

유전 알고리즘을 이용한 퍼지신경망 모델링에 관한 연구

권 오국*, 장 옥*, 주 영훈**, 최 운호***, 박 진배*

* 연세대 전기공학과, ** 군산대 제어계측공학과, *** 경기대 전자공학과

A Study on Fuzzy Neural Network Modeling Using Genetic Algorithm

Ok Kook Kwon*, Wook Chang*, Young Hoon Joo**, Yoon-Ho Choi***, Jin Bae Park*

* Dept. of Electrical Eng., Yonsei Univ., ** Dept. of Control & Instrumentation Eng., Kunsan Univ.

*** Dept. of Electronic Eng., Kyonggi Univ.

Abstract - Fuzzy logic and neural networks are complementary technologies in the design of intelligent system. Fuzzy neural network(FNN) as an auto-tuning method is actually known to an excellent method for the adjustment of the fuzzy rule. However, this has a weak point, because the convergence to the optimum depends on the initial condition. In this paper we develop a coding format to determine a FNN model by chromosome in GA and present systematic approach to identify the parameters and structure of FNN. The proposed hybrid tuning method realizes to construct minimal and optimal structure of the fuzzy mode simultaneously and automatically. This paper shows effectiveness of the tuning system by simulations compared with conventional methods.

따라 국소 수렴에 빠질 위험이 존재한다.

본 논문에서는 유전 알고리즘을 이용한 체계적인 퍼지신경망 모델링 방법을 제안한다. FNN의 구조 및 매개 변수의 결정과 BP 알고리즘의 국소 수렴과 같은 단점을 해결하기 위해 유전 알고리즘을 사용한 최적화 기법을 제안하고 이 방법의 효율성과 정확성을 증명하기 위하여 비선형 시스템에 적용하고 그 우수성을 확인한다.

1 서 론

퍼지 추론 시스템은 전문가의 지식을 언어적인 표현을 사용하여 근사화하는 것이다[1]. 퍼지 추론에 있어 퍼지 규칙을 결정하는데는 전문가의 지식을 필요하지만 이를 결정하는 것은 어려운 문제이다. 따라서 자기 조정 방법을 사용하여 퍼지 규칙을 생성하는 것이 작업 능력을 수행하는데 바람직하다. 퍼지 신경회로망(FNN)이 그러한 방법 중 하나이다[2].

FNN은 신경회로망의 저수준의 학습과 계산 능력을 퍼지 추론 시스템에 도입하고 퍼지 추론 시스템의 고수준의 인간과 유사한 사고와 추론 능력을 신경망에 도입하는 것이다. 자기 조정 방법으로서의 FNN은 퍼지 규칙을 조정하는 방법으로 많이 사용되고 있다[3]. 그러나 매개 변수를 조정하는 방법으로 BP 알고리즘을 사용하는데 이는 초기 조건에

2 퍼지 신경망

퍼지 시스템과 신경망은 수치적으로 플랜트에 대한 정확한 수학적 모델이 필요 없는 동적인 시스템이다. 또한, 불확실하고, 부정확한 환경에서 작업을 하는 비선형 시스템 제어를 향상시키는 지적 능력을 지니고 있다[4]. 퍼지 시스템은 구조적으로 수치 예측 시스템이며 전문가 지식이나 복잡한 비선형 시스템을 If-Then 규칙으로 표현한다. 반면에 신경망은 학습할 수 있는 동적 시스템인데 학습 데이터를 일반화하고 학습 능력을 구현하기 위해 노드(node)간에 많은 상호처리와 시간을 요한다. 퍼지 신경망(fuzzy neural network, FNN)은 두 시스템을 결합하여 서로의 장점을 보완하는 시스템이다.

