

# 신경회로망을 이용한 전기로의 온도제어

◦ 류제상, 최영규, 박준호  
부산대학교 전기공학과

## Temperature Control of Electric Furnace using Neural Network

◦ Jae-Sang Ryoo, Young-Kiu Choi, June-Ho Park  
Dept. of Electrical Eng. Pusan Nation University

### Abstract

In this paper, back-propagation neural network is used to implement a controller for electric furnace. Although the dynamics of furnace is nonlinear and time-delayed and depends on the environment, the time constant is relatively large so that manual control based on human expert can have good performance.

The input-output data of the manual controller are collected and used as training data for neurocontroller. From simulation, we find that the neurocontroller has better performances than the conventional controller.

### 1. 서론

전통적인 동적시스템 제어에서는 제어대상 시스템의 정확한 수학적 모델링을 필요로 하나, 실제 시스템이 비선형이고 시변인 경우에는 그 시스템을 정확히 모델링하는 것이 매우 어렵고 또한 정밀한 제어도 곤란하다. 실제로 발전소와 같은 복잡한 시스템에서는 많은 부분의 제어가 숙련된 작업자에 의해 수행되고 있다. 그런데 숙련된 작업자에 의한 제어법칙을, 제어대상의 상태 또는 출력과 제어대상의 입력간의 비선형함수로 표현할 수 있다. 인공신경회로망으로 비선형함수를 근사시킬 수 있다는 사실은 이미 잘 알려져 있으므로[1,2], 숙련된 작업자에 의한 제어방식을 인공신경회로망으로 표현하여 적절한 제어 특성을 얻을 수 있다[3].

한편 전기로는 전열부에 의해 열을 발생시켜 목표온도로 상승, 유지하게 되는데 이러한 시스템의 특성은 플랜트에서의 열의 저장과 방출에 관련되어 비선형적이며 시간지연이 크고 또한 시변이기 때문에 정확한 모델링과 정확한 제어가 매우 어렵다[4]. 그러나 전기로는 다른 종류의 플랜트에 비해서 시정수가 매우 큰 편이므로 수동조작에 의한 온도제어가 가능하며, 숙련된 작업자가 제어할 경우에 온도오차를 대폭 줄일 수 있다.

본 논문에서는 수동제어의 입출력관계로부터 제어를 비선형 매핑으로 보고, 플랜트의 출력과 입력벡터를 학습쌍으로 하여 제어를 신경회로망으로 실현하였다. 실현된 신경회로망 제어기의 제어 정밀도가 기존의 PID제어의 그것보다 매우 향상되었음을 확인할 수 있었다.

### 2. 전기로의 동적 방정식

본 연구에서 사용한 전기로의 동적방정식은 다음과 같은 형태로 나타낼 수 있다[5].

$$u^2 r = C[dT/dt] + [T - T_0]/R \dots \dots \dots (1)$$

단,  $u$ 는 전기로에 가한 전류,  $r$ 은 전기로의 전기저항,  $C$ 는 전기로의 열용량,  $T$ 는 전기로의 내부온도,  $T_0$ 는 전기로의 외부온도를 나타내며  $R$ 은 전기로의 열저항을 나타낸다.

전기로의 동적방정식은 시뮬레이션을 하기위해서 필요하며 실험에 의해 해당 파라미터 값을 구할 수 있다. 그림 1에서는  $T_0=13.5^\circ\text{C}$ 이고  $u=5\text{A}$  일때의 실험데이터들을 나타내고 또한 그러한 실험 데이터들에 가장 근접하는 동적모델의 출력을 나타낸다. 이러한 동적 모델의 파라미터 값은 다음과 같다.

\* 동적 모델의 파라미터값  
 $r = 3.5[\Omega]$ ,  $C = 972[\text{J}/^\circ\text{C}]$ ,  $R = 1.9[^\circ\text{C}/\text{W}]$




그림 1. 전기로의 계단입력에 대한 출력 데이터 및 근사 모델의 출력

### 3. 신경회로망에 의한 제어

앞에서와 같이 전기로의 동적 방정식의 시정수는 비교적 크므로, 고도로 숙련된 숙련자에 의한 수동제어는 기존의 PID제어보다 정밀한 온도제어를 가능하게 한다. 본연구에서는 목표온도가  $200^\circ\text{C}$ 일때에  $\pm 0.5^\circ\text{C}$ 의 오차범위에서 온도오차  $e(t) (=T_r(t) - T(t))$  단,  $T_r(t)$ 는 목표온도가 0으로 가계급 숙련자가 수동제어를 하여 발생시킨 제어량과 전기로의 온도 및 온도증분값  $\Delta e(t) (=e(t) - e(t - T_s))$  단,  $T_s$ 는 sampling time)을 신경회로망의 training data로 삼았다.




그림 2. raw data plotting( $\Delta e(t)=0$ 일때)

획득한 training data는 인간의 경험에 의한 것이므로 그림 2와 같이 매우 불규칙하고 상호 충돌이 일어나므로 이러한 data로는 신경회로망을 학습시키기 곤란하다. 이러한 문제를 해결하기 위해서 본 연구에서는  $e-\Delta e$  평면을 6400개의 작은 구역으로 세분화 하고 각 블록에 해당된 입력쌍은 중심값으로 하고,  $u$ 값은 평균값으로 취해서 그림 3과 같이 비교적 완만한 데이터로 변환시켰고 이러한 데이터로 신경회로망을 학습시켰다. 제어시스템의 구조는 그림 4와 같다.




