

유전자 알고리즘의 동적 탐색 방법을 이용한 자기구성 퍼지 다항식 뉴럴 네트워크의 진화론적 최적화 설계

Evolutionarily Optimized Design of Self-Organized Fuzzy Polynomial Neural Networks by Means of Dynamic Search Method of Genetic Algorithms

박호성¹, 오성권², 안태천¹

¹원광대학교 공과대학 전기전자 및 정보공학부

²수원대학교 공과대학 전기공학과

Ho-Sung Park¹, Sung-Kwun Oh², Tae-Chon Ahn¹

School of Electrical Electronic & Information Engineering, Wonkwang University

Dept. of Electrical Engineering, Suwon University

E-mail : ohsk@suwon.ac.kr

요 약

본 논문에서는 자기구성 퍼지다항식 뉴럴 네트워크(SOPFNN)를 구성하고 있는 퍼지 다항식 뉴론(FPN)의 구조와 파라미터를 유전자 알고리즘을 이용하여 최적화시킨 새로운 개념의 진화론적 최적 고급 자기구성 퍼지 다항식 뉴럴 네트워크를 소개한다. 기존의 자기구성 퍼지 다항식 뉴럴 네트워크에서 모델을 설계할 때에는 설계자의 주관적인 특징과 시행착오에 의해서 모델을 구축하였다. 이러한 설계자의 경험을 배제하고 객관적이고 효율적인 모델을 구축하기 위해서 본 논문에서는 FPN의 파라미터들을 최적화 알고리즘인 유전자 알고리즘을 이용하여 동조하였다. 즉, 모델을 구축하는데 기본이 되는 FPN의 각각의 파라미터들-입력변수의 수, 다항식 차수, 입력변수, 멤버십 함수의 수, 그리고 멤버십 함수의 정점-을 동조함으로써 기존의 모델에 비해서 구조적으로 그리고 파라미터적으로 최적화된 네트워크를 생성할 수 있다. 뿐만 아니라 주어진 데이터의 특성을 모델 구축에 반영하고자 멤버십 함수의 정점 역시 유전자 알고리즘으로 동조하였다. 실험적 예제를 통하여 제안된 모델의 성능을 확인한 결과 기존의 퍼지 모델 및 신경망 모델에 비해서 아주 우수한 근사화 능력과 일반화 능력을 가짐을 알 수 있다.

1. 서론

현재 대부분의 시스템 공정들은 모델의 차원이 증가하면서(즉, 변수들의 수가 증가) 이에 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 한가지 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 표현하는대는 어느 정도 한계가 있다. 이러한 단점을 극복하고자, Oh 등에 의해 자기구성 다항식 뉴럴 네트워크(Self-Organizing Polynomial Neural Networks ; SOPNN) [2]와 자기구성 퍼

지 다항식 뉴럴 네트워크(Self-Organizing Fuzzy Polynomial Neural Networks ; SOFPNN) [3]가 제안되었다. 그러나 성능을 향상시키기 위하여, 노드의 입력변수의 수, 규칙 후반부 다항식 차수, 입력변수 그리고 멤버십 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 구조적 최적화뿐만 아니라 파라미터까지 최적화 한 연속적인 최적화 방법을 이용하였다. 즉, 구조적 측면에서는 각 FPN 노드에 들어가는 입력변수 수와 입력변수, 규칙 후반부 다항식의 차수 그리고 멤버십 함수의 수를 탐색하여 최적의 퍼지 다항식 뉴럴 네트워크를 구축한다. 이렇게 구축된 모델에 멤버십 함수의 정점을 다시 동조한 파라미터적 최적화를 추구하여 더욱 성능이 개선된 고급 자기구성 퍼지 다항식 뉴럴네트워크를 구축한다.

본 논문의 평가를 위해서 6입력 1출력의 가스로 공정 데이터[6]를 성능지수식으로는 MSE 이용하여 제안된 모델의 타당성, 정확성 및 예측 성능 등을 기존 지능 모델들과 비교를 통해 그 우수성을 보인다.

