

Nonlinear PID Controller with Neural Network based Compensator

李昌求*
(Chang-Goo Lee)

Abstract – In this paper, we present an nonlinear PID controller with neural network based compensator which consists of a conventional PID controller that controls the linear components and a neuro-compensator that controls the output errors and nonlinear components. This controller is based on the Harris's concept where he explained that the adaptive controller consists of the PID control term and the disturbance compensating term. The resulting controller's architecture is also found to be very similar to that of Wang's controller. This controller adds a self-tuning ability to the existing PID controller without replacing it by compensating the output errors through the neuro-compensator. Various simulations and comparative studies have proven that the proposed nonlinear PID controller produces superior results to other existing PID controllers. When applied to an actual magnetic levitation system which is known to be very nonlinear, it has also produced an excellent results.

Key Words : PID control, Self-tuning, Nonlinear systems, Neuro-compensator

1. 서 론

PID(proportional integral derivative) 제어기는 구조가 단순하고 매우 견실한 특성을 지니고 있기 때문에 산업현장에서 널리 이용되고 있으나 좋은 성능을 유지하기 위해서는 적절한 동조가 필요하다. 동조 과정은 시간과 경비가 소모될 뿐만 아니라 강한 비선형성이나 큰 지연시간을 갖는 시스템에서는 매우 어렵다. 또한, 동조 후에도 시스템의 비선형성, 시변 특성 등에 의하여 제어성능이 감소되기 때문에 재 동조가 필요하다. 이러한 문제를 해결하기 위한 방법으로 적용제어기를 PID 구조로 변형하고 온라인으로 시스템 특성에 따라 PID 제어 파라미터를 자동 조절하는 적용 PID 제어기에 관한 연구들이 수행되어 부분적으로 산업현장에 적용되고 있다. 그러나, 이와 같은 방법은 적용 제어기를 설계할 때에 가정한 시스템의 모델차수, 지연시간 등이 실제 플랜트와 다른 경우에는 좋은 성능을 기대할 수 없고 초기 제어구간에서 안정한 start-up을 보장하지 못하는 문제점을 지니고 있다 [1]-[2]

최근들어 신경회로망을 이용한 비선형 시스템 제어에 관한 연구가 활발히 진행되어 많은 결과들이 발표되고 있다. 신경회로망을 이용한 PID 제어기의 동조에 대한 연구는 크게 플랜트 응답 패턴을 분석하고 학습하여 제어 파라미터를 조절하는 방법[3]-[4]과 신경회로망 구조를 PID 제어 구조와 유사

하게 구성하고 제어 평가함수를 최소화하도록 신경회로망의 연결강도(weights)를 학습하는 방법[5]-[6]으로 나눌 수 있다. 본 논문에서는 후자의 접근법을 주로 다루고자 한다. Keyser, Tan 등은 PID 구조의 신경회로망을 이용하여 비선형 플랜트를 실시간으로 인식(identification)하고 인식된 신경회로망 모델의 출력과 기준입력의 차로 표현된 평가함수를 최소화하도록 PID 제어 파라미터를 학습하는 방법을 제시하였다[5]. 이와 같이 설계된 신경회로망 PID 제어기는 제어 파라미터를 온라인으로 학습함으로써 자기동조 기능을 갖으나 신경회로망의 초기 연결강도, 학습률(learning rate) 등에 매우 민감한 단점을 보였다. 유사한 방법으로 Wang은 선형과 비선형 구조로 구성된 신경회로망을 이용하여 비선형 플랜트를 모델링하고, 선형 모델을 이용하여 적용 PID 제어기를 설계하고 비선형 모델은 측정이 불가능한 외란으로 간주하여 feed-forward 방식으로 보상하는 제어기를 제시하였다[6]-[7]. 이 방법은 신경회로망 변수들에 덜 민감하고 빠른 수렴특성과 적용성을 지녔다는 장점이 있다. 그러나, 선형 제어기 부분을 설계할 때에 적용제어 개념을 이용하기 때문에 앞서 언급한 적용 PID 제어기의 단점을 지닌다.

본 논문에서는 신경회로망 PID 제어기를 재해석하여 선형 부분을 제어하는 일반 PID 제어기와 비선형 성분 및 출력 오차를 보상하는 신경회로망 보상기로 구성된 신경회로망 보상기를 갖는 비선형 PID 제어기(이하: 신경회로망 보상 비선형 PID 제어기)를 제시하였다. 또한, 신경회로망의 초기 제어 파라미터 설정 방법을 제시하여 기존 신경회로망 PID 제어기의 단점을 개선하였다. 이와 같은 구조는 대부분의 적용 제어기가 PID 제어 항과 외란을 보상하는 항으로 구성되었다는 Harris의 이론에 근거한 것이며[8], Wang의 방법과도 개념적으로 유사하다. 신경회로망 보상 비선형 PID 제어기는 PID

* 正會員 : 全北大 工大 電子情報工學部 副教授 · 工博

接受日字 : 1999年 7月 30日

最終完了 : 2000年 3月 15日

제어기 구조를 변형하지 않고 신경회로망을 이용하여 PID 제어기에 온라인 동조 기능을 제공한다. 시뮬레이션을 통한 기존의 방법들과의 성능을 비교 분석하여 그 우수성을 보였다. 또한, 실제 시스템에서 실용성을 보이기 위해 강한 비선형 시스템으로 알려진 자기 부양(magnetic levitation) 시스템에 적용하여 실험한 결과 만족할 만한 결과를 얻었다.

