

### 신경제어기를 이용한 증류탑의 제어에 관한 연구

이 문 용                      박 선 원  
한국과학기술원      화학공학과

## A Study of Distillation Column Control by Using A Neural Controller

Moonyong Lee                      Sunwon Park  
Dept. of Chemical Engineering  
K A I S T

#### ABSTRACT

A neural controller for process control was proposed that combines a simple feedback controller with a neural network. This controller was applied to distillation control. The feedback error learning technique was used for on-line learning. Important characteristics on neural controller were analyzed. The proposed neural controller can cope well with strong interactions, significant time delays, sudden changes in process dynamics without any prior knowledge of the process. It was shown that the neural controller has good features such as fault tolerance, interpolation effect and random learning capability.

#### 1. 서론

일반적으로 화학공정의 동특성은 시간지연과 비선형성 및 제어변수 간의 상호 간섭작용 등으로 나타나며 이는 화학공정의 원활한 제어를 어렵게하는 주요원인이라 할수 있다. 한편 대부분의 고급제어 기법은 선형성을 기본 가정으로 하고 있으며 또한 공정의 정확한 모델을 선결조건으로 하고있기때문에 화학공정에의 실제적 적용시의 주요 제약조건으로 작용하고 있다. 따라서 DDC (Direct Digital Control)의 활발한 도입에도 불구하고 제어 알고리즘은 단순한 PID 제어가 주종을 이루고 있는 실정이다.

최근 인공 신경회로망 분야의 급속한 전개에 따라 이러한 인공 신경회로망 기법을 제어 분야에 응용하고자 하는 시도가 활발히 이루어 지고 있다. 신경제어기는 공정의 상태와 이어대한 적절한 조작변수상태를 학습에의해 각 뉴론(neuron)들의 연결형질값(weight)에 저장한후 외부로부터 입력된 신호의 패턴을 인식하여 제어를 수행한다. 신경 제어기는 공정의 모델을 몰라도 학습에의해 스스로 성능을 향상시키며 공정의 특성 변화에 잘 적응하며 fault에 강건하고 병렬성에의해 속도가 빠르다는 장점이 있다. 그러나 현재까지의 연구수준은 기초 단계에 있으며 대부분 Robot 제어 분야에 한정되어 있고 [1,2,3] 화학 공정에는 아직까지 적용사례가 거의 전무한 실정이다.

이에 본 논문에서는 인공 신경 회로망을 화학공정의 대표적 장치인 증류탑의 제어에 적용하는 방법을 연구하며 그 주요 특성과 성능을 분석하였다. 그 결과 기존의 제어기에서 나타나는 여러가지 문제점을 해결할 수 있었으며 기존 제어시스템과 병용하므로써 효율적인 제어가 가능함을 보였다.

#### 2. 인공 신경회로망

신경회로망은 뉴론간의 상호연결에 의한 본산기역과 병렬 처리에 의해 단 시간내에 오차보정 능력이 높은 패턴처리를 할 수 있으며 학습에 의해 스스로 새로운 것을 배워 나갈 수 있는 중요한 특성을 가지고 있으며 이러한 특성들은 제어분야의 활용에 큰 잠재력을 가지게 된다. 현재까지 연구된 여러가지 신경회로망 모델 중 로보트제어에 주로 사용되는 것은 그림 1에 나타난 다층 인식자 모델이라 할 수 있다. 상호 연결된 뉴론간의 연결강도는 Hebb의 가설 (i.e. 상호간에 계속적으로 연관되는 뉴론간의 연결 강도는 증가되어야 한다.)을 기본으로 학습에의해 조절된다. 널리 쓰이는 학습법칙으로는 최대 경사법 (steepest descent method)의 일종인 오차역류 방법 (error back propagation)이 있다. 다층 인식자 모델의 작동원리와 학습법칙은 다음과 같다. 신경회로는 입력층과 출력층 및 중간층으로 이루어져 있고 각 층마다 비선형 특성이 도입된다. 연상 재현을 위한 1번째 층의 j번째 뉴론의 출력값  $O_j$ 는 아래와 같다.

$$O_j = F\left(\sum_{i=1}^{N_i-1} W_{i,j} O_i^{l-1}\right) \text{ for } j=1, \dots, N_j, \& \text{ } l > 2 \quad (1)$$