2. SOFPNN의 최적화

2.1 GA에 의한 FPN의 최적화

FPN의 구조는 기존의 SOFPNN[5]에서 볼 수 있듯이 모델을 구축하기 위한 가장 기본적인 처리 단위의 일괄적인 형태이다.

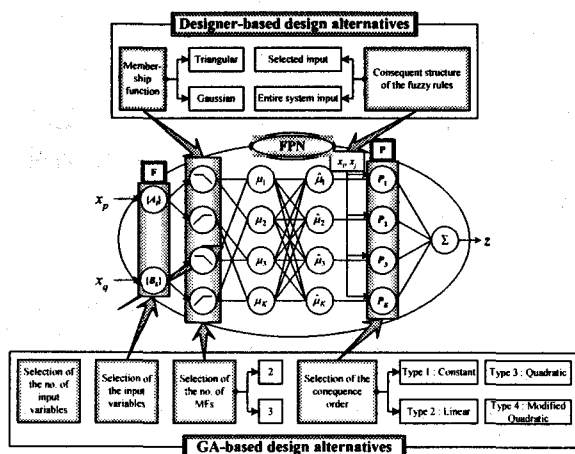


그림 1 유전자 알고리즘 기반 FPN 구조

본 논문에서는 그림 1에서 보였듯이 GA를 이용하여, FPN 안의 입력변수의 수와 이에 해당되

는 입력변수, 규칙 후반부 다항식 차수 그리고 선택된 입력변수들의 멤버십 함수의 수를 동조함으로써 모델을 최적화 시켰다.

2.2 동적 탐색 방법에 의한 MFs 정점 최적화

기존의 모델에서는 초기 멤버십 함수의 정점들을 입력 데이터들의 Min-Max을 기반으로 하였거나 또는 HCM 클러스터링 방법을 이용하여 주어진 데이터들의 멤버십 함수의 정점을 정하였다. 그러나 이는 데이터의 특성을 전혀 반영하지 못하였다. 본 논문에서는 멤버십 함수의 정점을 GA를 통하여 유동적으로 탐색함으로써 주어진 데이터의 특성에 맞게 멤버십 함수의 정점을 동조하였다.

