

GPC를 사용한 선형화 신경 제어구조

김석준, 박선원
한국과학기술원 화학공학과

Neural Linearizing Control Scheme using Generalized Predictive Control

Suk-Joon Kim and Sunwon Park
Dept. of Chem. Eng., KAIST

I. 서론

비선형 화학공정을 제어하기 위하여 인공 신경망을 이용한 제어기법들이 많이 연구되고 있으나 기존의 방법들을 화학공정에 적용하기에는 몇 가지 문제점이 있다[4]. 첫째, 안정성과 경제적인 여러가지 이유에 의해서 충분한 학습정보를 실제 공정에서 얻기는 매우 힘들다. 둘째, 신경망을 on-line으로 학습하는 경우에는 학습이 이루어지는 도중에도 충분한 제어가 이루어져야 한다. 셋째, 실제적인 적용을 고려하면, 신경 제어기로 제어구조를 완전히 바꾸는 것보다는 기존에 구현되어 있는 안정적인 제어기와 신경 제어기를 결합하여 제어성능을 향상하는 것이 바람직하다. 또한 화학공정에서는 설정치 추적뿐 아니라 외란제거 성능을 필요로 한다.

이러한 문제점을 극복하기 위하여 선형화 신경 제어구조가 연구되었다[3]. 선형화 신경 제어구조는 선형 제어기에 의해 안정적으로 조업되고 있는 비선형 화학공정에 적용는데, 이는 선형 제어기와 비선형 공정 사이에 radial basis function(RBF) network을 첨가하여, 선형 제어기와 비선형 공정의 관계를 선형화한다. RBF network의 학습이 진행되면서 공정 출력은 선형 제어기의 출력에 선형으로 응답하게 되고, 전반적인 제어성능은 초기의 선형 제어기로부터 비선형 제어기로 향상되게 된다.

이전의 연구[3]에서는 PI 제어기가 feedback 제어기로 사용되는 경우에 선형화 신경 제어구조를 적용하였다. 본 연구에서는 model based control(MBC)의 일종인 generalized predictive control(GPC)가 사용되는 경우에 대하여 선형화 신경 제어구조를 적용하는 연구를 수행하였다. 본 논문의 구성은 먼저 RBF network을 간단히 소개하고, GPC를 사용하는 선형화 신경 제어구조에 대하여 설명하고, 비선형 화학공정인 pH process에 대한 모사연구 결과를 소개한다.

II. Radial Basis Function Network

그림 1은 RBF network의 구조를 보여준다. 이 그림에서 x 와 u 는 RBF network의 입력과 출력을 나타내고, M 은 은익층의 갯수를 나타낸다. W_i 는 은익층의 i 번째 뉴런으로부터 출력으로의 weight 값을 나타낸다. regulation 이론으로부터 green 함수가 활성화 함수(activation function)으로 쓰일 수 있으나, 본 연구에서는 gaussian potential function(GPF)을 사용하였다. RBF network의 출력은 식 1을 이용하여 계산한다.

$$u(k) = \sum_{i=1}^M W_i(k) \exp\left(\frac{\|x(k) - c_i(k)\|}{\sigma_i^2(k)}\right) \quad (1)$$

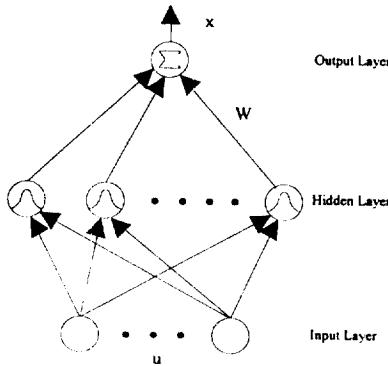


그림 1. Radial Basis Function Network.

여기서 u_i 와 c_i 는 은익층의 i 번째 GPF의 표준 편차와 중심값을 나타낸다. 또한 $\| \cdot \|$ 는 Euclidean norm이다.

RBF network에 대한 일반적인 학습방법은 은익층 활성화 함수의 중심값을 결정하기 위한 clustering algorithm과 weight 값을 수정하기 위한 least square algorithm으로 이루어져 있다. 본 연구에서는 은익층 뉴런을 self-generation하고 GPF의 변수를 온라인으로 수정하는 참고문헌 [5]의 학습방법을 적용하였다. 학습에 사용되는 목적함수는 gradient descent 방법과 오류 역전파 방법에 의해 최소화 된다.

