

직접신경회로망 제어를 사용한 보일러 터빈시스템의 제어에 관한 연구

우주희, 김종안
한국전력공사 전력연구원

A Study on the Direct Neural Network Controller of Boiler Turbine

Woo Joo Hee, Kim Jong An
Korea Electric Power Research Institute

Abstract - 본 논문에서는 직접신경회로망제어기(DNNC)를 사용하여 결합된 PI제어기의 이득을 구하여 보일러 터빈시스템을 제어하고자 한다. 직접신경회로망제어기는 플랜트의 동특성을 학습시키는 에플레이터없이 제어입력에 대한 플랜트의 동작방향에 대한 정보만을 사용하여 신경회로망을 학습시키고, 이 신경회로망을 사용하여 제어대상 플랜트인 다중입출력플랜트를 제어하기위하여 결합된 PI 제어기의 이득을 구한다. 컴퓨터 시뮬레이션을 통하여 제안한 알고리즘의 타당성을 입증하고자 한다.

1. 서 론

구조가 간단하고 과도응답특성이 좋으며 정상상태오차를 제거할 수 있는 PID제어기가 현장에서 대부분 널리 쓰이고 있다. 또한 최근에는 현장 운전자의 지식을 효율적으로 반영하기 위한 인공지능을 이용한 제어기법이 여러 가지로 제시되고 있다. 그 한가지 예로 인간 두뇌의 특성을 모방하기 위해 고안된 신경회로망과 PID제어기가 결합되어 사용되는 방법이 제시되고 있다[1].

일반적으로 신경회로망을 이용하여 플랜트를 제어할 때 두 개의 신경회로망을 사용하여 하나는 플랜트의 동특성을 사전에 학습시키는 에플레이터로 사용하고 다른 하나는 주어진 제어성능을 만족하도록 제어신경회로망을 학습시키는 간접학습구조를 사용한다[2]. 본 논문에서 사용하는 신경회로망은 플랜트의 동특성을 학습시키는 에플레이터없이 사용하고자 한다. 이것을 직접신경회로망제어기(Direct Neural Network Controller, DNNC)라 부르고, 이 DNNC를 학습시키기 위해서는 신경망의 출력에러를 학습신호로 사용하여 야하나 일반적으로 제어입력의 기준신호는 알기 힘들다. 따라서 플랜트의 동작방향에 대한 정보를 사용하여[4] DNNC를 오차역전달알고리즘에 의해 학습시켜서 선형제어기의 이득을 구하고자 한다. 이렇게 구한 제어기가 제어성능을 만족시킴을 컴퓨터시뮬레이션을 통해 확인한다.

2. 보일러-터빈시스템 모델

보일러-터빈시스템의 동특성을 나타내는 많은 비선

형모델중에서 최근에 Bell과 Astrom의 많은 시뮬레이션에 의하여 신뢰도가 입증된 160MW 화력발전기용 모델을 사용하여 제안한 알고리즘의 타당성을 확인하고자 한다. 이 비선형모델[3]은 제어기를 설계하기에 부적절하여 Taylor급수 근사를 이용하여 중간부하점에서 선형화시킨다. 그 결과는 아래수식과 같으며 표 1에서 여러동작점에서의 변수값을 보여주고 있다.

$$\begin{aligned} \bar{x}_1 &= -0.002509\bar{x}_1 + 0.9\bar{u}_1 - 0.349\bar{u}_2 - 0.15\bar{u}_3 \\ \bar{x}_2 &= 0.0694\bar{x}_1 - 0.1\bar{x}_2 + 14.155\bar{u}_2 \\ \bar{x}_3 &= -0.00669\bar{x}_1 - 1.389\bar{u}_2 + 1.659\bar{u}_3 \\ \bar{y}_1 &= \bar{x}_1, \quad \bar{y}_2 = \bar{x}_2 \\ \bar{y}_3 &= 0.00634\bar{x}_1 + 0.00471\bar{x}_3 \\ &\quad + 0.253\bar{u}_1 + 0.512\bar{u}_2 - 0.014\bar{u}_3 \end{aligned} \quad (1)$$

