

Radial Basis Function 회로망을 이용한 새로운 신경망 선형화 제어구조

A New Neural Linearizing Control Scheme Using Radial Basis Function Network

김석준, 이민호, 박선원, 이수영, 박철훈
(Suk-Joon Kim, Minho Lee, Sunwon Park, Soo-Young Lee and Cheol Hoon Park)

Abstract : To control nonlinear chemical processes, a new neural linearizing control scheme is proposed. This is a hybrid of a radial basis function(RBF) network and a linear controller, thus the control action applied to the process is the sum of both control actions. Firstly, to train the RBF network a linear reference model is determined by analyzing the past operating data of the process. Then, the training of the RBF network is iteratively performed to minimize the difference between outputs of the process and the linear reference model. As a result, the apparent dynamics of the process added by the RBF network becomes similar to that of the linear reference model. After training, the original nonlinear control problem changes to a linear one, and the closed-loop control performance is improved by using the optimum tuning parameters of the linear controller for the linear dynamics. The proposed control scheme performs control and training simultaneously, and shows a good control performance for nonlinear chemical processes.

Keywords : neural control, linearizing control, nonlinear chemical process

I. 서론

다층 신경망(multilayer neural network)은 동특성(dynamics)이 잘 알려지지 않은 비선형 시스템의 제어에 매우 성공적으로 사용되고 있다[4][5][6][8][10][11][12][16][17]. 이들 중에서 forward modeling에 기반을 둔 간접 적응 신경 제어(indirect adaptive neural control) 구조가 로보트 팔 제어[4][5], truck backer upper 문제의 제어[17], 비선형 공정 제어[1][10][15]에 효과적으로 사용되고 있다. 이러한 간접 방법에서 신경 제어기는 신경 공정 모델(neural process model)을 통한 오류 역전파 방법에 의하여 학습되어진다. 이러한 방법들이 매우 유용한 결과를 보이지만, 화학공정에 적용하기에는 몇 가지 문제점이 있다.

첫째, 화학공정에서 신경제어기를 off-line으로 학습하여 구성하는데는 많은 어려움이 있다. 왜냐하면, 안정성과 경제적인 여러 가지 이유에 의해서 충분한 학습정보를 실제 공정에서 얻기는 매우 힘들기 때문이다[10]. 둘째, 신경망을 on-line으로 학습하는 경우에는 학습이 이루어지는 도중에도 충분한 제어성능을 이루어어야 한다. 셋째, 많은 화학공정들은 고급 제어기법을 도입하기 이전에 PID 제어기와 같은 간단한 선형 제어기에 의하여 제어되고 있으므로, 실용적인 측면에서 제어구조를 완전히 바꾸는 것보다는 기존에 구현되어 있는 안정적인 제어기와 신경 제어기를 결합하여 제어 성능을 향상하는 것이 바람직하다.

이와같은 문제점을 해결하기 위하여 본 연구에서는 선형 제어기에 의하여 안정적으로 조업되고 있는 비선형 화학공정에 radial basis function(RBF) network을 추가하여 제어 성능을 향상시키는 새로운 신경망 선형화 제어구조를 제안

한다. 신경망 선형화 제어구조는 선형제어기와 비선형 공정 사이에 RBF network을 첨가하여, 선형제어기와 비선형 공정의 관계를 선형화한다. 폐경로(closed-loop) 제어 성능은 RBF network에 의하여 선형화된 동특성과 선형 제어기의 성능에 의하여 결정된다. 초기에 단독으로 선형제어기가 공정을 안정적으로 제어할 수 있다면, 제안된 제어구조는 학습도중의 안정성을 유지할 수 있고 점진적으로 제어성능을 향상시킬 수 있다. 본 논문의 구성은 먼저 RBF network에 대하여 간략히 소개를 하고, 제안되는 신경망 선형화 제어구조와 학습방법을 설명한 후, 비선형 화학공정인 continuous stirred tank reactor(CSTR)와 pH 공정에 대한 모사 연구 결과가 소개된다.

