

조건부적인 퍼지 클러스터링을 이용한
온-라인 적응 뉴로-퍼지 제어

신동철*, 박근창, 전병석, 김종근, 유정웅
충북대학교 전기공학과 대학원

On-line Adaptive Neuro-Fuzzy Control
using Conditional Fuzzy Clustering

D. C. Shin, K. C. Kwak, B. S. Jeun, J. G. Kim, J. W. Ryu
Dept. of Electrical Engineering, Chungbuk National University

Abstract - The main idea of the proposed neuro-fuzzy system is conditional clustering whose main objective is to develop clusters preserving homogeneity of the clustered patterns with regard to their similarity in the input space as well as their respective values assumed in the output space. In the proposed neuro-fuzzy system, the structure identification is used with conditional fuzzy clustering. the parameter identification carried out by the hybrid learning scheme using back-propagation and total least squares.

1. 서 론

퍼지 기법은 정량적으로 표현하기 힘든 전문가의 경험적 지식을 소속함수와 퍼지 규칙 베이스의 형태로 구성하여 효과적으로 시스템을 묘사할 수 있는 특성을 갖고 있다[1]. 또한 신경회로망은 학습능력을 가지고 있어서 시스템 구성에 유연성이 크며 병렬처리능력과 결합극복 능력에 우수함을 나타내고 있어[2] 퍼지 이론과 신경회로망의 장점을 융합한 뉴로-퍼지 제어시스템이 여러 분야에서 활발히 연구되고 있다.

이러한 뉴로-퍼지 제어 시스템의 대표적인 예로 ANFIS(Adaptive Neuro-Fuzzy Inference System)가 있다[3]. ANFIS의 구성으로 구조 식별은 입력공간 분할에 의한 퍼지 규칙과 소속함수 수, 전제부 및 결론부 형태 결정에 관련되고 파라미터 식별은 전제부 및 결론부 시스템 파라미터 조정에 관련된다. 그러나 ANFIS는 입력공간의 증가에 따른 계산량의 급증과 규칙의 수가 지수함수적으로 증가하는 문제점을 가지고 있다.

최근에 Pedryz는 조건부적인 퍼지 클러스터링을 이용하여 퍼지시스템과 동등성을 가지는 RBF(Radial Basis Function) 네트워크에 적용하여 그 타당성을 증명하였다[4]. 따라서 본 논문에서 구조 식별은 출력 패턴의 성질을 고려한 클러스터 중심을 추정하는 조건부적인 퍼지 클러스터링을 이용하여 퍼지 규칙과 소속함수를 생성하도록 한다[5]. 파라미터 식별은 역전파 알고리즘과 TLS(Total Least Square)[6]를 결합한 하이브리드 학습규칙에 의해 실행하는 새로운 뉴로-퍼지 추론 시스템의 구축을 제안한다. 시뮬레이션으로 프로세서 제어인 목욕물 온도 제어[7][8][9]를 다루어 제안된 온-라인 적응 뉴로-퍼지 제어기의 유용성을 설명한다.

2. ANFIS의 구조

두개의 퍼지 if-then 규칙을 갖는 TSK (Takagi-Sugeno-Kang) 형태의 추론 시스템은 다음과 같다[3].

$$R^1 : \text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1x + q_1y + r_1$$

$$R^2 : \text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f_2 = p_2x + q_2y + r_2 \quad (1)$$

여기서, x 와 y 는 입력이고 A_i 와 B_i 는 언어변수, $p_i, q_i,$

r_i 는 결론부 파라미터이다. 위와 같은 규칙을 가지는 ANFIS의 구조는 그림 1과 같이 나타낼 수 있다.

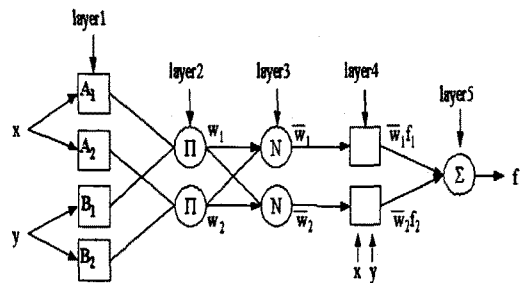


그림 1. ANFIS의 구조

퍼지 모델의 출력과 원하는 출력 사이의 오차를 최소화하기 위해 전향경로에서 전제부 파라미터가 고정되고, LSE(Least Squares Estimate)로 결론부 파라미터가 조정된다. 후향경로에서는 역전파 알고리즘으로 전제부 파라미터가 조정된다. 파라미터 학습 알고리즘은 출력오차로 나타내는 목적함수를 최소화하며 그 목적함수는 다음과 같다.