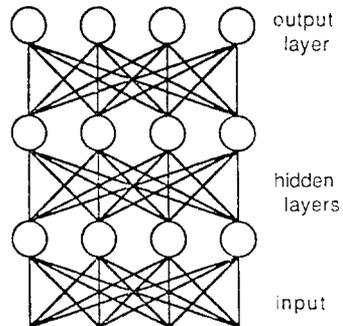


그림 1. 다층 인식자 모델 구조

이때  $W_{ij}^l$  는  $l$  번째 층의  $j$  번째 뉴론과  $l-1$  번째 층의  $i$  번째 뉴론간의 연결 행렬의 값이고,  $N^l$  은  $l$  번째 층의 뉴론 수이며,  $F(\cdot)$  는 비선형 전달함수이다.

한편 학습은 출력층부터 시작하여 오차역류방법에 의해 층마다 학습시켜 입력층까지 학습하게되며 이와 같은 과정을 반복하게 된다.  $k+1$  번째 학습 step에서의 연결행렬 값은 다음과 같다.

$$W_{ij}^{l+1}(k+1) = W_{ij}^{l+1}(k) + \eta \Delta W_{ij}^{l+1} \quad (2)$$

$$\begin{aligned} \Delta W_{ij}^{l+1} &= (T_j^l - O_j^l) F' \left( \sum_{i=1}^{N^{l-1}} W_{ij}^{l+1} O_i^{l-1} \right) O_i^{l-1} \\ &= \delta_j^l O_i^{l-1} \quad \text{for output layer} \end{aligned} \quad (3)$$

$$\begin{aligned} \Delta W_{ij}^{l+1} &= \left( \sum_{k=1}^{N^{l+1}} \delta_k^{l+1} W_{kj}^{l+1} \right) F' \left( \sum_{i=1}^{N^l} W_{ij}^{l+1} O_i^l \right) O_i^l \\ &= \delta_j^{l+1} O_i^l \quad \text{for hidden layer} \end{aligned} \quad (4)$$

이때  $T_j^l$  는 출력층의  $j$  번째 뉴론의 목표치이고  $\eta$  는 학습계수를 의미한다.

### 3. 화학공정제어를 위한 신경제어기 구조

로봇 제어 시스템은 동특성이 빠르고 시간지연요소가 작아서 kinematic 시스템으로 가정할 수 있다. 또한 만들어진 로봇은 설치 전에 충분한 학습을 거칠 수 있다는데에 신경회로망 적용시 유리하게 작용한다. 반면 화학공정은 특성상 off-line 학습이 용이하지 못하므로 미리 학습을 거칠 수 없다는 점이 주요 제약점으로 작용한다. 따라서 학습은 on-line 으로 이루어져야 하며 학습범위도 공정 운전의 안전범위내에서 점진적으로 이루어지는 것이 바람직하다. 한편 오차역류방법에 의한 학습을 위해서는 조작변수의 목표치를 미리 알아야 하나 제어의 경우는 이러한 목표치를 직접 알수가 없으며 공정의 제어변수 양상을 통해서 간접적으로 추정해야 하기 때문에 이에맞게 학습방법을 수정해야 한다. 이를 위해 본 논문에서는 Kawato [1] 등이 로봇제어에 적용했던 궤환오차학습 방법을 사용하였다. 본 논문에 적용한 신경제어기 구조는 그림 2 와 같다.

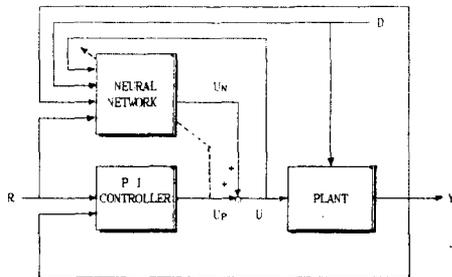


그림 2. 궤환오차 학습방식을 이용한 신경제어기 구조

일반적인 오차역류방법에서의 오차함수는 아래와 같다.

$$E = 1/2 \sum (U_n - U_n^{desired})^2 \quad (5)$$

이때  $U_n^{desired}$  를 직접적으로 알수없기때문에 오차함수 형태를 다음과 같이 변경한다.

$$E = 1/2 \sum (U_p)^2 \quad (6)$$

만약 완전한 제어가 이루어 진다면  $U_p = 0$  가 된다. 출력층에서의  $\delta_j^l$  는 다음과 같다.

$$\delta_j^l = -(\partial E / \partial O_j^l) (\partial O_j^l / \partial X_j^l) = U_{pj} F'(X_j^l) \quad (7)$$

$$\text{이때 } X_j^l = \sum_{i=1}^{N^{l-1}} W_{ij}^l O_i^{l-1}$$

중간층에서의 학습은 (4) 식을 그대로 적용한다.

