

인공신경망을 이용한 퍼지 규칙 인식 시스템

장 문 석[†] 장 덕 철^{††}

요 약

일반적으로 퍼지 시스템 모델링에 있어서, 퍼지 규칙을 인식하고 퍼지 추론의 소속함수를 조정하기란 매우 어렵다. 본 논문에서는 인공신경망을 이용함으로써, 자동으로 퍼지 규칙을 인식하고 동시에 퍼지 추론의 소속함수를 조정할 수 있는 방법을 제시하였다. 본 모델은 역전파를 기본으로 한 알고리즘으로 학습하며, 이 방법의 타당성을 로보트 매니퓰레이터를 통해 검증한다.

Fuzzy Rule Identification System using Artificial Neural Networks

Moonsuk Jang[†] and Duk Chul Chang^{††}

ABSTRACT

It is very hard to identify the fuzzy rules and tune the membership functions of the fuzzy reasoning in fuzzy systems modeling. We propose a method which can automatically identify the fuzzy rules and tune the membership functions of fuzzy reasoning simultaneously using artificial neural networks. In this model, fuzzy rules are identified by backpropagation algorithm. The feasibility of the method is simulated by a simple robot manipulator.

1. 서 론

1943년 McCulloch와 Pitts의 신경 모델, 1949년 Hebb의 신경 시스템, 1950년대 Rosenblatt의 퍼셉트론(perceptron) 이후로 인공신경망(artificial neural network)에 관한 연구가 진행되어 왔다. 한편, 1964년 Zadeh가 퍼지 집합 이론을 발표한 이후로 이에 관한 연구도 활발히 진행되어 왔다. 이를 인공신경망과 퍼지 시스템은 서로 다른 분야에서 독립적으로 많은 발전이 있었다.

인공신경망은 인간의 뇌를 소프트웨어 또는 하드웨어로 모델링한 시스템으로서 병렬성, 학습 능력, 견고성(robustness), 결함허용(fault tolerance)등의 장점으로 인해, 화상처리, 음성 처리, 자연어 처리, 플랜트 제어, 전문가 시스템 등에 널리 적용되고 있다. 한편, 퍼지 이론은 인간의 사고와 같은 불확실성을 내포한 정보를 처리하고 추론할 수 있는 강점으로 인해, 전문가 시스템,

다치논리 설계, 의사결정, 자동제어, 지식 표현, 패턴 인식 등에 널리 적용되고 있다.

인공신경망과 퍼지 시스템 두 가지 모두가 인간 사고 및 인식과 관련된 현상을 모델링하기 위한 강력한 도구이며, 또한 인공신경망과 퍼지 시스템의 내부 구조가 비슷하여 결합 가능하다는 점에 착안하여[1], 최근에는 뉴로퍼지 시스템(neurofuzzy system) 또는 퍼지 신경망(fuzzy neural network)라는 용어가 탄생하기에 이르렀는데, 이는 인공신경망과 퍼지 시스템의 장점을 결합하여 좀더 강력한 시스템을 개발하기 위한 연구라고 할 수 있다.

이들 두 시스템을 결합하려는 연구로는 예를 들면, 인공신경망을 퍼지 집합의 소속함수(membership function)의 학습에 사용하는 연구[2, 3], 인공신경망의 학습기법들을 퍼지 추론 규칙[4] 또는 퍼지 제어 규칙의[5] 학습에 적용하는 연구, 연상 기억장치(associative memory)에서 퍼지 지식을 습득하기 위한 퍼지 인식 맵(fuzzy cognitive map)에 관한 연구[6], 퍼지 논리를 인공신경망의 동작에 대한 감시 및 제어에 적용하는 연

[†]-종신회원 : 순천대학교 전자계산학과 부교수

^{††} 정회원 : 광운대학교 교수, 광운대학교 전산대학원장

논문접수 : 1994년 11월 10일, 심사완료 : 1995년 3월 10일

구[7], 퍼지 뉴런의 설계에 관한 연구[8, 9] 등이 있다.

