

# 자기학습 퍼지제어기를 사용한 하이브리드 제어기 설계

양해원, 이호형<sup>o</sup>  
한양대학교 전기공학과

## A Design of Hybrid Controller Using Self-Learning Fuzzy Controller

H. W. Yang, H. H. Lee<sup>o</sup>  
Dept. of Electrical Engineering, Hanyang University

### ABSTRACT

The PID controller is widely used due to its fast response and robustness. But its performance is not so good compared with modern controllers such as adaptive, robust, fuzzy, neural controller. Therefore, it is natural to replace PID controller by modern controllers. But, the problem is that modern controller can not be easily applied to the real time process. Hence, this paper proposes such a structure that PID controller and Self-Learning Fuzzy Controller(SLFC) are in parallel with each other. The parameter of SLFC will be updated by gradient descent method using neuro-identifier. The usefulness of this hybrid controller will be proved by simulation results.

### 1. 서론

기존의 PID 제어기는 빠른 응답성과 강인함때문에 널리 쓰이고 있는 제어기이지만, 정밀한 제어가 어렵고, operator가 상황에 맞게 각각의 이득값을 조정해 주어야 하며, 작동중에 생기는 뜻하지 않은 상황에 대해 제어하기가 매우 어렵다. 이러한 문제에 대해 이득값을 퍼지 알고리즘을 이용하여 투명화시키니, 적용성을 갖는 제어기를 연결하는 등<sup>[2]</sup>, 이러한 방법을 모색하였다. 그러나, Rule Base의 고정성, 플랜트에 대한 정보를 가지고 있지 않는 점 등 많은 문제점을 가지고 있다. 본 논문에서는 PID 제어기와 신경회로망-식별기의 정보를 이용하는 자기 학습 퍼지 제어기를 병렬로 연결한 하이브리드제어기를 구현하였다. 여러 가지 플랜트에 대하여 모의실험을 행함으로써 이 제어기의 효용성을 제시하고자 한다.

### 2. 신경회로망-식별기(Neuro-Identifier)

신경회로망은 비선형 mapping 능력과 식별기능 때문에 요사이 널리 쓰이고 있다<sup>[3]</sup>. 여러 가지 신경회로망 중에서도 자체 메모리 특성을 가지고 있는 Recurrent Neural Network(RNN)에서 변형된 Locally Recurrent Neural Network(LRNN)은 구조가 간단하고, 기능도 좋은 편이다<sup>[5]</sup>. 이 신경망의 구조는

$$O(k) = \sum_j W_{ji} X_j(k), \quad X_j(k) = f(S_j(k)) \quad (1)$$

$$S_j(k) = W_j X_j(k-1) + \sum_i W_{ji} I_i(k) \quad (2)$$

와 같으며, 여기서  $I_i(k)$ 는 LRNN의  $i$ 번째 입력을,  $S_j(k)$ 와  $X_j(k)$ 는 은닉층의  $j$ 번째 입력과 출력을,  $W_{ji}$ ,  $W_j$  와  $W_i$ 는

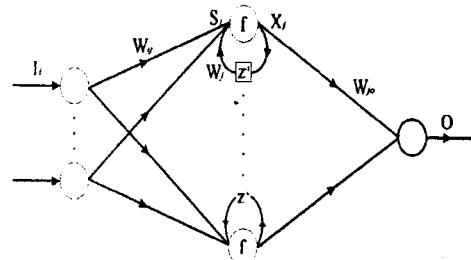


그림 1 LRNN의 구조

입력층과 은닉층, 은닉층과 출력층, 은닉층 뉴런 자신을 연결하는 가중치를,  $O(k)$ 는 최종 출력값을 각각 나타낸다. 은닉층의 뉴런들은 sigmoid 특성을 갖고 있지만, 출력층 뉴런은 선형적 특성을 갖는다.  $y(k)$ 를 플랜트의 출력이라 하고,  $E_a = 0.5 (y(k) - O(k))^2$ 를 식별기의 목적함수로 사용하여 가중치들( $W(k)$ )을 수정하면,

$$W(k+1) = W(k) - \eta_a \frac{\partial E_a}{\partial W} \quad (\eta_a = \text{식별기의 학습률}) \quad (3a)$$

$$\frac{\partial E_a}{\partial W} = -(y(k) - O(k)) \cdot \frac{\partial O(k)}{\partial W} \quad (3b)$$

