

퍼지-신경망을 이용한 시간지연 공정 시스템에 대한 적용제어 기법

최 중 락, 곽 동 훈, 이 동 익 (국방과학연구소)

Joong-Lack Choi, Dong-Hoon Kwak, Dong-Ik Lee (Agency for Defense Development)

ABSTRACT

We propose an approach to integrating fuzzy logic control with RBF(Radial Basis Function) networks and show how the integrated network can be applied to multivariable self-organizing and self-learning fuzzy controller. Using the hybrid learning algorithm. To investigate its usefulness and performance, this controller is applied to a time-delayed process system. Simulation results show good control performance and fast convergency in hybrid learning method.

Key words : fuzzy logic controller(퍼지제어), Radial basis function network(RBF 신경망), Hybrid learning method(혼합학습)

1. 서 론

퍼지 집합이론은 애매하고 불확실한 정보로부터 유용한 정보를 얻기위한 수학적 이론으로 애매한 정보를 소속함수(Membership function)로 표현하여 숙련된 경험이나 지식기반으로 구성된 제어규칙에 근거해서 논리적 추론을 가능하게 하는 이론으로 1965년 Zadeh[1]에 의해 처음 소개 되었다. 그러나 실제 산업현장에서 복잡한 제어 대상 플랜트는 퍼지 제어 이론을 적용하는데는 다음과 같은 어려운 문제점들이 나타났다.

첫째는 퍼지 제어를 실제 시스템에 구현할 때 숙련된 전문가의 경험이 없을 경우 현실적으로 이러한 제어규칙들을 구축하는 것이 어렵다. 둘째는 제어 규칙수가 많을 경우 실시간 구현시 컴퓨터의 과도한 기억용량과 추론계산시간이 소요된다. 후자의 문제는 고속 병렬 컴퓨터 시스템 및 퍼지추론 컴퓨터 시스템 개발등으로 점차 해결 가능하게 될것이지만 전자의 제어규칙의 구축 문제는 아직도 현실적으로 어려움이 있다.

상기 문제를 해결하기 위해서 본논문에서는 Nie[2] 가 제안한 전진부의 Kohonen 경쟁 학습방법 대신에 입력공간을 최적으로 퍼지 분할하는 퍼지 C-means를 이용함으로써 복잡한 패턴에 대해 보다 양호한 수렴특성을 갖도록 하였으며, 후진부는 반복 학습 알고리즘 대신에 교사신호가 필요하지 않는 모델출력과 플랜트 출력간에 오차를 최소화 하도록 경

사하강법(gradient descent)을 사용한다. 이 경우 입력변화에 대한 출력 변화인 자코비안(Jacobian)이 필요한데 이것을 위해서 비선형 시스템을 근사화 할 수 있는 다층 인식자인 신경망을 온라인으로 적용하였다. 그리고, 제어기의 형태는 모델기준 적용제어로서 제어기의 성능과 시스템 안정 문제를 분리할 수 있는 간접제어 방식을 채택하였다. 끝으로 제안된 방법의 타당성 및 성능을 확인하기 위해 시간지연 비선형 플랜트인 화학공정 시스템에 적용하여 전산 시뮬레이션을 수행하고 결과 분석을 제시한다.

2. 간단화된 퍼지추론

전통적인 퍼지 제어기는 다음의 3단계의 계산 절차, 즉 퍼지화(Fuzzify), 추론(Inference) 및 비퍼지화(Defuzzify) 등의 계산 절차를 수행해야만 된다. Nie[2]는 이러한 3단계중 퍼지화 및 비퍼지화가 필요없는 패턴 정합(Pattern matching)에 의한 추론 방법을 적용하므로써 계산시간을 크게 축소시킨 새로운 퍼지제어 알고리즘을 제시하였다. 일반적으로 다변수 퍼지 제어기가 n 개의 입력 u_i , m 개의 출력 v_k 를 갖는다고 하면 퍼지제어 규칙 R^j 는 다음과 같이 표현된다.

$$R^j: \text{If}(M_{u,1}^j, \delta_{u,1}^j) \text{ and } \dots \text{ and } (M_{u,i}^j, \delta_{u,i}^j) \text{ and } \dots \\ \text{THEN}(M_{v,1}^j, \delta_{v,1}^j) \text{ and } \dots \text{ and } (M_{v,k}^j, \delta_{v,k}^j) \text{ and } \dots$$

(2-1)

