

Diagonal 리커런트 신경망을 이용한 PID 제어기의 자기동조

신종욱, 채창현, 김상희, 최한고
금오공과대학교

Self-tuning of PID controller using diagonal recurrent neural networks

Jong-Wook Shin, Chang-Hyun Chai, Sang-Hee Kim, Han-Go Choi
Kumoh National University of Technology

Abstract - In this paper, we propose the self-tuning of PID controller using diagonal recurrent neural networks. The characteristic of the proposed structure is on-line adaptive learning scheme in spite of variations of feedback signals. Control performance is compared with that of neural network based PID controller which was proposed by Iwasa. Computer simulation results show that the proposed controller is effective in controlling of unknown nonlinear plants.

1. 서 론

PID 제어는 산업현장에서 가장 널리 사용되고 있는 제어 알고리즘이다. 이는 PID 제어 알고리즘 자체의 광범위한 응용능력, 단순성 및 장인성 이외에도 현장 운영자들의 친숙함 등에 기인한다. 그러나 PID 제어기를 이용하여 제어대상 플랜트가 원하는 응답을 출력하기 위해서는 플랜트의 동특성을 따라 제어기를 조절하는 동조 과정이 필요하다. 제어기의 계수 조정을 적응 제어 또는 신경회로망 제어 등의 고급 제어 알고리즘을 이용하는 연구가 진행 중이다.

Iwasa 등[1,2]은 3층 역전파 신경회로망을 사용하여 PID 제어기의 계수를 자기동조하는 직접제어기를 구성하였으며, 플랜트 자코비안은 근사화 식을 이용하고 출력층 뒷 단에 조절계수라는 연결강도를 하나 더 구성하여 전체적으로 4층 구조를 갖도록 하였다.

본 논문에서는 조절계수를 포함한 4개의 층을 갖는 DRNN(Diagonal Recurrent Neural Networks)을 직접제어기로 구성하여 PID 제어기의 계수를 자기동조하였다. DRNN은 자기 궤환(self recurrences)을 갖는 히든층으로 구성되어 있기 때문에 시스템의 동특성을 향상시킬 수 있으며, 일반적인 FRNN(Full Recurrent Neural Networks)보다 학습 속도가 빠르다[3]. DRNN의 연결강도를 갱신하기 위한

플랜트의 자코비안은 플랜트 근사화용 신경회로망인 DRNI(Diagonal Recurrent Neuroidentifier)를 사용하였다. 제안된 제어기의 성능을 평가하기 위해 외란이 없는 선형 모델과 비선형 모델에 대하여 시험하였다. 시뮬레이션 결과에 의하면 제안된 DRNN 제어기에 대해 만족할 만한 제어성능을 얻을 수 있었으며, 상대적인 평가를 위해 Iwasa의 방법과 비교한 결과 DRNN의 우수성이 입증되었다.

2. Diagonal 리커런트 신경망의 구조

그림 1에서 보인 것처럼 DRNN은 자기 궤환을 갖는 히든층으로 구성되어 있다. 그리고 일반적인 FRNN보다 연결강도의 개수가 줄었기 때문에 학습 속도가 더 빠르고, 히든층의 자기 궤환되는 값들에 의하여 동특성을 구현할 수 있는 특징을 가진다.

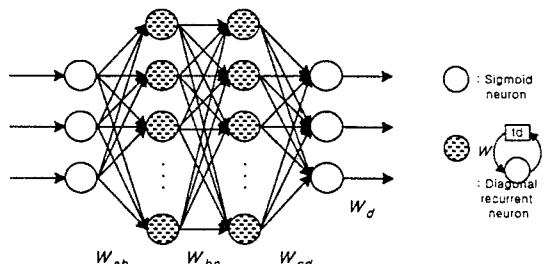


그림 1. Diagonal 리커런트 신경망의 구조

DRNN의 입력을 $I_a(t)$ 라고 하면, 입력층의 출력 $X_a(t)$ 은 다음과 같다.

$$X_a(t) = \frac{1}{1 + e^{-s \cdot I_a(t)}}, \quad a = 0, 1, \dots, IN \quad (1)$$

