

신경망을 이용한 PID 제어기의 제어 사양 최적의 이득값 추정

Optimal Condition Gain Estimation of PID Controller using Neural Networks

손 준혁*, 서 보혁**

*경북대학교 대학원 시스템제어연구실(전화:(053)940-8604, 팩스:(053)950-5505, E-mail : d7101194@palgong.knu.ac.kr)

**경북대학교 전자전기공학부 (전화:(053)940-5604, 팩스:(053)950-5505, E-mail : bhsuh@bh.knu.ac.kr)

Abstract : Recently Neural Network techniques have widely used in adaptive and learning control schemes for production systems. However, generally it costs a lot of time for learning in the case applied in control system. Furthermore, the physical meaning of neural networks constructed as a result is not obvious. And in practice since it is difficult to the PID gains suitably lots of researches have been reported with respect to turning schemes of PID gains.

A Neural Network-based PID control scheme is proposed, which extracts skills of human experts as PID gains. This controller is designed by using three-layered neural networks. The effectiveness of the proposed Neural Network-based PID control scheme is investigated through an application for a production control system. This control method can enable a plant to operate smoothly and obviously as the plant condition varies with any unexpected accident.

Keywords : neural, PID, gain, control method, learning

I. 서론

지금 산업 현장에서 사용되는 여러 생산 장비와 생산 환경을 조절하는 보조 장비들을 제어하는데 PID제어기가 많이 사용되고 있다. PID제어기는 사용이 편리하며, 비교적 우수한 성능을 가지고 있어 생산 장비의 제어에 용이하다. 이런 산업 현장에서의 PID제어기에 신경망을 적용함으로써 기존에 사용하던 PID제어기에 쉽게 신경망 제어기를 추가할 수 있어 산업 현장에서의 사용에 거부감이 없고, 기존 PID제어기의 구조를 수정 없이 제어기 설계가 가능하다.[1] 이 논문에서 설계된 제어기는 시스템의 제어 사양에 부합되는 최적의 이득값을 추정함으로써 전체 시스템의 성능을 향상시킨다. 그리고, 실제 시스템에서 제어 사양에 부합되는 이득값 추정을 사례 연구와 실험 결과로 검증한다.

II. 본론

이 논문에서는 기존의 PID제어기의 구조에 신경회로망 제어기를 Feedforward Controller로 사용하는 구조를 제안하였다. 이와 유사한 제어기로서 Kawato등이 제안한 제어기 구조가 있으나 제안된 구조에서는 플랜트의 역을 학습하는 형태가 아니고, 플랜트의 정방향 동력학을 학습한 후, 그 신경회로망의 역을 구하여 제

어하는 것이다. PID알고리즘은 신경회로망의 학습오차를 보완해주는 역할을 하고, 신경회로망 PID제어기는 PID제어기의 성능을 학습에 의하여 꾸준히 향상시키는 역할을 한다.[2] 이런 신경회로망 PID제어기에서 추정된 최적의 이득값을 Mat.Lab v6.5를 통해 검증한다. 그리고, 결과에서 볼 수 있듯이 기존의 제어기보다 시스템의 제어 사양에 부합되는 최적의 이득값이 추정됨을 확인한다.

II-1. 전체 시스템 구조

전체 시스템의 구조는 신경회로망을 기반으로 한 신경회로망 PID제어기와 산업 현장에서 사용되는 시스템으로 구성된다. 신경회로망 PID제어기는 신경망 부분과 PID 제어기 부분으로 구성되고, 신경망 부분에서는 신경망

의 입력으로 y, u, e, r, ρ 이 주어진다. 이 값들이 신경망에 의한 연산을 통해 Kp, Ki, Kd 로 출력되어 PID제어기의 입력으로 작용한다. Command signal(r)은 PID제어기의 입력으로 작용될 뿐만 아니라 신경망의 입력으로도 작용한다. 그리고, PID제어기의 출력(u)은 시스템의 입력과 신경회로망 PID제어기의 신경망 부분의 입력으로 작용함으로써 시스템의 제어 사양 최적의 이득값을 추정한다.

시스템의 출력(y)는 Command signal(r)과의 연산으

로 error signal(e)을 만들어 신경망 PID제어기의 신경망 부분과 PID제어기 부분의 입력으로 작용한다.

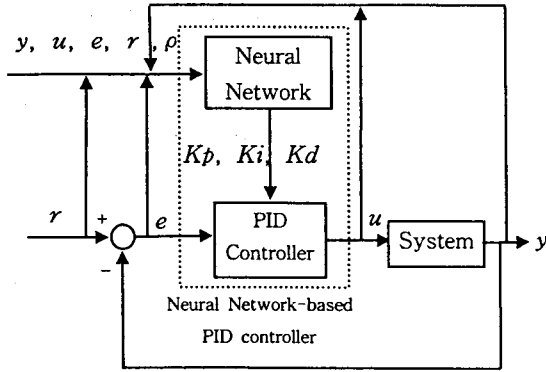


그림 1. PID 제어기의 전체 제어 구조도
figure 1. structure of PID controller

u : input

y : system output signal

r : command signal

e : error signal

$$e(t) = r(t) - y(t)$$

ρ : command signal이 동작할 때 방향 지시 signal

$$\rho(t) = \begin{cases} \eta & (\Delta r(t) > 0) \\ \rho(t-1) & (\Delta r(t) = 0) \\ -\eta & (\Delta r(t) < 0) \end{cases}$$

여기서 η 는 positive constant

$$\Delta = 1 - z^{-1}$$

으로 정의한다.