(3b)식에서  $\frac{\partial O(k)}{\partial W}$ 은

$$\frac{\partial O(k)}{\partial W_{ji}} = X_j,$$

$$\frac{\partial O(k)}{\partial W_j} = W_{ji} \cdot \frac{\partial X_j(k)}{\partial W_j(k)} = W_{ji} P_j(k),$$

$$\frac{\partial O(k)}{\partial W_i} = W_{ji} \cdot \frac{\partial X_j(k)}{\partial W_i(k)} = W_{ji} Q_{ji}(k) \quad (4a)$$

$$P_j(k) = f'(S_j(k))(X_j(k-1) + W_j P_j(k-1)),$$

$$Q_{ji}(k) = f'(S_j(k))(I_i(k) + W_{ji} Q_{ji}(k-1)) \quad (4b)$$

### 3. 자기학습 퍼지제어기(Self-Learning Fuzzy Controller)

SLFC는 개선되어야 할 변수들을 가지고 있는 square 뉴런들과 그러한 변수들을 갖지 않는 circle 뉴런들로 구성된 다중 신경망 구조로되어 있으으며, Takagi - Sugeno 형식의 if-then 규칙을 포함하고 있다. 그림 2에 이 제어기 구조를 나타내

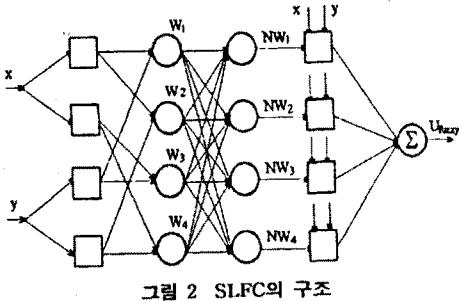


그림 2 SLFC의 구조

있다. 수식으로 표현하면,

$$O_i^1 = \mu_i(x) = \exp(-|x - a_i|^b) \quad (i=1 \text{ 또는 } 2) \quad (5a)$$

$$O_j^1 = \mu_j(y) = \exp(-|y - a_j|^b) \quad (j=3 \text{ 또는 } 4) \quad (5b)$$

$$W_m = \mu_i(x) \mu_j(y) \quad (6)$$

$$NW_m = \frac{W_m}{\sum_{m=1}^4 W_m} \quad (7)$$

$$U_{fuzzy} = \sum_{m=1}^4 NW_m (p_m x + q_m y + r_m) \quad (8)$$

이다. 첫째층 square 뉴런들은 소속함수를 나타내는 뉴런들로써 입력  $x(y)$ 에 대한 변수  $a_1, a_2, b_1, b_2, a_3, a_4, b_3, b_4$ 을 가지고 있으며,  $a$  와  $b$ 는 각각 중심값과 폭을 나타낸다. 둘째층 circle 뉴런들은 입력신호들을 모두 끊어지지 출력하는 뉴런들이며, 셋째층 circle 뉴런들과 넷째층 square 뉴런들은 식 (7), (8)에서와 같이 규격화된 값과 입력 값과 관련된 파라미터들 ( $p_m, q_m$ )을 이용하여 if-then 규칙에 대한 최종 값을 각각 출력한다. 다섯째층 circle 뉴런은 최종 값을 모두 합한 SLFC의 제어입력을 출력한다. 원하는 궤적값과 플랜트 출력값을  $ref(t)$ ,  $y(t)$ 라 하고, 현재부터 이전의  $(P+1)$  step 까지 목표함수들의 합을 이용하여,

$$E = \sum_{t=k-P}^k E_t = 0.5 \sum_{t=k-P}^k (ref(t) - y(t))^2 = 0.5 \sum_{t=k-P}^k e^2(t) \quad (9)$$

