

신경망을 이용한 PID제어기의 적응동조에 관한 연구

김상원*, 이홍규
한국기술교육대학교 전기전자공학과

A Study on Adaptive-Tuning of PID Controller
Using a Neural Network

Sang-Won Kim*, Hong-Kyu Lee

Dept. of Electric and Electronic Eng., Korea Univ. of Technology and Education

Abstract - In this thesis, We implement the controller system only using the neural network to identify the plant characteristics with keeping the PID controller structure. The neural network has learned by the adaptive learning rates that has suggested by Chao-Chee Ku and the DBP algorithm. We proposed the on-line tuning algorithm about the unknown plant using the adaptive tuning technique. As a result of executing the parameters has tuned from the initial value to more suitable ones, and the output of the plant has improved and also it is appeared that the convergence is guaranteed.

1. 서 론

현대 제어이론의 급격한 발전에도 불구하고 산업현장에서는 PID제어기가 주종을 이루고 있는데 이것은 PID제어기가 단순한 구조를 가지면서도 강인한 특성을 갖고 있기 때문이다. J.G.Ziegler와 N.B.Nichols가 최초로 PID 매개변수에 대한 체계적인 동조방법을 제안한 후 국내에 많은 사람들에 의해 PID제어기의 매개변수를 체계적으로 동조할 수 있는 알고리즘이 개발되어 왔으며, 최근에는 신경망을 PID제어기에 융합시켜 PID제어기의 특성을 유지하면서 자동동조의 문제를 해결하려는 노력이 시도되어 왔다.^{[3][5]} 그러나 신경망을 이용한 페루프시스템의 안정도는 대단히 중요한 과제로 자리잡고 있으며 잘 알려진 바와 같이 신경망 제어시스템의 안정도는 학습율과 매우 밀접한 관계를 갖는다.^{[1][2][4]} 본 논문에서는 Chao-Chee Ku 등이 제안한 대각 회귀 신경망(Diagonal recurrent neural network : 이하 DRNN)을 이용한 PID제어기의 적응동조 방법을 제안하고자 한다.

2. 본 론

2.1 신경망을 이용한 PID제어기

2.1.1 DRNN의 DBP 알고리즘

Chao-Chee Ku 등이 제안한 DRNN은 한 개의 은닉층 뉴런을 가지며 은닉층 뉴런에서 각각 자신에게로만 회귀하는 연결을 갖는 구조로 은닉층 뉴런 전체로 회귀하는 FRNN(Fully connected recurrent neural network)보다 적은 연결을 가지면서도 플랜트의 동특성을 충분히 모사할 수 있다. 따라서 단순한 구조로 짧은 학습시간이 요구되므로 온-라인 제어시스템에 보다 유리하게 적용할 수 있다.

본 논문에서는 PID 매개변수 적응동조시 요구되는 입·출력 감도(Sensitivity)를 추정하는 플랜트 식별기(Identifier)로 사용하였으며, DRNN의 구조는 그림 1

과 같다.

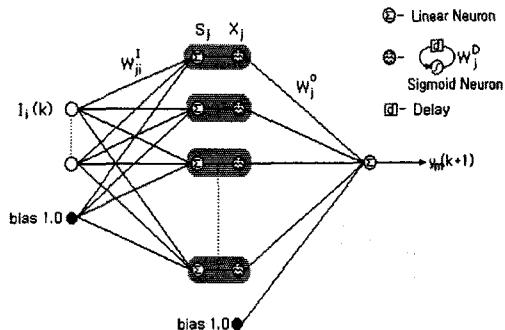


그림 1. DRNN 구조

DRNN의 출력은 다음과 같다.

$$S_j(k) = \sum_{i=1}^{n+1} W_{ij}^I I_i(k) + W_j^D X_j(k-1) \quad (1)$$

$$I_{n+1}(k) = bias$$

 n : 입력의 수, h : 은닉층 뉴런의 수

$$X_j(k) = f_{sig}(S_j(k)) \quad (2)$$

$$f_{sig}(S_j(k)) = \frac{1}{1 + e^{-S_j(k)}}$$

$$Y_M(k+1) = \sum_{j=1}^{n+1} W_j^O X_j(k) \quad (3)$$

$$X_{n+1}(k) = bias$$

여기서 W_{ij}^I 는 은닉층의 j 번째 뉴런과 i 번째 입력간의 가중치, W_j^D 는 j 번째 뉴런에서 자신에게로 회귀하는 연결의 가중치, W_j^O 는 j 번째 뉴런과 출력층간의 가중치이고 X_j 는 j 번째 뉴런의 출력, $I_i(k) = [u(k), y_p(k)]^T$ 이며 은닉층 뉴런의 활성화 함수는 시그모이드 함수이다.

