 있어서 기본적인 정보를 결정한다. 즉, SOFSPNN의 퍼지 추론 방법 및 동정을 설계하는 부분과 SOFSPNN 모델의 구조를 결정하는 초기 정보를 결정한다.

[단계 4] 유전자 알고리즘을 이용한 SOFSPNN 구조를 결정한다.

유전자 알고리즘은 유전학과 자연 진화를 흉내낸 적응 탐색법으로 1975년 Holland [4]에 의해 개발되었다. 본 논문에서는 유전자 알고리즘을 시뮬레이션하기 위해 한 개체에 여러 변수의 정보를 담은 직렬 방식을 사용한다. 재생산 연산으로 룰렛 휠 방식, 교차 연산은 one-crossover 방식, 돌연변이 연산은 선택된 비트를 반전시키는 invert 방식을 사용하였다. 그러나 룰렛 휠 방식은 확률적 속성 때문에 선택 과정에서 최적자를 반드시 선택하지 못하는 단점을 가진다. 이를 보완해줄 수 있는 한 방법으로 엘리트 전략을 사용하였다[5].

[단계 4-1] 입력변수의 수 선택

[단계 4-2] 퍼지규칙 후반부 다항식 차수 선택

[단계 4-3] 입력변수 선택

[단계 4-4] 각 입력변수에 대응하는 멤버십 함수의 수 선택

[단계 4-1]부터 [단계 4-3]까지 수행해서 얻은 선택된 입력변수와 퍼지규칙 후반부 다항식 차수를 이용하여 퍼지 추론을 적용한다. [단계 4-2]에서 결정된 퍼지 추론 방법인 간략 추론 및 회귀 다항식 추론의 후반부 구조는 표 1에서 표현한 것과 같이 Type 1~4를 사용한다.

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

표 1 퍼지규칙 후반부에서 회귀다항식의 서로 다른 형태

퍼지 추론 규칙과 파라미터 동정을 위한 매개변수 추정은 다음과 같다.

i) 간략 추론

후반부가 다음과 같이 단일의 상수항만을 가지는 것으로 이와 같은 추론법을 간략 추론법이라 한다. $R^i : \text{If } x_1 \text{ is } A_{1i} \text{ then } y_i \text{ is } a_{1i}$ (1)

i 번째 데이터의 추론된 값 \hat{y}_i 는 다음과 같다.

$$\hat{y}_i = \frac{\sum_{j=1}^m w_{ji} y_j}{\sum_{j=1}^m w_{ji}} = \frac{\sum_{j=1}^m w_{ji} a_{j0}}{\sum_{j=1}^m w_{ji}} = \sum_{j=1}^m \hat{w}_{ji} a_{j0} \quad (2)$$

$$w_{ji} = A_{j1}(x_{1i}) \wedge \dots \wedge A_{jm}(x_{mi})$$

여기서, i 는 $i(i=1, \dots, m)$ 번째 데이터이고, 후반부 파라미터 a_{j0} 의 동정은 입출력 데이터가 주어졌을 때 최소자승법에 의해 구해진다.

ii) 회귀다항식 추론

후반부가 다음과 같이 1, 2, 변형된 2차 다항식 형태로 표현된 것으로 회귀다항식 추론이라 한다. R^i : If x_1 is A_{j1} then $y_j = f_j(x_1, \dots, x_n)$ (3)

[단계 5] 모델의 구축과 테스트 그리고 노드 선택을 한다. 각 층의 생성과정으로부터 유전자 알고리즘에 의한 SOFSPNN 구조의 전체 최적화 과정은 다음과 같은 절차와 같이 수행된다.

Step 1) SOFSPNN 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 즉, 최적 다항식 구조 선택을 위해 노드(FSPN)을 구축한다.

Step 3) Population에 의해서 생성된 노드의 성능 테스트를 위해서 기존의 SOFSPNN에서와 같이 모델의 테스트 데이터만을 이용하여 노드를 테스트한다. 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 population 정보와 적합도 값들을 이용하여 선택 연산, 교배, 돌연변이를 실행한다.

Step 5) 구해진 적합도 값들(F_1, F_2, \dots, F_n)을 선호되는 적합도 값 순(내림차순)으로 정렬한다.

Step 6) 정렬된 적합도 값들 중에서 중복된 적합도 값들은 제거하고 하나의 적합도 값으로 처리한다.

Step 7) 중복된 적합도 값들을 하나로 처리한 후 설계자가 SOFSPNN 구조를 설계하기전 결정한 노드의 제한된 개수 #개만큼 선호되는 적합도 값들을 선택한다.

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

Step 9) 다음세대에서의 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 Step2)에서 Step 9)까지 반복한다.

Step 11) 이전 세대에서 구해진 적합도 값들과 현재 세대에서 구해진 적합도 값들을 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.

$$F_1 \geq F^* \quad (5)$$

단, F^* 는 이전 층의 최적 노드인 최대 적합도 값이다. 본 논문에서의 모델의 성능지수식으로 식 (6)과 같이 MSE(Mean Squared Error)을 사용해서 구해진다. $MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$ (6)

[단계 7] 현재 층에서 보존된 노드의 출력들 ($z_{1i}, z_{2i}, \dots, z_{wi}$)에서 다음 층의 새로운 입력들 ($x_{1j}, x_{2j}, \dots, x_{wj}$)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.

