

퍼지 신경망을 적용한 공정제어에 응답특성에 관한 연구

김종대, 이광대
한국전력공사 전력연구원 I&C그룹

The study on the Response Characteristics of Process Control using Fuzzy Neural Networks

Kim Jong Dae, Lee Kwang Dae
KEPCO Korea Electric Power Research Institute I&C Group

Abstract - 신경망을 이용한 적응제어는 학습능력에 따라 외란작용에 스스로 대처하고, 정밀한 제어가 가능하지만 학습파라미터가 최적화되기 전에는 불안정한 제어 응답을 보인다. 퍼지논리는 전문가의 경험을 논리화한 것으로 제어특성은 좋으나, 외란에 대한 적응력이 부족하여 계속적인 오프셋이 발생할 수 있다. 따라서, 퍼지와 신경망을 시스템의 동특성에 따라 혼용한 제어방식을 제시하고, 시뮬레이션으로 시간지연이 있는 CSTR의 온도 및 비선형 공정인 pH 중화공정에 적용하여 단순신경망 제어어보다 개선된 제어응답 특성을 얻었다.

1. 서 론

일반적으로 화학공정은 물리, 화학적 현상이 매우 다양하게 발생하고, 대부분 비선형적이며 예측이 어렵다. 이러한 이유로, 일반적인 선형제어기법으로는 양호한 제어결과를 얻기 힘들었다. 그래서, 최근에는 다양한 비선형제어기법들이 제시되고 있다. 그 중, 모델예측제어의 경우는 공정모델을 필요로 하는데, 이는 공정의 현상을 정확히 규명하고, 수치적으로 표현해야하는데 많은 노력과 시간이 들며, 공정의 운전주기가 길어질수록 신뢰도가 떨어지는 단점과 갑작스런 시스템의 조건변화에 적응력이 부족하다. 이러한 문제점을 해결하기 위해서, 수치적인 계산이 필요없고, 과거의 조업데이터만을 학습시켜 공정을 모델화할 수 있도록 하는 인공신경망(Artificial Neural Networks:ANNs)을 이용하고자하는 연구가 활발하다[1-3]. 근래에는 오프라인 학습 없이 온라인으로 모델링과 제어를 동시에 하려는 적응제어시스템에 대한 연구결과들이 많이 보고되고 있다[4,5]. 그러나, 신경망의 학습변수에 대한 최적화가 어렵고, 학습데이터의 부족으로 학습이 완전하지 않아서 실제실험결과에서는 초기제어응답에서 큰 최대오버슈트와 진동이 지속적으로 발생하여 불안정한 경우가 많았다. 또한, 공정이 시간지연이 크거나, 노이즈가 심하게 발생하는 경우는 공정의 동적거동을 정확하게 묘사하기 힘들어 온라인 제어가 어려웠다. 초기에 임의로 설정한 신경망의 학습변수는 공정에 따라서 신경망 제어기의 출력이 포화상태에 이르러 적절한 제어동작을 하지 못함으로써 불안정한 응답을 초래할 수 있다.

본 연구에서는 신경망 적응제어의 응답특성을 학습변수에 따라 분석하고, 제한한 퍼지-신경망을 이용하여 공정의 응답특성 및 신경망의 출력변화량에 따라서 유연한 학습변수를 갖도록 하여 시간지연과 비선형성이 있는 화학공정에서 보다 개선된 응답특성이 갖는 시스템을 설계하고, 효용성을 검토하였다.