III. 선형화 신경 제어구조

그림 2는 선형화 신경 제어구조의 블락 선도를 보여준다. 이 구조는 일반적인 feedback 제어구조에 RBF network와 학습을 위한 선형 참고 모델을 첨가한 것이다. 공정입력은 선형 제어기와 RBF network의 출력들의 합으로 이루어져 있다. 선형화 신경 제어구조의 목적은 RBF network를 선형 제어기와 공정 사이에 첨가함으로써, 선형 제어기의 출력과 공정출력의 비선형 관계를 선형화하는 것이다. 즉 그림에서 점선으로 표시된 부분의 선형화를 이루어, 선형 제어기의 출력에 대하여 공정의 출력이 선형적으로 응답하도록 하는 것이다.

선형화 신경 제어구조에 포함된 RBF network을 학습하기 위하여 선형 참고 모델이 도입된다. 선형 참고 모델은 일반적인 선형식으로 다음과 같은 ARX (autoregressive exogineous) 모델을 사용할 수 있다.

$$\tilde{y}(k) = A(q^{-1})y(k-1) + B(q^{-1})u(k-t_d-1) \quad (2)$$

여기서 q^{-1} 은 shift operator이고, A 와 B 는 다항식이고, t_d 는 시간지연(time-delay)이다. 그리고 \tilde{y} , y 와 u 는 각각 선형 참고 모델의 출력, 공정출력, 공정입력이다. 선형 참고 모델은 공정의 과거 조업결과를 분석하여 그중에서 가장 빠른 동특성을 보이는 조업결과를 선형모델로 근사한 것이다.

RBF network를 학습은 목적함수는 식 3과 같으며 이는 선형 참고 모델과 실제 공정의 출력들의 차이를 최소화하기 위하여 수행된다.

$$E(k) = \frac{1}{2} (\tilde{y}(k) - y(k))^2 \quad (3)$$

RBF network을 학습하기 위하여 학습오차는 RBF network의 출력오차로 전달

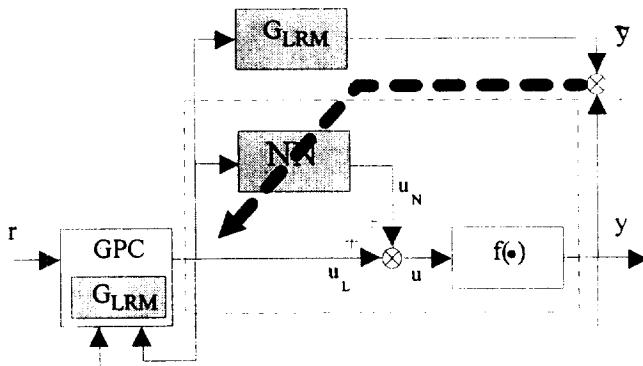


그림 2. 선형화 신경 제어구조의 블락 선도.

되어야 한다. 공정의 동특성이 알려져 있지 않고 신경 공정 모델이 없는 경우 공정의 Jacobian을 근사는 방법이 있어야 한다. 본 연구에서는 공정의 Jacobian을 선형 참고 모델의 것으로 근사하였다.

feedback 제어기로 GPC를 사용하는 경우에 GPC 내의 공정모델을 선형 참고 모델과 같은 것을 사용하면 학습이 진행됨에 따라 GPC의 제어신호에 대하여 공정의 응답이 공정모델과 같아진다. 즉, RBF network의 역할에 따라 GPC는 마치 보다 정확한 공정모델을 사용하는 효과를 갖게된다.

IV. 모사연구

제안된 제어구조의 제어성능을 알아보기 위하여 pH process에 모사연구를 통하여 제안된 제어구조를 적용하여 보았다. 모사연구는 Bhat와 McAvoy[1]에 의하여 보고된 pH 중화 공정에 대하여 이루어졌다. 본 연구에 사용된 pH 중화 공정에서는 산성 액체를 중성 액체로 중화한다. 본 예제에서 제어변수(y)는 반응기의 pH이고 조작변수(u)는 염기용액의 유량이다. 기존의 공정조업 데이터로부터 근사한 선형 참고 모델은 다음과 같다.

$$\tilde{y}(k+1) = 0.81 y(k) + 0.072 u_L(k-1) \quad (13)$$

RBF network을 충분히 학습하여 공정을 선형화한 후에 GPC의 공정모델이 공정과 매우 유사하다고 생각할 수 있으므로 GPC의 tuning parameter인 λ 를 조정하여 보다 강력한 제어출력을 발생하도록 할 수 있다. 그림 3은 GPC만을 사용하였을 때 제어성능을 보여준다. 그림 4는 최종적으로 RBF network의 학습이 끝난 후 선형화 신경 제어구조의 closed-loop 제어성능을 보여준다. 강한 비선형 동특성에도 불구하고 제안된 제어구조가 여러가지 다른 설정치 변화에 대하여 선형적이며 탁월한 제어성능을 보임을 알 수 있다. 또한 측정되지 않는 외란에 대해서도 보다 강력한 제어를 수행함을 알 수 있다.