플랜트의 입·출력 감도를 추정하는 DRNN을 DRNI (Diagonal recurrent neuroidentifier)라 하며 DRNI 학습을 위한 오차함수는 다음과 같다.

$$E_M(k) = \frac{1}{2} (y_p(k) - y_M(k))^2 = \frac{1}{2} e_M(k)^2 \quad (4)$$

각 층에 대한 가중치의 변화는 오차함수가 감소하는 방향 즉, 부경사도(Negative gradient) 방향으로 이루어져야 하므로 가중치의 갱신 식은 다음과 같다.

$$W(k+1) = W(k) + \Delta W(k) \quad (5)$$

$$\Delta W(k) = -\eta_M \frac{\partial E_M(k+1)}{\partial W(k)}$$

여기서 η_M 는 DRNI의 학습율이다.

한편, 플랜트의 입·출력 감도는 일반적으로 알려져 있지 않으므로 플랜트와 DRNI의 온·라인 학습을 통하여 구할 수 있으며 DRNI가 플랜트의 동특성을 잘 추정한다고 가정하면 다음과 같이 정할 수 있다.

$$\begin{aligned} \frac{\partial y_P(k+1)}{\partial u(k)} &\approx \frac{\partial y_M(k+1)}{\partial u(k)} \\ \frac{\partial y_M(k+1)}{\partial u(k)} &= \sum_{j=1}^{k+1} W_j^0(k) f(S_j(k)) W_j^I(k) \end{aligned} \quad (6)$$

2.1.2 PID제어기의 적응동조 알고리즘

이산시간 PID제어기의 일반식은 다음과 같다.

$$\begin{aligned} u(k) &= u(k-1) \\ &+ K_P(k)(e_P(k) - e_P(k-1)) + K_I(k) T_0 e_P(k) \\ &+ K_D(k)(e_P(k) - 2e_P(k-1) + e_P(k-2)) / T_0 \end{aligned} \quad (7)$$

여기서 K_P , K_I , K_D 는 PID제어기의 매개변수이고 $u(k)$ 는 제어기 입력, T_0 은 샘플링시간이다

PID 매개변수 동조를 위한 오차함수는 다음과 같다.

$$e_P(k) = r(k) - y_P(k) \quad (8)$$

여기서 $r(k)$ 은 기준신호, $y_P(k)$ 는 플랜트 출력이다.

PID 매개변수에 대한 오차함수 e_P 의 부경사도 방향으로 매개변수를 갱신하면 다음과 같이 나타낼 수 있다.

$$\begin{aligned} K(k+1) &= K(k) + \Delta K(k) \quad (9) \\ \Delta K(k) &= -\eta_C \frac{\partial e_P(k+1)}{\partial K(k)} \\ &= \eta_C \frac{\partial y_P(k+1)}{\partial u(k)} \frac{\partial u(k)}{\partial K(k)} \end{aligned}$$

여기서 $K = [K_P, K_I, K_D]^T$, η_C 는 제어기의 동조율이다.

2.2 적응학습율과 적응동조율

Chao-Chee Ku 등이 제안한 DRNI의 적응학습율은 다음과 같다.

$$0 < \eta_M < \frac{2}{\max_k \left\| \frac{\partial y_M(k+1)}{\partial W(k)} \right\|^2} \quad (10)$$

본 논문에서 제안한 적응동조율은 다음과 같다.

$$0 < \eta_C < \frac{2}{\max_k \|W^0\|^2 \max_k \|W_1^I\|^2 \max_k \left\| \frac{\partial u}{\partial K} \right\|^2} \quad (11)$$

여기서 W_1^I 는 $[W_{11}^I, W_{21}^I, \dots, W_{41}^I]^T$ 이며 $\|\cdot\|$ 은 전부 \mathbb{R}^n 의 유클리드 놈이다.

2.3 모의실험 및 결과분석

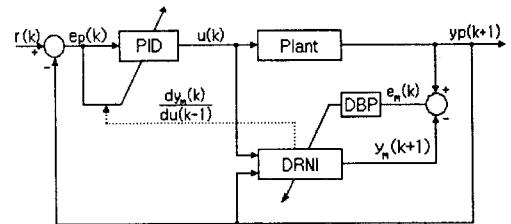


그림 2. 신경망을 이용한 PID제어 시스템

모의실험에 사용한 플랜트의 전달함수는 다음과 같다.

$$G_1(s) = \frac{27}{(s+1)(s+3)^3}$$

모의실험 수행과정은 다음과 같다.