2. 신경회로망 PID 제어기

2.1 직접 적응 PID 제어기

신경회로망을 이용하여 PID 제어기를 설계하는 방법은 크게 두가지로 나눌 수 있다. 신경회로망으로 직접 제어기를 구성하는 직접(direct) 적응제어 방식과 신경회로망으로 시스템을 인식하고 인식된 신경회로망 모델에 기반하여 제어기를 설계하는 간접(indirect) 적응제어 방식이다. 신경회로망을 이용한 직접 적응 PID 제어기 설계의 기본적인 개념은 Ishida가 제시한 그림 1과 같다[9].




그림 1 신경회로망을 이용한 직접 적응 PID 제어기

Fig. 1 Direct adaptive PID controller based on neural network

그림 1에서 신경회로망 PID 제어기의 구조는 그림 2와 같으며 e , e_i , e_d 는 각각 출력오차 ($r(t) - y(t)$), 출력오차의 적분, 출력오차의 미분신호이다.




그림 2 신경회로망 PID 제어기의 구조

Fig. 2 Structure of an neural network PID controller

또한, 제어 파라미터(연결강도) K_p , K_i , K_d 는 각각 비례이득, 적분이득, 미분이득이며 $r(t)$ 는 기준입력, $y(t)$ 는 출력이다. $u_D(t)$ 는 직접 적응 PID 제어기의 제어입력으로 식(1)과 같다.

$$u_D(t) = f(K_p e_p + K_i e_i + K_d e_d) \quad (1)$$

식(1)에서 $f(\cdot)$ 는 활성함수로서 일반적으로 시그모이드 함수이다. 만약 평가함수 $J_d(t)$ 를 식(2)와 같이 설정하면,

$$J_d(t) = 1/2[r(t) - y(t)]^2 \quad (2)$$

신경회로망 PID 제어기의 계수 K_p , K_i , K_d 는 평가함수를 최소화하도록 온라인으로 gradient descent 방법에 의하여 식(3)과 같이 구한다.

$$\begin{aligned} K_p(t) &= K_p(t-1) - \eta_1 \frac{\partial J_d}{\partial K_p} \\ K_i(t) &= K_i(t-1) - \eta_2 \frac{\partial J_d}{\partial K_i} \\ K_d(t) &= K_d(t-1) - \eta_3 \frac{\partial J_d}{\partial K_d} \end{aligned} \quad (3)$$

식(3)에서 η_j ($j=1, 2, 3$)는 수렴속도를 결정하는 학습률이다. gradient descent 방법은 학습률, 초기 연결강도에 따라 제어성능이 매우 민감한 영향을 받는다는 것과 국부 최소치에 빠지기 쉽다는 단점을 지니고 있다. 따라서, 전실한 직접 적응 PID 제어기를 설계하기 위해서는 최적의 초기 제어 파라미터 설정 방법과 함께 빠른 학습능력을 갖는 신경회로망에 대한 연구가 필요하다.

2.2 간접 적응 PID 제어기

신경회로망 모델을 이용한 간접 적응 PID 제어기 설계에 대한 연구는 Wang, Keyser 등에 의하여 최근까지 수행되어 왔으며 많은 결과들이 발표되었다[5]-[6]. Keyser가 제안한 신경회로망 예측모델을 이용한 간접 적응 PID 제어기의 일반적인 개념도는 그림 3과 같으며 본 장에서는 이에 대한 개념을 간략하게 설명하고자 한다.




그림 3 신경회로망을 이용한 간접 적응 PID 제어기

Fig. 3 Indirect adaptive PID controller based on neural network

불연속 일반 PID 제어기($u_P(t)$)는 식(4)와 같이 표현할 수 있으며 h 는 샘플주기를 나타내고 K_p 는 비례이득, T_i 는 적분시간, T_d 는 미분시간이다. 또한, $e(t)$ 는 출력오차로 $r(t) - y(t)$ 이다.

$$\begin{aligned} u_p(t) = & u_p(t-1) + K_p[(e(t) - e(t-1)) + \frac{h}{T_i} e(t)] \\ & + \frac{T_d}{h}(e(t) - 2e(t-1) + e(t-2)) \end{aligned} \quad (4)$$

식(4)를 좀더 간략히 표현하면 식(5)와 같으며 여기에서 제어 파라미터 G_j ($j=1, 2, 3$)를 적절히 조절하는 것을 동조라고 한다.

$$u_r(t) = u_r(t-1) + G_1 e(t) + G_2 e(t-1) + G_3 e(t-2) \quad (5)$$

일반 PID 제어기의 동조는 G_j ($j=1, 2, 3$)가 고정된 값을 갖으며, 본 장에서는 신경회로망 모델에 기초하여 온라인으로 G_j 를 조절하는 간접 적응 PID 제어기의 특징을 분석하고자 한다. 간접 적응 제어기는 매 샘플 시간마다 신경회로망 모델을 이용하여 출력력을 예측하고 식(6)으로 표현된 평가함수 $J_i(t)$ 를 최소화하는 제어 파라미터 G_j 를 구한다.