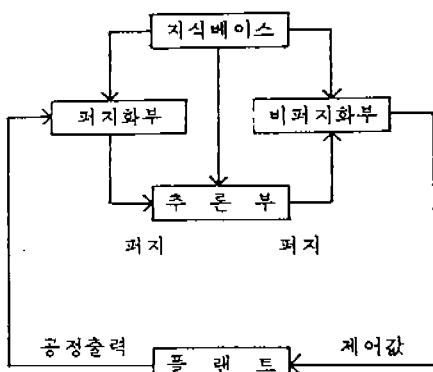
인공신경망을 이용하여 퍼지 규칙을 생성하고 소속함수를 조정하려는 연구는 Takagi[10] 등 여러 연구 팀에서 시도되어 퍼지 모델링과 제어에 적용되었다. 그 후에 Horikawa[11] 등은 퍼지 규칙에 대한 자동 인식과 소속함수의 조정을 동시에 수행할 수 있는 퍼지 신경망을 제안하였는데, 이 FNN은 조건부와 결론부를 인공신경망으로 구성함에 있어서 출력이 상수, 선형함수, 퍼지변수인가에 따라 다른 모델을 제시했다. 국내에서는 전홍태[12] 등이 출력이 선형함수인 경우를 개선한 연구를 발표하였다.

본 논문에서는, 인공신경망을 이용하여 자동으로 퍼지 규칙을 인식하고 동시에 퍼지 추론의 소속함수를 조정할 수 있는 인공신경망 모델을 제시하였다. 역전파(back-propagation) 알고리즘을 기본으로 하는 학습 방법을 사용하여 로보ット 매니퓰레이터를 구현하여 타당성을 검증하였다.

본 논문의 2장에서는 퍼지 시스템을 기술하고, 3장에서는 퍼지 신경망 추론 시스템의 모델과 학습 알고리즘을 기술하고, 4장에서 시뮬레이션 결과를 제시한다.

2. 퍼지 시스템

시스템의 복잡성이 어느 정도 이상 증가하면



(그림 1) 퍼지 시스템의 구조
(Fig. 1) A structure of fuzzy system

정량적인 방식으로는 시스템의 거동에 대해 정확하고 의의가 있는 기술이 불가능하게 되는데, Zadeh는 이를 상반 원리(principle of incompatibility)라 했다[13]. 퍼지 추론은 시스템의 특성이 복잡하여 기존의 정량적인 방법으로는 해석할 수 없거나, 정보가 정성적, 부정확, 불확실한 경우에 기존의 추론 방식보다 우수하다고 할 수 있다.

퍼지 시스템은 일반적으로 (그림 1)과 같이 퍼지화부(fuzzifier), 지식베이스(knowledge base), 추론부(inference engine), 그리고 비퍼지화부(defuzzifier)로 구성된다.

퍼지화부는 명확한(crisp) 입력 영역으로부터 이에 상응하는 전체 집합(universe of discourse)상의 퍼지 집합으로 대응시킨다. 지식베이스는 퍼지 데이터를 조작하고 규칙을 정의하는데에 필요한 사항들을 정의하는 데이터베이스와, 전문가의 처리 방침을 나타낸 규칙부로 구성된다. 추론부는 퍼지 관계(relation)와 추론 규칙으로부터 퍼지 입력을 추론한다. 그리고 비퍼지화부는 추론된 퍼지 값을 명확한 값으로 변환시킨다.

퍼지 규칙은 전문가의 지식을 언어적인 형식으로 나타낸 것으로서, 다음과 같은 퍼지 조건문들로 이루어진다.

If (만족해야 할 일련의 조건)
then (추론된 일련의 결론)

If 이하를 조건부(antecedent), then 이하를 결론부(consequent)라 하고, 각각은 복수개의 퍼지 변수들이 도입될 수 있으며, 일반적으로 전체 규칙은 여러 개의 복수입력-복수출력 퍼지 조건문들로 구성된다. 복수입력-단일출력 형식의 전형적인 퍼지규칙의 예는 다음과 같다.

$R_i : \text{If } x \text{ is } A_i \text{ and } y \text{ is } B_i \text{ then } z \text{ is } C_i$

여기에서 x 와 y 는 입력, y 는 출력 변수이고, A_i , B_i 그리고 C_i 는 전체 집합 U , V , W 에서 정의된 x , y , z 의 퍼지 값을 나타낸다. 또한, 개별적인 퍼지 조건문들은 R_i 라는 퍼지 관계로 대변될 수 있으며, 이들이 모여서 퍼지 규칙 집합을 이룬다.