여기서, a 는 입력층의 유닛수이며, s 는 시그모이드 함수의 기울기이다. 첫 번째 히든층의 출력 $X_b(t)$ 은 다음과 같다.

$$X_b(t) = \frac{1}{1 + e^{-s \cdot s_b(t)}}, \quad b = 0, 1, \dots, HN \quad (2)$$

여기서, b 는 첫 번째 히든층의 유닛수이며, 첫 번째

히든층 시그모이드 함수의 입력 $S_b(t)$ 은 다음 식과 같다.

$$S_b(t) = \sum_{a=0}^{HN} w_{ab}(t) \cdot X_a(t) + w_b(t) \cdot X_b(t-1) \quad (3)$$

위 식에서 $w_{ab}(t)$ 는 Diagonal 리커런트 신경망의 입력층과 첫 번째 히든층 사이의 연결강도이며, $w_b(t)$ 는 첫 번째 히든층의 리커런트되는 연결강도이고, $X_b(t-1)$ 는 시간 지연된 첫 번째 히든층의 출력이다. 그리고, 신경망의 두 번째 히든층의 출력 $X_c(t)$ 는 다음과 같이 구해진다.

$$X_c(t) = \frac{1}{1 + e^{-s \cdot S_c(t)}} , c = 0, 1, \dots, HN \quad (4)$$

여기서, c 는 두 번째 히든층의 유닛수이며, 두 번째 히든층 시그모이드 함수의 입력 $S_c(t)$ 은 다음 식과 같다.

$$S_c(t) = \sum_{b=0}^{HN} w_{bc}(t) \cdot X_b(t) + w_c(t) \cdot X_c(t-1) \quad (5)$$

위 식에서 $w_{bc}(t)$ 는 DRNN의 첫 번째 히든층과 두 번째 히든층 사이의 연결강도이며, $w_c(t)$ 는 두 번째 히든층의 리커런트되는 연결강도이고, $X_c(t-1)$ 는 시간 지연된 두 번째 히든층의 출력이다. 그리고 출력층의 출력 $X_d(t)$ 는 다음과 같이 계산된다.

$$X_d(t) = \frac{1}{1 + e^{-s \cdot S_d(t)}} \quad (6)$$

$$S_d(t) = \sum_{c=0}^{HN} w_{cd}(t) \cdot X_c(t) \quad (7)$$

식 (7)은 출력층의 입력이며, $w_{cd}(t)$ 는 두 번째 히든층과 출력층 사이의 연결강도이고, $X_d(t)$ 는 두 번째 히든층의 출력이다. DRNN의 출력은 출력층의 출력 $X_d(t)$ 과 출력층 이후의 연결강도인 $w_d(t)$ 의 곱으로 나타낼 수 있다.

Diagonal 리커런트 신경망의 층간 결합계수는 기존의 오차 역전과 알고리즘을 이용하여 학습한다.

3. Diagonal 리커런트 신경망 PID 제어기

적용 Diagonal 리커런트 신경망 PID 제어기의 구조는 그림 2와 같다. 그림 2에서 PID 제어기의 계수를 생성하는 DRNN의 구조는 그림 1과 같으며 신호 전달 특성은 앞에서 정의한 수식과 동일하나, 학습 방법은 전체 시스템의 구조에 맞게 수정되었다. DRNN의 학습에 필요한 플랜트의 자코비안을 계산하기 위하여 그림 1의 구조에서 히든층을 하나만 사용하고 한 개의 출력을 갖는 DRNI를 구성하였다. DRNI의 신호전달은 위에서 설명한 DRNN의 방법과 동일하다.

제안된 DRNN PID 제어기는 일반적인 off-line 방법이 아닌 on-line으로 학습한다.

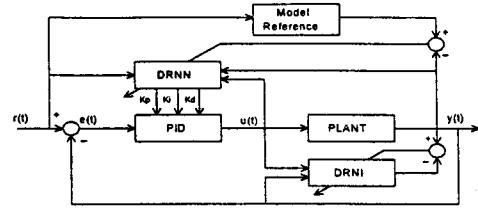


그림 2. 적용 DRNN PID 제어기의 구조

디지털 PID 제어기의 알고리즘은 다음의 식으로 표현될 수 있다.

$$u(t) = u(t-1) + K_P [e(t) - e(t-1)] + K_I \cdot e(t) + K_D [e(t) - 2e(t-1) + e(t-2)] \quad (8)$$

여기서, K_P, K_I, K_D 는 DRNN에 의해 계산된 파라미터이고, $e(t)$ 는 입력신호 $r(t)$ 와 출력신호 $y(t)$ 의 오차를 나타낸다.