화학공정은 상태변수의 직접적인 측정이 어려우므로 신경제어기의 입력변수는 공정의 상태를 추정하기에 충분한 측정변수들로 대체된다. 본 연구에서는 입력변수로서 설정점, 조작변수, 제어변수 및 외란변수등의 과거 및 현재값을 이용했다. 신경제어기는 이들 값으로부터 공정의 상태와 이에대한 적절한 조작변수값을 학습을 통해 연결행렬에 본산저장 시킨 값을 이용하여 제어를 수행하게 된다. 초기에는 모든 제어동작을 PI 제어기가 수행하게 되나 학습이 진행됨에따라 대부분의 제어동작을 신경제어기가 수행하게되며 PI 제어기는 궤환 오차보정을 위한 작은 부분만을 보조하게 된다.

### 4. 모사연구 및 결과분석

모사연구를 위한 종류탐모델은 Wood and Berry [4] 가 물-메탄을 시스템에대해 실험적으로 구한 모델을 사용하였으며 아래와 같다.

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} 12.8e^{-s} & -18.9e^{-s} \\ 16.7s+1 & 21.0s+1 \\ 6.6e^{-s} & -19.8e^{-s} \\ 10.9s+1 & 14.4s+1 \end{bmatrix} \begin{bmatrix} m_1 \\ m_2 \end{bmatrix} + \begin{bmatrix} 3.8e^{-s} \\ 14.9s+1 \\ 4.9e^{-s} \\ 13.2s+1 \end{bmatrix} d$$

이 종류탐의 정상상태 운전조건 및 제어기의 매개변수값은 표 I 와 같다.

표 I . WOB Column 정상상태 및 PI 제어기 매개변수 값

변수	설명	운전조건
$y_1$	탑상 조성	96.25 mol % 메탄올
$y_2$	탑저 조성	0.5 mol % 메탄올
$m_1$	환류 량	1.95 lb/min
$m_2$	스팀 량	1.71 lb/min
$d$	원료 량	2.45 lb/min
$K_c$	비례기 상수	0.2, -0.04
$\tau_1$	적분기 상수	4.44, 2.67

#### 4-1 서보 (servo) 특성 분석

탐상조성과 탐저조성의 설정점을 0.05 ~ -0.05 (mol %) 범위 내에서 동시에 랜덤하게 변화시키면서 반복 학습시켰다. 그 결과 (그림 3,4) PI 제어기 만을 사용했을 경우 (이하 기존 경우로 표기)보다 79%의 ISE (Integral Square Error) 감소를 보였다. 학습된 신경제어기를 0.05 ~ -0.05 (mol %) 범위 내의 또 다른 임의의 랜덤 변화에 따른 interpolation 효과를 본 결과 (그림 5) 성능향상이 그대로 유지됨을 확인할 수 있었다.

#### 4-2 외란제거 (regulatory) 특성 분석

화학공정제어는 servo 보다는 주로 regulatory 문제이다. 증류탑에서의 외란으로 작용하는 인자로서 원료량의 변화에 대한 제어 특성을 살펴보았다. 원료량을 0.025 ~ -0.025 (lb/min) 범위내에서 랜덤하게 변화시키면서 (그림 6) 반복 학습시켰다. 그 결과 (그림 7,8) 기존 경우보다 98%의 ISE 감소라는 뛰어난 성능향상을 보였다. 학습된 후에는 신경제어기가 대부분의 제어동작을 수행하게되는 것을 그림 9 에서 알 수 있다. 학습된 신경제어기를 0.025 ~ -0.025 (lb/min) 범위 내의 또 다른 임의의 랜덤 변화(그림 10)에 따른 interpolation 효과를 본 결과 (그림 11) 성능향상이 그대로 유지됨을 확인할 수 있었다. 공정 동적특성의 급격한 변화에 따른 적응성을 보기위해 모델의 매개변수를 아래와 같이 임의로 대폭 변화시킨 결과 변화 싹점에서는 ISE 가 약간 상승하지만 (0.7 → 4) 기존구조의 ISE (= 35.4) 비교하면 높은 성능을 유지하며 이것도 학습에의해 더욱 ISE 가 줄어드는 (0.3) 뛰어난 적응성을 보였다 (그림 12).