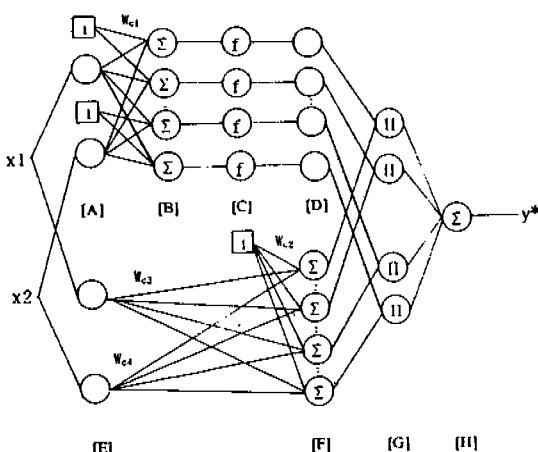
3. 뉴로퍼지 추론 시스템

3.1 시스템의 구성

일반적으로 퍼지 시스템에서 전문가가 자신의 경험과 지식으로 규칙을 생성하기란 상당히 어려운 것이 현실이며, 일단 결정된 규칙은 환경의 변화에 적응할 수 없다는 문제점이 있다.

이러한 문제점을 해결하기 위해, 본 논문에서는 인공신경망을 이용하여 퍼지 규칙을 생성하고 퍼지 추론의 소속함수를 조정할 수 있는 모델을 제시하고자 한다. 일반적으로 인공신경망을 복잡하게 하면 학습 패턴에 대해서는 잘 처리할 수 있지만 문제의 성질을 일반화시키기에는 어려운 문제점이 있다. 특히 학습 패턴에 노이즈가 포함되어 있는 경우에는 본질적이지 못한 패턴까지도 학습된다. 따라서 복잡도를 줄일 수 있는 방법도 모색되어야 한다.

본 시스템에서 사용한 모델은 (그림 2)와 같이 조건부([A] ~ [D]층)와 결론부 ([E] ~ [H]층)로 구성된다. 학습 방법으로는 역전파(backpropagation)를 기본으로 한 알고리즘을 사용한다 [14]. 그리고 복잡도를 줄이기 위해 본 모델은 다른 뉴로퍼지 모델들에 비해 중간 유니트의 수를 줄이고 대칭성을 높였다.



(그림 2) 뉴로퍼지 추론 모델
(Fig. 2) A neurofuzzy inference model

3.2 학습 알고리즘

본 시스템에 대한 학습은 역전파를 기본으로 한 알고리즘을 사용한다. (그림 2)에서, [A]층부터 [D]층까지는 조건부로서 두개의 입력 x_1 과 x_2 가 있다. w_{c1} , w_{c2} , w_{c3} , w_{c4} , 그리고 1은 연 결 가중치를 의미하며, 처음에는 1로 주어진다.

[B]층과 [C]층의 입력 및 출력은 각각 다음과 같다.

$$\begin{aligned} \sum : & \left\{ \begin{array}{l} i_j = \sum_k w_{jk} o_k \\ o_j = i_j \end{array} \right. \quad (1) \end{aligned}$$

$$f : \left\{ \begin{array}{l} i_j = \sum_k w_{jk} o_k \\ o_j = f(i_j) \end{array} \right. \quad (2)$$

[C]층의 출력은 다음과 같은 시그모이드(sigmoid) 함수로 표현될 수 있다.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (3)$$

[G]층의 입력 및 출력은 각각 다음과 같다.

$$i_j = \prod_k w_{jk} o_k \quad (4)$$

$$o_j = \frac{i_j}{\sum_k i_k} \quad (5)$$

입력이 두 개이고 출력이 하나의 선형함수인 경우에 추론은 다음과 같이 수행된다.

$$R^1 = \text{If } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ then} \quad (6)$$

$$y = f_i(x_1, x_2), \quad (i = 1, 2, \dots, n)$$

$$f_i(x_1, x_2) = a_{i0} + a_{i1}x_1 + a_{i2}x_2 \quad (7)$$

$$a_{ij} \quad (j = 0, 1, 2) : \text{상수}$$

$$y^* = \sum_{i=1}^n w f_i(x_1, x_2) \quad (8)$$

이 때, R_i 는 i 번째 퍼지 규칙이고, A_{ij} 와 A_{kj} 는 퍼지 변수이고, y^* 는 추론 값이다.