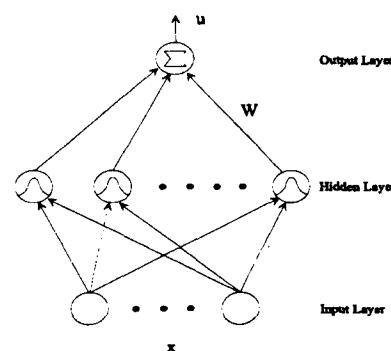


그림 1. 레디얼 기초 함수 회로망.
Fig. 1. Radial basis function network.

II. Radial basis function network

그림 1은 RBF network의 구조를 보여준다. 이 그림에서 x 와 u 는 RBF network의 입력과 출력을 나타내고, M 은 은닉층(hidden-layer)의 갯수를 나타낸다. w_i 는 은닉층의 i 번째 뉴런으로부터 출력으로의 weight 값을 나타낸다. regulation 이론으로부터 Green 함수가 활성화 함수(activation function)으로 쓰일 수 있으나[18], 본 연구에서는 Gaussian

접수일자 : 1996. 12. 9., 수정완료 : 97. 9. 30.

김석준 : 주식회사 유공, 생산기술센터

이민호 : 한국해양대학교 전기공학과

박선원 : 한국과학기술원 화학공학과

이수영, 박철훈 : 한국과학기술원 전기및전자공학과

* 본 논문은 포항공대 지능자동화 연구센터를 통한 한국과학재단에서 부분적 재정지원으로 연구하였습니다.

potential function(GPF)을 사용하였다. RBF network의 출력은 (1)을 이용하여 계산한다.

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

여기서 σ_i 와 c_i 는 은닉층의 i 번째 GPF의 표준 편차와 평균값(mean value)을 나타낸다. 또한 $\|\cdot\|$ 는 Euclidean norm이다.

RBF network에 대한 일반적인 학습방법은 은닉층 활성화 함수의 평균값을 결정하기 위한 clustering algorithm과 weight 값을 수정하기 위한 least square algorithm으로 이루어져 있다[2][9]. 본 연구에서는 은닉층 뉴런을 self-generation하고 GPF의 변수를 온라인으로 수정하는 참고문헌[9]의 학습방법을 적용하였다. 학습에 사용되는 목적함수는 gradient descent 방법과 오류 역전파 방법에 의하여 최소화 된다.

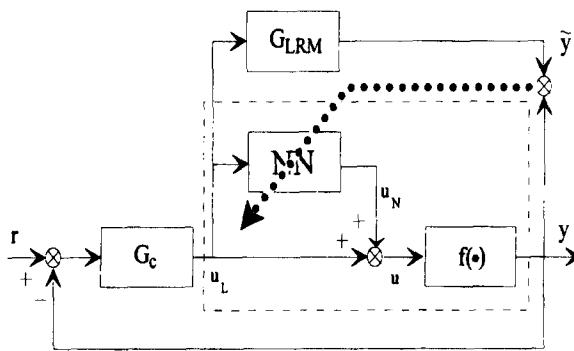


그림 2. 선형화 신경 제어 구조의 블록 선도.

Fig. 2. Block diagram of neural linearizing control architecture.

III. Radial basis function network을 이용한 선형화 제어구조

신경망 선형화 제어구조를 구현할 대상공정이 비선형성이 강하며 선형제어기에 의하여 안정적으로 제어되고 있다고 가정한다. 이는 고급제어 기법을 도입하려는 화학공정의 일반적인 상황이다. 그림 2는 신경망 선형화 제어구조의 블록선도를 보여준다. 이 구조는 일반적인 feedback 제어구조에 RBF network과 학습을 위한 선형 참고 모델을 추가한 것이다. 공정입력은 선형제어기의 출력(u_L)과 RBF network의 출력(u_N)의 합으로 이루어져 있다. 신경망 선형화 제어구조의 목적은 RBF network를 선형제어기와 공정 사이에 첨가함으로써, 선형제어기의 출력과 공정출력의 비선형 관계를 선형화하는 것이다. 즉 그림에서 점선으로 표시된 부분의 선형화를 이루어, 선형제어기의 출력에 대하여 공정의 출력이 선형적으로 응답하도록 하는 것이다.