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} 9.0e^{-8s} & -14.9e^{-3s} \\ 26.7s+1 & 41.0s+1 \\ 4.6e^{-7s} & -14.4e^{-3s} \\ 20.9s+1 & 24.4s+1 \end{bmatrix} \begin{bmatrix} m_1 \\ m_2 \end{bmatrix} + \begin{bmatrix} 1.8e^{-10s} \\ 10.9s+1 \\ 2.9e^{-5s} \\ 8.2s+1 \end{bmatrix} d$$

한편 실제공정에서는 정확한 반복학습이 현실적으로 어려운 경우가 많으므로 랜덤학습에 의존하는 경우를 고려했을때도 반복학습의 결과와 대등한 성능향상을 확인 할수 있었다 (그림 13). Fault tolerance 효과를 보기위해 학습된 신경제어기의 연결행렬의 50%를 임의로 파손시킨 후의 임의의 원료량 변화에 대한 제어특성을 살펴본 결과 ISE 가 기존구조보다 67% 정도 감소된 상태를 유지하는 강건성을 볼 수 있었다.

#### 5. 결론

화학공정의 제어에 신경회로망을 이용하는 방법에 대해 증류탑을 예로서 연구한 결과 기존 PI 제어구조보다 뛰어난 성능을 얻을 수 있었다. 신경제어기는 공정의 모델을 알 필요없이 학습에의해 스스로 성능을 향상시키며 공정의 비선형성, 시간지연, 상호간섭작용 및 동특성의 급격한 변화에 강인함을 확인할 수 있었다. 이러한 신경제어기는 화학공정제어에서 나타나는 주요 문제점을 극복하는 새로운 방법으로 기대된다.

#### 6. 참고 문헌

- 1) Kawato, M. et al, " Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics ", IEEE Control Systems Magazine, April, pp. 5-16, 1988.
- 2) Psaltis, D. et al, " A Multilayered Neural Network Controller ", IEEE Control Systems Magazine, April, pp. 17-21, 1988.
- 3) Guez, A. et al, " Neural Network Architecture for Control ", IEEE Control Systems Magazine, April, pp. 22-25, 1988.
- 4) Wood, R. K. and Berry, M. W., Chem. Eng. Sci., 28, 1707, 1973

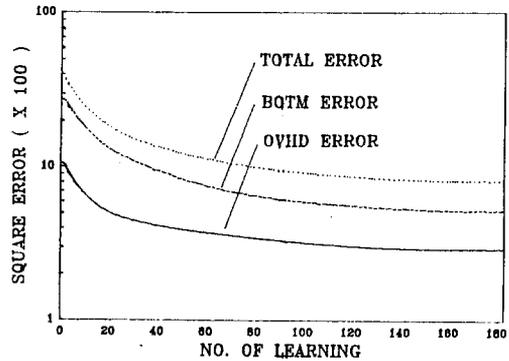
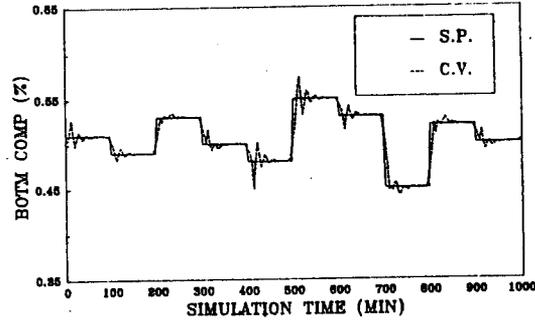
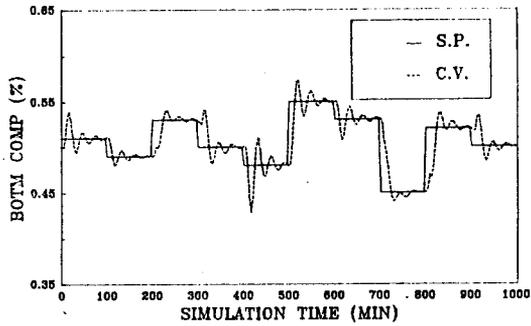
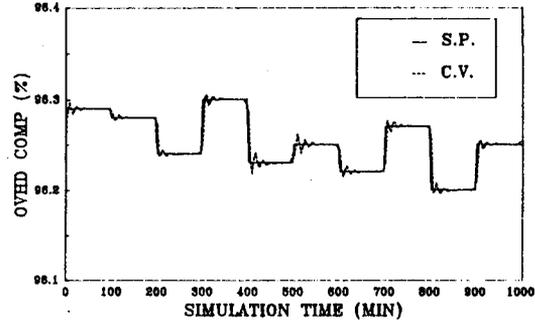
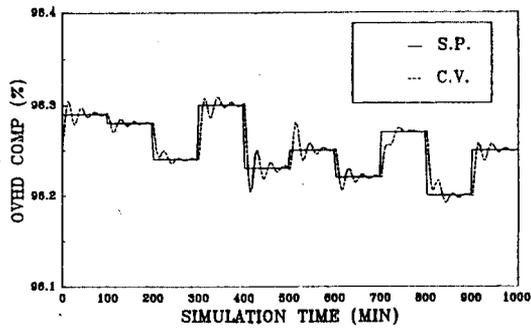