파라미터( $\psi(k)$ )들을 수정하면 다음과 같다.

$$\psi(k+1) = \psi(k) - \eta_c \frac{\partial E}{\partial \psi(k)} \quad (\eta_c \text{는 SLFC의 학습률}) \quad (10)$$

$$\frac{\partial E_t}{\partial p_m} = -e(t) \frac{\partial y}{\partial u} \frac{\partial u}{\partial p_m} = -e(t) \cdot \frac{\partial y}{\partial u} \cdot NW_m \cdot x \quad (11)$$

$$\frac{\partial E_t}{\partial q_m} = -e(t) \frac{\partial y}{\partial u} \frac{\partial u}{\partial q_m} = -e(t) \cdot \frac{\partial y}{\partial u} \cdot NW_m \cdot y \quad (12)$$

$$\begin{aligned} \frac{\partial E_t}{\partial a_{k,j}} \text{ (또는 } \frac{\partial E_t}{\partial b_{k,j}}) &= -e(t) \frac{\partial y}{\partial u} \frac{\partial u}{\partial a_{k,j}} \\ &= -e(t) \frac{\partial y}{\partial u} \sum_{m=1}^4 \frac{\partial u}{\partial NW_m} \frac{\partial NW_m}{\partial a_{k,j}} \end{aligned} \quad (13)$$

$$\begin{aligned} \frac{\partial NW_m}{\partial a_{k,j}} \text{ (또는 } \frac{\partial NW_m}{\partial b_{k,j}}) &= \frac{\frac{\partial W_m}{\partial a_{k,j}} \sum_{m=1}^4 W_m - W_m \sum_{m=1}^4 \frac{\partial W_m}{\partial a_{k,j}}}{(\sum_{m=1}^4 W_m)^2} \end{aligned} \quad (14)$$

$$\frac{\partial W_m}{\partial a_{k,j}} = -b_{k,j} \cdot W_m \cdot |x(y) - a_{k,j}|^{b_{k,j}-1} \quad (15)$$

$$\frac{\partial W_m}{\partial b_{k,j}} = -W_m \cdot \ln|x(y) - a_{k,j}| \cdot |x(y) - a_{k,j}|^{b_{k,j}} \quad (16)$$

여기서, 식별기의 첫번째 입력이  $u(k)$ , 두번째 입력이  $y(k-1)$ 라 할 때 식(2)를 이용하여  $\frac{\partial y(k)}{\partial u(k)}$ 를 구하면,

$$\frac{\partial y(k)}{\partial u} = \sum_j \frac{\partial O_j(k)}{\partial X_j(k)} \cdot \frac{\partial X_j(k)}{\partial S_j(k)} \cdot W_b \quad (17)$$

#### 4. 하이브리드 제어기

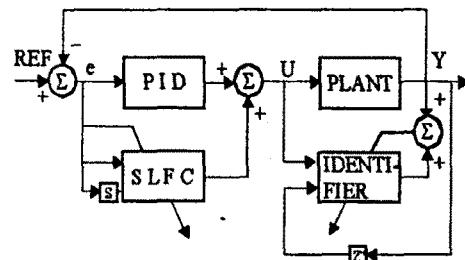


그림 3 하이브리드 제어기의 구조

그림 3은 기존의 PID 제어기에 다른 제어기를 병렬로 연결한 하이브리드 제어기 구조이다. PID 제어기는 정밀한 제어나 알맞은 이득값을 설정해야 하는 등 단점이 많지만 빠른 응답성을 가지고 있다. SLFC는 정상상태에서 정밀한 제어가 가능하고 외부환경 변화에 강인한 특성을 갖고 있으나, 플랜트의 입·출력 패턴을 학습하는 신경회로망의 정보를 가지고 임의로 초기화 되어 있는 파라미터들을 식 (9)에서 주어지는 목적함수를 이용하여 수정하기 때문에 과도상태 응답이 좋지 못하다. 이와 같이, 서로의 장·단점을 보완한 하이브리드 제어기는 과도상태나 정상상태에서 우리가 원하는 제어동작을 할 수 있다.