단, $i = 1, 2, \dots, n$
 $k = 1, 2, \dots, m$
 $j = 1, 2, \dots, p$

$$A_i^j(u) = (M_{u,i}^j, \delta_{u,i}^j).$$

$$B_k^j(v) = (M_{v,k}^j, \delta_{v,k}^j)$$

M : 소속함수의 중심값, δ : 소속거리
 이때 퍼지추론은 다음과 같이 주어진다.

$$S^j = \bigwedge_{i=1}^n A_i^j(u_i) \quad (2-2)$$

$$A_i^j(u_i) = \exp\left\{-\frac{1}{2} \cdot \left(\frac{M_{u,i}^j - u_i}{\delta_{u,i}^j}\right)^2\right\} \quad (2-3)$$

$$v_k = \frac{\sum_{j=0}^p S^j M_{v,k}^j}{\sum_{j=0}^p S^j} \quad (2-4)$$

이상과 같이 유도된 간단화된 다변수 퍼지제어 알고리즘은 v_k 를 계산할 때 입력 및 출력 데이터가 수치값(Numerical value)이 됨에 따라 퍼지화 및 비퍼지화가 필요 없게 되고 추론 알고리즘이 간단해서 컴퓨터 계산 시간이 크게 단축되는 효과가 있다.

3. RBF (Radial Basis Function) 신경망

3.1 RBF 신경망의 일반특성

RBF 신경망은 그림 3-1과 같으며 임.출력간의 비선형 사상(Nonlinear mapping)으로 근사 식별할 수 있는 범용 근사자(Universal approximator)이다 [3,4]. 즉, 은닉층에서 비선형 결합과 출력층에서 선형결합을 취하므로써 연속사상 $f_k(u) : R^n \rightarrow R^m$ 을 근사화 한다. 수식으로 표현하면 식(3-1)과 같이 정의된다[4].

$$f_k(u) = \sum_{j=0}^N \pi_k^j \phi^j(u) \quad (3-1)$$

단, N : 은닉층의 노드수

$u \in R^{n \times 1}$: 입력벡터

ϕ^j : 은닉층의 j 번째 활성화 함수출력

π_k^j : 출력층의 k 노드와 은닉층의 j 노드간에 연결강도

이상과 같이 정의되는 RBF 신경망의 활성화 함수를 가우시안 함수 형태로 고려하면 식(3-2)와 같이 된다.

$$\phi^j(u) = \exp\left\{-\frac{1}{2} \cdot \frac{\|u - w^j\|^2}{(\sigma^j)^2}\right\} \quad (3-2)$$

단, $\|\cdot\|$: Euclidian norm

여기서, 활성화 함수 ϕ^j 의 국부적 영역은 σ^j 에

의해서 결정되며, Moody[16]가 지적했던 것처럼 국부적 근사화는 빠른 수렴속도를 갖게 되며 근접한 노드들간에 ϕ^j 와 w^j 간에 효과적인 보간(Interpolation)을 얻기 위해서 식(3-1) 대신에 정규화된(Normalized) 응답함수를 고려하면 다음과 같다.

$$\hat{f}_k(u) = \frac{\sum_{j=1}^N \pi_k^j \phi^j(u)}{\sum_{j=1}^N \phi^j(u)} \quad (3-3)$$

그리고, 활성화 함수 ϕ^j 를 입력 u_i 에 대해서 양자화(Quantization)하면 다음과 같다.

$$\begin{aligned} \phi^j(u) &= \bigwedge_{i=1}^n \phi_i^j(u_i) \\ &= \bigwedge_{i=1}^n \exp\left\{-\frac{1}{2} \cdot \frac{|u_i - w_i^j|^2}{(\sigma^j)^2}\right\} \end{aligned} \quad (3-4)$$

단, \wedge : min 연산자




그림 3-1 RBF 신경망 모델구조
 Fig. 3-1 Structure of a Radial Basis Function Neural Network

3.2 퍼지추론과 RBF 신경망의 등가관계

간단화된 다변수 퍼지 제어 알고리즘 관계식(2-4) 및 (2-6)과 RBF 신경망 관계식(3-3) 및 (3-4)로부터 표 3-1과 같이 퍼지 제어기와 신경망간에 등가관계를 얻을 수 있다[5]. 퍼지 제어의 전건부 ($M_{u,i}^j, \delta_{u,i}^j$)는 RBF 신경망의 입력층과 은닉층간에 연결강도 (w^j, σ^j)에 해당되고, 후건부인 $M_{v,k}^j$ 는 RBF 신경망의 은닉층과 출력층간에 연결강도 π^j 이며, 소속함수 $A_i^j(u_i)$ 는 RBF 신경망의 활성화 함수의 입력 u_i 에 대해 양자화된 $\phi_i^j(u_i)$, 유사성 정도 S^j 는 RBF 신경망의 활성화 함수 ϕ^j 가 된다.