1. 초기값 설정- PID 매개변수, 학습율, 동조율
2. DRNI 오차 $e_M(k)$ 로부터 $E_M(k)$ 계산
3. DRNI 각 층의 오차 경사도 $\frac{\partial E_M(k)}{\partial W(k-1)}$ 계산
4. DRNI 각 층에 대한 적응학습율 η_M 계산
5. 플랜트 입·출력 감도 $\frac{\partial y_P(k)}{\partial u(k-1)}$ 계산
6. DRNI 각 층에서의 가중치 갱신
7. 플랜트 오차 $e_P(k)$ 계산
8. 매개변수에 대한 오차 경사도 $\frac{\partial e_P(k)}{\partial K(k-1)}$ 계산
9. PID 적응동조율 η_C 계산
10. PID 매개변수 갱신
11. PID제어기 출력 $u(k)$ 계산
12. $y_P(k+1)$ 및 $y_M(k+1)$ 계산
13. 2번 단계로 이동하여 반복 실행

그림 3에서부터 그림 7은 기준신호를 처음 500 샘플링 동안 1과 다음 500 샘플링 동안 0을 번갈아 주는 1000샘플링을 1epoch하여 100epoch동안 동조를 수행한 결과를 나타낸 것이다. 적응동조율은 식 (11)에서 문자를 1로 하였으며 초기값은 0.2로 하였다. 매개변수 초기값으로는 $K_P = 3.0$, $K_I = 2.1$, $K_D = 1.1$ 을 사용하였는데 이것은 Ziegler-Nichols의 폐루프 응답으로부터 구한 것이며 샘플링 시간은 0.02 초로 하였다.

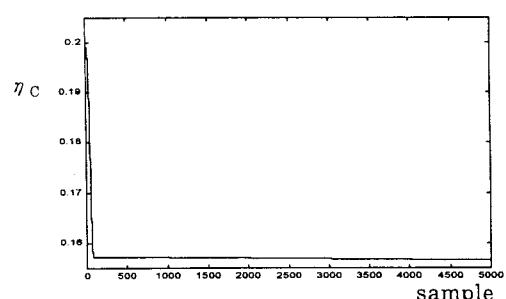


그림 3. 플랜트의 적응동조율 η_C 곡선

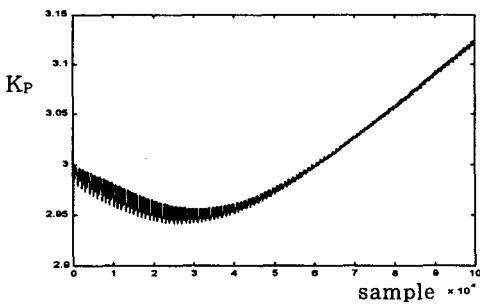


그림 4. 플랜트의 K_P 변화곡선

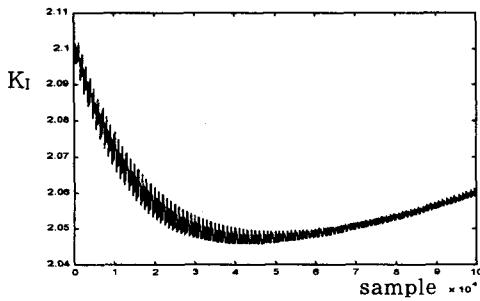


그림 5. 플랜트의 K_I 변화곡선

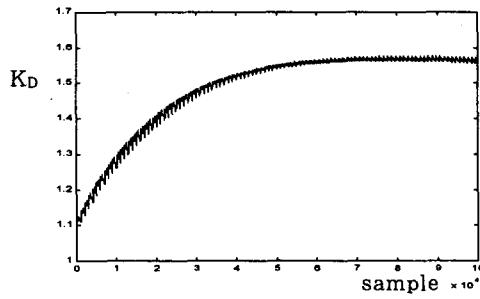


그림 6. 플랜트의 K_D 변화곡선

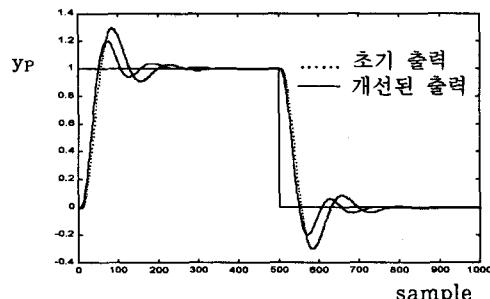


그림 7. 60epoch 후의 플랜트 출력

4차 플랜트를 통한 모의실험 결과는 다음과 같다.
첫째, 적응동조율을 η_C 의 변화는 그림 3과 같이 초기 값으로부터 90샘플까지 감소하다가 일정한 값으로 수렴하였다. 이와 같은 변화에 가장 크게 관련된 것은 식

(11)에서 $\|W^0\|$ 이며 다른 요소들은 주로 전체적인 크기를 결정하는 것으로 나타났다.