#### 5. 모의 실험

그림 4는 선형 안정 플랜트  $\dot{y} + 2\dot{y} + y = u(t)$ 에 대한 실험 결과이다.

원하는 궤적은  $ref(t) = \cos(\pi \cdot t/5) + 0.2 \cdot \cos(\pi \cdot t/10)$ 이며 PID의 이득값은  $K_p = 5, K_d = 1, K_i = 5$ , LRNN의 식별기 구조는 2-10-1,  $\eta_c$ (SLFC의 학습률)은 0.05,  $\eta_a$ (식별기의 학습률)은 0.1,  $T_s$ (샘플링 시간)은 0.01로 하여 얻은 결과이다.

SLFC 파라미터들의 변화를 각 경우에 대하여 표 1에 나타내 있고, 이때 100 step까지 목적함수들의 합을 이용하여 수정하였다.

그림 5는 30초에서 플랜트가  $\dot{y} + 0.9\dot{y} + 0.2y = u(t)$ 에서

$\dot{y} + 2\dot{y} + y = u(t)$ 로 급변하는 상황에 대한 실험결과이다.

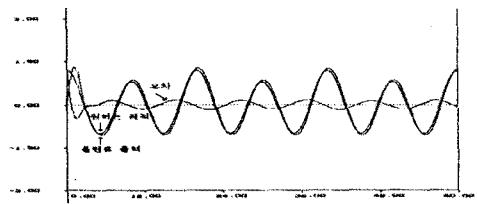
원하는 궤적은  $ref(t) = \cos(\pi \cdot t/5)$ 이다. 그림 6은

$\dot{y} + (0.4 + a(t))\dot{y} - (0.5 + a(t))y = u(t) \quad (|a(t)| < 0.1)$ 와 같은 time-varying 불안정 플랜트에 대한 실험 결과이다.

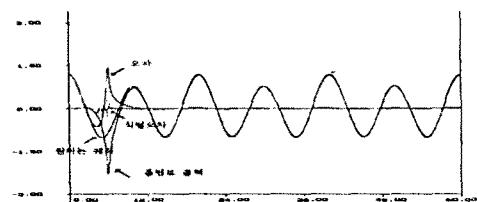
PID의 이득값은  $K_p=5, K_d=2, K_i=5, \eta_c$ (SLFC의 학습률)은 0.01,  $\eta_a$ (식별기의 학습률)은 0.1로 하여 얻은 결과이다. 그림 7은 비선형 플랜트,  $0.314\dot{q} + 0.007\ddot{q} + 0.8\sin q = u(t)$ 에 대하여 주기가 8초이고, 크기가  $\pi \cdot 5/2$  인 구형파를 입력으로 하는 기준모델  $4/(s^2 + 4s + 4)$ 의 출력을 따라가도록

하였다.  $K_p = 5$ ,  $K_d = 1$ ,  $K_i = 5$ ,  $\eta_a = 0.0007$ ,  $\eta_c = 0.01$ 로 하여 일은 결과이다.

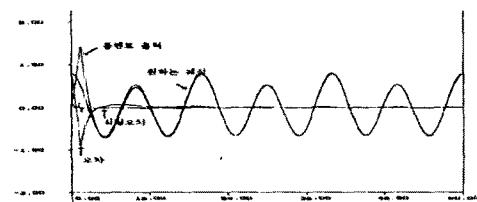
자기학습 퍼지 제어기의 공통적 현상은 파라미터들을  $(P+1)$  step까지 목적함수들의 합으로 수정하고자 할 때 과도상태에서의 불안정성을 들 수 있다. 따라서 Lyapunov 함수를 이용하여 안정한 작용치를 구하거나 파라미터들의 발산을 막기 위한 알고리즘의 개발이 필요하다.