4. 기준모델 추종 퍼지 신경망 제어기 구성

본 논문에서는 간접 방식을 선택하였으며, 퍼지

-RBF 신경망 제어기를 그림4-1과 같이 구성한다. 일반적으로 비선형 이산 시간 다변수 시스템은 다음과 같이 나타낼 수 있다.

$$y(t+1) = f(y(t), \dots, y(t-n_y), v(t), \dots, v(t-m_v)), n_y \geq m_v \quad (4-1)$$

단, $y \in R^{n \times 1}$, $v \in R^{m \times 1}$

여기서, $y(t)$, $v(t)$ 는 각각 시스템 출력과 입력을 나타내며, n_y 및 m_v 는 각각 출력과 입력에 대한 차수를 의미한다. 이러한 시스템에서 $v(t)$ 를 인가할 때 시스템 출력 $y(t+1)$ 와 원하는 출력 $y_d(t+1)$ 간에 오차 E 가 식(4-2)와 같이 0으로 수렴되도록




그림 4-1 퍼지-RBF 신경망 제어기 구성도
Fig.4-1 Block diagram of Fuzzy-RBF Network Controller

퍼지-RBF 신경망의 연결강도 즉, 전건부 w^j , σ^j 및 후건부 π^j 를 학습한다.

$$E = \lim_{t \rightarrow \infty} (y_d(t+1) - y(t+1)) \approx 0 \quad (4-2)$$

본 논문에서는 전건부를 자율학습으로, 후건부를 지도학습으로 구성되는 혼합학습(Hybrid learning) 방법을 적용하였으며 세부 학습절차를 소개하면 다음과 같다.

4.1 전건부의 자율학습(unsupervised learning) 알고리즘

퍼지-RBF 신경망의 전건부 연결강도 w^j 와 뉴런 수 N 을 결정하기 위해 먼저 σ^j 를 고정한다. 그리고, 코호넨의 경쟁학습 알고리즘은 패턴 분류상 K-means 알고리즘에 대응되므로 보다 일반화 되고 수렴성 및 최적분할이 용이한 퍼지 C-means 알고리즘을 이용한다. 즉, 연결강도 w^j 를 조정하기 위해서 다음과 같은 관계식의 U^j (4-3)을 이용한다.

$$U^j = \frac{1}{\sum_{i=1}^N \left(\frac{d^j}{d_i} \right)^{\frac{2}{m-1}}} \quad (4-3)$$

단, $m : [0, \infty]$
 $d^j : \sqrt{(u - w^j(t))^T (u - w^j(t))}$

여기서, U^j 는 폐구간 $[0, 1]$ 에서의 퍼지 소속값으로써 Bezdek[6]에 의해 제시되었으며, N 은 클러스터의 갯수으로써 퍼지 RBF 신경망의 은닉층 노드에 해당되며, U^j 는 입력 $u(t)$ 값의 클러스터 j 에 대한 퍼지 소속값으로 총 합계는 항상 1이 된다. 실제로 적용된 학습 알고리즘은 Kim[7]이 제안한 자율 학습 방법을 다음과 같이 노드수 N 을 자동 탐색하도록 수정하여 적용하였다.

단계 1 초기화

$$\sigma^j(0) = \sigma_0, \quad w^j(0) = \text{랜덤넘버}[-1, +1], \quad \text{이웃 반경 (Neighbourhood :NB)} = N/2, \quad \alpha = 1/d_0, \quad d_0 = 1$$

단계2 정규화된 전체입력 $u(t)$ ($t=1, 2, \dots, T$: 샘플

링 수)와 w^j 간에 거리정보 d^j

$$d^j = \sqrt{[u(t) - w^j(t)]^T [u(t) - w^j(t)]} \quad (4-4)$$

단, $j = 1, 2, \dots, N$

단계 3 거리정보 d^j 에서 최소값의 출력노드 d^{j*} 가 σ_0 보다 크면 노드수를 $N=N+1$ 로, $w^j(0) = [w^j \ u(t)]$ 로 초기화 한 후 단계1로 가고, 그렇지 않으면 단계4로 간다.

단계 4 각각의 클러스터 중심과의 거리 d^j 에 유사성 측정인 퍼지 소속값 U^j 를 식(4-3)과 같이 계산한다. 단, d^{j*} 가 0이면 $U^{j*} = 1$ 이고 나머지는 0으로 한다.