4. 시뮬레이션 및 결과 고찰

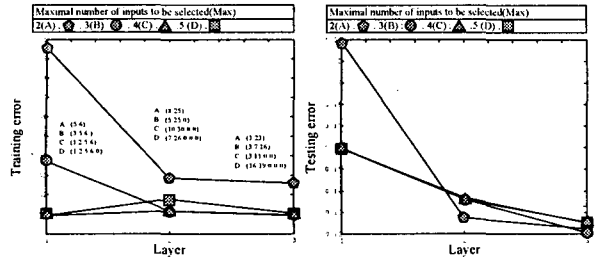
제안된 모델의 성능을 테스트하기 위해서 가스로 시계열 데이터[9]를 이용하였다. 1입력 1출력의 가스로 시계열 데이터 296쌍을 시뮬레이션 하기 위해 전체 시스템 입출력을 [$u(t-2), u(t-1), y(t-2), y(t-1) : y(t)$]와 같이 설정하여 사용한다. 표 2는 유전자 알고리즘의 염색체 정보와 고급 자기구성 다항식 뉴럴 네트워크 구축을 위한 정보를 나타낸 것이다.

표 2 유전자 알고리즘과 자기구성 퍼지 다항식 뉴럴 네트워크 정보

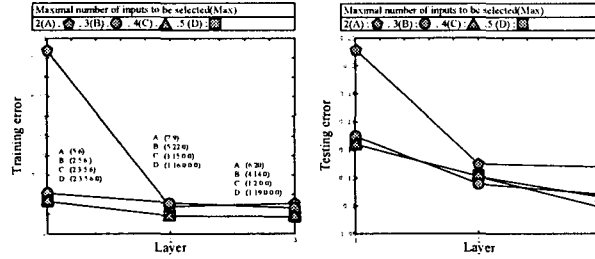
| | Parameters | 1층~3층 |
|---------|---|--------------------------------------|
| GA | Maximum gen. | 100 |
| | Total population size | 60 |
| | Selected population size | 30 |
| | Crossover rate | 0.65 |
| | Mutation rate | 0.1 |
| | String length | 3+3+2+30 |
| SOFSPNN | Maximal no. of inputs to be selected(Max) | $1 \leq I \leq \text{Max}(2 \sim 5)$ |
| | Polynomial Type(Type T) of the consequent part of rules | $1 \leq T \leq 4$ |
| | Membership function(MF) type | Gaussian |
| | No. of MFs per each input | $1 \leq M \leq 4$ |

I, T : integer

* : 규칙 후반부 다항식의 입력이 전체 시스템 입력이 사용된 경우



(a) Triangular MF



(b) Gaussian-like MF

그림 2 층의 증가에 따른 SOFSPNN의 성능지수
 그림 3은 선택된 입력의 변화에 따른 SOFSPNN
 각 층의 성능지수를 나타낸 것이다. 그림 2는 선
 택된 입력변수의 수가 4입력이고 멤버쉽 함수로
 는 삼각형 함수를 사용한 경우로 각 층에서
 generation 수행 과정에 따른 Training 성능지수
 와 Testing 성능지수의 최적화 과정을 나타낸 것
 이다.

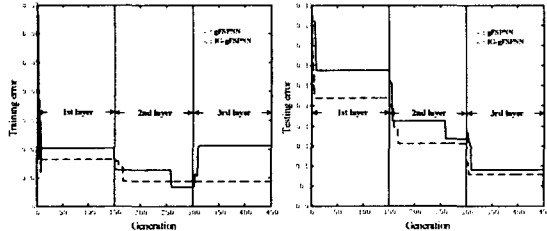


그림 3 유전자 알고리즘에 의한 각 성능지수들의
 최적화 과정

표 3은 가스로 공정 데이터를 사용하여 성능
 지수를 식 (6)에 의해 계산된 값으로 기존의 모
 델과의 성능비교를 한 것이다.

| 모델 | PI | EPI |
|---------------------------|---------------|-------|
| Oh and Pedrycz's model[7] | 0.271 | 0.020 |
| Kim, et al.'s model[8] | 0.244 | 0.034 |
| SONN[3] | Basic | 0.016 |
| | Modified | 0.018 |
| Our model | Triangular | 0.007 |
| | Gaussian-like | 0.012 |

표 3 기존의 퍼지모델과 동정오차비교

5. 결론 및 향후과제

본 논문에서는 유전자 알고리즘을 이용하여 고
 급 자기구성 퍼지 다항식 뉴럴 네트워크의 효율

적인 설계 방법을 제안하였고 이를 기반으로 주
 어진 비선형 예제를 통하여 기존의 GA기반
 SOFSPNN의 퍼지 규칙에 Information Granulation
 을 추가한 IG-gFSPNN의 우수성을 입증하였다. 기
 존의 SOFSPNN 구조에서는 성능을 향상시키는데
 크게 영향을 미치는 네트워크 층을 구성하는 노
 드내의 입력변수의 수와 퍼지규칙 후반부 다항식
 의 차수 그리고 고정된 입력변수 선택을 설계자
 의 경험에 의해서 결정함으로써 최적에 근접한
 모델을 구축하기 위해서 많은 시행착오를 필요로
 하였다. 이러한 SOFSPNN 모델의 구조의 한계를
 극복하고자 유전자 알고리즘을 이용하여 노드의
 입력변수의 수와 그에 해당하는 입력변수 그리고
 퍼지규칙 후반부 다항식 차수 등의 파라미터를
 선택하여 모델 구축에 있어서 유연성과 정확성을
 가지며 더욱 정확한 예측 능력을 가진 최적화된
 SOFSPNN 모델 구조를 구축할 수가 있었다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초
 전력연구원(R-2004-B-133-01) 주관으로 수
 행된 과제임.

6. 참고문헌

[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 Arbour. 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] G. E. P. Box and G. M. Jenkins, *Time Series Analysis, Forecasting, and Control*, 2nd edition Holden-Day, SanFrancisco, 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.