a) PID 제어기

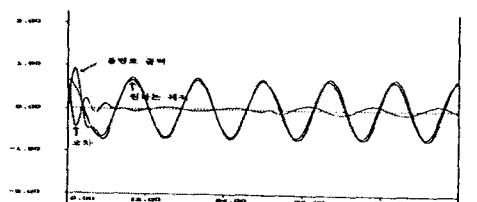


b) SLFC

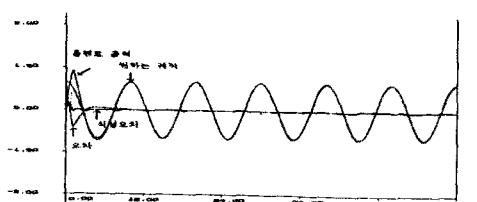


c) 하이브리드 제어기

그림 4 선형 안정 플랜트에 대한 여러가지 모의실험



a) PID 제어기



b) 하이브리드 제어기

그림 5 플랜트가 급변할때의 모의실험

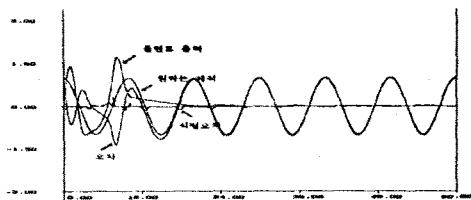


그림 6 시변 불안정 플랜트

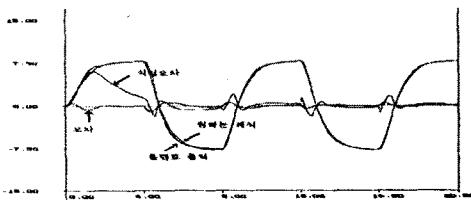


그림 7 비선형 플랜트

## 6. 결론

PID 제어기와 자기 학습 퍼지 제어기(SLFC)를 병렬로 연결한 하이브리드 제어기는 과도 상태에서는 PID 제어기가 주제어기로, 정상 상태에서는 SLFC가 주제어기로 그 역할을 하게 되어 빠른 응답성과 정밀한 제어를 할 수 있는 제어기 구조이다. 그러나, 만족할 만한 tracking을 하여도 SLFC의 내부 파라미터들의 유계성을 보장하는 문제를 해결해야 안정성을 보장할 수가 있다. 따라서, 안정되게 최적의 값으로 파라미터들을 수렴하도록 하는 것이 앞으로의 연구방향이다.

## 참고문헌

- [1] Z. Y. Zhao and S. Isaka, "Fuzzy Gain Scheduling of PID Controllers," IEEE Trans. Syst., Man, Cybernetics, vol. 23, No. 2 1993, pp. 1392-1398.
- [2] R. E. Nordgren, P. H. Meekl, "An Analytical comparison of a Neural Network and a Model-Based Adaptive controller," IEEE Trans. Neural Networks, vol. 4, No. 4, 1993, pp. 685-694.
- [3] K. S. Narendra and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks," IEEE Trans. Neural Networks, vol. 1, No. 1, 1990, pp. 4-27.
- [4] J. R. Jang, "Self-Learning Fuzzy Controllers Based on Temporal Back Propagation," IEEE Trans. Neural Networks, vol. 3, No. 5, 1992, pp. 714-723.
- [5] C.C. Ku, K.Y. Lee, "System Identification and Control Using Diagonal Recurrent Neural Networks," ACC, 1992, pp. 545-549.

표 1. SLFC 파라미터들의 변화

	a1	a2	a3	a4	b1	b2	b3	b4
초기값	3	-3	7	-7	0.4	0.4	0.1	0.1
SLFC	3.47	11.7	7.06	-7	-4.4	6.63	4.55	-1.4
하이브리드	4.02	23.1	7.04	-7	7.4	-5.5	4.4	-2.3
p1	p2	p3	p4	q1	q2	q3	q4	
0	0	0	0	0	0	0	0	
3.7	37.3	1.26	2.41	0.41	47.6	0.27	-2.31	
1.77	2	2.6	43.5	0.1	-0.5	-4.4	42.0	