단계 5 w^j 갱신

(i) 최소값의 출력노드 j^* 에서 NB 범위내에 있는 모든 이웃 노드

$$w^j(t+1) = w^j(t) + \alpha \cdot U^j \cdot [u(t) - w^j(t)] \cdot W \quad (4-5) \quad \text{for } j \in \text{NB}$$

단, $\alpha = \frac{1}{d_0}$

$$W = \begin{cases} 2 \text{ or } 5 & \text{for } j^* \text{ node} \\ 1 & \text{other nodes} \end{cases}$$

(ii) 최소값의 출력노드 j^* 에서 NB밖에 있는 이웃노드

$$w^j(t+1) = w^j(t) \text{ for } j \in \text{NB} \quad (4-6)$$

단계 6 학습을 및 이웃반경 조정

$$\text{total_dw} = \sum_{j=1}^N (w^j(t+1) - w^j(t))^T \cdot (w^j(t+1) - w^j(t)) \quad (4-7)$$

여기서 total_dw 가 dw_limit 보다 크면 NB=NB-1로, 그렇지 않으면 $d_0 = d_0 + 1$,

total_dw=0 로 하고 단계 7로 간다.

단계 7 NB=0 이면 stop 하고, 그렇지 않으면 단계 2로 간다.

4.2 후건부의 지도학습(supervised learning) 알고리즘

그림4-1의 기준모델 추종 퍼지-RBF 신경망 제어기의 구성에서 시스템 출력 y 가 기준모델 출력 y_d 를 추종하도록 평가함수를 다음과 같이 정의한다.

$$E_f(t+1) = \frac{1}{2} (y_d(t+1) - y(t+1))^T \cdot (y_d(t+1) - y(t+1)) \quad (4-8)$$

윗식(4-8)에서 기준모델 출력 $y_d(t+1)$ 은 알 수 있는 값이므로 평가함수 E_f 를 최소화 하는 경사 하강법(Gradient descent method)을 이용하여 후건부 연결강도 π^j_k 를 찾을 수 있다. 경사하강법 알고리즘으로부터 모멘텀을 고려한 가중치 갱신은 다음과 같다.

$$\pi^j_k(t+1) = \pi^j_k(t) + \Delta \pi^j_k(t) \quad (4-9a)$$

$$\Delta \pi^j_k(t) = -\alpha \cdot \frac{\partial E_f}{\partial \pi^j_k(t)} + \beta \cdot \Delta \pi^j_k(t-1) \quad (4-9b)$$

여기서, α 는 학습률이고, β 는 모멘텀 계수이다. 연결강도 π^j_k 에 대한 평가함수 E_f 의 미분을 구하면 사슬법칙(Chain rule)에 의해 다음과 같이 계산된다.

$$\begin{aligned} \frac{\partial E_f(t+1)}{\partial \pi^j_k(t)} &= \frac{\partial E_f(t+1)}{\partial y(t+1)} \cdot \frac{\partial y(t+1)}{\partial v(t)} \cdot \frac{\partial v(t)}{\partial \pi^j_k(t)} \\ &= -(y_d(t+1) - y(t+1))^T \cdot \frac{\partial y(t+1)}{\partial v(t)} \cdot \frac{\partial v(t)}{\partial \pi^j_k(t)} \end{aligned} \quad (4-10)$$

식(4-10)에서 $y_d(t+1) - y(t+1)$ 값은 측정 가능한 값이고, $\frac{\partial y(t+1)}{\partial v(t)}$ 는 자코비안(Jacobian) 식별 신경망으로부터 구한다. $\frac{\partial v(t)}{\partial \pi^j_k(t)}$ 는 식(2-7) 또는 식(3-3)으로부터 다음과 같이 계산될 수 있다.

$$\frac{\partial v_k(t)}{\partial \pi^j_k(t)} = \frac{\partial}{\partial \pi^j_k(t)} \left[\frac{\sum_{j=1}^N \pi^j_k \phi^j}{\sum_{j=1}^N \phi^j} \right] \quad (4-11)$$

$$= \begin{cases} \frac{\phi^j}{\sum_{j=1}^N \phi^j} & \text{for } k = k' \\ 0 & \text{for } k \neq k' \end{cases}$$

단, $k = 1, 2, \dots, m$

5. 시뮬레이션 및 결과 고찰

5.1 적응 시스템 모델

그림5-1과 같이 엔진의 배기가스에서 CO_2 를 해수에 의해 CO_2 흡수기(absorber)에서 용해시켜 원하는 수준의 압력으로 유지되도록 제어하는 문제이다. 여기서 디젤엔진 모델은 강한 비선형항이 포함된 열역학적(thermodynamic) 화학공정 시스템으로 고려된다. 이때 CO_2 흡수기의 수학적모델은 시간지연이 있는 1차계 전달함수로 모델링 된다. 제어입력 u 는 해수의 유량(flow rate)를 조절한다.