$$E = \frac{1}{2} (y^* - y_d)^2$$

$$= \frac{1}{2} \left[\frac{\sum_{i=1}^2 (\mu_{A_i}(x) \cdot \mu_{B_i}(x)) f_i}{\sum_{i=1}^2 (\mu_{A_i}(x) \cdot \mu_{B_i}(x))} - y_d \right]^2 \quad (2)$$

여기서, y_d 는 입력에 대해 원하는 데이터 출력 값이고 y^* 는 퍼지 모델의 출력 값이다. 결론부 파라미터가 정의 되면 목적함수 E 는 전제부 파라미터로 나타낼 수 있다.

ANFIS는 입력공간을 그리드 분할하기 때문에 규칙의 수가 지수함수적으로 증가하게 된다. 따라서 데이터 수보다 추정해야 하는 파라미터 수가 많아지는 과대적합(Over-fitting) 문제를 발생시키게 된다.

3. 제안된 뉴로-퍼지 시스템


제안된 뉴로-퍼지 시스템은 ANFIS의 단점을 개선하고자 조건부적인 퍼지 클러스터링에 의한 구조식별을 수행하고 역전파 알고리즘과 TLS를 이용한 하이브리드 학습을 통해 파라미터 식별을 수행한다[5][6]. 구조 식별에서 대표적인 FCM 클러스터링 방법의 목적함수는 다음과 같다.

$$J = \sum_{i=1}^n \sum_{k=1}^m u_{ik}^m \|x_k - c_i\|^2 \quad (3)$$

FCM 클러스터링은 각각의 데이터와 클러스터 중심 사이의 직선 거리로 나타내는 목적함수가 최소화되도록 클러스터 중심을 추정하는 반복적인 알고리즘이다[7]. 이 방법은 입력 데이터만을 고려하므로 다른 패턴의 성질을 가지는 출력 데이터가 같이 분류될 수 있다. 따라서 출력 패턴의 성질을 고려하는 Pedrycz의 조건부적인 퍼지 클러스터링을 이용한 구조식별을 수행하도록 한다.

3.1 조건부적인 퍼지 클러스터링

그림 2는 입력공간 $x = [x_1 \ x_2]$ 에서 출력 데이터의 두 패턴(흑, 백)에 FCM과 조건부적인 퍼지 클러스터링의 클러스터 추정을 보여주고 있다. 그림 2(a)는 단지 클러스터 중심과 데이터 사이의 직선 거리를 이용해 두 개의 클러스터를 형성한다. 반면에 그림 2(b)는 출력 패턴의 같은 성질을 유지하기 위해 세 개의 클러스터로 형성한다. 그림 2에서 알 수 있듯이 후자의 방법으로 얻어진 클러스터는 전자의 방법보다 각각의 클러스터가 포함하는 데이터 사이에 보다 큰 유사성을 볼 수 있다[5].



(a) FCM 클러스터 (b) 조건부적인 퍼지 클러스터
그림 2. FCM과 조건부적인 퍼지 클러스터링의 클러스터 비교

이와 같이 유용한 출력 특성을 고려하기 위해 $(n+1)$ 차의 입력력 벡터 공간으로 확장한다. 입력력 벡터 확장 공간에서 출력 데이터를 고려한 확장 목적 함수는 다음과 같다.

$$\tilde{x}_k = [x_k \ y_k]$$

$$J = \sum_{i=1}^N \sum_{k=1}^M u_{ik}^2 \|x_k - c_i\|^2 + \sum_{i=1}^N \sum_{k=1}^M u_{ik}^2 \|y_k - c_i\|^2 \quad (4)$$

조건부적인 퍼지 클러스터링 알고리즘은 다음과 같다.

[단계 1] 클러스터 수 c ($2 \leq c \leq N$)와 가중치 m ($1 < m < \infty$)을 정의한다.

