

퍼지 제어규칙을 기반으로한 RBF 신경회로망 제어기 설계

최종수*, 권오신**

*포항산업과학연구원 자동화연구부문, **군산대학교 제어계측공학과

Design of RBF Neural Network Controller Based on Fuzzy Control Rules

Jong-Soo Choi*, Oh-Shin Kwon**

*Research Institute of Industrial Science & Technology, **Kunsan National University

Abstract - This paper describes RBF network controller based on fuzzy control rules for intelligent control of nonlinear systems. The proposed scheme is derived from the functional equivalence between RBF networks and fuzzy inference systems. The design procedure of the proposed scheme is realized by first transforming the fuzzy control rules into the parameters of RBF networks. The optimized RBF network controller is then performed through the gradient descent learning mechanism to an error function. The proposed method is rigorously tested using a nonlinear and unstable nonlinear system. Simulation is performed to demonstrate the feasibility and effectiveness of the proposed scheme.

1. 서 론

신경회로망은 학습과 적응 능력, 함수 근사화 및 대규모 병렬처리 능력을 갖고 있기 때문에 지능 제어 시스템을 구성할 수 있는 강력한 능력을 갖고 있으며, 지능 제어 시스템에서 분류기(Classifier)와 적응 제어기로 이용될 수 있다. 퍼지 논리도 역시 지능 제어 시스템을 구성할 수 있는 능력을 갖추고 있다. 전문가 시스템에서, 퍼지 집합은 기존의 two-valued 논리로 모델링 할 수 없는 불분명한 언어를 모델링 할 수 있기 때문에 전문가와 사용자 사이의 의사소통에서 발생하는 복잡성 및 모호성을 모델화 할 수 있다. 최근 많은 연구들은 신경회로망과 퍼지 논리의 결합을 통해서 각각의 결점을 상호 보완하고자 하는 연구들이 많이 진행되고 있다.

신경회로망 모델 중 RBF (radial basis function) 신경회로망[1]은 일반화 능력, 계산 능력 및 생물학적 plausibility에서 기존 다층 신경회로망의 개선된 모델로 생각할 수 있다. RBF 신경회로망은 패턴 분류, 예측 및 시스템 모델링 분야 등 다양한 분야에 적용되어 그 유용성이 입증되고 있다. 특히, 지역적 감응함수를 갖는 특성 때문에 동작특성에 따라 비선형성이 변화하는 시스템의 안정한 제어에 적용되었다[2]. 최근, Jang 등은 RBF 신경회로망과 Takagi-Sugeno 퍼지추론 시스템과의 기능적 동가성을 해석하였고[3], Hunt 등은 Jang 등의 연구를 확장하여 일반화하였다[4].

RBF 신경회로망에는 조정해야 할 많은 파라미터를 가지고 있다. 예를 들면, distance 형태, basis function의 형태 및 파라미터, kernel의 위치 등이 있다. RBF 신경회로망을 응용할 때 가장 중요한 문제 중의 하나는 프로토타입(kernels, centers)의 초기값과 RBF 함수의 출력과

출력단 사이의 연결강도를 결정하는 것이다. RBF 신경회로망을 제어문제에 적용할 경우, 제어대상 시스템에 대한 정성적 지식을 알고 있다면 이를 RBF 신경회로망 제어기의 파라미터 초기화에 사용할 수 있다.

이 논문에서는 퍼지 추론 시스템과 RBF 신경회로망의 동가성을 이용하여 플랜트에 대한 퍼지제어 규칙 정보를 RBF 신경회로망의 초기 파라미터로 변환하고 학습을 통해서 제어기를 최적화하는 방법을 제안한다. 제안한 알고리즘의 유용성을 입증하기 위해서 비선형 시스템 제어의 benchmark test로 널리 이용되는 cart-pole 균형제어 문제에 적용하고 시뮬레이션을 수행하였다.