2. 이 론

2.1 퍼지신경망 제어 시스템의 설계

본 연구에서 적용한 제어시스템은 시스템의 동적거동을 실시간으로 묘사하고 예측할 수 있는 신경망 공정모델과 신경망 제어기로 구성되어 있는 간접적응제어구조

를 갖는다. 신경망 모델은 공정의 실제 출력값과 비교하여 그 오차를 계속해서 줄여가면서 실제 공정을 묘사할 수 있는 공정모델 역할을 한다. 신경망 모델은 입력층-은닉층-출력층의 뉴런수가 6-10-1인 3층의 다층구조이며 입력층의 각 노드에는 현재와 과거의 공정의 실제 출력데이터가 입력된다. 그림 1은 신경망 모델의 구조를 보이고 있다. 여기서, W_{ij} 와 W_{jk} 는 각 층사이의 가중치를 나타낸다. 출력층에서 근사 공정값이 출력되며, 이 값은 실제 공정값과 비교되어 그 오차를 줄이도록 오류역전파 학습알고리즘(backpropagation learning algorithm)에 의해 그 오차를 계속적으로 줄여간다. 공정의 동적거동은 system jacobian($\partial y/\partial u$)로 나타내며 신경망 모델이 실제 공정을 잘 근사한다면 식(1)의 좌변과 같다.

$$\frac{\partial y'(t+1)}{\partial u(t)} = \frac{\partial y'(t+1)}{\partial O_j} \cdot \frac{\partial O_j}{\partial net_j} \cdot \frac{\partial net_j}{\partial u(t)} \quad (1)$$

$$= \sum_j W_{jk} O_k (1 - O_k) O_j (1 - O_j) W_{ji}$$

여기서, net 은 뉴런에 연결되는 이전 층의 출력과 가중치의 곱의 총합이다. 우변처럼 미분연쇄법칙에 의해 풀어 쓸 수 있고, 각 미분식들은 다시 신경망 모델의 출력값(O_j, O_k), 가중치로 바꾸어 정리하여 나타낼 수 있다. 공정 동적 거동은 매 샘플링주기에 따라 신경망 제어기에 피드백되어 진다.




그림 1 공정모델에 위한 신경망

신경망 제어기도 신경망 모델과 3층 구조로 시스템의 과거의 입, 출력 데이터와 설정값에 대한 정보를 입력받아서 제어량을 출력하게 된다. 신경망의 학습은 제어오차를 최소화하도록 신경망 모델과 마찬가지로 오류역전파알고리즘을 이용하였다.

신경망 제어기의 목적함수는 다음과 같다.

$$E_c = \frac{1}{2} \sum r(t+1) - y'(t+1)^2 \quad (2)$$

여기서, $r(t+1)$ 은 설정값, $y'(t+1)$ 은 신경망 모델의 근사값이다.

신경망 제어기에서 오차를 최소화하기 위해 역전파될 때의 오차함수는 다음과 같다.

$$\delta_k = - \frac{\partial E_c}{\partial net} \quad (3)$$

신경망 제어기에서 공정의 동적거동을 나타낼 수 있도록 하기 위해 식(3)을 미분연쇄법칙으로 풀어 나타내면 다음과 같다.

$$\begin{aligned} - \frac{\partial E_c}{\partial net} &= - \frac{\partial E_c}{\partial y'} \cdot \frac{\partial y'}{\partial u} \cdot \frac{\partial u}{\partial net} \\ &= (y' - r) \cdot \frac{\partial y'}{\partial u} \cdot f'(net) \end{aligned} \quad (4)$$

신경망제어기에서 중간층과 출력층의 각 뉴런들의 활성화함수는 비선형 근사에 적당한 log sigmoid함수를 사용하였다.

$$f(net) = \frac{1}{1 + e^{-a \cdot net}} \quad (5)$$

여기서, a 는 활성화함수의 기울기로 0과 1사이의 값을 갖는다.

