

기호 코딩을 이용한 유전자 알고리즘 기반 퍼지 다항식 뉴럴네트워크의 설계

Design of Genetic Algorithms-based Fuzzy Polynomial Neural Networks Using Symbolic Encoding

이인태*, 오성권**, 최정내***

(In-Tae Lee, Sung-Kwun Oh, Jeoung-Nae Choi)

Abstract - In this paper, we discuss optimal design of Fuzzy Polynomial Neural Networks by means of Genetic Algorithms(GAs) using symbolic coding for non-linear data. One of the major subject of genetic algorithms is representation of chromosomes. The proposed model optimized by the means genetic algorithms which used symbolic code to represent chromosomes. The proposed gFPNN used a triangle and a Gaussian-like membership function in premise part of rules and design the consequent structure by constant and regression polynomial (linear, quadratic and modified quadratic) function between input and output variables. The performance of the proposed model is quantified through experimentation that exploits standard data already used in fuzzy modeling. These results reveal superiority of the proposed networks over the existing fuzzy and neural models.

Key Words : Symbolic Encoding, Fuzzy Polynomial Neural Networks(FPNN), Genetic Algorithms(GAs), Membership Functions(MFs), Optimal Model

1. 서 론

많은 연구자들은 인간의 일상생활 속에서 다양한 지식이나 정보를 사용한 학습, 판단, 예측 등이 민감하게 이루어 질수 있도록 하나의 함수 또는 관계로 나타내어, 인간의 판단과 유사한 결과를 얻을 수 있는 장치를 마련하고자 노력하고 있다. 최근에는 CI 기술의 바탕인 지능관련 컴퓨터 기술이 산업 전반에 활용되면서 이의 능력에 대해 많은 관심이 모아지고 있고, 활발한 연구를 바탕으로 응용되고 있다[1]. CI 기술은 인간의 신경구조를 모방한 신경망과 인간의 언어적 지식과 전문가적 경험을 사용한 퍼지이론 그리고 유전자 알고리즘과 같은 지능시스템들이 활발하게 연구되면서 합성, 융합, 결을 통한 고급 CI 기술에 관한 연구가 다양한 형태로 추진되고 있다.

이러한 고급 CI 기술 중에 A. G. Inakhnenko가 소개한 Group Method of Data Handling(GMDH) 알고리즘은 비교적 간단한 시스템에 대해서 매우 복잡한 다항식을 생성하는 단점이 있으며, 2입력, 2차 회귀다항식의 형태로 복잡한 비선형 시스템을 표현하는 데는 어느 정도 한계가 있다. 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)[3]가 제안되었다. SOFPNN (또는 FPNN)의 구조

는 일반적인 다층 퍼셉트론 구조와 달리 미리 정해져 있지 않고 층이 진행되는 동안 모델 스스로 노드의 선택과 제거를 통해 최적의 네트워크 구조를 생성할 수 있다. 그러나 기존 FPNN 구조는 성능을 향상시키기 위하여, 노드의 입력변수의 수와 입력변수, 규칙 후반부 다항식 차수 그리고 멤버십 함수의 수를 설계자의 경험 또는 반복적인 학습을 통해 네트워크 구조를 선택하여 최적의 네트워크 구조를 구축하는 데는 어려움이 있었다.

이에 본 논문에서는 고급 CI 기술의 한 영역으로써 효과적인 비선형 문제의 분석과 해결을 위한 Symbolic encoding 기반 유전자적 퍼지 다항식 뉴럴네트워크(Symbolic encoding based Genetically Fuzzy Polynomial Neural Networks; gFPNN)의 설계를 목표로 한다. FPNN을 최적화시키기 위해서 최적화 탐색 방법인 기호 코딩 기반 유전자 알고리즘[4, 5]을 이용하여 FPNN의 입력변수 수와 입력변수, 규칙 후반부 다항식의 차수 그리고 멤버십 함수의 수를 탐색하여 최적의 퍼지 다항식 뉴럴 네트워크를 구축한다. 이전 이진코딩에서 발생하는 두 수 사이의 급격한 비트 차이에 의한 해밍질벽을 해결하기 위하여 기호코딩을 사용하였다. 평가를 위해서 시계열 가스로 공정 데이터[6]를 이용하여 제안된 모델의 타당성, 정확성 및 예측 성능 등을 기존 지능 모델들과 비교를 통해 그 우수성을 보인다.