control input $u(t)$ 는

$$\Delta u(t) = Kp \left\{ \Delta + \frac{T_s}{Ki} + \Delta^2 \frac{Kd}{T_s} \right\} e(t)$$

여기서 Kp 는 비례이득(Proportional Gain)

Ki 는 적분이득(Integral Gain)

Kd 는 미분이득(Derivative Gain)

T_s 는 sampling time

로 계산되며, 이득값은 신경망에서 출력이 된다.[3]

II-2. 신경망의 구조

정규화 된 데이터가 신경망을 통과하게 되면, 그 데이터는 숫자로 바뀌게 된다. 이는 수많은 데이터를 일일이 저장하거나 데이터 전체를 가지고 비교하는 것이 아니라, 그 데이터를 나타내는 숫자 다시 말해, 신경망으로 패턴을 분석한 값으로써 데이터를 비교하게 하는

것이다.[4]

정규화 된 데이터를 숫자로 바꾸기 위해서는 어떤 기준에 의해서 신경망을 통과시켜야 일관된 패턴분석이 가능할 것이다. 그래서 우선 패턴 분석에 필요한 기준 패턴을 만들어서 그 패턴을 기준으로 신경망을 학습시킨다.

위에서 학습에 이용된 알고리즘은 널리 알려진 역전파법[5, 6, 7, 8]을 사용했다. 일반적으로 다층의 신경망이 있을 수 있다. 이 논문에서는 3층의 신경망을 역전파법으로 학습시키는 방법을 설명한다.




그림 2. 신경망의 구조
figure 2. structure of neural networks

여기서 정규화 된 데이터를 위한 평가함수 E 는

$$E = \frac{1}{2} e^2(t+1)$$

이며, 신경망 출력은 각각 Kp , Ki , Kd 로 결정된다. 출력층:

$$\Delta W_{kj}(t+1) = -\eta \frac{\partial E}{\partial W_{kj}} + \alpha \Delta W_{kj}(t)$$

중간층:

$$\Delta W_{ji}(t+1) = -\eta \frac{\partial E}{\partial W_{ji}} + \alpha \Delta W_{ji}(t)$$

III. 사례 연구와 실험 결과

III-1 사례 연구

전체 시스템 구조도에서 시스템 부분으로는 차수가 4차이고 지연(delay)이 -0.2로 가정하여 실험했다. 그리고, 이 시스템의 제어 사양으로

●overshoot가 30%이하

●setting time까지의 sum of square error + square control input을 최소화 하는 것을 목적으로 한다.

III-2 실험 결과

ISE=Integral of Square Error

IE =Input Error

●신경회로망 PID제어기에서 추정된 PID 이득값

$K_p=7.69$

$K_d=0.6$

$K_i=100000$

overshoot = 0.0023

sum of square error + square control input = 0.0482




그림 3. 신경회로망 PID제어기의 overshoot와 control input
figure 3. overshoot & control input of neural networks PID controller

●기존 제어기에서 PID 이득값

$K_p=8.37$

$K_d=0.83$

$K_i=1300000$

overshoot = 0.2856

sum of square error + square control input = 0.0876




그림 4. 기존 제어기의 overshoot와 control input
figure 4. overshoot & control input of PID controller

III-3 실험 결과

신경회로망 PID제어기와 기존 PID제어기의 비교

제어 사양	overshoot가 30%이하 setting time까지의 sum of square error + square control input을 최소화	
	신경회로망	기존
이득값	$K_p=7.69$ $K_d=0.6$ $K_i=100000$	$K_p=8.37$ $K_d=0.83$ $K_i=1300000$
overshoot	0.0023	0.2856
sum	0.0482	0.0876

신경회로망 PID제어기와 기존 PID제어기의 비교에서 볼 수 있듯이 두 제어기 모두 제어 사양에 부합하는 이득값을 찾았으나, 신경회로망 PID제어기가 기존의 제어기보다 시스템의 제어 사양에 최적으로 부합되는 이득값이 추정됐음을 확인했다.

참고문헌

- [1] Takagi, S.-I., Oki, T., Yamamoto, T., Kaneda, M., "A Skill-Based PID Controller Using Artificial Neural Networks", IEEE International Conference on Volume 5, pp. 4454 -4459, 1997.
- [2] Jeong-Woo Lee, "Inversion Control of Nonlinear Systems with Neural Network Modelling", IEE Proceeding D(Control System and Application) 9 vol, pp 481-488, 1997.
- [3] Omatu, S., Iwasa, T., Yoshioka, M., "Skill-Based PID Control by Using Neural Networks", IEEE International Conference on Volume 2, pp. 1972 -1977, 1998.
- [4] 이진하, 라경택, 이영석, 서보혁, "고장 패턴을 이용한 시스템의 고장진단", 대한 전기 학회지, 대한 전기 학회 논문집, pp 988-990, 1999.
- [5] Jacek M. Jurada, "Introduction to Artificial Neural Systems", PWS, pp 163-206, 1992.
- [6] Kumpati S. Narendra, Kannan Parthasarathy, "Identification and Control of Dynamical systems Using Neural Networks", IEEE trans. on Neural Networks, Vol. 1, No. 1, pp 4-27, 1990.
- [7] Simon Haykin, "Network: A Comprehensive Foundation", Prentice-Hall International, 1990.
- [8] John Hertz, Anders Krogh, Benny Lautrup, Torsten Lehmann, "Nonlinear Backpropagation: Doing Backpropagation Without Derivative of the Activation Function", IEEE trans. on Neural Networks, Vol. 8, No. 6, pp 1321-1326, 1997.