제안된 Diagonal 리커런트 신경망 PID 제어기의 성능을 평가하기 위하여 수학적인 선형모델과 비선형 모델을 대상으로 외란이 없는 경우에 대해 시험하였다. 제어 대상은 다음과 같은 입출력 관계식을 같은 플랜트로 설정하였다.

$$y(t) = 0.7y(t-1) + u(t) + 2u(t-1) \quad (9)$$

$$y(t) = 0.9y(t-1) - 0.001y(t-1)^2 + u(t) + \sin(u(t-1)) \quad (10)$$

식 (9)의 선형 플랜트는 임의로 선정된 안정한 비최소 위상 플랜트이나, 플랜트 이득이 크므로 일반적으로 제어하기 어렵다. 또한, 식 (10)의 플랜트는 Iwasa 등이 사용한 임의의 비선형 함수로 플랜트 입력이 큰 경우이다.

4. 시뮬레이션 결과 및 검토

시뮬레이션은 별도의 학습없이 DRNN과 DRNI를 PID 제어기에 결합시켜 온라인으로 PID 제어기의 계수를 동조하였다.

DRNN은 기준 입력 $r(t)$, $r(t-1)$ 과 플랜트 출력 $y(t-1)$, $y(t-2)$, 그리고 바이어스를 신경망의 전체 입력으로 가진다. 첫 번째 히든층은 12개, 두 번째 히든층은 6개, PID 제어기의 계수를 생성하는 출력층은 3개의 뉴런으로 구성하였으며, PID 계수들은 양의 값을 갖도록 제한하였다. DRNI의 입력층은 바이어스와 PID 제어기의 출력인 제어입력 $u(t)$, 플랜트 출력 $y(t-1)$ 을 합하여 3개로 구성하고, 히든층은 10개, 출력층은 1개의 뉴런으로 구성하였다. 뉴런의 개수와 학습율등의 변수는 실험에 의해서 결정되었다.

시뮬레이션 결과를 비교하기 위하여 Iwasa 등에 의해 제안된 히든층을 2개 갖는 4층 역전파 신경회로망 PID 제어기를 사용하였다. Iwasa 등이 제안한 4층 역전파 신경회로망 PID 제어기는 학습에 필요 한 플랜트 자코비안을 근사화 식으로 계산하였다.

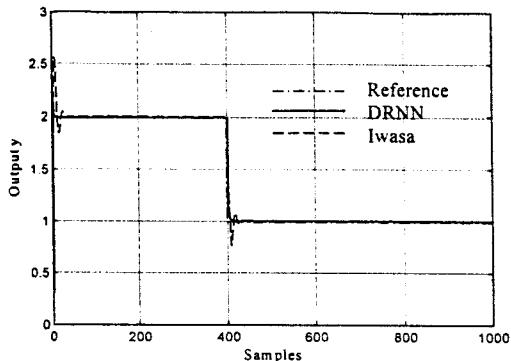


그림 3. 1000번 학습 후 선형 플랜트의 출력

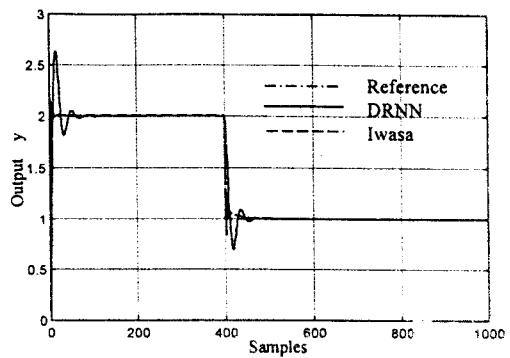
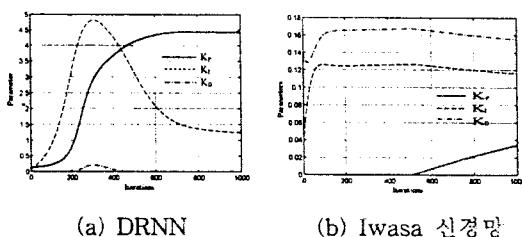