$\bar{x} \equiv x - x^\circ$, $\bar{u} \equiv u - u^\circ$, $\bar{y} \equiv y - y^\circ$
여기서 상태변수 x_1 , x_2 , x_3 는 각각 드럼증기압 [kg/cm²], 전기적출력[MW], 드럼내의 유체농도 [kg/cm³]를 나타내고, 출력 y_3 는 드럼수위[m]를 나타낸다. \circ 표시는 각 변수의 공칭동작점을 나타낸다. 제어입력 u_1 은 보일러 연료조절기의 위치이며, u_2 는 터빈으로 가는 증기의 양을 조절하는 밸브의 위치이고, u_3 는 급수조절기의 위치이다. 이들 제어입력들은 모두 정규화되었으며 다음과 같은 제한을 갖는다.

$$\begin{aligned} |\dot{u}_1| &\leq 0.007/\text{sec}, \quad 0 \leq u_1 \leq 1 \\ -2/\text{sec} &\leq \dot{u}_2 \leq 0.02/\text{sec}, \quad 0 \leq u_2 \leq 1 \\ |\dot{u}_3| &\leq 0.05/\text{sec}, \quad 0 \leq u_3 \leq 1 \end{aligned} \quad (2)$$

표 1. 여러 동작점에서의 변수 값

동작점	($x_1^\circ, x_2^\circ, x_3^\circ$)	($u_1^\circ, u_2^\circ, u_3^\circ$)
90%	(97.2, 50.52, 385.2)	(0.271, 0.621, 0.34)
100%	(108, 66.65, 428)	(0.34, 0.69, 0.435)
110%	(118.8, 85.06, 470.8)	(0.418, 0.759, 0.543)

3. 제어시스템의 구성

본 논문에서 사용되는 플랜트모델을 제어하기 위한 전체 제어시스템구조는 그림 1과 같다.

3.1 DNNC의 구조

본 논문에서 사용하는 DNNC의 구조는 하나이상의

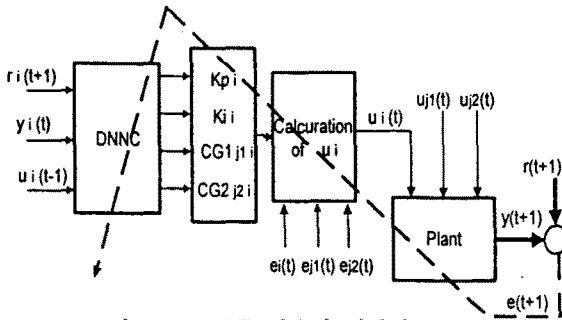


그림 1. DNNC를 이용한 제어기 구조

중간층을 가지는 다중신경회로망 구조를 가진다. 이 신경회로망에서의 신호흐름은 입력층이 주어지면 입력층에서 출력층으로 처리되는 순방향흐름과 이 순방향흐름에서 결정된 출력오차를 최소화하기 위해서 다시 출력층에서 입력층으로 오차를 역전달하면서 학습이 이루어지는 역방향흐름이 있다. 우선 순방향흐름은 아래와 같다

$$\begin{aligned} net_j &= \sum_{i=1}^I w_{ji} \cdot Out_i + \theta_j, \quad Out_j = f(net_j) \\ net_k &= \sum_{j=1}^J w_{kj} \cdot Out_j + \theta_k, \quad Out_k = f(net_k) \\ f(x) &= \frac{1}{1 + e^{-x}} \end{aligned} \quad (3)$$