RBF network은 지역적인 정보(locality of information)를 표현하기에 적합하다[18]. 그러므로, RBF network은 학습이 이루어지는 영역에서의 공정정보를 지역적으로 저장하는 장점을 갖게 된다. 신경망 선형화 제어구조에서 학습이 이루어진 영역에서는 선형제어기에 대한 공정의 비선형성이 보상되어지지만, 학습이 이루어지지 않은 영역에서는 선형제어기의 제어성능만을 나타내게 된다.

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

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

여기서 q^{-1} 은 shift operator이고, A와 B는 다항식이고, t_d 는 시간지연(time-delay)이다. 그리고 \tilde{y} 와 y 는 각각 선형 참고 모델과 공정의 출력들이다. 선형 참고 모델은 공정의 과거조업결과를 분석하여 그중에서 가장 빠르고 안정적인 농특성을 보이는 조업결과를 선형모델로 근사한 것이다.

RBF network의 학습을 위한 목적함수는 (3)과 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 전달되어야 한다. 공정의 농특성이 알려져 있지 않고 신경 공정 모델이 없는 경우 공정의 Jacobian을 근사는 방법이 있어야 한다[13]. 본 연구에서는 공정의 Jacobian을 선형 참고 모델의 것으로 근사하였는데 이 가정은 공정의 Jacobian 부호가 변하지 않는 상황에서 만 타당하며 올바른 학습이 이루어질 수 있다. 그러나, 많은 화학공정의 경우에 이 가정을 적용할 수 있다. 목적함수의 gradient는 다음의 식으로 표현된다.

$$\begin{aligned} & \frac{\partial E(k)}{\partial v(k-t_d-1)} \\ &= -[\tilde{y}(k) - y(k)] B(q^{-1}) \frac{\partial u_N(k-t_d-1)}{\partial v(k-t_d-1)} \\ &= -[\tilde{y}(k) - y(k)] \frac{\partial y(k)}{\partial u(k-t_d-1)} \frac{\partial u(k-t_d-1)}{\partial v(k-t_d-1)} \end{aligned} \quad (4)$$

여기서 v 는 RBF의 변수, W_i , σ_i , c_i 들이며, $B(q^{-1})$ 는 선형 참고 모델의 Jacobian이다. (3)을 변수 v 로 미분하여 (4)에 대입하면 완전한 목적함수의 gradient를 얻을 수 있다.

RBF network의 입력변수는 다음과 같다.

$$\begin{aligned} x(k) &= [y(k) \ y(k-1) \cdots \ y(k-N_y)] \\ &\quad u_p(k) \ u_p(k-1) \cdots \ u_p(k-t_d-1)]^T \end{aligned} \quad (5)$$

여기서 N_y 와 t_d 는 각각 선형 참고 모델의 차수와 시간지연이다. 또한 u_p 는 선형제어기의 제어출력중 제어오차, 즉 설정치와 공정응답의 차이에 비례하는 부분만을 나타낸다.

선형제어기에 의하여 제어되는 공정은 초기에 비선형적인 응답을 보여준다. 학습은 선형제어기의 출력에 대한 선형 참고 모델과 공정의 출력 차이를 최소화하도록 점진적으로 진행된다. RBF network의 학습이 충분히 진행되면, RBF network을 첨가한 공정, 즉 그림 2에서 점선으로 표시된 부분의 농특성은 결국 선형 참고 모델과 비슷해지게 되며, 공정의 선형화가 이루어진다. 선형화된 공정에 대하여 선형이론을 이용한 최적의 선형제어기 tuning parameter의 값을 구할 수 있다. 그러면 선형제어기의 tuning parameter를 초기에 안정성만을 고려한 값으로부터 최적의 값으로 변화시키면서 학습을 계속한다. 이렇게 하면 학습도중에 안정성이나 제어성능 저하의 문제를 일으키지 않으면서, 즉 안정적으로 제어와 학습을 동시에 수행하면서 폐경로 제어성능을 향상시킬 수 있다.