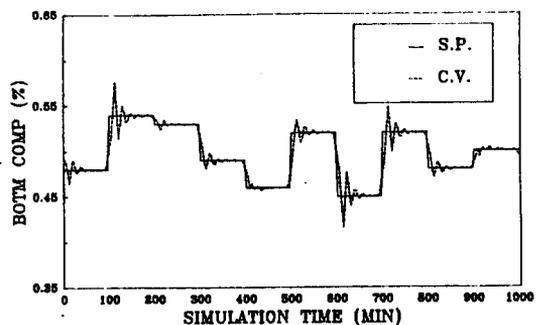
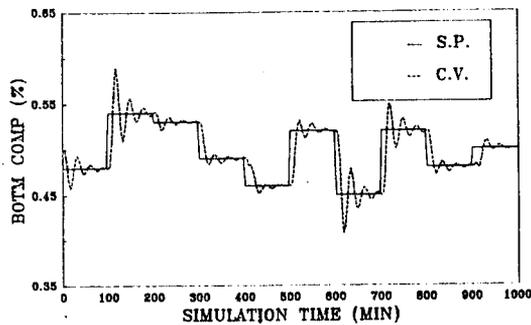
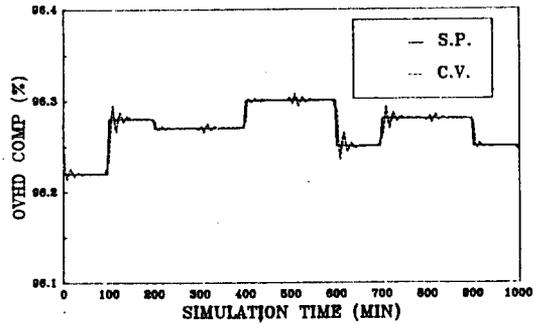
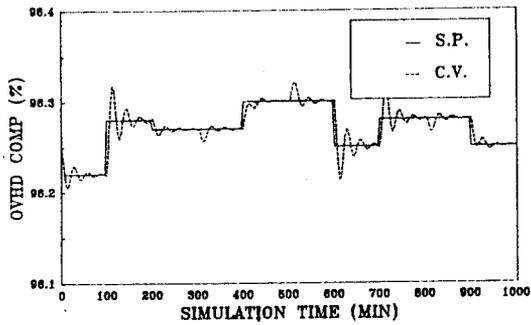
그림 3. 학습에 따른 ISE 변화