다음과 같은 오차 함수에 대해,

$$E = \frac{1}{2} \sum_j (t_j - o_j)^2 \quad (9)$$

일반화 텔타 규칙에 따라, 연결 가중치의 변화량은 다음과 같으며,

$$\Delta w_{ji} = \eta \delta_j o_j \quad \eta = \text{학습률} \quad (10)$$

오차 신호는 다음과 같이 구할 수 있다.

$$\text{출력층: } \delta_j = (t_j - o_j) f'(i_j) \quad (11)$$

$$\text{중간층: } \delta_j = f'(i_j) \sum_k \delta_k w_{kj} \quad (12)$$

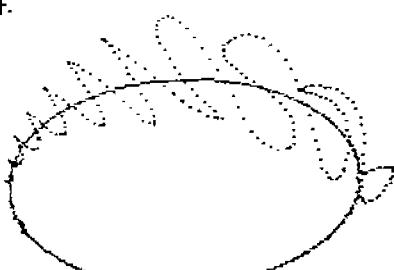
따라서, 학습시 연결 가중치는 다음과 같이 수정된다.

$$\Delta w_{ji}(n+1) = \eta \delta_j o_j + \alpha w_{ji}(n) \quad (13)$$

α 는 상수이며, $\alpha w_i(n)$ 는 모멘텀 항(momentum term)이다.

4. 시뮬레이션

본 뉴로퍼지 모델의 타당성을 검증하기 위해, 타원 궤적을 추적하는 로보트 매니퓰레이터에 대해 시뮬레이션하였다. (그림 3)은 첫번째 수행 결과로서, 실선은 원하는 궤적이고, 점선은 로보트의 추적 경로이다. (표 1)은 초기 가중치를 나타낸다.



(그림 3) 첫번째 학습 후의 결과
(Fig. 3) The result after the first learning

(표 1) 로보트 매니퓰레이터의 초기 가중치
(Table 1) Initial weights of robot manipulator.

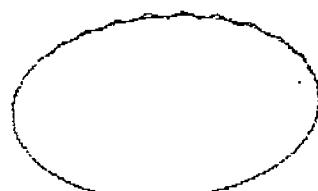
(a) Initial weights of joint 1

WC1	WC2	WC3	WC4
1.000	0.008	-0.003	0.007
1.000	-0.006	0.008	0.000
1.000	0.008	0.005	0.002
1.000	-0.009	-0.006	0.008
1.000	0.005	0.000	-0.008
1.000	0.003	0.008	-0.008
1.000	0.010	0.003	0.009
1.000	-0.006	0.006	0.000
1.000	0.002	0.009	0.008

(b) Initial weights of joint 2

WC1	WC2	WC3	WC4
1.000	0.002	-0.004	0.008
1.000	0.007	0.001	0.007
1.000	-0.001	-0.006	-0.005
1.000	0.001	0.005	-0.003
1.000	0.000	-0.007	0.008
1.000	-0.002	-0.004	0.000
1.000	-0.001	-0.002	0.007
1.000	0.003	-0.001	0.009
1.000	-0.005	-0.004	0.010

첫번째 수행 결과는 매우 큰 오차가 나타났으나, (그림 4)와 (그림 5)에서 보는 바와 같이 학습이 반복됨에 따라 오차가 급격히 줄어들어 10번째 수행시에는 원하는 궤적을 거의 오차 없이 추적함을 알 수 있다. (표 2)는 10번째 학습 후의 가중치 변화로서, 적절한 규칙이 생성되었음을 볼 수 있다.



(그림 4) 두번째 학습 후의 결과
(Fig. 4) The result after the second learning



(그림 5) 10회 학습 후의 결과
(Fig. 5) The result after the 10th learning

〈표 2〉 10회 학습 후의 가중치 변화
(Table 2) Identified weights after 10th learning.

(a) Identified weights of joint 1

WC1	WC2	WC3	WC4
1.073	-0.310	0.122	0.215
1.339	-0.839	0.319	0.017
1.030	-0.207	0.082	-0.116
1.118	-0.371	0.260	0.254
1.324	-0.157	0.879	0.127
1.026	-0.043	0.251	-0.047
1.007	0.107	0.032	-0.047
1.113	0.471	0.146	0.027
1.018	0.159	0.060	0.097

(b) Identified weights of joint 2

WC1	WC2	WC3	WC4
1.315	-0.668	0.342	0.427
2.259	-1.819	0.916	0.083
1.159	-0.462	0.219	-0.306
1.157	-0.269	0.538	0.128
1.813	0.208	1.528	0.145
1.110	0.030	0.514	0.086
1.175	0.482	0.248	-0.322
2.292	1.827	0.985	0.040
1.363	0.688	0.384	0.516

성을 간단한 로보트 매니퓰레이터를 통해 검증하였다.