IV. 모사연구

제안된 제어구조의 제어성능을 알아보기 위하여 대표적인 화학공정인 continuous stirred tank reactor(CSTR)와 pH 공정의 공정모델을 이용하여 신경망 선형화 제어구조의 모사연구를 수행하였다. 모사연구는 비록 공정모델을 이용

하였지만, 신경망 선형화 제어구조의 학습과정에서는 공정모델을 구할 수 없다는 가정하에 공정모델에 관한 정보는 사용하지 않았다. 그러므로 본 연구의 결과는 학습패턴을 구하기 어려운 실제 화학공정에 적용하는 경우를 충분히 모사한다고 볼 수 있다.

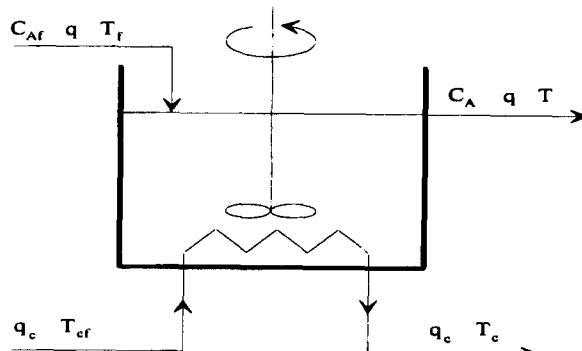


그림 3. CSTR 공정의 개략도.

Fig. 3. Configuration of the CSTR process.

표 1. CSTR의 정상 조업 조건.

Table 1. Plant parameters of the CSTR process operating under the normal condition.

변수	변수설명	변수값	변수	변수설명	변수값
q	원료 유량	100 l/min	E/R	에너지상수 /기체상수	9.95×10^3 K
C _{Af}	성분 A의 원료 농도	1 mol/l	C _A	성분 A의 생산물 농도	8.36×10^{-2} mol/l
T _f	원료 온도	350 K	ρ , ρ_c	원료비중, 냉각수 비중	1000 g/l
T _{cf}	냉각수 입력 온도	350 K	C _p , C _{pc}	원료열 용량, 냉각수 열용량	1 al/g/K
T	반응기 온도	440.2 K	q _c	냉각수 유량	103.41 l/min
hA	열전달 상수 × 열전달 넓이	7×10^5 cal/min/K	-ΔH	반응열	2×10^5 cal/mol
k ₀	반응상수	7.21010 /min	V	반응기 부피	100 l

a) CSTR 예제

본 예제에서는 Henson과 Seborg[3]가 개발한 CSTR 모델을 사용하였다. 그림 3은 사용된 CSTR의 개괄적인 구조를 보여준다. 반응기에서는 A→B로의 비가역 빌열반응이 일어난다. 공정의 모델식은 다음과 같다.

$$\dot{C}_A = \frac{q}{V} (C_{Af} - C_A) - k_0 C_A \exp\left(-\frac{E}{RT}\right) \quad (6)$$

$$\begin{aligned} \dot{T} &= \frac{q}{V} (T_f - T) - \frac{(-\Delta H) k_0 C_A}{\rho C_p} \exp\left(-\frac{E}{RT}\right) \\ &+ \frac{\rho C_{pc}}{\rho_c C_p V} q_c \left[1 - \exp\left(-\frac{hA}{q_c \rho_c C_{pc}}\right) \right] \times (T_{cf} - T) \end{aligned} \quad (7)$$

이 공정의 정상 조업 조건은 표 1에 정리되어 있다.

본 예제에서 제어변수(y)는 CA이고 조작변수(u)는 q이다. 조작변수 ±10% 계단변화에 대한 공정의 출력이 그림 4에 보여지는데 이 그림으로부터 공정의 비선형성이 강함을 알 수 있다. 제안된 제어구조를 구현하기 전에 공정이 PI 제어기에 의하여 제어되고 있다고 가정하였다. 사용된 PI 제어기의 tuning parameter는 proportional gain(k_c)=150, integral time(t_c)=0.3분, sampling time(Δt)=0.1분이다. 공정의 비선형성이 강하므로 전체 조업조건에 적합한 PI 제어기의 tuning parameter를 manual로 설정하였다. 그림 5에 PI 제어기로 제어된 공정응답을 보여주며, 이 조업결과부터 근사한 선형 참고 모델은 다음과 같다.

$$\tilde{y}(k+1) = 0.72y(k) + 0.00087u_L(k-1) \quad (8)$$

그림 6은 RBF network의 학습이 진행됨에 따른 설정치와 공정응답의 차이인 제어오차(실선)와 3의 학습오차(굵은 실선)를 보여준다. On-line 학습이 진행됨에 따라 제어오차와 학습오차가 점진적으로 줄어들게 되는 것을 알 수 있다.