[단계 2] 0과 1사이의 임의의 값으로 소속함수 행렬 $U([u_{ij}])$ 의 초기치 $U^{(0)}$ 를 설정하고 클러스터 c_1, c_2, \dots, c_c 의 값을 초기화한다. 소속도 행렬에 의한 조건을 수정하고 다음 집합을 정의한다.

$$\sum_{i=1}^N u_{ik} = f_k, \quad k=1 \dots N, \quad i=1 \dots c$$

$$U(f) = \left\{ u_{ik} \in [0, 1] \mid \sum_{i=1}^N u_{ik} = f_k \forall k \text{ and } 0 < \sum_{i=1}^N u_{ik} < N \forall i \right\} \quad (5)$$

[단계 3] 각각의 클러스터 중심 $c_i^{(b)}$ 를 계산한다.

$$u_{ik} = \frac{f_k}{\sum_{i=1}^N \left(\frac{\|x_k - c_i\|}{\|x_k - c_j\|} \right)^{2/(m-1)}}, \quad c_i = \frac{\sum_{k=1}^M u_{ik}^m x_k}{\sum_{k=1}^M u_{ik}^m} \quad (6)$$

[단계 4] $c^{(b)}$ 와 목적함수를 이용하여 다음 목적함수 $J^{(b+1)}$ 을 구하고 역치 ϵ ($\epsilon > 0$)를 정의하여 $\|J^{(b)} - J^{(b+1)}\| \leq \epsilon$ 이 만족할 때 까지 [단계 3]~[단계 4]를 반복한다.

3.2 파라미터 식별

파라미터 식별은 전체부 소속함수와 결론부의 선형 계수의 시스템 파라미터와 관련된다. 전체부 파라미터는 기존의 역전파 알고리즘을 이용하고 결론부 파라미터는 TLS를 사용한다. 다음 행렬식을 고려하자.

$$Ax = B$$

전형적인 LSE 문제에서는 모든 오차가 관측벡터 B 에만 한정되어 있다는 가정이 필요하다. 그러나 이러한 가정은 시스템 모델링 오차, 표본화오차, 계측기기의 오차 등으로 인해 성립하지 않고 데이터 행렬 A 에도 오차가 포함되는 경우가 대부분이다. 이러한 생각을 관측벡터뿐만 아니라 데이터 행렬에도 적용하여 다음과 같이 확장한 것이 TLS이다[6].

[단계 1] $B \in \mathbb{R}^{m \times n}$, $E \in \mathbb{R}^{m \times n}$, $R \in \mathbb{R}^{m \times k}$ 이고 $D = \text{diag}(d_1, \dots, d_m)$, $T = \text{diag}(t_1, \dots, t_{n+k})$ 는 정칙행렬이다.

$$\min_{\text{rang}(B+R) \in \text{rang}(A+E)} \|D[E, R]T\|_F \quad (7)$$

여기서, $m \geq n+k$ 라 가정하면 C 는 다음과 같다.

$$C = D[A, B]T = \begin{bmatrix} C_1 & C_2 \\ n & k \end{bmatrix} \quad (8)$$

[단계 2] 특이값 분해(Singular Value Decomposition) $U^T C V = \text{diag}(\sigma_1, \dots, \sigma_{n+k}) = \Sigma$ 에서 U, V 와 Σ 는 다음과 같이 얻는다.

$$U = \begin{bmatrix} U_1 & U_2 \\ n & k \end{bmatrix}, \quad V = \begin{bmatrix} V_{11} & V_{12} \\ V_{21} & V_{22} \\ n & k \end{bmatrix}, \quad \Sigma = \begin{bmatrix} \sum_1 & 0 \\ 0 & \sum_2 \\ n & k \end{bmatrix} \quad (9)$$

[단계 3] $T_1 = \text{diag}(t_1, \dots, t_n)$ 이고 $T_2 = \text{diag}(t_{n+1}, \dots, t_{n+k})$ 이면 $(A+E_0)X = (B+R_0)$ 에 유일 해는 다음과 같다.

$$X_{TLS} = -T_1 V_{12} V_{22}^{-1} T_2^{-1} \quad (10)$$

4. 시뮬레이션 및 결과

조건부적인 퍼지 클러스터링을 이용한 온-라인 뉴로-퍼지 시스템의 성능을 입증하기 위해 목욕물 온도제어 시스템에 적용한다. 그림 3은 n 이 1일 때, 온-라인 학습에 대한 블록 다이어그램이다.




그림 3. 온-라인 학습에 대한 블록 다이어그램

여기서, z^{-1} 는 i 만큼의 지연을 나타낸다. 시변 시스템을 다루기 위한 온-라인 적응 모드에서 제어 반응은 매 단계 온-라인 학습이 발생하는 동안 매 n 번의 단계를 만든다. 제어할 욕조 플랜트는 다음과 같다.

$$y(k+1) = a(T_s)y(k) + \frac{b(T_s)}{1 + e^{0.5\lambda(k) - \gamma}} u(k) + [1 - a(T_s)]Y_0 \quad (11)$$