둘째, 적응동조에 따른 PID 매개변수 변화율은 K_D 가 가장 크게 나타났으며 플랜트 출력 개선에 미치는 영향도 K_D 가 가장 큰 것으로 나타났다.

셋째, PID 매개변수 변화 곡선을 보면 K_D 가 일정한 값으로 수렴하는 것을 알 수 있는데 이것이 제어시스템의 수렴성과 관련 있는 것으로 나타났다.

넷째, PID 매개변수의 초기값을 Ziegler-Nichols의 방법으로 정하면 적응동조가 잘 이루어지는 것으로 나타났다.

다섯째, 동조과정에서 DRNI의 W_j^0 과 W_j^D 는 변화가 크지 않았고 W_j^0 는 비교적 크게 변화하였다. 따라서 DRNI의 출력은 W_j^0 에 의해 영향을 크게 받는 것으로 나타났다.

3. 결 론

본 논문에서는 PID제어기의 구조를 그대로 유지하면서 플랜트의 동특성을 추정하기 위하여 DRNN 하나만을 사용한 제어시스템을 구성하여 계단입력에 대한 플랜트의 출력을 개선하기 위한 적응동조를 수행하였다.

그 결과, Chao-Chee Ku 등이 제안한 DRNN의 적응학습율이 신경망을 이용한 PID제어기에서도 수렴성이 보장되는 것으로 확인하였으며, DRNI는 플랜트의 동특성을 잘 추정하는 것으로 나타났다.

또한, 미지의 플랜트에 대한 적응동조는 플랜트의 전달함수를 알 수 없기 때문에 온-라인 동조를 해야 하며 이를 위해 수렴성을 보장하는 적합한 동조율이 요구되는데 본 논문에서 제안한 적응동조율은 모의실험 결과 제어기의 수렴성을 보장하며 적응동조 알고리즘에 의해 플랜트 출력이 개선되는 것으로 나타났다.

그러나 플랜트에 따라서는 K_D 값은 잘 개선하나 K_P 와 K_I 값은 적은 범위에서 개선이 이루어지는데 이것은 $\partial u / \partial K_D$ 값이 $\partial u / \partial K_P$ 와 $\partial u / \partial K_I$ 값 보다 비교적 크기 때문에 특히 플랜트의 응답속도가 매우 빠를수록 그리고 샘플링 시간이 작을수록 $\partial u / \partial K_D$ 값이 적응동조에 미치는 영향이 커서 K_D 값만 효과적으로 개선하는 것으로 나타났다.

따라서 향후에는 PID 매개변수 전체에 대하여 보다 광범위한 탐색이 안정적으로 이루어짐으로써 다양한 플랜트에 대하여 강인하게 적응동조가 이루어질 수 있도록 본 알고리즘을 발전시키는데 노력하고자 한다.

[참 고 문 헌]

- [1] Chao-Chee Ku and Kwang Y. Lee, "Diagonal recurrent neural networks for dynamical system control", IEEE Trans. on Neural Networks, Vol. 6, No. 1, pp. 144~156, Jan. 1995.
- [2] M. M. Polycarpou and P. A. Ioannou, "Learning and convergence analysis of neural-type structured networks", IEEE Trans. on Neural Network, Vol. 3, No. 1, pp. 39~50, Jan. 1992.
- [3] Sigeru Omatsu, Takeshi Iwasa, and Michifumi Yoshioka, "Skill-based PID control by using neural networks", IEEE, Int. Cont. Systems, Man, and Cybernetics, Vol. 2, pp. 1972~1977, 1998.
- [4] 김진환, 이제희, 허옥열, "적응 학습율을 가지는 신경망 적응제어", 전기학회논문지, 제47권, 제5호, 1998.
- [5] 정종대, "신경망에 의한 PID 제어기의 자동동조 및 직류 전동기 속도제어에의 응용", 한국 페지 및 지능시스템학회 논문지, Vol. 6, No. 2, 1996.