본 모델에서는 복잡도를 줄이기 위해 다른 모델들에 비해 중간 유닛의 수를 줄이고 대칭성을 높였다. 본 모델은 약 10회 정도의 학습만에 만족할 만한 결과를 얻을수 있었다. 그러나, 충분한 학습 전의 상태 즉, 완전한 규칙 베이스를 얻기 전까지의 상태에 적응할 수 있는 방법에 대한 연구와 신경망의 수렴도를 향상시키기 위한 연구가 뒤따라야 하리라 사료된다.

참 고 문 헌

- [1] N. Kashiwagi and T. Tobi, "Neuro Fuzzy Inference System," Proc. Int. Conf. on Fuzzy Logic & Neural Networks, pp. 925-928, 1990.
- [2] H. Ishibuchi and H. Tanaka, "Identification of Real-valued and Interval-valued Membership Functions by Neural Networks," Proc. Int. Conf. on Fuzzy Logic & Neural Networks, pp. 179-182, 1990.
- [3] Y. Pao, Adaptive Pattern Recognition and Neural Networks, Addison-Wesley, 1989.
- [4] K. Uehara and M. Fujise, "Learning of Fuzzy Inference Criteria with Artificial Neural Network," Proc. Int. Conf. on Fuzzy Logic & Neural Networks, pp. 193-198, 1990.
- [5] S. Horikawa, et al, "A Fuzzy Controller Using a Neural Network and Its Capability to Learn Expert's Control Rules," Proc. Int. Conf. on Fuzzy Logic & Neural Networks, pp. 103-106, 1990.
- [6] B. Kosko, "Fuzzy Associative Memories," Fuzzy Expert Systems, A. Kandel(ed.), Addison-Wesley, 1987.
- [7] J. Yen, "The Role of Fuzzy Logic in the Control of Neural Networks," Proc. Int. Conf. on Fuzzy Logic & Neural Networks, pp. 771-774, 1990.
- [8] T. Yamakawa and S. Tomota, "A Fuzzy

5. 결 론

본 논문에서는 인공신경망을 이용하여 퍼지 규칙을 인식하고 퍼지 추론의 소속함수를 조정할 수 있는 모델을 제시하였다. 본 모델은 역전파 알고리즘에 근거하여 학습하며, 이 방법의 타당

- Neuron and Its Application to Pattern Recognition," Proc. 3rd IFSA Congress, pp. 30-38, 1989.
- [9] MM Gupta and J. Qi, "On Fuzzy Neuron Models," Proc. Int. Joint Conf. on Neural Networks, pp. II-431-436, 1991.
- [10] T. Takagi and M. Sugeno, "Fuzzy Identification of Systems and Its Applications to Modeling and Control," IEEE Trans. Systems, Man and Cybernetics, Vol. SMC-15, No. 1, pp. 116-132, 1985.
- [11] S. Horikawa, et al, "A Study on Fuzzy Modeling Using Fuzzy Neural Networks," Proc. Int. Fuzzy Engineering Symp.'91, pp. 562-573, 1991.
- [12] 임광우 외, "뉴럴-퍼지 융합을 이용한 퍼지 제어 규칙의 자동생성에 관한 연구," 전자 공학회논문지, 제29권, B편, 제11호, pp. 1066-1075, 1992.
- [13] L. A. Zadeh, "Outline of a New Approach to the Analysis of Complex Systems and Decision Processes," IEEE Trans. Systems, Man, and Cybernetics, Vol. SMC-3, No. 1, pp. 28-44, 1973.
- [14] D.E. Rumelhart, et al, Parallel Distributed Processing, The MIT Press, 1986



장 문 석

1983년 광운대학교 전자계산학
과 졸업(이학사)
1985년 광운대학교 대학원
전자계산학과 졸업(이학석사)
1991년 광운대학교 대학원 전
자계산학과 박사과정 수료
1988년~91년 순천대학교 전자
계산학과 전임강사
1991년~95년 순천대학교 전자계산학과 조교수
1995년~현재 순천대학교 전자계산학과 부교수
관심분야: 인공지능, 퍼지 시스템, 인공신경망



장 덕 철

1974년 고려대학교 대학원 졸
업(석사)
1982년 고려대학교 대학원 졸
업(박사)
1981년~82년 University of Cal-
ifornia at Berkeley 객원교수
1976년~현재 광운대학교 전자
계산학과 교수, 광운대학교
전산대학원장
관심분야: 의사결정지원 시스템, 소프트웨어 공학