2. Symbolic based gFPNN 설계

본 논문에서 이용한 유전자 알고리즘은 한 개체에 여러 번의 정보를 담은 직렬 방식을 사용하였고, 선택연산으로는 Roulette-Wheel 방식을, 교차연산으로는 One-crossover방식

* 準 會 員 : 水原大學校 電氣工學科 碩士課程

** 正 會 員 : 水原大學校 電氣工學科 教授

*** 正 會 員 : 圓光大學校 制御計測工學科 博士

을 사용하였고, 또한 돌연변이 연산으로는 Invert 방식을 사용하여 최적의 FPNN 구조를 동정하였다. 그 설계과정은 다음과 같다.

[단계 1] gFPNN 구조를 구축하는데 있어서 기본적인 정보를 결정한다.

[단계 2] gFPNN 모델을 구축하는데 기본 유닛인 Fuzzy Polynomial Neuron(FPN)[3]을 유전자 알고리즘을 통하여 최적 구조를 선택한다.

[단계 2-1] 입력변수의 수 선택

[단계 2-2] 퍼지규칙 후반부 다항식 차수 선택

[단계 2-3] 입력변수 선택

[단계 2-4] 멤버쉽 함수의 수 결정

[단계 2-1]에서 [단계 2-4]까지 수행해서 얻은 선택된 입력변수의 수와 퍼지규칙 후반부 다항식 차수, 입력변수의 수에 따른 입력변수 그리고 멤버쉽 함수의 수를 이용하여 퍼지 추론에 적용한다.




그림 1. 염색체 구조

표 1. 퍼지규칙 후반부에서 회귀다항식의 서로 다른 형태

입력차수	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

[단계3] 모델의 구축과 테스트 그리고 노드의 선택

Step 1) GAs 기반의 FPNN 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(1)과 같이 변환하여 유전자 알고리즘의 적합도 함수로 사용한다.

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

Step 4) 다음 세대의 생성을 위해서 구해진 개체군 정보와 적합도 값들을 이용하여 선택연산, 교배, 돌연변이를 실행한다.

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

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

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

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

Step 9) 다음세대에서의 엘리트 전략을 위해서 선택된 노드

들 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 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 4] [단계 4]의 현재 층에서 얻어진 최적 노드의 최대 적합도 값 F_1 이 다음 부등식을 만족하는 경우에 알고리즘을 종료한다.

$$F_1 \leq F_s \quad (2)$$

단, F_s 는 이전 층의 최적 노드인 최대 적합도 값이다. 본 논문에서의 모델의 성능지수를 구하는 식으로 다음 식을 이용하였다.

$$E = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (3)$$

[단계 5] 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 2]으로 간다(여기서, $j=i+1$). 이후, [단계 2]부터 [단계 5]까지를 반복한다. 알고리즘이 종료할 경우, 마지막 층의 최적 적합도 값 F_s 을 얻은 노드의 다항식에 입력이 되는 전 층의 출력을 대입하고 동일한 조작을 제 3층까지 반복하여 최종 추정 모델 \hat{y} 를 얻는다.

3. 실험 데이터를 통한 결과 고찰

Symbolic based gFPNN의 성능을 테스트하기 위해서 시계열 가스로 공정 데이터[6]를 이용하였다. 표 2는 GAs정보와 FPNN 구축을 위한 정보를 나타낸 것이다.