$$J_i(t) = 1/2[e_p(t+1)]^2 = 1/2[r(t+1) - y'''(t+1)]^2 \quad (6)$$

여기에서 $e_p(t+1) = r(t+1) - y'''(t+1)$ 은 예측 출력오차, $r(t+1)$ 은 한 step이후의 기준입력, $y'''(t+1)$ 은 신경회로망 모델에 기반한 예측출력으로 식(7)과 같다.

$$y'''(t+1) = f[\mathbf{w}_L^T f[\mathbf{w}_{L-1}^T \dots f[\mathbf{w}_1^T \mathbf{x}_1]]] \quad (7)$$

단, $\mathbf{x}_1 = [y(t), \dots, y(t-n+1), u_r(t), \dots, u_r(t+1-m)]^T$
 $\mathbf{w}_L, \mathbf{w}_1$ 는 각각 L층, 1층의 연결강도 벡터이다.

식(5)로 표현된 간접 적응 PID 제어기의 제어 파라미터 (G_j , $j=1, 2, 3$)는 평가함수를 최소하도록 gradient descent 방법에 의하여 매샘플 시간마다 식(8)과 같이 조절한다.

$$\begin{aligned} G_j(t) = & G_j(t-1) - \lambda \frac{\partial J_i}{\partial G_j}(t) \\ = & G_j(t-1) + \lambda e_p(t+1) \frac{\partial y'''(t+1)}{\partial u_r(t)} \frac{\partial u_r(t)}{\partial G_j(t)} \end{aligned} \quad (8)$$

제어입력 $u_r(t)$ 에 대한 $y'''(t+1)$ 의 미분은 신경회로망 모델(식(7))로부터 쉽게 구할 수 있다. 즉, 간접 적응 PID 제어기는 식(7)에 의하여 모델을 예측하고 식(8)에 의하여 제어기 계수를 온라인으로 update함으로써 자기동조 기능을 갖도록 하였다. 그러나, 제어기 성능이 초기 제어 파라미터 $G_j(0)$ 와 신경회로망 모델에 크게 의존하기 때문에 견실한 초기 제어 파라미터 선정 방법과 함께 실시간 동조를 위한 빠른 학습방법을 갖는 신경회로망이 요구된다. 널리 이용하는 BP(back-propagation) 신경회로망은 초기 연결강도, 학습률 등에 민감하고 수렴속도가 느려 적응제어기 설계를 위한 모델로는 적절하지 못하다. 이러한 이유로 지금까지 대부분의 연구 결과

들은 오프라인으로 제어대상 플랜트를 학습한 고정된 신경회로망 모델에 기초하여 제어기를 설계하였고 이러한 접근법은 적응 제어기 개념과 거리가 있다.

3. 신경회로망 보상 비선형 PID 제어기

최근들어 Wang은 선형 모델과 비선형 모델로 구성된 신경회로망 모델을 이용하여 비선형 시스템을 인식하고 두 단계로 나누어 제어기를 설계하였다[6]-[7]. 먼저, 선형 모델에 기반하여 선형제어기를 설계하고 다음 신경회로망으로 이루어진 비선형 모델은 측정할 수 없는 외란(disturbance) 성분으로 보고 feedforward 제어기에 의하여 선형 제어기를 보상하는 개념이다. 즉, 비선형 시스템 제어 문제를 선형제어기로 해결하고 비선형 성분을 신경회로망으로 보상하는 방법이다. 그러나, 선형 제어기를 설계할 때에 적응 제어기 개념을 적용하기 때문에 적응제어기의 문제점을 지닌다. 한편, Harris는 Minimum Variance 형태의 모든 적응제어기는 일반 PID 제어기에 과거 입출력 신호를 필터링한 외란 보상기를 첨가한 구조와 같다논문을 발표하였다[8].

본 논문에서는 Wang이 제시한 개념과 Harris 이론에 근거하여 신경회로망 간접 적응 PID제어기를 재해석하고, 최적의 초기 제어 파라미터 값을 제공함으로써 강인성 향상과 함께 현장에 이미 설치 운영되고 있는 일반 PID 제어기에 자기동조 기능을 제공한다. 먼저, 식(8)에서 초기 제어 파라미터 $G_j(0)$ 를 식(9)와 같이 정하고 식(5)에 대입하여 정리하면 간접 적응 PID 제어기는 식(10)과 같이 일반 PID 제어기와 외란, 비선형 항을 보상하는 제어기로 구성됨을 알 수 있다.