퍼지 추론 규칙은 식 (1)과 같이 표현할 수 있다.

$$R^j : \text{IF } x_1 \text{ is } A_{1j}, \dots, \text{ and } x_n \text{ is } A_{nj}, \quad (1)$$

$$\text{THEN } y = w_j$$

여기서 x_n 은 입력변수, y 는 출력 변수이며 A_{1j} 는 전반부의 소속함수로 기울기가 w_{1j} 이고 중심이 w_c 인 시그모이드 함수이다. 본 논문에서 퍼지 추론 규칙을 모델링하기 위하여 Horikawa[1][5]가 제안한 FNN 구조를 사용한다. 이 구조는 그림 1과 같으며 결론부가 실수인 간략화된 퍼지추론방법을 사




그림 1. 퍼지 신경망의 구조
Fig. 1 The structure of the FNN

용한다. 그림 1에서 보는 바와 같이 (A), (B), (C), (D)층은 규칙의 전반부를 나타내고 (E)와 (F)층은 결론부를 나타낸다. 전반부의 소속정도는 A층과 D층사이에서 계산된다. 그림에서 원과 사각형은 신경망의 노드(node)이고, 노드간의 결선 강도를 나타내는 w_b 와 w_c 는 소속함수의 매개 변수인 기울기와 중심을 나타낸다. w_b 는 후반부의 결선강도로 비퍼지화하는 매개 변수이다. C층의 활성화함수는 시그모이드(sigmoid) 함수이다. 규칙층인 E층에서는 규칙의 적합도를 구하는 층으로 T-norm을 연산하는데 본 논문에서는 곱을 이용한다. F층은 FNN의 출력부로 상수 실수치를 갖는 비퍼지화 단계이다. 이 층의 출력은 식 (2)와 같이 무게중심법(center of gravity method)으로 표현되어진다.

$$y^* = \frac{\sum_{i=1}^n \mu_i w_{bi}}{\sum_{i=1}^n \mu_i} = \sum_{i=1}^n \hat{\mu}_i w_{bi} \quad (2)$$

여기서 μ_i 는 T-norm 연산을 나타낸다.

3 유전 알고리즘

3.1 유전 알고리즘 개요

유전 알고리즘은 생물학 원리인 교차, 돌연변이, 선택 등에 기반한 통계적인 최적화 방법이다. 유전 알고리즘을 이용하여 최적화 문제를 푸는 경우, 각 개체가 가지는 일련된 정보를 비트, 정수, 혹은 실수 스트링으로 표현한다. 이러한 스트링을 염색체(chromosome)라고 부른다. 각 개체가 풀고자 하는 문제에 얼마나 적합한지는 적합도(fitness)에 의해

평가되며 이 적합도에 따라 집단 내에서 그 개체의 생존 여부가 결정이 된다. 이러한 개체들의 모임인 개체군을 세대(generation)라고 한다. 유전 알고리즘은 다음의 재생산, 교차(crossover), 돌연변이 연산자를 사용하여 최적해를 탐색해 간다[6].

재생 연산자 : 적합도 함수 값에 의해서 개별적인 스트링이 복제되는 과정으로 높은 적합도를 갖는 스트링이 이후의 세대에서 더 많은 수의 자손을 갖게 된다.

교차 연산자 : 교배 풀에서 두 스트링은 임의적으로 자신의 짝을 결정하여 쌍을 이룬 스트링 내의 한 지점이 교차점으로서 임의로 결정된다.

돌연변이 연산자 : 본질적으로 돌연변이는 스트링 공간을 통한 랜덤 작업으로, 재생 및 교배와 함께 사용될 때 중요한 개체의 조기 손실을 막아준다.

3.2 유전 암호화(genetic coding)

풀고자하는 잠재적인 해들이 어떻게 암호화 되는지는 유전 알고리즘의 성능에 중요한 역할을 한다. 모델링할 때 고려해야 할 것은 최적의 규칙 수와 동시에 각 규칙의 소속 함수의 매개 변수들을 최적화하는 것이다. 제안된 FNN에 사용한 염색체는 그림 2와 같은 구조를 지니며 전반부의 매개 변수와 후반부의 매개 변수 그리고 각 규칙의 가중치로 암호화되어 있다. 규칙을 최적화하기 위해 각 규칙에 가중치 0과 1을 할당하여 유효한 규칙에는 1을 유효하지 않는 규칙에는 0인 염색체를 할당한다.