여기서, $a(T_s) = e^{-\sigma T_s}$, $b(T_s) = (\beta/\alpha)(1 - e^{-\sigma T_s})$ 이고 플랜트의 파라미터는 $\alpha = 1.00151e^{-4}$, $\beta = 8.67973e^{-3}$, $\gamma = 40$, $Y_0 = 25^\circ\text{C}$ 로 고정된다. 플랜트 입력 $U(k)$ 은 0과 5 볼트 사이로 제한되고 샘플링 시간 T_s 는 60초이다. 가능한 기준 신호에 따라 물 온도를 제어할 온-라인 적응 뉴로-퍼지 제어를 설계하기 위해 기준 신호는 $0 \leq t \leq 40$ 분에 35° , $40 \leq t \leq 80$ 분에 50° , $80 \leq t \leq 120$ 분에 65° , $120 \leq t \leq 180$ 분에 80° 이다.

시스템을 학습하기 위한 학습 데이터는 선택 입력 $u(k)$ 은 0과 5 사이의 불규칙 분포 랜덤수로 정의한다. $[y(k), y(k+1): u(k)]$ 형태의 50개 학습 데이터 쌍을 찾기 위해 식 (11)을 사용한다. 그림 4는 학습 데이터와 클러스터링의 분포를 나타낸다. 이 경우 조건부적인 퍼지 클러스터링에 기초로 생성된 규칙수는 6이다.




그림 4. 학습 데이터(o)와 클러스터(*)의 분포




그림 5. 오프-라인 학습에 시뮬레이션 결과 실제 출력(-)과 추론 출력(o)




그림 6. 온-라인 학습에 시뮬레이션 결과 원하는 온도(·)와 제어된 온도(-)

그림 5는 실제 출력과 추론출력의 학습 결과를 보인다. 그러나 오프-라인 학습에 기초한 시뮬레이션 결과가 좋은 성능을 가질지라도 시변 동적 플랜트를 가지는 욕조 제어 시스템은 불안정할 수도 있다. 따라서, 플랜트에 대한 제어기(Working Controller)를 찾기 위해 오프-라인 학습을 사용하고 제어기의 미세 조정에 온-라인 학습의 사용이 필요하다. 온-라인 학습에서 사용된 파라미터는 $\eta_c = \eta_o = 0.1$ 이고 결과 파라미터는 $\lambda = 0.99$ 인 RLSE로 조정한다. 제어결과는 그림 6에서 보이고 온-라인 학습 동안 결론부 파라미터 변동은 그림 7에서 보인다.




그림 7. 온-라인 학습시 결론부 파라미터 변화

5. 결 론

기존의 퍼지 클러스터링 방법에서 초기 클러스터의 위치에 따른 영향이 큰 단점을 조건부적인 퍼지 클러스터링을 통해 개선하였다. 또한 관측벡터 뿐만 아니라 행렬 A의 오차도 고려하여 오프-라인에서 욕조 제어 시스템의 뉴로-퍼지 모델링을 구축하였고, 온-라인으로 전제부 및 결론부 파라미터를 미세 조정하였다. 시뮬레이션 결과 시변 시스템에서도 좋은 성능을 보였다.

(참 고 문 헌)

- [1] M. Sugeno, T. Yasukawa, "A Fuzzy-logic based Approach to Qualitative Modeling", IEEE Trans. Fuzzy Systems, Vol. 1, No. 1, pp. 7-31, 1993.
- [2] S. Haykin, Neural Networks, Macmillan Inc., 1994.
- [3] J. S. R. Jang, "ANFIS : Adaptive-Network based Fuzzy Inference System", IEEE Trans. System Man Cybernetics, Vol. 23, No. 3, pp. 665-685, 1993.
- [4] J. Jang, C. T. Sun, "Functional equivalence between radial basis function networks and fuzzy inference systems", IEEE Trans. Neural Networks, Vol. 4, pp. 156-159, 1993.
- [5] W. Pedrycz, "Conditional fuzzy Clustering in the design of Radial Basis function Neural Networks", Proc. IEEE Trans. on Neural Networks, Vol. 9, pp. 601-612, 1998.
- [6] G. H. Golub, C. F. Van Loan, Matrix Computations, The Johns Hopkins University Press., no. 3, 1996.
- [7] C. T. Lin, C. S. G. Lee, "Neural Fuzzy Systems", Prentice Hall, 1996.
- [8] J. Tanomaru, S. Omatu, "Process control by on-line trained neural controllers", IEEE Trans. Indust. Electronics, Vol. 39, pp. 511-521, 1992.
- [9] C. F. Juang, C. T. Lin, "An on-line self-constructing neural fuzzy inference network and its applications", IEEE Trans. on Fuzzy Systems, Vol. 6, No. 1, pp. 12-32, 1998.