RBF network을 충분히 학습하여 공정을 선형화한 후 폐경로의 제어성능을 증가시키기 위하여 PI 제어기의 k_c 를 220으로 점진적으로 증가시키면서 학습을 계속하였다. 최종적으로 RBF network의 학습이 끝난 후 신경망 선형화 제어구조의 폐경로 제어성능은 그림 7에서 보는 바와 같다. 이 그림으로부터 비선형 공정이 여러가지 다른 설정치 변화에 대하여 선형적인 출력을 보임을 알 수 있고, 그림 5와 비교하여 제안된 제어구조가 우수한 제어성능을 보임을 알 수 있다.

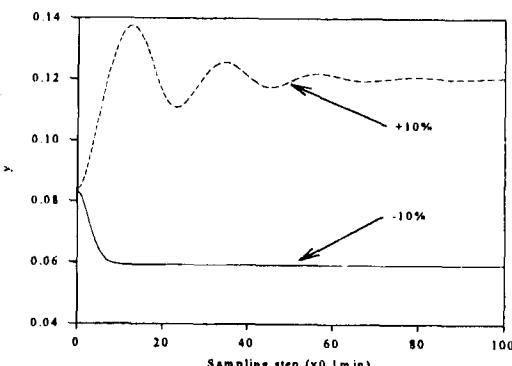


그림 4. 계단 공정입력에 대한 공정의 출력 - 예제a.

Fig. 4. Process output when the step input is used - example a.

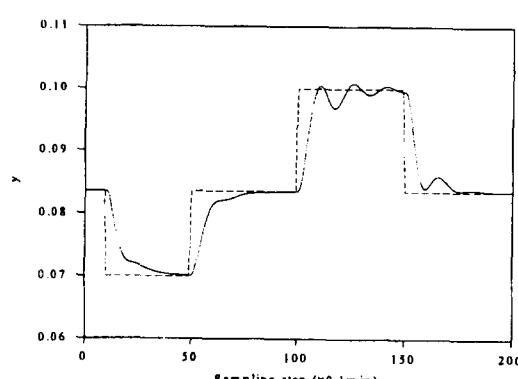


그림 5. PI 제어기에 의한 제어 결과 - 예제a.

Fig. 5. Control result by PI controller - example a.

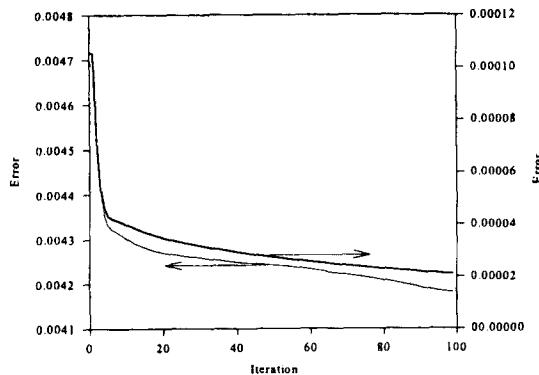


그림 6. 학습 횟수에 따른 제어오차(실선)와 학습 오차(굵은 실선) - 예제a.

Fig. 6. Control error during the learning process (solid line) and learning error(bold solid line) - example a.

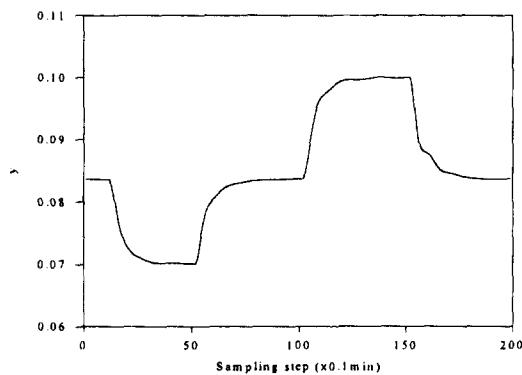


그림 7. 선형화 신경 제어 구조의 제어 결과 - 예제a.