$i = 1, 2, \dots, I, \quad j = 1, 2, \dots, J, \quad k = 1, 2, \dots, K$

여기서 i, j, k 는 각각 입력층, 중간층, 출력층의 노드 위치를, w_{ji} 와 w_{kj} 는 각층 사이의 가중치를 나타낸다. net_j 와 net_k 는 중간층 j 번째와 출력층 k 번째노드의 입력값을 나타낸다. θ_j, θ_k 는 각각 중간층, 출력층의 바이어스항을 나타낸다. Out_i, Out_j 와 Out_k 는 입력층 i 번째, 중간층 j 번째와 출력층 k 번째노드의 출력값을 나타낸다. 또한 $f(x)$ 는 활성화함수로서 미분가능한 비선형함수이며 0에서 1사이의 값을 가진다. 역방향흐름은 다음과 같다. 식 (4)와 같이 정의된 목적함수가 감소하는 방향으로 가중치를 학습시키는데 이를 위하여 최대경사법의 일종인 오차역전달알고리즘을 사용한다[5].

$$E(t+1) \equiv \frac{1}{2} \sum_{m=1}^M \{r_m(t+1) - y_m(t+1)\}^2 \quad (4)$$

$$w(t+1) = w(t) + \Delta w(t+1) \quad (5)$$

$$\begin{aligned} \Delta w(t+1) &= -\eta \frac{\partial E(t+1)}{\partial w(t)} \\ &= -\eta \frac{\partial E(t+1)}{\partial y(t+1)} \frac{\partial y(t+1)}{\partial u(t)} \frac{\partial u(t)}{\partial net(t)} \frac{\partial net(t)}{\partial w(t)} \end{aligned} \quad (6)$$

여기서 r, y, u 는 각각 기준입력, 플랜트출력, 제어입력을 나타내며, w 와 net 는 중간층 혹은 출력층의 해당 가중치와 노드의 입력을 나타낸다. η 는 신경망의 학습률을 나타낸다. 앞에서 살펴본 바와 같이 역방향 흐름에서 $\frac{dy}{du}$ 가 필요한데 일반적으로 미지의 제어대상 플랜트에 대해서는 이 정보를 알수가 없다. 그래서 플랜트의 동특성을 학습하기 위한 식별신경망을 사용하는 간접학습구조를 사용한다[2]. 그러나 이 학습구조는 플랜트의 동특성을 학습시키는데 오랜 시간이 필요하고 특히 플랜트의 동특성이 변한다면 식별신경망이 다시 학습할때까지 만족할만한 제어성능을 얻기

어려우므로 플랜트변화에 즉시 적응하기가 힘들다. 본 논문에서는 이러한 플랜트의 동특성을 학습시키는 식별신경망을 사용하지 않고 $\frac{dy}{du}$ 의 방향만 고려하기로 한다[4]. 대부분의 플랜트는 제어입력이 증가 또는 감소하면 플랜트의 출력도 증가 또는 감소하는 정반응 플랜트와 그렇지 않은 역반응 플랜트로 나눌수 있다. 여기서 전자의 경우 $\frac{dy}{du} = 1$, 후자의 경우 $\frac{dy}{du} = -1$ 로 두어 제어신경망을 학습시킨다. 이 부호의 결정은 단위계단입력이나 경사입력을 플랜트에 인가하여 그 출력방향을 보고 결정할 수 있다.

3.3 결합된 PI 제어기

기존의 선형제어기의 우수성을 그대로 이용하고자 여러분야에서 성공적으로 사용되고 있으며 비교적 구현방법이 쉬운 제어방식인 PI제어기를 사용한다. 또한 MIMO인 제어대상플랜트를 제어하기위하여 PI제어기 값에 커플드항을 추가하여 시각 i 에서의 i 번째 제어입력을 결정한다. 즉 $u_i(t)$ 는 $e_i(t)$ 에 의해 PI이득 (Kp_i, Ki_i)이 결정되고, 나머지 제어오차 $e_{j_1}(t), e_{j_2}(t)$ 에 의해 커플드이득 (CG_{j_1i}, CG_{j_2i})이 결정된다.

$$u_i(t) = Kp_i e_i(t) + Ki_i T \sum_{m=0}^i e_i(m) + CG_{j_1i} e_{j_1}(t) + CG_{j_2i} e_{j_2}(t) \quad (7)$$