2. 퍼지 시스템과 RBF 신경회로망

2.1 퍼지 시스템

Takagi-Sugeno 모델은 퍼지 조건과 입출력 공간사이의 함수관계를 결합한 복합모델이다. 규칙의 Canonical 형태는 다음과 같다.

$$R_i: \text{if } x_1 \text{ is } A_{i1} \wedge x_2 \text{ is } A_{i2} \wedge \dots \wedge x_{in} \text{ is } A_{in} \text{ then } y = w_i(\bar{x}).$$

추론 규칙은 먼저, 다음과 같이 전건부의 발화정도(firing strength)를 계산에 의해서 구현된다.

$$\mu_{R_i}(\bar{x}) = \mu_{A_{i1}}(x_1) \wedge \dots \wedge \mu_{A_{in}}(x_{in}).$$

여기에서 μ_{ij} 는 퍼지집합 A_{ij} 의 멤버쉽 함수이고, \wedge 는 T-norm 특성의 퍼지 conjunction 연산자이다. 다음, 출력 발화정도 값은 출력함수와 곱해진다. 비퍼지화기로 무게 중심법을, 추론방식으로 product-inference 규칙, 그리고 퍼지화기로 singleton을 적용할 경우 퍼지 시스템은 다음 식과 같이 표현된다[4].

$$y = f(\bar{x}) = \frac{\sum_{i=1}^M \mu_{R_i}(\bar{x}) \cdot w_i(\bar{x})}{\sum_{i=1}^M \mu_{R_i}(\bar{x})} \quad (1)$$

2.2 RBF 신경회로망

신경회로망 분야에서 지역 학습 및 중첩 감응 영역은 cerebral cortex, visual cortex 등의 영역에서 연구된 잘 알려진 구조이다. 생물학적 감응 영역을 기반으로 Moody 등은 함수 매핑을 수행하기 위해서 지역적 감응 영역을 이용하는 RBF 신경회로망을 제안하였다[1].

전형적인 RBF 신경회로망은 다음과 같이 기술할 수 있다.

$$y = f(\bar{x}) = \sum_{j=1}^J \theta_j(\bar{x}) \phi_j(\bar{x}) = \bar{\theta}^T \bar{\phi} \quad (2)$$

여기에서 '는 transpose 연산자이다. 각 프로세싱 유니트의 출력은 연결강도 함수 $\theta_i(\bar{x})$ 에 의해서 곱해지고 이 값들은 network 출력을 형성하기 위해 더해진다. Network의 정규화된 형태는 다음과 같이 표현된다.

$$y = f(\bar{x}) = \frac{\sum_{i=1}^n \theta_i(\bar{x}) \phi_i(\bar{x})}{\sum_{i=1}^n \phi_i(\bar{x})} \quad (3)$$

함수 $\theta_i(\bar{x})$ 는 validity가 활성화 값 $\phi_i(\bar{x})$ 에 의해서 정의되는 지역모델(local model)로 생각할 수 있다. 그러므로 지역활성화 함수 $\phi_i(\bar{x})$ 를 통해서 입력공간을 지역모델이 정의된 n 개의 동작영역으로 분해한다. 지역모델 $\phi_i(\bar{x})$ 가 상수값을 갖는다면, 즉, $\theta_i(\bar{x}) = \theta_i$ 이라면 식 (2)와 (3)은 다음과 같이 표현된다.

$$y = f(\bar{x}) = \sum_{i=1}^n \theta_i \phi_i(\bar{x}), \quad (4)$$

$$y = f(\bar{x}) = \frac{\sum_{i=1}^n \theta_i \phi_i(\bar{x})}{\sum_{i=1}^n \phi_i(\bar{x})}. \quad (5)$$

Gaussian 활성화 함수는 각 차원에서 동일한 폭을 갖는 경우 다음과 같이 간략하게 표현할 수 있다.

$$\phi_i(\bar{x}) = \exp\left[-\frac{\|\bar{x} - \bar{c}_i\|^2}{\sigma_i^2}\right] \quad (6)$$

여기에서 $\|\cdot\|$ 는 Euclidean norm이다.

2.3 퍼지 시스템과 RBF 신경회로망의 등가성

아래의 조건들을 전제로 식 (1)과 (4)로부터 RBF 신경회로망과 퍼지 시스템 사이에는 기능 및 구조적으로 등가성이 있음을 알 수 있다[3,4].