그림 5. 3000번 학습 후 비선형 플랜트의 출력



(a) DRNN

(b) Iwasa 신경망

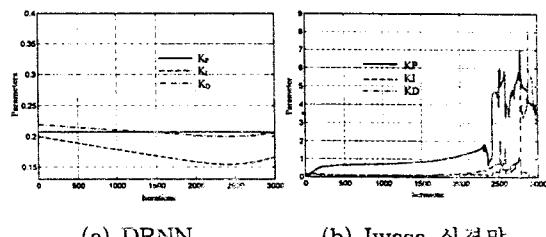
그림 4. PID 계수 변화 곡선

그림 3은 식 (9)의 선형 플랜트에 대해 제안된 Diagonal 리커런트 신경망 PID 제어기의 시뮬레이션 결과이다. 제안된 방법이 오버슈트가 작고 상승 시간도 빠른 좋은 제어 성능을 보인다. 그림 4의 (a)와 (b)는 각각 1000번 학습 동안 제안된 신경망 제어기와 Iwasa 등이 제안한 방법에 의한 PID 계수 변화를 나타낸 것이다. 제안된 방법의 PID 계수들은 학습이 진행됨에 따라서 적절한 값으로 수렴하였으나, 기존의 신경망 제어기는 PID 계수들이 완전히 수렴하지 않음을 확인할 수 있다.

식 (10)의 비선형 플랜트에 대해 제안된 적응 Diagonal 리커런트 신경망 PID 제어기의 시뮬레이션 결과는 그림 5에 나타나 있다. 제안된 방법이 오우버 슈트가 크고 상승 시간이 좀 느리지만, 그림 6의 (a)와 (b)를 비교해 보면 기존의 방법은 PID 계수들이 상당히 불안정하게 발산하고 있으나 제안된 방법은 계수의 변화 곡선이 안정하게 수렴함을 알 수 있다. 따라서 기존의 방법으로는 비선형 플랜트에 대하여 학습 중에 적절한 제어 성능을 구현할 수 없으며 학습을 많이 시키더라도 안정성을 보장할 수 없다. 그러나 제안된 방법을 사용할 경우 보다 안정된 on-line 제어가 가능함을 알 수 있다.

5. 결 론

본 논문에서는 단입력 단출력(SISO) 시스템에 대한 Diagonal 리커런트 신경망 PID 제어기를 설계하



(a) DRNN

(b) Iwasa 신경망

그림 6. PID 계수 변화 곡선

였다. 제안된 제어기의 구조는 Diagonal 리커런트 신경망과 PID 제어기의 결합 구조로 확장오차에 의한 적응 학습 알고리즘에 의해 학습된다.

제안된 적응 Diagonal 리커런트 신경망 PID 제어기를 선형 모델과 비선형 모델을 제어 대상으로 선정하여 시뮬레이션한 결과, Iwasa 등에 의해 제안된 역전파 신경망 PID 제어기보다 제어 성능을 개선할 수 있었을 뿐만 아니라, 학습율과 모멘텀율 등 신경망의 파라미터 설정이 쉽고, 비선형 모델에 적용하였을 때에도 오차의 감소와 PID 계수들의 수렴이 기존의 방법보다 뛰어나며, 만족할 만한 제어 성능을 얻을 수 있었다.

[참 고 문 헌]

- [1] K. Iwasa, N. Morizumi and S. Omatsu, "Pressure control in a plant generating chloride by neural network PID control," Proc. of IEEE Int. Joint Conf. on Neural Networks, pp. 627-630, 1995.
- [2] S. Akhyar and S. Omatsu, "Neuromorphic self-tuning PID controller," Proc. of IEEE Int. Joint Conf. on Neural Networks, pp. 552-557, 1993.
- [3] C. C. Ku and K. Y. Lee, "Diagonal recurrent neural network for nonlinear system control," IJCNN, pp. 315-319, 1992.