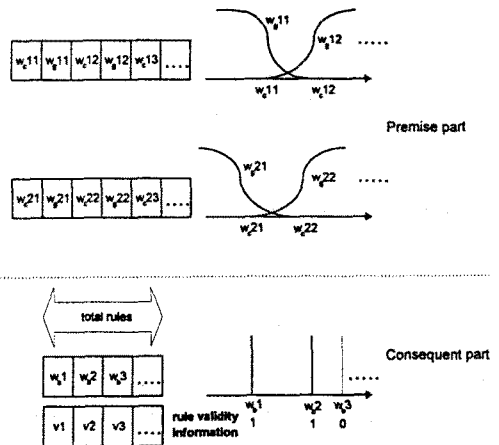


그림 2. 제안된 GA의 염색체 구조
Fig. 2 The structure of the chromosome in the proposed GA

3.3 미세조정과정

GA에 의해 최적화한 매개 변수들은 근사 최적해

이기 때문에 미세 조정 단계를 거쳐 최적해를 구한다. 이 단계에서는 식 (3)과 같이 신경망의 학습방법인 오차 역전파(BP)[1][5] 또는 경사법(gradient method)[7]을 사용한다.

$$\Delta w = -\frac{\partial E}{\partial w} = -\frac{\partial E}{\partial y_i^*} \frac{\partial y_i^*}{\partial w} = (y_{id} - y_i^*) \frac{\partial y_i^*}{\partial w} \quad (3)$$

$$w[n+1] = w[n] + \eta \cdot \Delta w$$

식 (3)은 신경망의 BP의 전형적인 형태로 파라미터를 갱신해 준다. y_i^* 는 FNN 모델의 최종 결과인 추정치이고, η 는 학습률이다. GA와 BP를 사용한 FNN 모델의 동정과정은 그림 3과 같이 표현할 수 있다.

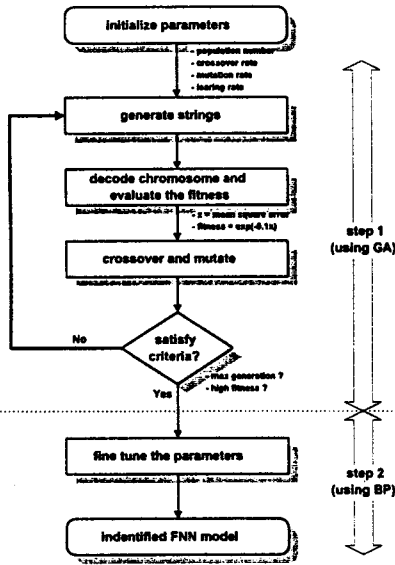


그림 3. 퍼지 신경망 모델링을 위한 흐름도
Fig. 3 Flowchart chart for modeling of FNN

4 모의 실험

본 논문에서 제안한 방법의 유용성을 증명하기 위하여 식 (4)와 같은 비선형 시스템을 이용한다. 식 (4)는 Sugeno[5]가 사용한 시스템으로 비교를 위하여 사용되었다. Sugeno는 이 비선형 시스템의 모델링을 위해 20개의 평가용 데이터 쌍과 20개의 동정용 데이터 쌍을 제시하였다. 본 논문에서도 같은 데이터를 사용하였다.

$$y = (1 + x_1^{0.5} + x_2^{-1} + x_3^{-1.5})^2 \quad (4)$$

모의 실험에서 전반부는 입력 변수를 2개로 분할하였고, 소속 함수로는 시그모이드 함수를 사용하였다.