오류역전 학습알고리즘에 의한 각 층의 가중치의 변화량은 다음 식을 따른다.

$$\Delta W_{jk} = \eta \delta_k O_j \quad (6)$$

$$\Delta W_{ji} = \eta \delta_i O_j \quad (7)$$

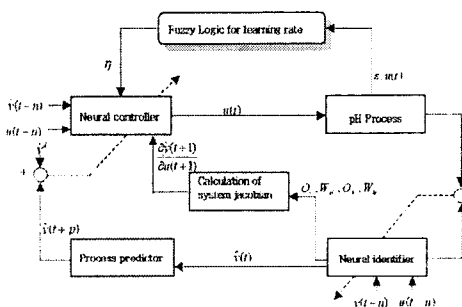


그림 2 퍼지 신경망제어시스템의 구조

화학공정은 시간지연이 크고, 비선형적인 공정이 많기 때문에 제어 출력의 변화량도 공정의 동특성에 맞추어야 한다. 실시간 적응제어인 경우 초기 학습데이터의 부족과 학습변수의 최적화가 되지 않으므로써 비선형 공정인 경우 신경망 제어기의 출력이 초기에 포화상태에 빠질 수 있다.

이것은 제어응답에서 overshoot와 진동현상을 일으키는 원인이 된다. 이를 개선하기 위해 학습변수인 학습율과 활성화함수의 기울기에 퍼지 논리를 도입하여 적절히 변화를 주도하도록 하였다. 퍼지 논리의 조건부 변수는 제어출력량과 공정변수이고, 결론부의 변수는 학습변수이다. 소속함수(Membership function)는 삼각형 함수를 사용하

였고 비퍼지화(Defuzzification)는 무게중심법(Center of Gravity)를 사용하였다.

2.2 CASE 1: 연속교반탱크가열기 모델

연속교반탱크가열기(이하 CSTH)에 대한 모델식은 다음과 같다.

$$F_i = F_o \quad (8)$$

$$\frac{dT}{dt} = \frac{F_i T_i - F_o T}{V} + \frac{Q}{\rho C_p} \quad (9)$$

2.3 CASE 2: pH 중화공정모델

pH 중화공정은 비선형성이 강한 대표적인 공정이며, McAvoy(6)에 의해 모델식이 제시된 CSTR에 가성소다(NaOH)를 초산(CH₃COOH)으로 중화시키는 공정을 선택하였다. CSTR 내에서의 초산과 가성소다의 물질이동식과 이온반응식에 의해 다음과 같이 수소이온에 대한 다항식으로 나타낼 수 있다.

$$\begin{aligned} [H^+]^3 + (K_a + x_b)[H^+]^2 \\ + \{K_a(x_b - x_a) - K_w\}[H^+] - K_w K_a = 0 \end{aligned} \quad (10)$$

여기서, x_a 와 x_b 는 산과 염기의 농도, K_a 와 K_w 는 산과 물의 이온화상수이다. 그리고, $pH = -\log_{10}[H^+]$ 로 정의되므로 식(10)으로부터 산/염기의 농도에 따라서 pH를 구할 수 있다. CSTR내에서 혼합액의 체적은 250 ml이고, 항상 25°C를 유지하며, 초산 유속은 0.135 ml/sec로 일정하게 공급되고, 조절변수는 가성소다의 유속이며 최대 0.2 ml/sec까지 조절된다. 산/염기의 농도는 모두 0.001 M이다.

3. 결과 및 고찰

먼저, CSTH에서 설정점 변화에 대한 온도제어 응답 특성을 알아보았다. 그림 3과 같이 첫 번째 설정점의 계단변화에서 최대오버슈트가 크게 나타남을 알 수 있다.




그림 3 일반적인 신경망 적응제어의 응답

학습이 부족하고, 가중치가 최적화되지 않는 초기 설정값에 대한 제어응답은 오버슈트가 커서 응답 특성이 좋지 않다. 그러나, 설정점 계단변화를 반복할 수록 응답 특성이 양호해지고 있다.

그림 4는 신경망 제어기에서 학습속도를 결정하는 학습율을 0.1에서 1까지 다양하게 변화시켰을 때 나타나는 응답특성을 보이고 있다.