Fig. 7. Control result by the proposed neural linearizing controller - example a.

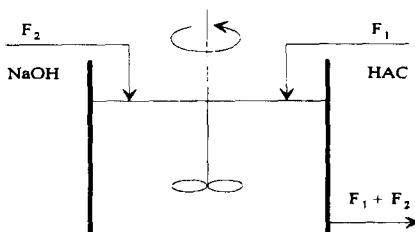


그림 8. pH 공정의 개략도.

Fig. 8. Configuration of the pH process.

표 2. pH 공정의 정상 조업 조건.

Table 2. Plant parameters of the pH process operating under the normal condition.

변수	변수설명	변수값	변수	변수설명	변수값
V	반응기 부피	1000 l	F ₁	산용액 농도	81 l/min
pH	.	7.0	F ₂	염기용액 농도	515 l/min
C ₁	산농도	0.32 mol/l	[HAC]	아세트산 농도	0.0435 mol/l
C ₂	염기농도	0.05 mol/l	[NAOHO]	수산화나트륨 농도	0.0432 mol/l

b) pH 공정 예제

두번째 모사연구는 McAvoy 등 [14]에 의하여 보고된 pH

공정에 대하여 이루어졌다. 공정의 개괄도가 그림 8에 나타나 있다. 본 연구에 사용된 pH 공정에서는 산성 액체를 중성 액체로 중화한다. 공정의 보렐식은 다음과 같다.

total acetate balance

$$F_1 C_1 - (F_1 + F_2) \xi = V \frac{d\xi}{dt} \quad (9)$$

sodium ion balance

$$F_1 C_1 - (F_1 + F_2) \zeta = V \frac{d\zeta}{dt} \quad (10)$$

HAC equilibrium

$$\frac{[AC^-][H^+]}{[HAC]} = K_a \quad (11)$$

water equilibrium

$$[H^+][OH^-] = K_w \quad (12)$$

electroneutrality

$$\xi + [H^+] = [OH^-] + [AC^-] \quad (13)$$

여기서 $[\cdot]$ 는 각 성분의 농도이며, $\xi = [HAC] + [AC^-]$ 이고, $\zeta = [Na^+]$ 이다. 또한 K_w 와 K_a 는 물과 아세트산의 평형상수이다. 그밖에 pH 공정의 정상 조업 조건은 표 2에 정리되어 있다.

본 예제에서 제어변수(y)는 pH이고 조작변수(u)는 F_2 이다. 조작변수 ± 2 l/min의 계단변화에 대한 공정의 출력이 그림 9에 도시되어 있다. 그림으로부터 공정의 비선형성이 매우 강함을 알 수 있다. CSTR 예제와 같은 방법으로 tuning parameter가 $k_c=3.0$, $t_c=2.0$ 분, $\Delta_t=0.5$ 분인 PI 제어기를 사용하였고, 그림 10에 PI 제어기의 폐경로 제어성능이 나타나 있다. 이 조업결과로부터 모사한 선형 참고 모델은 다음과 같다.

$$\dot{y}(k+1) = 0.81y(k) + 0.076u_{t-1}(k-1) \quad (14)$$

그림 11은 RBF network의 학습이 진행됨에 따른 설정치와 공정응답의 차이인 제어오차(실선)와 (3)의 학습오차(굵은 실선)를 보여준다. 이 그림에서 학습이 진행됨에 따라 신경망 선형화 제어구조의 제어성능이 선형제어기의 제어성능에서 점진적이고 안정적으로 향상되는 것을 알 수 있다.

RBF network을 학습하여 충분히 공정을 선형화한 후, PI 제어기의 k_c 를 점진적으로 6.0으로 증가시켰다. 최종적으로 RBF network의 학습이 끝난 후 신경망 선형화 제어구조의 폐경로 제어성능은 그림 12에서 보는 바와 같다. 강한 비선형 동특성에도 불구하고 제안된 제어구조가 여러가지 다른 설정치 변화에 대하여 선형적이며 좋은 제어성능을 보임을 알 수 있다.