$$\begin{aligned} G_1(0) &= K_p(1 + \frac{h}{T_i} + \frac{T_d}{h}) \\ G_2(0) &= -K_p(1 + \frac{2T_d}{h}) \\ G_3(0) &= K_p \frac{T_d}{h} \end{aligned} \quad (9)$$

$$u(t) = u_p(t) + \text{외란}, \text{비선형 보상항}(u_N(t)) \quad (10)$$

$$u_N(t) = G_1 e(t) + G_2 e(t-1) + G_3 e(t-2) \quad (11)$$

식(10)에 따라 그림 4와 같이 선형 부분을 제어하는 일반 PID 제어기와 비선형 성분 및 출력오차 보상 기능을 갖는 신경회로망 보상기로 구성된 신경회로망 보상 비선형 PID 제어기를 제안한다. 일반 PID 제어기의 제어 파라미터 (K_p, T_i, T_d)는 릴레이 궤환실험에 의해 초기 동조구간에서 제공함으로써 간접 적응 PID 제어기의 문제점으로 지적된 초기 제어 파라미터 선정과 Wang의 선형 제어기 설계 문제를 동시에 해결한다. 또한, 신경회로망 모델은 견실하고 빠른 학습기능을 갖는 알고리즘을 개발하여 실시간 자기동조가 이루어 지도록 하였다[11]. 이와같은 구조는 일반 PID 제어기에 의하여 안정되고 견실한 제어 기능을 수행토록 하고 시스템 동특성 변화나 비선형 성분은 신경회로망 보상기로 교정함으로써 동특성이 변화하는 비선형 시스템에서도 우수한 제어

성능을 얻을 수 있다. 그림 4에서 보상 제어기는 식(11)과 같으며 제어 파라미터는 초기값을 임의의 작은 값으로 정하고 식(7), 식(8)에서 $u_f(t)$ 대신에 $u(t)$ 로 대치하고 식(8)에 의하여 온라인으로 update한다.




그림 4 신경회로망 보상 비선형 PID 제어기

Fig. 4 Nonlinear PID controller with neural network based compensator

3.1 릴레이 케환에 의한 초기 동조

지금까지 연구된 신경회로망 적용 PID 제어기의 공통적인 단점은 초기 제어 파라미터와 연결강도, 학습률 등에 따라 제어성능이 크게 좌우되기 때문에 초기 제어구간에서 안정한 제어를 할 수 없다는 점과 수렴속도가 느리다는 것이다. 본 논문에서는 선형 제어기로 일반 PID 제어기로 설정하고 초기 제어 파라미터를 릴레이 케환에 의한 임계값으로부터 제공함으로써 안정한 제어를 수행하도록 한다.




그림 5 릴레이 케환

Fig. 5 Relay feedback

일반 PID 제어기의 제어 파라미터는 그림 5와 같이 릴레이 케환을 형성하고 플랜트 출력이 일정한 진폭과 주기를 갖도록 인위적으로 진동하여 식(12)에 의하여 임계이득(k_c)과 임계주기(T_c)를 구한 후에 Ziegler -Nichols 동조법에 따라 식(13)과 같이 정한다[10]. 그림 5에서 d는 릴레이 진폭이고 ϵ 는 히스테리시스 폭이다. 또한, α 는 출력파형의 첨두치값이다.

$$k_c = \frac{4d}{\pi\alpha} \quad (12)$$

$$K_p = 0.6k_c, T_i = 0.5T_c, T_d = 0.25T_c \quad (13)$$

3.2 신경회로망에 의한 온라인 동조

신경회로망 보상기는 일반 PID 제어기로 fine 동조가 되지 않은 비선형 성분에 대한 보상 기능과 함께 동특성 변화에 따른 재동조 기능을 실시간으로 수행하도록 한다. 이를 위한 신경회로망은 앞서 지적하였듯이 안정되고 빠른 수렴특성을 지녀야 한다. 본 논문에서는 견실하고 빠른 학습 기능을 갖는 신경회로망을 제시하고 이를 이용하여 보상 제어기를 설계한다[11] 최근들어 Scalero와 Tepedelenlioglu는 다층 순방향 신경회로망을 구성하는 신경소자를 그림 6과 같이 선형과 비선형 구간으로 구분하고 연결강도를 칼만 필터링 방법을 도입하여 구함으로써 초기 연결강도값에 따른 장인성을 개선하고 수렴속도를 향상시킨 학습알고리즘을 제시하였다[12].




그림 6 은닉층과 출력층에서 신경소자의 구분

Fig. 6 Linear and nonlinear portion of the neurons in the hidden and output layers

이들 학습방법은 먼저, 출력층과 은닉층에서 각각 목표하는 합(summation) 출력(d_{Lk}, d_{jk})을 식(14), 식(15)에 의해 구한후에 신경회로망 합출력(y_{Lk}, y_{jk})과의 오차를 최소화하도록 칼만기법에 의하여 이득(k_j)과 Covariance 매트릭스(P_j)를 계산하고 연결강도 벡터(w_{jk})를 갱신하는 것으로 다음과 같이 요약할 수 있다.

1) 출력층과 은닉층에서 목표하는 합출력을 식(14), 식(15)에 의하여 구한다.

$$d_{Lk} = f^{-1}(o_k) \quad (14)$$

$$d_{jk} = y_{jk} + \mu \delta_{jk} \quad (15)$$

식(15)에서 μ 는 학습률을, δ_{jk} 는 은닉층의 선형구간에 전달되는 오차로 BP 알고리즘에서와 같은 방법으로 구한다. 각각의 기호에 붙은 첨자 j 는 j 번째 은닉층을 의미하며 L 은 출력층을 나타낸다. 또한 k 는 각각의 층에서 k 번째 노드(node)를 표현한다. $f(\cdot)$ 는 활성함수이다.