그림 3. 구역별로 평균한 데이터




그림 4. 제어 시스템의 구조

#### 4. 시뮬레이션 및 고찰

온도오차  $e$ 가  $-0.5 \sim +0.5$  사이의 구간에서는 신경회로망에 의해 온도가 제어되고  $e \leq 0.5$ 이면  $u=20A$ 로 하여 온도를 제어하였고 실제 플랜트에서 사용 가능한  $u$ 의 최고값은  $20A$ 이다. 입력( $e, \Delta e$ )와 출력  $u$  각각의 학습쌍을 학습시키기 위한 학습 방법으로는 역전파 알고리즘을 사용하였고 신경회로망은 2층 구조이며 입력층, 은닉층, 출력층 뉴우런의 갯수를 각각 2개, 7개, 1개로 구성하였다. 학습률 파라메타  $\eta$ 와 모멘텀 파라메타  $\alpha$ 는 표1과 같다.


표 1. 학습 파라메타  $\eta$ 와 모멘텀 파라메타  $\alpha$

횟수	100,000	200,000	300,000	400,000	500,000
학습률	0.2	0.1	0.05	0.03	0.01
모멘텀	0.3	0.5	0.7	0.9	0.9

인공신경회로망 제어기와 성능을 비교하기 위하여 기존의 제어기로서 가장 널리 쓰이는 PID 제어기를 선택하였고 제어 이득을  $K_p=0.3, K_i=0.3, K_d=0.3$ 으로 설정하였다.

신경회로망 제어기와 PID 제어기 각각에 의한 계단 응답은 그림 5와 같으며 PID 제어기의 경우에 큰 오버슈트가 발생하는데 이것은  $U$ 가  $20A$  이상을 넘을 수 없기 때문인 것으로 생각된다. 그림 6에서는  $T_r(t) = 0.9325t + 13.5$ 에 대한 경사 응답을 각각에 대해 얻었고 신경회로망에 의한 제어기 PID 제어 보다 거의 섭동이 없이 정상상태에 도달함을 알 수 있었다. 또 그림 7에서는 외란이 있을 때 각각에 대한 결과를 얻었으며 신경회로망이 잡음에도 불구하고 상당히 좋은 제어특성을 유지하는데 반해 PID제어기의 제어기 특성은 매우 떨어 짐을 볼 수 있다.

##### (i) 신경회로망제어기



##### (ii) PID제어기





그림 5. 신경회로망 제어기와 PID 제어기의 계단 응답

##### (i) 신경회로망제어기



(ii) PID제어기





그림 6. 신경회로망 제어기와 PID 제어기의 경사용답

(i) 신경회로망제어기(20초 동안의 온도 변화)



(ii) PID제어기(120초 동안의 온도 변화)




그림 7. 온도 측정치에 noise가 있을 때의 결과

그림 5의 계단 응답에 대한 시뮬레이션 결과를 볼 때 정상 상태까지 도달하는 시간과 섭동이 기존의 PID제어보다 신경회로망에 의한 제어가 더 뛰어난 것을 알 수 있었다. 그림 7은  $\pm 0.1^{\circ}\text{C}$ 의 random noise를 0.2초 마다 온도 측정치에 발생시켰을 때 신경회로망이 잡음에 대해 강인함을 보였다.

5. 실험 장치




그림 8. 온도제어를 위한 블록 선도

그림 8과 같이 전기로제어 시스템을 구성하여 본 논문에서 제안한 방법을 적용한다.

전기로의 온도제어를 위한 전력공급회로는 아래 그림 9와 같다.




그림 9. 전기로 온도제어를 위한 전력회로

6. 결론

기존의 PID제어 방법과 신경회로망에 의한 전기로의 온도제어에 있어서 전자보다 후자가 과도상태와 정상상태에 이르는 동안 섭동이 거의 없음을 알 수 있었고 정상상태까지 소요되는 시간이 훨씬 적음을 보였다. 또한 신경회로망에 의한 전기로 온도제어를 할 경우 잡음에 대한 강인성이 뛰어난 것을 보였다.

시뮬레이션의 결과 기존의 제어방법에 의해서는 설정온도와 거의 차이가 없는 미세한 온도제어가 어려웠으나 신경회로망을 이용했을 경우 정밀한 온도제어의 가능성이 있음을 확인하였다.

속련자에 의한 training data 추출시 좀 더 세밀하고 적절한 학습데이터가 획득된다면 더욱 오차를 감소시킬 수 있는 결과를 얻을 수 있을 것으로 기대한다.

전기로 실험장치 및 인터페이스회로가 완성단계에 있으므로 조만간 신경회로망에 의한 전기로의 제어 특성을 실험적으로 얻고 평가할 예정이다.

참고 문헌

- [1] J.L.McClelland, D.E.Rumelhart and the PDP research group, "Parallel Distributed Processing: Exploitations of cognition", Vol.1., Badford books, Cambridge, MA, 1986.
- [2] K.S.Narendra and Parthasarathy "Identification & control of dynamical systems using neural networks", IEEE Transactions on Neural Networks, Vol.1, pp. 4-27, Mar., 1990.
- [3] Allen Guez, John Selinsky, "A neuromorphic controller with a human teacher," Int. Conf. Neural Networks, Vol II, pp.595-602, 1988.
- [4] 명노직 외 2인, "전기로의 퍼지제어에 관한 연구," 대한 전기학회 논문지 제40권 제12호 pp.1262-1268, 1991.
- [5] S.M.Shinners, Modern Control System Theory and Application, PP.128-130, Addison-Wesley, 1972.