표 1은 FNN에서 GA와 BP의 학습을 위한 설정 값들이다. FNN의 입력은 3개이고 2개의 분할을 가지므로 최적화되지 않은 총 규칙수는 8개이다. 규칙을 최적화한 경우는 7개의 규칙을 갖는데 이때의 추론 오차는 최적화하지 않은 경우보다 크다. 본 실험에서 사용한 추론 오차는 식 (5)와 같은 평균 제곱 오차를 사용한다.

$$E = 100 \times \frac{1}{n} \sum_{i=1}^n \frac{|y_{id} - y_i^*|}{y_{id}} \quad (5)$$

표 2는 FNN과 일반 신경망의 추론오차를 비교한 것이다. E1은 20개의 학습용 데이터 쌍에서의 추론 오차이고 E2는 20개의 평가용 데이터 쌍에서의 추론 오차이다. 표 2에서 알 수 있듯이 본 논문에서 제안한 방법이 BP만을 사용한 신경망보다 학습과 평가면에서 모두 우수함을 보여준다. 여기서 사용된 신경회로망은 입력층, 은닉층, 출력층의 3개층으로 이루어졌고, 은닉층 마디의 수는 10개로 하였다. 학습 반복수는 FNN과 같이 1000회로 일치시켰다.

표 1. 퍼지 신경망 모델링을 위한 초기 값
Table 1 Initial values for the modeling of FNN

	Parameters	Values
GA	max generation	1000
	individual	100
	crossover rate	0.8
	mutation rate	0.3
FNN	iteration	1000
	learning rate	0.1

표 2. 퍼지 신경망과 신경망의 성능 비교
Table 2 Comparison of performance with FNN and BP

	FNN	BP(NN)
E1	0.74	1.28
E2	3.97	10.25

5. 결 론

본 논문에서는 자동 퍼지 조정 기법으로 퍼지 신

경망(FNN)과 유전 알고리즘의 조합 방법에 대해 제안하였다. 유전 알고리즘은 퍼지 신경망의 구조와 매개변수들을 동시에 최적화시킬수 있는 유전암호화 키고, 연결 강도에 해당하는 매개 변수들을 최적화한다. 그러나 유전 알고리즘을 사용하여 얻은 해는 근사 최적해이므로 전역 최적해를 찾기위해 미세 조정 단계를 거친다. 본 논문에서는 BP 알고리즘을 사용하여 미세 조정을하여 보다 나은 최적해를 탐색하게 된다. 비선형 데이터 쌍의 모의 실험으로부터 제안된 FNN은 기존의 신경회로망보다 정확도나 적용면에서 우수함을 알 수 있다. 제안된 방법은 최적해의 수렴과 규칙 결정면에서 성능이 우수하였다. 이를 이용하여 퍼지 모델을 구성하기 위한 인간 전문가 지식의 역할을 제안된 방법으로 대체하고 보다 우수한 성능을 가진 모델을 구성할 수 있다.

[참 고 문 헌]

- [1] S. Horikawa, T. Furuhashi et al., "A study on fuzzy model using fuzzy neural networks", Proc. IFES, 1991.
- [2] H. Ishigami, T. Fukuda et al., "Structure optimization of fuzzy neural network by genetic algorithm", Fuzzy sets and systems, vol. 71, pp. 257-264, 1995.
- [3] T. Hasegawa, S. Horikawa et al., "On design of adaptive fuzzy controller using fuzzy neural networks and a description of its dynamical behavior", Fuzzy Sets and Systems, vol.71, pp. 3-23, 1995.
- [4] C. T. Lin and C. S. G. Lee, Neural Fuzzy Systems, Prentice Hall, Upper Saddle River, 1996.
- [5] S. Horikawa, T. Furuhashi and Y. Uchikawa, "On fuzzy modeling using fuzzy neural networks with the back-propagation algorithm", IEEE Trans. Neural Networks vol. 3(5), pp. 801-806, 1992.
- [6] D. E. Goldberg, Genetic Algorithm in Search Optimization and Machine Learning, Addison Wesley, Reading, MA, 1989.
- [7] J. S. Jang, "ANFIS: adaptive-network-based fuzzy inference systems", IEEE Trans. Systems Man Cybernet., vol. 23(3), pp. 665-684, 1993.