2) 각각의 층(즉, j 는 1에서 L 까지)에서 칼만이득과 Covariance 메트릭스를 계산한다.

$$\mathbf{k}_j = \mathbf{P}_j \mathbf{x}_{j-1} / (\lambda + \mathbf{x}_{j-1}^T \mathbf{P}_j \mathbf{x}_{j-1}) \quad (16)$$

$$\mathbf{P}_j = (I - \mathbf{k}_j \mathbf{x}_{j-1}^T) \mathbf{P}_j / \lambda \quad (17)$$

단, \mathbf{x}_{j-1} 는 $j-1$ 층의 출력벡터이면서 j 층의 입력이고 λ 는 망각인자이다.

3) 출력층과 은닉층(j 는 1에서 $L-1$ 까지)의 연결강도 벡터를 식(18), 식(19)에 의하여 개선한다.

$$\mathbf{w}_{Lk} = \mathbf{w}_{Lk} + \mathbf{k}_L (d_{Lk} - y_{Lk}) \quad (18)$$

$$\mathbf{w}_{jk} = \mathbf{w}_{jk} + \mu \mathbf{k}_j \delta_{jk} \quad (19)$$

Scalero와 Tepedelenlioglu가 제시한 학습방법은 칼만필터링 방법에 의하여 수렴속도를 개선하고 초기 연결강도값에 견실한 장점이 있으나 은닉층의 목표값을 BP 알고리즘과 같은 방법으로 구하기 때문에 학습률에 따라 성능이 크게 좌우되는 단점이 있다.

본 논문에서는 이와같은 단점을 개선하기 위하여 은닉층의 목표값(\mathbf{x}_{jk}^*)을 최적기법에 의하여 구하고 연결강도는 RLS에 의하여 추정하는 학습알고리즘을 개발하였다. 설명을 간략화하기 위하여 은닉층이 하나인 순방향 신경회로망을 생각하여 보자. 입력, 은닉, 출력 층의 노드수가 각각 N, P, M이라 하고 평가함수를 식(20)과 같이 표시하도록 하자.

$$E = \frac{1}{2} \sum_{k=1}^M (d_{Lk} - \mathbf{x}_j^T \mathbf{w}_{Lk})^2 \quad (20)$$

여기에서 $d_{Lk} = f^{-1}(o_k)$ 는 각각 출력층 k 노드의 목표값과 선형목표값이고, \mathbf{w}_{Lk} 는 은닉층과 출력층의 k 번째 노드 사이의 연결강도 벡터로 식(21)과 같다. 또한, \mathbf{x}_j 는 은닉층의 출력벡터이고 식(22)와 같다.

$$\mathbf{w}_{Lk} = [\mathbf{w}_{Lk0}, \mathbf{w}_{Lk1}, \dots, \mathbf{w}_{LkP}]^T \quad (21)$$

$$\mathbf{x}_j = [\mathbf{x}_{j0}, \mathbf{x}_{j1}, \dots, \mathbf{x}_{jP}]^T \quad (22)$$

식(20)에서 출력층의 연결강도 메트릭스를 최적의 값으로

보고 은닉층의 출력에 대한 식(20)을 최소화하는 최적의 출력값을 구하여 이를 은닉층의 목표값으로 정한다. \mathbf{x}_j 에 대한 함수 E의 최소화 결과는 식(23)과 같이 표시할 수 있으며 이를 메트릭스 형태로 다시쓰면 식(24)과 같다.

$$\frac{\partial E}{\partial \mathbf{x}_j} = 0 \Rightarrow \sum_{k=0}^M d_{Lk} \mathbf{w}_{Lk} = \sum_{k=0}^M \mathbf{w}_{Lk} \mathbf{w}_{Lk}^T \mathbf{x}_j \quad (23)$$

$$\mathbf{W}_L \mathbf{d}_L = \mathbf{W}_L \mathbf{W}_L^T \mathbf{x}_j \quad (24)$$

식(24)에서 $\mathbf{W}_L = [\mathbf{w}_{L0}, \dots, \mathbf{w}_{Lk}, \dots, \mathbf{w}_{LM}]$ 은 $P \times M$ 차원의 출력층 연결강도 메트릭스이고 $\mathbf{d}_L = [d_{L0}, \dots, d_{Lk}, \dots, d_{LM}]^T$ 는 출력층의 선형목표값로 구성된 $M \times 1$ 벡터이다. 은닉층의 최적 목표값($\mathbf{x}_j^* = [\mathbf{x}_{j0}^*, \dots, \mathbf{x}_{jk}^*, \dots, \mathbf{x}_{jM}^*]$)은 $P \geq M$ 인 경우에 식(24)를 만족하는 해는 하나 이상이 있을 수 있으며 minimum norm 방법을 이용하여 식(25)와 같이 구할 수 있다.

$$\mathbf{x}_j^* = \mathbf{W}_L (\mathbf{W}_L^T \mathbf{W}_L)^{-1} \mathbf{d}_L \quad (25)$$

다만, 식(25)에서 $\mathbf{W}_L^T \mathbf{W}_L$ 는 nonsingular 메트릭스가 되어야 하며 만약 singular인 경우에는 pseudoinverse 개념을 적용하여 계산한다. 식(25)으로 표현된 은닉층의 목표값으로 부터 은닉층 k 노드의 선형 목표값은 식(26)와 같이 구한다.

$$d_{jk} = f(\mathbf{x}_{jk}^*)^{-1} \quad (26)$$

새로운 학습알고리즘은 식(26)에 의하여 최적의 은닉층 목표값을 구하여 식(19) 대신에 식(27)에 의하여 은닉층의 연결강도를 개선한다.

$$\mathbf{w}_{jk} = \mathbf{w}_{jk} + \mathbf{k}_j d_{jk} \quad (27)$$

신경회로망 보상기는 매샘플마다 먼저, 앞서 제안한 학습방법에 따라 연결강도를 개선한 후에 식(8)에 의하여 제어파라미터를 구한다.