- 1) 감응 영역 유니트의 수가 퍼지 "If-Then" 규칙의 수와 같다.
- 2) 각 퍼지 "If-Then" 규칙의 출력이 상수이다.
- 3) 각 규칙의 소속함수가 Gaussian 함수로 구성된다.
- 4) 각 규칙의 발화정도(firing strength)를 계산하기 위해 이용하는 T-norm 연산자는 곱(product)연산이다.
- 5) 시스템의 전체 출력을 계산하기 위해서 RBF 신경회로망과 퍼지 추론 시스템이 동일한 방법을 이용한다. 위의 제약 조건들이 없다면, RBF 신경회로망은 단지 퍼지 추론 시스템의 한가지 경우에 불과하다. 위에서 보인 것과 같은 기능적 공통점 때문에 두 시스템은 서로 호환성을 갖는다.

3. RBF 신경회로망 제어기 설계

퍼지 추론 시스템과 RBF 신경회로망의 등가성을 이용하여 플랜트에 대한 퍼지제어 규칙 정보를 RBF 신경회로망의 초기 파라미터로 변환하고 학습을 통해서 제어기를 최적화하는 방법을 기술한다. 제안하는 RBF 신경회로망 제어기의 설계 과정은 다음과 같다.

[단계 1] 플랜트에 대한 경험 지식을 이용하여 퍼지 제어 규칙 설계

숙련된 전문가로부터 플랜트의 특성을 취득하여 규칙화한다. 신경회로망 제어기들의 어려움은 훈련 데이터를 획득하는 것인데, 이 방법은 퍼지 규칙으로부터 대략적인 훈련 데이터를 취득할 수 있다. 퍼지 규칙은 표현되며 2-입력/1-출력 시스템인 경우 다음과 같이 표현된다.

If x_1 is FV1 and x_2 is FV2, Then y is CV

여기에서 x_1 과 x_2 는 입력 변수이고, FV1 및 FV2는 퍼지 멤버십 함수로써 식 (10)과 같은 Gaussian 함수를 사용

한다. 그리고 제어기 y 는 출력변수이고 CV는 상수값을 사용한다.

[단계 2] 퍼지 제어규칙을 RBF 신경회로망의 파라미터로 변환

퍼지 규칙 전진부의 멤버십 함수를 정의하는 Gaussian 함수 $\mu_{R_i}(\bar{x}_i)$ 를 RBF 신경회로망의 지역활성화 함수 $\phi_i(\bar{x}_i)$ 로 변환한다. 즉, $\mu_{R_i}(\bar{x}_i) = \phi_i(\bar{x}_i)$. 또한, 후진부의 출력 $w_i(x)$ 를 RBF 출력과 출력단 사이의 연결강도 $\theta_i(\bar{x})$ 로 대체한다. 따라서, 두 시스템의 등가성을 기반으로 퍼지 제어규칙은 RBF 신경회로망의 초기화 값으로 변환된다.

[단계 3] RBF 신경회로망 제어기의 최적화

최적의 RBF 제어기를 얻기 위해서 오차 함수에 대한 gradient descent 법을 적용하여 RBF 신경회로망 제어기의 파라미터들을 훈련시킨다. n 번째 입력에 대한 오차 함수 E_n 는 다음과 같이 정의된다.

$$E_n = \frac{1}{2} \sum_{k=1}^m (t_{nk} - y_{nk})^2 \quad (7)$$

여기에서 m 은 출력 유니트의 개수이고, t_{nk} 와 y_{nk} 는 각각 원하는 출력과 실제 출력의 k 번째 성분이다. 학습되어야 할 파라미터 벡터를 $v = [c_{nk}^T, \sigma_{nk}^2, \theta_{nk}^T]^T$ 라 하면, 파라미터 갱신법칙은 다음과 같다.

$$v(t+1) = v(t) + \eta \Delta v = v(t) + \eta \frac{\partial E_n}{\partial v_i}, \quad (8)$$

여기에서 η 는 학습률이다.