$$G(s) = \frac{K}{s+a} \cdot e^{-\tau s} \quad (5-1)$$




그림5-1 화학공정 모델의 구조

Fig.5-1 Structure of chemical process model

5.2 시뮬레이션 방법 및 초기치

기준모델은 SPR(Strictly Positive Real) 조건을 만족하도록 하여야 하며, 여기서는 편의상 1로 고려한다. 그리고, 자코비안 계산은 상수로 고려할 수 있지만 식별신경망을 은-라인으로 제어기에 적용하여 BP 학습 방법에 의해 시스템 변화에 적응되도록 하였다. 퍼지-신경망 제어기의 관련 초기치는 표5-1과 같다.

표5-1 시스템 모델과 초기조건
Table 5-1 Plant model and initial conditions


parameter	value	parameter	value
τ_d	1.5	α	0.001
a	1	β	0.01
K	1	W	1
dw_limit	0.01	σ	0.3
NB	1		

5.3 시뮬레이션 결과 및 분석


기준입력은 크기 1의 단위계단으로 하여 학습을 수행하였다. 시뮬레이션 결과는 그림5-2와 같으며

RBF(Radial Basis Function) 신경망을 이용하여 혼합 학습을 적용하였기 때문에 iteration 마다 학습속도가 매우 빠르게 나타났다.


이상의 시뮬레이션 결과로부터 본논문에서 제안한 퍼지-RBF 신경망 제어기에서 퍼지 C-means 개념에 기본된 전건부의 자율학습 알고리즘과 주어진 모델에 플랜트 출력이 추종하도록 경사하강법에 기본되는 후건부의 지도학습 알고리즘으로 구성되어지는 온-라인 혼합학습 알고리즘이 비선형 시간지연 시스템에 매우 효과적으로 적용될 수 있음을 확인하였다.




(a) 5 iteration



(b) 20 iteration



(c) Node 수



(d) 학습오차

그림5-2 시뮬레이션 결과

Fig.5-2 Simulation results

6. 결론

본 논문에서는 SISO 및 MIMO 비선형 시스템에 효과적으로 적용될 수 있는 기준모델 추종형 퍼지-RBF 신경망 제어기설계와 학습 알고리즘에 대하여 다음과 같은 결과를 얻었다.

- 1) 제안된 퍼지-RBF 신경망 제어기는 퍼지 제어기의 전건부에서 입력 패턴에 대해 최적의 퍼지 분할로 수렴하는 퍼지 C-means 알고리즘에 기본된 자율학습과 후건부에서 기준모델 출력과 플랜트 출력간 오차가 최소화 되도록 경사하강법에 기본된 지도학습으로 구성된 혼합학습 방법을 적용함으로써 학습속도와 수렴특성을 개선시켰다.
- 2) 제안된 제어 알고리즘의 타당성과 유용성을 분석하기 위하여 시간지연이 있고, 강한 비선형성을 갖는 화학공정 시스템에 적용한 결과 양호한 수렴특성과 제어성능을 보여준다.

참고문헌

- [1] L.A. Zadeh, "Fuzzy Sets", Information and Control, Vol.8, pp.338-353, 1965
- [2] J. Nie, "A Class of New Fuzzy Control Algorithms", Proc. IEEE Int. Confr. Control and Appli., Israel, pp.1-2, 1989
- [3] J. Moody and C.J. Darken, "Fast Learning Networks of Locally-Tuned Processing Units", Neural Computation, Vol.1, pp.281-294, 1989
- [4] T. Poggio and F. Girosi, "Networks for Approximation and Learning", Proc. IEEE, Vol.78, pp.1481-1497, 1990
- [5] J.S.R. Jang and C.T. Sun, "Functional Equivalence Between Radial Basis Function Networks and Fuzzy Inference Systems", IEEE Trans. on Neural Networks, Vol.4, No.1, pp.156-159, 1993
- [6] J.C. Bezdek, Pattern Recognition with Fuzzy Objective Function Algorithms, Plenum Press, New York, 1981
- [7] D.S. Kim and T.L. Huntsberger, "Fuzzy Neural Network Pattern Classifier", Korea Fuzzy Mathematics and System Society, Vol.1, No.1, pp.4-19, 1991