여기서, $i = 1, 2, 3$

$$\begin{aligned} j_1, j_2 &\neq i \text{ and } j_1, j_2 = 1, 2, 3 \\ e_i(t) &= r_i(t) - y_i(t) \\ Kp_i &= f(net_{j_1}), \quad Ki_i = f(net_{j_2}) \\ CG_{j_1i} &= f(net_{j_3}), \quad CG_{j_2i} = f(net_{j_3}) \end{aligned}$$

T 는 샘플링주기를 나타낸다. 이들 계수의 선택이 제어기 성능을 좌우하는 중요한 요소임에도 불구하고 주어진 시스템에서 최적의 계수를 결정하는 것은 쉽지 않다. 따라서 본 논문에서는 4절에서 설명하는 DNNC를 사용하여 이들 계수를 구하고자 한다.

4. DNNC를 이용한 제어기 설계

$u_i(t)$ 의 제어기이득을 구하기 위한 DNNC의 학습을 위한 출력층의 가중치변화는 아래와 같다.

$$\begin{aligned} \Delta w_{kj}(t+1) &= -\eta \frac{\partial E(t+1)}{\partial w_{kj}(t)} \\ &= -\eta \frac{\partial E(t+1)}{\partial u_i(t)} \frac{\partial u_i(t)}{\partial Out_k(t)} \frac{\partial Out_k(t)}{\partial net_k(t)} \frac{\partial net_k(t)}{\partial w_{kj}(t)} \\ &= \eta \delta_k Out_j \end{aligned} \quad (8)$$

$$\text{여기서, } \delta_k \equiv \frac{\partial E(t+1)}{\partial u_i(t)} \frac{\partial u_i(t)}{\partial Out_k(t)} \frac{\partial Out_k(t)}{\partial net_k(t)}$$

$$\frac{\partial E(t+1)}{\partial u_i(t)} = \sum_{m=1}^3 \{r_m(t+1) - y_m(t+1)\} \left| \frac{\partial y_m(t+1)}{\partial u_i(t)} \right|$$

$$\frac{\partial u_i(t)}{\partial Out_k(t)} = \begin{cases} e_i(t) & , k=1 (Kp_i) \\ T \sum_{m=0}^i e_i(m) & , k=2 (Ki_i) \\ e_{j_1}(t) & , k=3 (CG_{j_1i}) \\ e_{j_2}(t) & , k=4 (CG_{j_2i}) \end{cases}$$

$$\frac{\partial Out_k(t)}{\partial net_k(t)} = f'(net_k)$$

$$\theta_k(t+1) = \theta_k(t) + \eta \delta_k \quad (9)$$

중간층의 가중치변화는 다음과 같다.

$$\begin{aligned} \Delta w_{jk}(t+1) &= -\eta \frac{\partial E(t+1)}{\partial w_{jk}(t)} \\ &= -\eta \frac{\partial E(t+1)}{\partial Out_j(t)} \frac{\partial Out_j(t)}{\partial net_k(t)} \frac{\partial net_k(t)}{\partial w_{jk}(t)} \\ &= \eta \delta_j \cdot Out_k(t) \end{aligned} \quad (10)$$

여기서 $\delta_j = f'(net_j(t)) \sum_{k=1}^n \{\delta_k \cdot w_{jk}(t)\}$

$$\theta_j(t+1) = \theta_j(t) + \eta \delta_j \quad (11)$$

주어진 모델의 방향을 찾기위하여 어떤 한 입력에 경사입력을 인가하고 나머지 두 입력은 정상상태값을 입력시켜 주어진 입력에 대하여 플랜트 출력이 증가 혹은 감소하는지 살펴본다. u_1 변화에 대한 y_1, y_2 변화는 같은방향이고 y_3 는 반대방향이며, u_2 변화에 대한 y_2 변화는 같은방향이고 y_1, y_3 는 반대방향이며, u_3 변화에 대한 y_3 변화는 같은방향이고 y_1, y_2 는 반대방향이다. u_i 에 대한 이득을 구하기위해 i 번째 제어입력을 제외한 나머지 제어입력은 표 1에서 주어진 정상값을 입력하여 u_i 에 대한 4개의 이득을 DNNC를 학습시켜 구한다. 두 번째 제어입력에 대한 4개의 이득은 앞에서 구한 4개의 이득과 표 1에서의 정상값을 입력하여 DNNC를 학습시켜 구한다. 마지막 세 번째 제어입력은 앞에서 구한 8개의 이득을 사용하여 DNNC를 학습시켜 구한다. 또한 학습시 과포화를 막기위해 아래와 같은 조건하에서는 학습을 시키지 않았다($\eta=0$).