a) 학습 전

b) 학습 후

그림 4. 신경제어기의 servo 특성



a) 기존구조

b) 신경제어기

그림 5. Servo 문제에서의 interpolation 효과

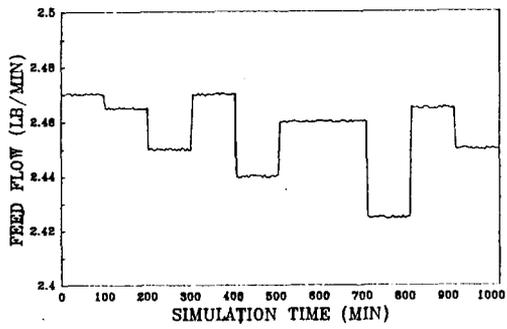


그림 6. 학습에 쓰인 랜덤 외란

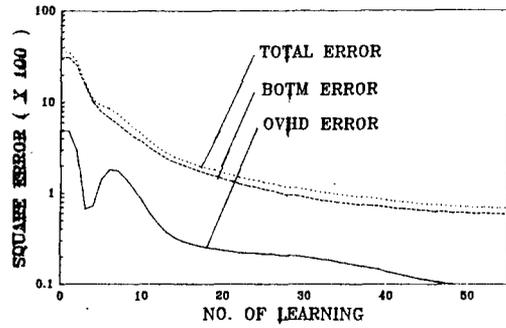
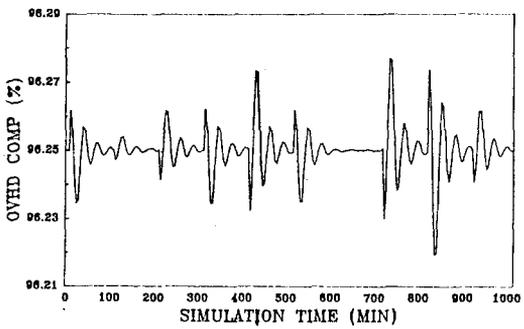
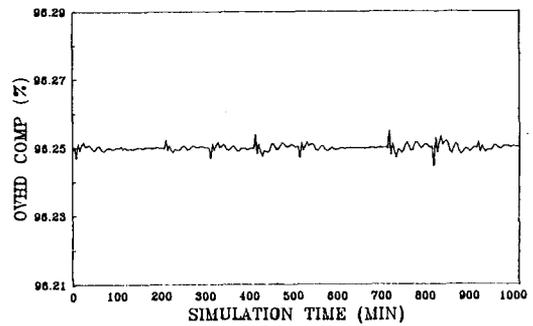


그림 7. 학습에 따른 ISE 변화



a) 학습 전



b) 학습 후

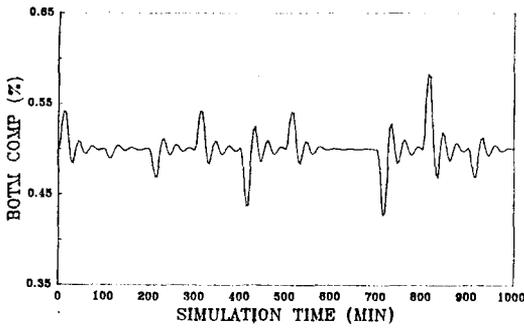


그림 8. 신경제어기의 regulatory 특성

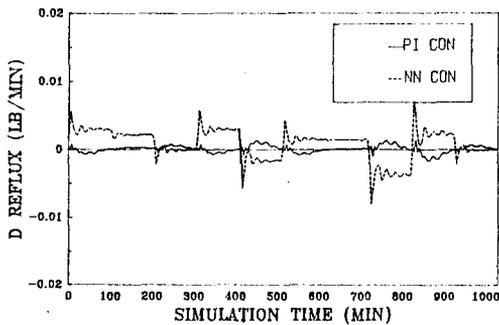
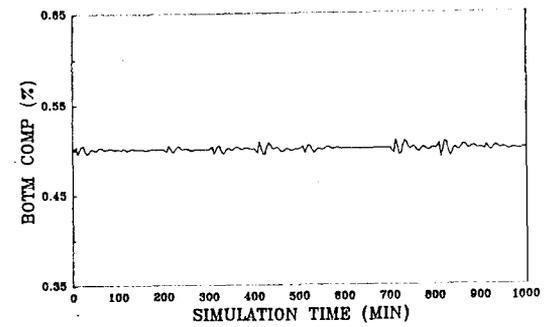
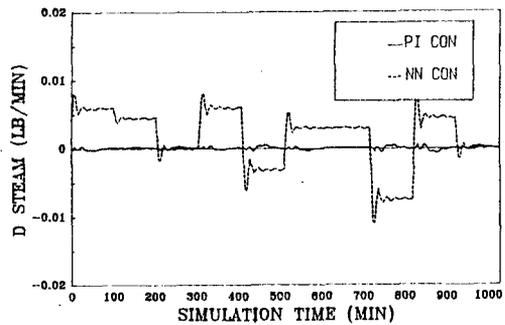