본 논문에서 신경회로망의 구조는 은닉층이 하나 있는 디층 구조이고 입력층은 노드수가 4개, 은닉층은 7개를 갖도록 하였다. 이 때에 식(8)의 $y'''(t+1) = f(\mathbf{w}_2^T f(\mathbf{w}_1^T \mathbf{x}_1))$ 이고 \mathbf{x}_1 는 $[y(t), y(t-1), u(t), u(t-1)]$ 이므로 $\partial y'''(t+1) / \partial u(t)$ 는 쉽게 구할 수 있고 제어 파라미터도 실시간으로 동조한다.

4. 실험 및 결과

본 논문에서 언급한 제어기들의 성능을 평가하기 위하여 로봇의 서보 실험 모델로 널리 이용되는 식(28)와 같은 비선형 시스템을 선정하였다.

$$\begin{aligned} y(t) = & 0.2y^2(t-2) + 0.2y(t-1) + 0.25y(t-2) \\ & + 0.25u(t-1) + 0.45 \sin(0.5(y(t-1) \\ & + y(t-2))) \cos(0.5(y(t-1) + y(t-2))) \end{aligned} \quad (28)$$

기준입력으로 $r(t)=0.3\sin(2\pi t/90)$ 로 설정하고 제어 파라미터(연결강도)의 초기값, 외란, 시스템 특성 변화 등에 대하여 본 논문에서 언급한 제어기의 성능을 비교 분석하였다.

4.1 PID 제어 파라미터(연결강도)에 따른 응답

그림 7은 Ziegler-Nichols 동조법에 따라 PID 제어 파라미터를 각각 $K_p=2.82$, $T_i=1.48$, $T_d=0.37$ 로 설정하였을 경우에 일반 PID제어기의 응답 곡선이다. Ziegler -Nichols법으로 동조된 일반 PID제어기는 플랜트의 비선형성 때문에 일정한 출력오차가 발생함을 알 수 있다.




그림 7 일반 PID 제어기의 응답

Fig. 7 The response of conventional PID controller




그림 8 직접 적응 PID 제어기의 응답

Fig. 8 The response of direct adaptive PID controller

그림 8와 9은 초기 제어 파라미터와 학습률을 임의로 설정하였을 경우의 직, 간접 적응제어기 응답으로 설정값에 따라 제어 성능이 민감하다. 즉, 초기 제어 파라미터를 일반 PID 제어기의 동조값으로 제공하였을 경우와 임의의 다른 값으로 제공하였을 때의 응답으로 초기 제어 파라미터 선정에 매우 민감함을 알 수 있었다.




그림 9 간접 PID 제어기의 응답

Fig. 9 The response of indirect adaptive PID controller




그림 10 적응 극배치 제어기의 응답

Fig. 10 The response of adaptive pole-placement controller

그림 10은 Wang이 제안한 신경회로망에 의하여 학습하고 선형 부분을 적응 극배치 설계에 의하여 설계한 신경회로망 기반 적응 극배치 제어기의 응답이다. 극배치 설계시에 폐루 우프 극의 위치를 2차계($s^2 + 2\xi\omega_n s + \omega_n^2$)로 하고 $\xi=0.7$, $\omega_n=1$ 로 정하였다. 또한 각각의 설계방법은 Zero를 cancel 한 경우와 않는 경우로 나누었다. 그림에서 보듯이 초기 응답에 문제가 있으며, 설계방법에 따라 강한 bursting 현상이 발생하여 실제 현장에는 이용하기 힘들다.

그림 11은 일반 PID 제어기의 초기 동조값은 Ziegler-Nichols법에 따라 제공하고 신경회로망의 초기 연결강도를 -0.5에서 0.5사이의 랜덤한 값으로 주었을 경우의 신경회로망 보상 비선형 PID 제어기의 응답으로 초기 연결강도에 견실하고, 비선형 성분들이 신경회로망 보상 제어기에 의하여 빠르게 보상됨을 확인할 수 있다. 즉, 일반 PID 제어기에 의하여 견실한 start-up을 할 수 있었고, 비선형 항에 의한 오차는 신경회로망 보상제어기에 의하여 실시간으로 빠르게 동조됨을 확인할 수 있었다.

4.1.2 모델 변화에 대한 응답

시스템의 모델이 300 step 시점에서 식(28)에서 식(29)과 같이 변하는 플랜트에 대한 각각의 제어기 특성을 비교하였다.