이와 같이 오버슈트가 크게 발생하는 이유는 활성화함수의 상위 포화상태에 머물러 있는 시간이 길어지기 때문이다. 큰 (-)오차가 발생함에도 불구하고 고정된 학습율

로 인하여 포화상태를 빠져 나오는 데 많은 학습시간이 필요하였다. 이런 현상은 학습율을 크게 할 수록 상위 포화상태에 도달하는 시간이 빨라져서 응답시간은 짧아 지지만, 제어량이 신경망 활성화함수의 선형구간으로 회복 되는 시간은 길어지기 때문이다.




그림 4 학습율에 따른 신경망 적응제어의 응답




그림 5 신경망 제어와 퍼지신경망 제어에 대한 온도응답

그림 5는 일반적인 신경망 적응제어와 퍼지 신경망 제어의 응답을 비교하였다. 전반적으로 일반적인 신경망을 이용할 경우는 오버슈트가 발생한 반면, 신경망의 학습율에 퍼지논리를 적용하여 조절한 오버슈트가 발생하지 않은 개선된 제어응답을 보였다.

다음은 pH 증화공정에서 일반적인 신경망 제어와 퍼지 신경망제어의 응답을 검토하였다.




그림 6 신경망 적응제어의 pH 응답

0.001M의 초산올 가성소다로 적정할 때의 모델식으로 부터 시뮬레이션결과 산/염기의 농도가 같아지는 적정점은 pH 8부근이다. 이 설정점은 외란에 매우 민감해서, 제어가 어렵다. 일반적인 신경망 적응제어를 pH제어에 적용할 경우는 그림 6처럼 큰 오버슈트와 진동이 계속 되어 설정점에 수렴하는데 상당한 시간이 필요하다. 그러나, 퍼지신경망을 이용한 경우에는 그림 7처럼 진동이 거의 감소되고 응답시간이 감소되는 양호한 특성을 얻을 수 있었다.




그림 7 퍼지 신경망 제어의 pH 응답

4. 결론

일반적인 신경망 적응제어시스템에서 신경망 제어기의 학습율에 퍼지 논리를 적용한 퍼지신경망에 대한 제어응답을 고찰한 결과 퍼지신경망 제어의 경우 시간지연이 존재하는 온도제어와 비선형성이 강한 pH 증화공정에서 초기 오버슈트가 크게 감소하고, 진동현상이 줄어들면서 전체적으로 응답시간이 감소하였다. 간단한 형태의 퍼지 논리를 이용하여 학습변수를 조절하는 퍼지신경망 제어는 신경망 제어응답을 개선하는데 효과가 있음을 확인하였다.

[참 고 문 헌]

- [1] Bhat, N.; McAvoy, T. J., "Use of neural nets for dynamic modeling and control of chemical process systems". *Comput. Chem. Eng.* 14(4/5), 573, 1990.
- [2] Ungar L. H. B. A. Powell and S. N. Kamens, "Adaptive networks for fault diagnosis and process control." *Comp. And Chem. Eng.*, 14, pp. 561-572, 1990.
- [3] Song, J. J.; Par, S., "Neural Model Predictive Control for Nonlinear Chemical Processes". *J. Chem. Eng. Jpn.* 26(4), 347, 1993.
- [4] Matsumura, S.; Omatu, S. Higasa, H. "Improvement of speed control performance using PID type neurocontroller in an electric vehicle system." *Proc. IEEE Int. Conf. Neural Networks*, 4, 2649-2654, 1994
- [5] Tan, Y.; Cauwenbergh, A., "Nonlinear One-step-ahead Control Using Neural Networks: Control Strategy and Stability Design". 32(12), pp. 1701-1706, 1996.
- [6] McAvoy, T. J.; Hsu, E.; Lowenthal, S., "Dynamics of pH in Controlled stirred tank reactor". *Ind. Eng. Chem. Process Des. Dev.* 11, pp. 68-70, 1972.