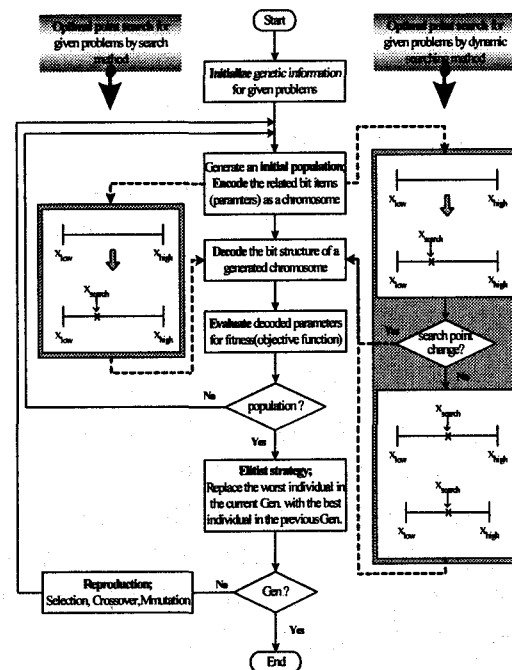


그림 2 동적 탐색 방법에 의한 GAs

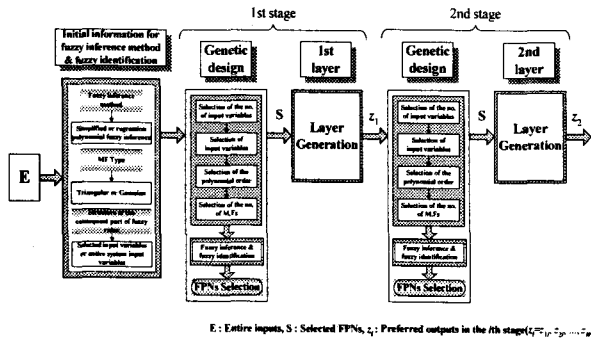
3. SOFPNN 알고리즘 설계

본 논문에서 제안된 SOFPNN 모델은 GA를 이용하여 FPN 구조의 구조 및 멤버십 함수의 정점까지 동조하여 모델을 구조적으로뿐만 아니라 파라미터적으로도 최적화된 모델을 구축한다. 제안된 모델의 설계절차는 다음과 같다.

[단계 1] 시스템 입력변수의 결정-입출력변수 결정

[단계 2] 데이터 분할-학습·테스트 데이터로 분할

[단계 3] 모델 구조의 최적화를 위한 모델 설계



E: Entire inputs, S: Selected FPNs, z_i : Preferred outputs in the i th stage($i=1, 2, \dots, n$)

그림 3 유전자 알고리즘을 이용한 모델 구조의 최적화

[단계 4] 파라미터 동조를 위한 구조가 최적화된 모델 추출-파라미터 동조를 위한 네트워크 선택
 [단계 5] 동적 탐색방법을 이용한 FPN의 멤버쉽 함수의 정점 동정

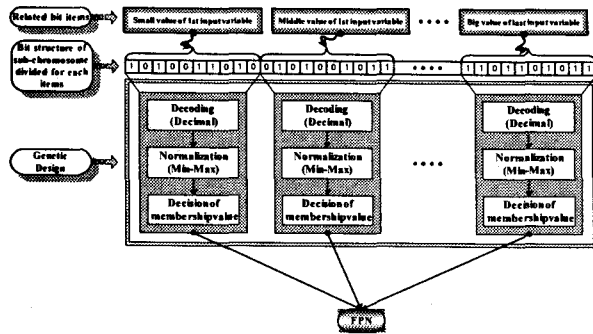


그림 4 GA에 의한 FPN의 멤버쉽 함수 정점 동정

[단계 6] 진화론적 파라미터 동정에 의한 고급 SOFPNN 모델 구축

4. 시뮬레이션을 통한 결과 고찰

제안된 모델의 성능을 테스트하기 위해서 6입력 1출력의 입출력 관계를 가진 가스로 공정 데이터[8]을 이용하여 모델의 성능을 평가하였다.

	Parameters	1층~3층
GA	Maximum gen	100
	Total population size	300*No. of 1st layer node
	Crossover rate	0.65
	Mutation rate	0.1
	String length	90
SOFPNN	Maximal no. of inputs to be selected(Max)	$1 \leq l \leq \text{Max}(2 \sim 3)$
	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

표 1 GAs과 SOFPNN정보

표 2는 본 논문에서 제안한 모델을 구축하였을 때의 성능지수들을 나타낸 것이다.

Model	Layer	3rd layer			
	MF	Triangular MF	Gaussian-like MF		
	Max	PI	EPI	PI	EPI
Selected input variables	2	0.019	0.102	0.013	0.101
	3	0.015	0.115	0.011	0.116
Entire system	2	0.011	0.105	0.012	0.102
input variables	3	0.011	0.110	0.007	0.106

표 2. 가스로 공정에 대한 모델의 성능지수

그림 5는 표 2에서 보여준 성능지수중 가우시안 멤버쉽 함수를 사용하고 Max=2인 경우 PI=0.012, EPI=0.102인 최적 구조 모델을 나타낸 것이다.




그림 5 진화론적 알고리즘에 의한 최적 SOFPNN 구조

그림 5에서 보여준 노드 “ $\frac{FPN_n}{NI \quad T}$ ”는 다음과 같이 표현된다. ‘FPNn’는 각 층에서 n번째 FPN 노드를 나타낸 것이고, ‘NI’는 해당 노드로 들어오는 입력의 수를, ‘T’는 해당 노드에 사용된 규칙 후반부 다항식 차수를 나타낸 것이다. 노드들의 앞에 표시되어 있는 사각형은 멤버쉽 함수의 수를 의미한다. 즉, □□는 멤버쉽 함수의 수가 2개를 의미하고, □□□는 멤버쉽 함수의 수가 3개를 의미한다.