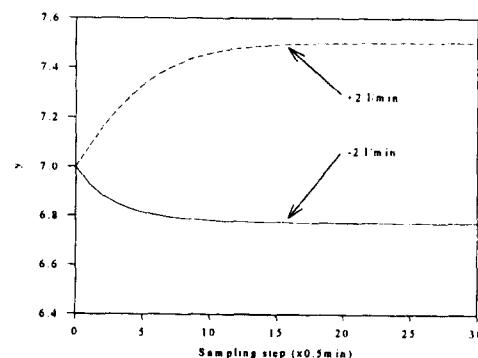
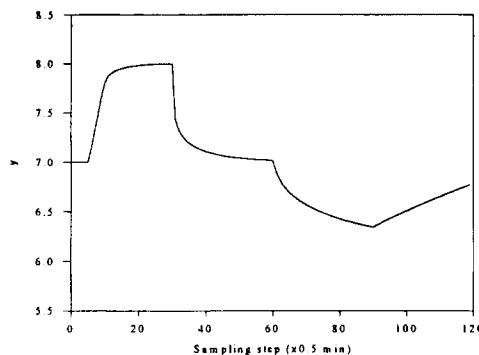
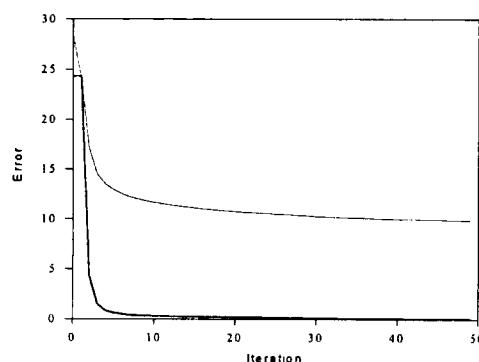


그림 9. 계단 공정 입력에 대한 공정의 출력 - 예제b.

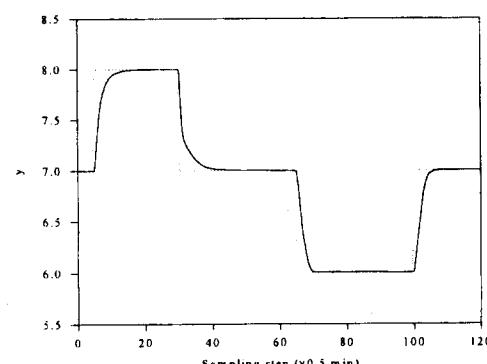
Fig. 9. Process output when step input is used - example b.



[그림] 10. PI 제어기에 의한 제어 결과 - 예제b.
Fig. 10. Control result by PI controller - example b.



[그림] 11. 학습 횟수에 따른 제어오차(실선)와 학습 오차(굵은 실선) - 예제b.
Fig. 11. Control error during the learning process (solid line) and learning error(bold solid line) - example b.



[그림] 12. 선형화 신경 제어 구조의 제어 결과 - 예제b.
Fig. 12. Control result by the proposed neural linearizing controller - example b.

V. 결론

화학공정의 특별한 상황을 만족하기 위하여 RBF network을 이용한 새로운 제어구조인 신경망 선형화 제어구조를 제안하였다. 이는 RBF network을 선형 제어기와 결합한 제어구조로써 제어와 학습을 동시에 수행할 수 있다. RBF network의 학습을 위하여 먼저 조업결과로부터 선형 참고모델을 구성하며, 학습은 공정출력과 선형 참고 모델의 출력의 차이를 최소화하기 위하여 점진적으로 이루어진다. 학습 결과, RBF network을 합한 비선형 공정의 동특성은 선형 참고 모델의 동특성으로 수렴하게 되고, 전반적인 제어문제가 선형화된다. 대표적인 화학공정인 CSTR과 pH 공정의 모사

연구를 수행한 결과 제안된 신경망 선형화 제어구조가 좋은 제어 성능을 보임을 알 수 있었다.