4. 비선형 시스템 제어 시뮬레이션

이 절에서는 제안한 RBF 신경회로망 제어기를 이용하여 비선형 시스템 제어 문제에 적용하였다. 대상 시스템은 전형적인 비선형 시스템인 Cart-pole 시스템 (또는 역진자 시스템)이다. Cart-pole 시스템의 운동방정식은 다음과 같다.

$$\begin{aligned} \ddot{\theta} &= \frac{G \sin \theta - \cos \theta (F + M_p L \dot{\theta}^2 \sin \theta) / M_t}{L(4/3 - M_p \cos^2 \theta / M_t)} \\ \dot{x} &= \frac{F + M_p L (\dot{\theta}^2 \sin \theta - \ddot{\theta} \cos \theta)}{M_t} \end{aligned} \quad (9)$$

여기에서, 중력가속도(G)는 9.81 m/sec^2 , pole 질량 (M_p)은 0.1 kg , Cart 질량(M_c)은 0.9 kg , 전체 질량 (M_t)은 1.0 kg 이다. 샘플링 주기 T 는 $0.02(\text{sec})$ 이다.

제어의 목적은 가능한 한 빠른 시간 안에 pole의 각도 $\theta(t)$ 와 $\dot{\theta}(t)$ 가 0으로 수렴하기 위해 필요한 힘(F)을 찾는 것이다. 따라서, 먼저 제어 공학적 지식을 기반으로 퍼지 제어기를 설계하여야 한다. 초기 문제는 각 제어기 변수들에 대한 멤버십 함수를 정의하고 제어 규칙을 설계하는 것이다. 퍼지 제어기의 입력 변수인 pole의 각도와 각속도의 전체집합(universe of discourse)은 모든 가능한 범위 이내로 결정해야 한다. 그러므로 각도 θ 에 대한 전체집합 범위는 $[-\pi/4, \pi/4]$ (rad)로 정한다. 각도가 이 범위를 벗어나면 pole은 제어에 실패한 상태로 간주한다. 이론적으로 모든 범위의 각속도가 가능하지만 인공적으로 일정 범위만 가능하다고 가정한다. 즉, 각속도는 $-5 \leq \dot{\theta} \leq 5$ (rad/sec)의 범위로 물리적 액츄에이터 제약에 의해 제한된다고 가정한다. 퍼지 제어기의 출력 변수는 힘으로서 ± 30 (Newtons) 이내에서 유지된다고 가정한다.

균등하게 분포하는 5개의 Gaussian 형태의 멤버십 함

이 연구는 한국과학재단(과제번호 961-0924-144-1)의 지원에 의해서 수행되었습니다.

[참 고 문 헌]

[1] J. Moody and C. Darken, "Fast learning in networks of locally-tuned processing units," *Neural Computation*, vol. 1, pp. 281-294, 1989.
 [2] R. M. Sanner and J.-J. E. Slotine, "Gaussian networks for direct adaptive control," *IEEE Transactions on Neural Networks*, vol.3, no.6, 1992.
 [3] J.-S. R. Jang and C. -T. Sun, "Functional equivalence between radial basis function networks and Fuzzy inference system," *IEEE Transactions on Neural Networks*, vol. 4, no. 1, pp. 156-159, 1993.
 [4] K. J. Hunt, R. Haas, and R. Murray-Smith, "Expanding the functional equivalence of radial basis function networks and fuzzy inference systems," *IEEE Transactions on Neural Networks*, vol. 7, no. 3, pp. 776-781, 1993.
 [5] L.-X. Wang, *Adaptive fuzzy systems and control: Design and stability analysis*, Prentice-Hall Intern'l Inc., 1994

수가 입력변수에 할당되고, 출력변수는 singleton 형태의 멤버십 함수로 정의한다. 이것은 퍼지 제어 시스템과 RBF 신경회로망의 유사성을 고려하기 위한 것이다. 즉, Gaussian 형태의 각 입력변수의 멤버십 함수는 RBF 신경회로망의 은닉층 유닛의 활성화 함수로, singleton 형태의 출력변수 멤버십 함수는 RBF 은닉층 유닛과 출력단 사이의 선형 연결강도(weights)로 변환할 수 있다. 각 멤버십 함수는 다음 식과 같은 Gaussian 함수로 구성된다.

$$\mu_x(x) = \exp\left(-\frac{1}{2}\left(\frac{x-c_i}{\sigma_i}\right)^2\right) \quad (10)$$

여기에서, $\mu_x(x)$ (벡터 X 는 $X=[\theta, \dot{\theta}]$)는 입력 x 에 대한 멤버십 함수값이다. Pole 각도에 대한 중심 벡터 값은 $[-\pi/4, -\pi/8, 0, \pi/8, \pi/4]$ 이고 폭은 $\pi/18$ 이다. 또한, 각속도의 중심 및 폭은 각각 $[-5, -2.5, 0, 2.5, 5]$ 와 $5/4.5$ 이다.