V. 결론

pH 중화 공정의 모사연구를 통하여 GPC를 사용하는 선형화 신경 제어구조가 좋은 제어 성능을 보임을 알 수 있었다. 선형화 신경 제어구조에서 RBF network의 학습이 진행되면서 선형 제어기의 출력과 비선형 공정의 출력을 선형화하도록 부가적인 제어출력을 발생하고, 결과적으로 RBF network을 첨가한 공정의 동특성은 선형으로 변화한다. 또한 GPC를 사용하는 경우에 다변수 제어

에서 제어변수의 상호간섭을 고려한 decoupling 효과를 기대할 수 있다.

참고문헌

1. Bhat, N. V. and T. J. McAvoy, "Use of neural nets for dynamic modeling and control of chemical process systems," *Computers Chem. Engng.*, vol 14, p573-582, 1990.
2. Kawato, M., "Feedback-error-learning neural network for trajectory control of a robotic manipulator," *Neural Networks*, vol 1, p251-265, 1988.
3. Kim, S.-J., M. Lee, S. Park, S.-Y. Lee and C. H. Park, "Neural linearizing control with radial basis function network for chemical processes," *World Congress on Neural Networks*, San Diego, vol 2, p94-98, 1994.
4. Lee, M. and S. Park, "A new scheme combining neural feedforward control with model-predictive control," *AICHE Jl*, vol 38, p193-200, 1992.
5. Lee, S. and R. M. Kil, "A gaussian potential function network with hierarchically self-organizing learning," *Neural Networks*, vol 4, p207-224, 1991.
6. Song, J. J. and S. Park, "Neural Model Predictive Control for Nonlinear Chemical Processes," *Journal of Chemical Engineering of Japan*, 26, p347-354, 1993.

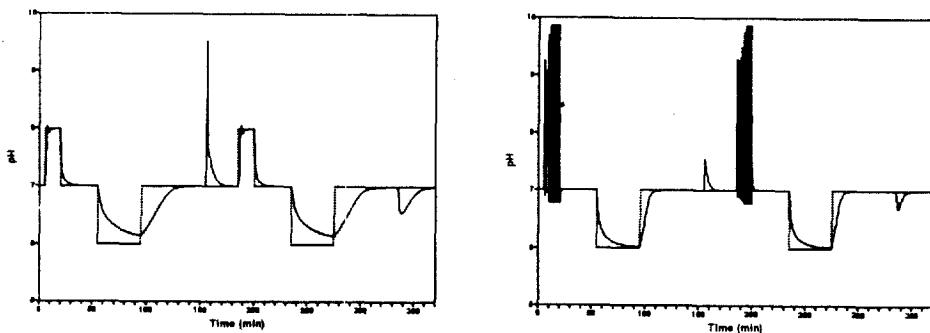


그림 3. GPC에 의한 제어 결과: (a) $\lambda=0.1$ (b) $\lambda=0$.

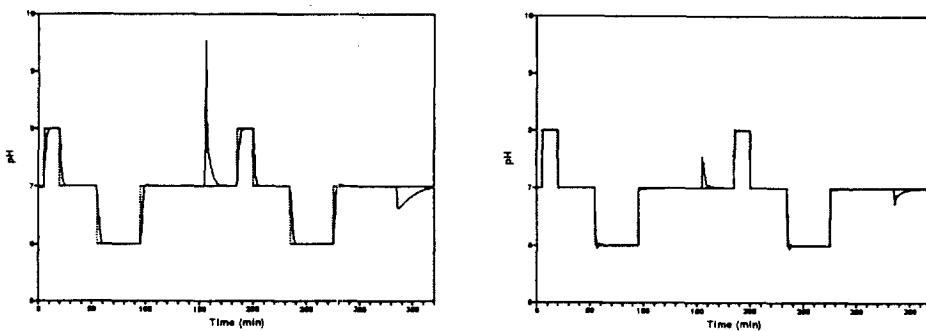


그림 4. 선형화 신경 제어구조의 제어 결과: (a) $\lambda=0.1$ (b) $\lambda=0$.