참고문헌

- [1] N. V. Bhat and T. J. McAvoy, "Use of neural nets for dynamic modeling and control of chemical process systems," *Computers Chem Engng.*, vol. 14, pp. 573-582, 1990.
- [2] S. Chen, F. N. Cowan and P. M. Grant, "Orthogonal least square learning algorithm for radial basis function networks," *IEEE Trans. on Neural Networks*, vol. 2, pp. 302-309, 1991.
- [3] M. A. Henson and D. E. Seborg, "A critique of exact linearization strategies for process control," *AIChE Jl*, vol. 36, pp. 1753-1757, 1990.
- [4] T. M. Hoshio, Kano and T. Endo, "Optimal control with a recurrent neural networks and a priori knowledge of the system," *Procs. of International Joint Conf. on Neural Network*, vol. 1, no. 3, pp. 226-231, 1991.
- [5] M. I. Jordan and D. E. Rumelhart, "Forward models: supervised learning with a digital teacher," preprint.
- [6] M. Kawato, "Feedback-error-learning neural network for trajectory control of a robotic manipulator," *Neural Networks*, vol. 1, pp. 251-265, 1988.
- [7] S. J. Kim, 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, pp. 94-98, 1994.
- [8] B. Kosko, "Neural networks for signal processing," The Prentice-Hall international editions, pp. 161-187, 1992.
- [9] S. Lee and R. M. Kil, "A gaussian potential function network with hierarchically self-organizing learning," *Neural Networks*, vol. 4, pp. 207-224, 1991.
- [10] M. Lee and S. Park, "A new scheme combining neural feedforward control with model-predictive control," *AIChE Jl*, vol. 38, pp. 193-200, 1992.
- [11] M. Lee, S.-Y. Lee and C. H. Park, "Neural controller of nonlinear dynamic systems using higher order neural networks," *Electronics Letters*, vol. 28, no. 3, pp. 276-277, 1992.
- [12] M. Lee, S.-Y. Lee and C. H. Park, "Feedforward / feedback neural control structure and its application to a robotic system," *Procs. of International Joint Conf. on Neural Network*, vol. 3, pp. 2757-2760, 1993.
- [13] Y. H. Maeda, Yamashita and Y. Kanada, "Learning rules for multilayer neural networks using a difference approximation," *Procs. of International Joint Conf. on Neural Network*, vol. 1, pp. 628-633, 1991.
- [14] T. J. McAvoy, E. Hsu and S. Lowenthal, "Dynamics

- of pH in CSTR," *Ind. Engng. Chem. Procedss Des. Dev.*, vol. 11, pp. 68-70, 1972.
- [15] E. P. Nahas and D. E. Seborg, "Nonlinear internal model control strategy for neural networks," *Computers Chem. Engng.*, vol. 16, pp. 1039-1057, 1992.
- [16] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamic system using neural networks," *IEEE Trans. on Neural Networks*, vol. 1, no. 1, pp. 4-27, 1990.
- [17] D. H. Nguyen and B. Widrow, "Neural networks for self-learning control systems," *IEEE Control Systems Magazine*, vol. 10, no. 3, pp. 18-23, 1990.
- [18] T. Poggio and F. Girosi, "A theory of networks for approximation and learning," A. I. Memo no. 1140, Artificial Intelligence Lab., MIT, 1989.



김석준

1990년 과학기술대학교 화학공학과 졸업(학사). 1992년 한국과학기술원 화학공학과 졸업(석사). 1996년 한국과학기술원 화학공학과 졸업(박사). 현재 주식회사 유공, 생산기술센터연구원.

이민호

제어·자동화·시스템공학회 학회지 제 1권 제 3호 91p 참조.

이수영

제어·자동화·시스템공학회 학회지 제 1권 제 3호 91p 참조.



박철훈

1984년 서울대학교 공과대학 전자공학과 졸업(학사). 1985년 Caltech, 전기공학과 졸업(석사). 1990년 Caltech, 전기공학과 졸업(박사).



박선원

1970년 화학공학과 졸업(학사). 1974년 Oklahoma State University 화학공학과 졸업(석사). 1979년 Univ. of Texas at Austin 화학공학과 졸업(박사). 1987년 Univ. of Houston-Clear Lake(MBA). 1979 ~ 1988년 Hoechst Celanese, System Engineer, Sr. Process Control Engineer, Staff Engineer. 1988년 ~ 현재 한국과학기술원 화학공학과 교수.