Model	PI	EPI
Kim et al.'s model[7]	0.034	0.244
Lin and Cunningham's model[8]	0.071	0.261
Fuzzy model[9]	0.017	0.289
FNNs[10]	0.027	0.289
PNN[11]	0.027	0.258
Adaptive FPNN[12]	0.018	0.246
Our model	Selected	0.013
	Entire	0.106

표 3 기존의 모델과 동정오차비교

5. 결론

본 논문에서는 최적화 알고리즘인 유전자 알고리즘의 동적 탐색 방법을 이용하여, 진화론적으로 최적화된 FPN 노드에 기반한 자기구성 퍼지 다항식 뉴럴 네트워크에 대한 구조 및 이에 대한 효율적인 설계방법을 제안하였다.

기존의 SOPNN 또는 SOFPNN 구조는 성능을 향상시키는데 크게 영향을 미치는 파라미터들을 설계자의 경험에 의해서 결정함으로써 객관적이고 주어진 데이터의 특성에 맞는 최적의 모델을 구축하는데 어려움이 있었다. 이러한 SOFPNN 모델 구조의 한계를 극복하고자 본 논문에서는 최적화 방법인 유전자 알고리즘을 이용하여 주어진 모델의 구조적뿐만 아니라 파라미터를 최적화하여 즉, 구조적 측면에서는 각 FPN 노드에 들어가는 입력변수 수와 입력변수, 규칙 후반부 다항식의 차수 그리고 멤버십 함수의 수를 탐색하여 최적의 퍼지 다항식 뉴럴 네트워크를 구축한다. 이렇게 구축된 모델에 멤버십 함수의 정점을 다시 동조한 파라미터적 최적화를 추구하여 더욱 성능이 개선된 자기구성 퍼지 다항식 뉴럴 네트워크를 구축하였다.

ACKNOWLEDGMENTS

This work has been supported by KESRI(R-2004-B-133 -01), which is funded by MOCIE(Ministry of commerce, industry and energy).

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] D. E. Box and G. M. Jenkins, Time Series Analysis, Forecasting and Control, California: Holden Day, 1976.
- [7] E. Kim, H. Lee, M. Park and M. Park, "A Simply Identified Sugeno-type Fuzzy Model via Double Clustering", Information Sciences, Vol 110, pp. 25-39. 1998.
- [8] Y. Lin, G. A. Cunningham III, "A new Approach to Fuzzy-neural Modeling", IEEE Transaction on Fuzzy Systems, Vol. 3, No. 2, pp. 190-197, 1997.
- [9] S. K. Oh, W. Pedrycz and B. J. Park, "Hybrid Identification of Fuzzy Rule-Based Models", International Journal of Intelligent Systems, Vol. 17, Issue 1, pp. 77-103, 2002.
- [10] 오성권, 박호성, 김현기, "HCM과 하이브리드 동정 알고리즘을 이용한 퍼지-뉴럴 네트워크 구조의 최적 설계", 대한전기학회, Vol. 50D, No. 7, pp. 339-349, 2001. 7.
- [11] S. K. Oh, W. Pedrycz, and B. J. Park, "Polynomial Neural Networks Architecture: Analysis and Design", Computers and Electrical Engineering, Vol. 29, Issue 6, pp. 653-725, 2003.
- [12] 박병준, 오성권, 장성환, "퍼지뉴럴 네트워크와 자기구성 네트워크에 기초한 적응 퍼지 다항식 뉴럴네트워크 구조의 설계", 제어자동화시스템공학 논문지, 8권, 2호, pp. 126-135, 2002.