그림 11 신경회로망 보상 비선형 PID 제어기의 응답
Fig. 11 The response of an nonlinear PID controller with neural network based compensator




그림 12 시스템의 모델이 변할 때 일반 PID 제어기의 응답
Fig. 12 The response of conventional PID controller under change of model

$$y(t) = 0.2y^2(t-2) + 0.2y(t-1) + 0.25y(t-2) + 0.25u(t-1) + 0.45 \sin(0.5(y(t-1) + y(t-2))) \quad (29) \\ \cos(0.5(y(t-1) + y(t-2))) + 0.12y(t-3)$$




그림 13 시스템의 모델이 변할 때 직접 적응 PID 제어기의 응답
Fig. 13 The response of direct adaptive PID controller under change of model

그림 12는 일반 PID 제어기의 응답으로 모델 변화에 적응성이 없음을 알 수 있다. 그림 13은 직접 적응 PID 제어기의




그림 14 시스템의 모델이 변할 때 간접 적응 PID 제어기의 응답
Fig. 14 The response of indirect adaptive PID controller under change of model




그림 15 시스템의 모델이 변할 때 적응 극배치 제어기의 응답
Fig. 15 The response of adaptive pole-placement controller under change of model

응답으로 초기 제어 파라미터를 적절히 제공하면 적응능력을 보유함을 알 수 있다.

그림 14은 간접 적응 PID 제어기의 응답으로 동특성 변화에 대한 시스템인식의 수렴속도가 늦어 적응능력이 실시간으로 이루어지지 않아 제어성능이 떨어짐을 보였다. 그림 15은 Wang이 제시한 선형과 비선형으로 모델화된 신경회로망으로 학습하고 선형 구간을 적응 극배치 제어기 설계한 제어기의 응답으로 start-up뿐만 아니라 300 step 이후의 플랜트의 모델 변화에 따른 적응성이 현저히 감소함을 알 수 있다. 그림 16는 신경회로망 보상 비선형 PID 제어기의 응답 곡선으로써 일반 PID제어기로 안정한 start-up를 제공하고 시스템 모델 변화에도 빠르게 적응함을 보였다.

4.2 Levitation 시스템에 적용 실험 및 결과

자기 부양 시스템(MAGLEV) 실험 장비의 개략도는 그림 17과 같다. 제어기는 시스템의 특성(대역폭, 전압 이득 등)을 가변할 수 있는 PID 제어기로 구성되어 있다. ball의 위치를 계측하기 위한 photo-sensor는 적외선을 이용하고 있다.




그림 16 시스템의 모델이 변할 때 신경회로망 보상 비선형 PID 제어기의 응답

Fig. 16 The response of an nonlinear PID controller with neural network based compensator under change of model




그림 17 자기 부양 시스템의 개략도

Fig. 17 Block diagram of magnetic levitation system

자기 부양 시스템은 비선형 모델로 식(30)과 같은 전자기학적인 방정식을 갖는다.

$$m\ddot{x} = mg - k \frac{I^2}{x^2} \quad (30)$$

식(30)에서 m 은 ball의 질량이고, g 는 중력상수, x 는 ball의 위치, I 는 전자기에 흐르는 전류값, k 는 상수이다. 본 실험에서는 기준입력으로 $r(t)=0.5\sin(4\pi t)-0.5$, 샘플링 시간은 0.01초로 설정하였다. 다음 그림들의 y축은 ball의 지구 중심 방향으로의 수직 위치이며 단위는 (cm)이다. x축은 샘플링 시간에 따른 카운터의 숫자를 나타내고 있다.

4.2.1 초기 제어 파라미터에 대한 응답

초기 PID 제어기의 계수는 Ziegler-Nichols 동조식에 의하여 설정하였으며, 그림 18와 19에서 보듯이 신경회로망 보상 비선형 PID 제어기가 일반 PID 제어기보다 빠른 속도로 기준입력에 수렴함을 알 수 있다. 그림 18와 10에서 정상상태에서 약간의 오차는 기계적인 요인에 의한 것이다. 자기부양




그림 18 일반 PID 제어기의 응답

Fig. 18 The response of the conventional PID controller




그림 19 신경회로망 보상 비선형 PID 제어기의 응답

Fig. 19 The response of an nonlinear PID controller with neural network based compensator

시스템은 강한 비선형성을 갖고 있고 민감하기 때문에 임의로 설계한 직·간접 PID 제어기는 제어가 되지 않아 응답 곡선을 얻지 않았다.

4.2.2 특성 변화에 따른 응답

자기 부양 시스템은 식(30)으로 표현된 ball의 위치 x 와 u 에 의한 비선형 방정식이다. 이를 불연속 형태로 표현하면 식(31)과 같다. 시스템 특성 변화에 대한 일반 PID 제어기와 신경회로망 보상 비선형 PID 제어기의 특성을 비교하기 위해 $k=480$ 인 시점부터 식(32)과 같이 시스템을 가변하였다.

$$x(k) = \text{fun}(x, u) \quad (31)$$

$$x(k) = \text{fun}(x, u) + x(k-1) \quad (32)$$

그림 20은 일반 PID 제어기에 의한 응답 곡선인데 시스템의 특성 변화에 적응하지 못하고 제어불능 상태에 이르렀다. 그림 21은 신경회로망 보상 비선형 PID 제어기의 응답 곡선으로써 별별로 연결된 신경회로망 보상 제어기의 오차 보상 기능 때문에 시스템 동특성 변화에도 강인한 제어 특성을 보여 주었다.