Cart-pole 시스템에 대한 사전지식을 기반으로 설계된 제어규칙은 모두 25개로 구성되고 각 규칙은 IF-THEN 형태로 다음과 같이 표현된다. 전체 제어규칙은 표 1에 나타났다.

R(1) : IF θ is LL and $\dot{\theta}$ is NL, THEN F is -30.

R(2) : IF θ is LS and $\dot{\theta}$ is NL, THEN F is -27.

.....

R(25) : IF θ is RL and $\dot{\theta}$ is PL, THEN F is 30.

그림 1은 초기 조건으로 θ 가 20° ($0.35[\text{rad}]$)이고, $\dot{\theta}$ 가 ($-5 [\text{rad/sec}]$)인 경우에 대한 pole의 응답을 보여준다. 결과로부터 알 수 있듯이 pole의 위치는 5초 정도까지의 과도상태를 정상상태에 도달하지만, 결국 약간의 off-set이 존재한다. 이것은 초기에 설계된 멤버십 함수 및 퍼지 제어규칙으로 인한 오차로 생각할 수 있다. 그림 2는 RBF 제어기 제어결과로서 그림 1의 시뮬레이션과 동일한 초기 조건일 때 pole의 응답을 보여준다. 결과로부터 알 수 있듯이 pole의 위치는 2초 정도까지의 과도상태를 거쳐 정상상태에 도달함을 보여준다. 또한 앞의 퍼지 제어기 응답에서 나타났던 off-set도 존재하지 않고 0으로 수렴함을 알 수 있다. 결과적으로 제안한 RBF 제어기는 퍼지 제어기에 비해 우수한 성능을 보이고 있음을 알 수 있다.

5. 결 론

이 논문에서는 퍼지 시스템과 RBF 신경회로망 모델의 기능적 등가성을 기반으로 퍼지 제어규칙을 이용하여 RBF 신경회로망 제어기를 설계하는 방법을 제시하였다. 제안한 기법은 플랜트에 대한 경험적 지식을 기반으로 대략적인 퍼지 제어규칙을 설계하고 퍼지 시스템과 RBF 신경회로망 사이의 등가성에 근거하여 퍼지 제어규칙으로 RBF 신경회로망을 초기화한 다음 학습을 통해서 RBF 제어기를 최적화 하는 방법이다. 이 방법은 플랜트에 대한 정보를 RBF 신경회로망 제어기 설계시 제공해 줌으로써 학습에 소요되는 노력을 절약할 수 있다는 장점이 있다. 또한 최적화된 RBF 제어기는 등가성을 이용하여 퍼지 시스템으로 역변환 함으로써 최적화된 퍼지 제어규칙을 취득할 수 있다.

제안한 알고리즘의 유용성을 입증하기 위해서 비선형 시스템 제어의 benchmark test로 널리 이용되는 cart-pole 균형제어 문제에 적용하였다. 시뮬레이션 결과 제안한 알고리즘은 기존의 퍼지 제어에 의한 제어결과 제어 성능이 우수함이 입증되었다.

표 1. 설계한 퍼지 제어규칙.

Force		Pole Angle [rad]				
		LL	LS	CE	RS	RL
Angular Velocity [rad/sec]	NL	-30	-27	-22	-15	-5
	NS	-25	-20	-12	-2	7
	ZE	-17	-10	0	10	17
	PS	-7	2	12	20	25
	PL	5	15	22	27	30




그림1. 퍼지 제어기에 의한 제어 응답.




그림 2. RBF 신경회로망 제어기에 의한 제어 응답.