표 2. GAs과 FPNN정보

	Parameters	1층~3층
GA	Maximum gen	300
	Total population size	150
	Selected population size	30
	Crossover rate	0.65
	Mutation rate	0.1
	String length	$1+(\text{Max} \times 2)+1$
FPNN	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(MFs) type	Gaussian Triangular
	No. of MFs per each input	2 or 3

I, T ; integer

*; 규칙 후반부 다항식의 입력이 전체 시스템 입력이 사용된 경우 Max; 최대로 선택될 수 있는 입력변수의 수

그림 2는 후반부 다항식에 전체입력을 사용했을 때의 최대 입력(Max)값에 따른 각 층별 성능지수를 나타내고 있다. 그림에서 A(1, 0; 2; 3)을 풀이하면 최대 입력이 2일때(A) 선택된 입력변수는 1번이고 후반부 다항식은 선형(2)을 선택하고 선택된 입력변수에 해당하는 멤버쉽 함수의 개수는 3을 나타내고 있다.



(a) Gaussian-like MF (b) Triangular MF
 그림 2. 전체입력을 사용했을 때의 성능지수

그림 2는 Max=4이며, 규칙의 후반부에 전체입력을 사용하고 가우시안형일 때의 네트워크 구조를 나타내고 있다. 이 구조가 설계된 모델 중에 가장 좋은 성능 지수를 보여주고 있다.




그림 3. 최적의 네트워크 구조

표 3은 기존의 FPNN과 제안된 모델의 성능지수를 비교한 표이다. 표에서 보는 바와 같이 제안된 모델이 전체적으로 성능이 우수함을 보여주고 있다. 특히 앞에서 보여준 그림의 출력인 Max=4이며, Gaussian-like 멤버십 함수일 때 최고의 성능 지수를 나타내고 있다.

표 3. 기존의 모델과 제안된 모델의 성능지수비교

Model				PI	PIs	EPIs
Box and Jenkin'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	CASEI	G	5th layer		0.016	0.116
	[9]	CASEII	G	5th layer		0.012
Our model	4	T	3rd layer		0.008	0.107
		G	3rd layer		0.011	0.097
	5	T	3rd layer		0.006	0.101
		G	3rd layer		0.011	0.103

그림 2와 3에서 보여주듯이 간편일수록 구조가 아닌 층의 진행에 따라 입력변수 수와 입력변수, 다항식의 차수, 멤버십 함수의 수를 최적으로 선택한다.

4. 결론

Symbolic encoding based gFPNN 모델은 기존의 FPNN 모델의 최적 구조에 영향을 미치는 FPN의 입력변수의 수와 후반부 차수, 고정된 입력변수 선택 그리고 멤버십 함수의 수

를 설계자의 경험이 아닌 최적 탐색방법인 유전자 알고리즘을 사용하여 입력변수의 수와 그에 따른 입력변수, 후반부 차수 그리고 멤버십 함수를 선택 동조한다. 따라서 설계자의 주관적인 모델이 아닌 객관적인 모델을 만들 수 있고 보다 층에 증가에 따라 유동적인 최적 구조를 설계할 수 있다. 또한 이진코딩에서 발생할 수 있는 해밍절벽(Hamming cliff)으로 인한 비전역 최적해쪽으로의 수렴되는 문제를 미연에 방지할 수 있다. 따라서, 제안된 모델은 기존의 모델보다 최적 모델을 구축하는 면에서 성능면과 구조면에서 더욱 정확한 모델 구조를 구축할 수 있었다.

감사의 글

본 연구는 산업자원의 지원에 의하여 기초전력연구원 (I-2004-0-074-0-00) 주관으로 수행된 과제임.

참고 문헌

- [1] W. Pedrycz and J.F. Peters, Computational Intelligence and Software Engineering, Word Scientific, Singapore, 1998.
- [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] D. E. Box and G. M. Jenkins, Time Series Analysis, Forecasting 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.