그림 21의 응답파형을 관찰하면 많은 오차를 갖는 것처럼




그림 20 시스템의 특성이 변할 때 일반 PID 제어기의 응답
Fig. 20 The response of conventional PID controller under dynamic change




그림 21 시스템의 동특성이 변할 때 신경회로망 보상 비선형 PID 제어기의 응답
Fig. 21 The response of an nonlinear PID controller with neural network based compensator under dynamic change

보이나 실제 1mm정도의 오차로 육안으로 판별하기 어렵고, 실험 대상 시스템의 정밀도가 이 범주안에 있기 때문에 거의 제어오차가 없는 것으로 평가할 수 있다. 신경회로망을 이용한 직, 간접 적용 PID제어기는 연결강도의 초기값, 학습률, 신경회로망의 구조에 매우 민감하여 제어응답을 구할 수 없었다.

5. 결 론

본 논문에서는 신경회로망 PID 제어기를 제작하여 선형 부분을 제어하는 일반 PID 제어기와 비선형 성분 및 출력 오차를 보상하는 신경회로망 보상기로 구성된 신경회로망 보상 비선형 PID 제어기를 제작하였다. 또한, 신경회로망의 초기 제어 파라미터 설정 방법을 제시하여 기존 신경회로망 PID 제어기의 단점을 개선하였다. 이와 같은 구조는 대부분의 적용 제어기가 PID 제어항과 외란을 보상하는 항으로 구성되었다는 Harris의 이론에 근거한 것이며[8], Wang의 방법과도 개념적으로 유사하다. 신경회로망 보상 비선형 PID 제어기는 PID 제어기 구조를 변형하지 않고 신경회로망으로 출력오차를 보상함으로써 일반 PID 제어기에 자기동조 기능을 제공한

다. 초기 제어 파라미터, 외란, 시스템 동특성 변화 등 다양한 조건에서 시뮬레이션을 통하여 제시한 비선형 PID 제어기의 우수성을 보였다. 또한, 실제 강한 비선형 시스템으로 알려진 자기 부양 시스템에 적용하여 실험한 결과 만족할 만한 결과를 얻었다. 앞으로, 좀더 단순하고 빠른 수렴특성을 갖는 신경회로망과 H/W구현에 대한 연구를 하여 저비용으로 현장에 이미 설치된 PID 제어기에 견실하고 우수한 자기동조 기능을 제공하는 노력이 요구된다.

참 고 문 헌

- [1] Watanabe, K., *Adaptive estimation and control, partitioning approach*, Prentice-hall, 1992.
- [2] Ahmed, M. S. and Tasadduq, I. A., "Neural-net control for nonlinear plants: design approach through linearization," *IEE Proc. Control Theory Application*, Vol. 141, No. 5, pp. 315-322, 1994.
- [3] Chan, K. C. and Leong, S. S., "A neural network PI controller tuner," *Artificial intelligence in engineering*, Vol. 9, pp. 167-176, 1995.
- [4] Jota, F. G., "Practical automatic tuning methods of PID controllers for a sour water stripper," *IEEE international symposium on intelligent control*, Columbus, Ohio, USA, pp. 22-26, 1994.
- [5] Tan, Y and Keyser, R, "Adaptive PID control with neural network based predictor," pp. 1490-1494, *CONTROL'94*, March 1994.
- [6] Wang Fuli and et. all, "Neural network pole placement controller for nonlinear systems through linearization," *Proc. of the ACC*, pp. 1984-1988, 1997.
- [7] Wang Fuli and et. all, "A PID-like controller for nonlinear systems," *Proc. of the ACC*, pp. 1558-1562, 1997.
- [8] Harris, T. J. and MacGREGOR, J. F., "An overview of discrete stochastic controllers: generalized PID algorithms with dead-time compensation," *The canadian J. of Chemical Eng.*, Vol. 60, pp. 425-432, 1982.
- [9] Ishida, Y. and et. all, "Nonlinear PID controller using neural networks," *IEEE International Conf. on Neural Networks*, pp. 811-814, 1997.
- [10] Astrom, K. J. and Hagglund, T., *Automatic tuning of PID controllers*, ISA, NC, 1995.
- [11] 이창구, 신동용, "오차 자기순환 신경회로망에 기초한 적용 PID 제어기," 제어자동화시스템 논문지, Vol. 4, No. 2, pp.209-214, 1998
- [12] Scalero, R. S. and Tepedelenlioglu, N., "A fast new algorithm for training feedforwrd neural networks," *IEEE Trans. Signal Processing*, Vol. 40, pp. 202-210, 1992.

저자 소개



이 창 구 (李 昌 求)

1958년 12월 25일 생. 1981년 전북대 전기공학과 졸업. 1991년 동 대학원 전기 공학과 졸업(공박). 1983년~1992년 한국전자통신 연구소 선임연구원. 1996년 Alberta대학 방문교수. 현재 전북대 공대 전자정보공학부 부교수

Tel : (0652) 270-2476

E-mail : changgoo@moak.chonbuk.ac.kr