$$\left\{ \begin{array}{l} u_i \text{가 속도제한치의 한계값을 벗어날 때} \\ u_i(t) = u_{High} \text{ 이고 } \frac{\partial E(t+1)}{\partial u_i(t)} > 0. \\ u_i(t) = u_{Low} \text{ 이고 } \frac{\partial E(t+1)}{\partial u_i(t)} < 0. \end{array} \right.$$

여기서 속도제한치란 식 (2)에서 제시한 값이고 $u_{High} = 1, u_{Low} = 0$ 을 각각 나타낸다.

5. 모의실험

DNNC를 사용한 결합된 PI제어기의 성능을 분석하기 위해 컴퓨터시뮬레이션으로 그 결과를 확인하였다. 입력층, 중간층, 출력층의 노드수는 3, 15, 4개로 하였고 초기 가중치는 0에서 0.01사이의 임의수로 하였으며 학습율은 0.0001로 하였다. 모의실험은 초기상태에서 각 제어입력에 대한 4개의 이득을 구하고(표 2) 이때의 동작결과와 정상상태에서 동작점을 변화했을때의 추적성능(그림 3, 4)을 표 1의 결과를 만족시키는지 확인해본 결과 다소 진동하는 출력을 보이지만 정상상태값은 서로 일치함을 보여주고 있다.

표 2. DNNC를 사용하여 구한 제어기 이득

i	j_1	j_2	Kp_i	Ki_i	$CG_{j_1 i}$	$CG_{j_2 i}$
1	2	3	0.5619	0.0350	0.5186	0.0643
2	1	3	0.5133	0.1628	0.4516	0.0581
3	1	2	0.8187	0.0010	0.4907	0.5013

6. 결 론

본 논문에서는 플랜트의 동작방향을 결정하여 신경회로망을 학습시켜 결합된 선형제어기의 이득 12개를 구

하여, 3개의 입출력을 가지는 선형화시킨 보일러 터빈 모델식에 적용하였다. 그 결과 플랜트 출력이 다소 진동하는 결과를 보이지만 정상상태값을 잘 추적함을 볼 수 있었다. 따라서 본 논문에서 제안한 방법이 MIMO 시스템의 PI 이득의 초기값 결정에 도움이 되며, 제시한 학습알고리즘중에 η 를 0으로 두는 조건에 대한 조사 및 학습시 필요한 각종 파라메타의 미세조정대 대한 연구가 앞으로 더 진행되어야 한다.




그림 2. 정상상태에서 110%로 변할때의 제어입력




그림 3. 정상상태에서 110%로 변할때의 y_1, y_2




그림 4. 정상상태에서 110%로 변할때의 y_3

[참 고 문 헌]

- [1] Saiful Akhyar and Sigeru Omatu, "Neuromorphic Self-Tuning PID Controller", IEEE Int. Conference on Neural Networks, pp. 552~557, 1993
- [2] K.S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks", IEEE Trans. Neural Networks, vol. 1, no. 1, pp 4~27, 1990
- [3] R. Dimeo, Kwang Y. Lee, "Boiler-Turbine Control System Design Using a Genetic Algorithm", IEEE Trans. on Energy Conversion, vol. 10, no. 4, pp. 752~759, 1995
- [4] Xianzhong Cui, Kang G. Shin, "Direct Control and Coordination Using Neural Networks", IEEE Trans. on Systems, Man, and Cybernetics, vol. 23, no. 3, pp. 686~697, 1993
- [5] J.M. Zurada, "Introduction to Artificial Neural Systems", WEST, pp. 186~190, 1992