그림 9. 학습후의 신경제어기와 PI제어기의 제어동작 비교



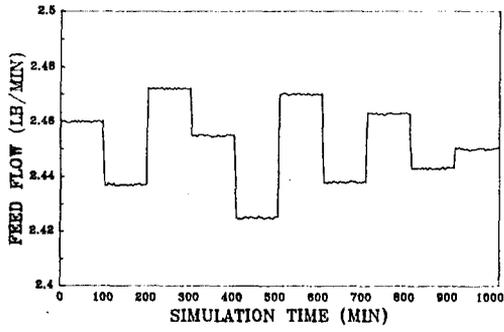
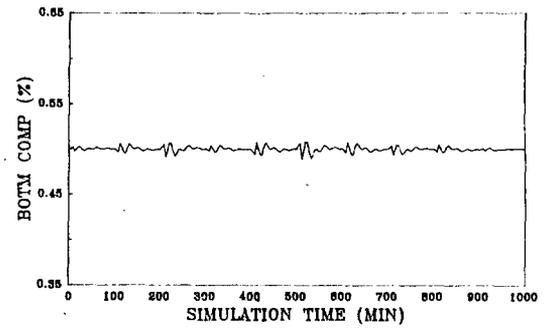
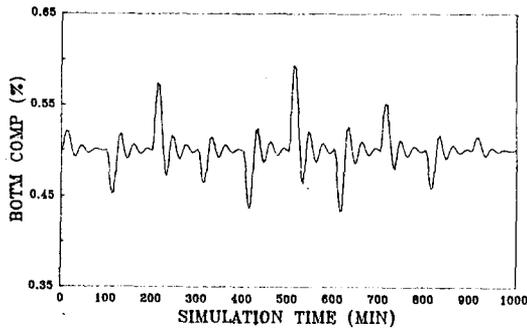
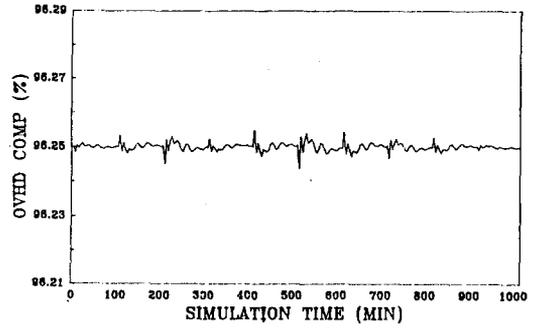
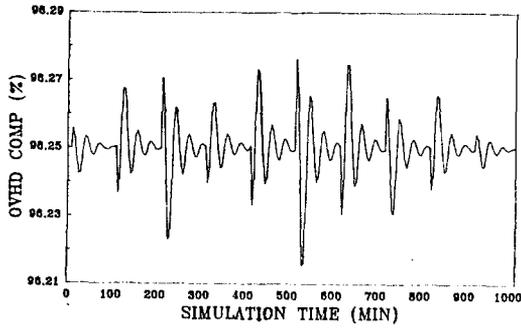


그림 10. Interpolation 효과분석에 쓰인 랜덤 외란



a) 기존구조

b) 신경제어기

그림 11. Regulatory 문제에서의 interpolation 효과

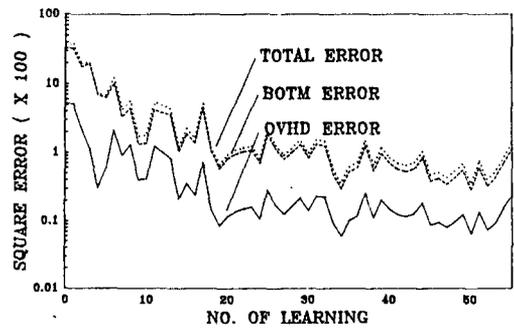
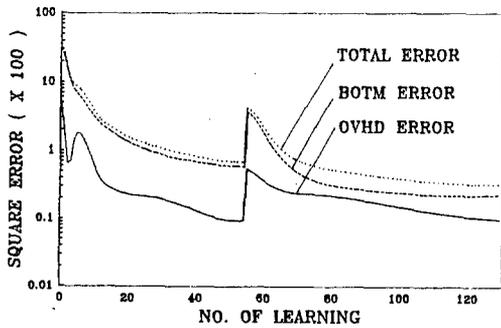


그림 12. 공정의 동적특성 변화에 따른 ISE 변화

그림 13. 랜덤 학습에 따른 ISE 변화