

인공신경망에 의한 PID 제어기 자동동조에 관한 연구

A Study on the Auto-Tuning of a PID Controller using Artificial Neural Network

정 종 대*

Jong Dae Jung*

이 논문은 1994년도 한국학술진흥재단의 공모과제 연구비에 의하여 연구되었음

요 약

본 논문에서는 인공 신경망(ANN)을 이용하여 파라미터를 자동동조 시킴으로써 미지의 공정을 제어할 수 있는 PID제어기를 제안하였다. 제안된 알고리즘에서는 제어기의 파라미터가 제어 공정의 오차를 줄이는 방향으로 조정된다. 이 과정에서 미지의 공정의 입출력간 감도가 필요하게 된다. 따라서 이 감도를 얻기 위하여 ANN의 학습능력이 사용되었다. regulation 문제에 대해서 컴퓨터 모의실험을 수행하여 Ziegler-Nichols PID 제어기와 결과를 비교하였다. 결과적으로 제안된 알고리즘은 상승시간, 오버슈트, 언더슈트 그리고 세틀링시간의 측면에서 Ziegler-Nichols 제어기의 성능을 능가함을 보였다.

ABSTRACT

In this paper, we proposed a PID controller, which could control unknown plants using Artificial Neural Network(ANN) for auto-tuning of the PID parameters. In the proposed algorithm, the parameters of the controller were adjusted to reduce the error of the controlled plant. In this process, the sensitivity between input and output of the unknown plant was needed. So, in order to obtain this sensitivity, the ANN's learning ability was used. Computer simulations were performed for the regulation problems, and the results were compared with those of Ziegler-Nichols PID controller. As a result, it was shown that the proposed algorithm outperformed Ziegler-Nichols controller in rise time, overshoot, undershoot, and settling time.

I. 서 론

PID 제어기는 구조가 단순함에도 불구하고 강인한 특성 때문에 아직도 대부분의 산업공정에 널리 사용되고 있으며 그 설계 및 응용에 관한 연구는 역사가 상당히 오래 되어서 많은 연구결과들이 나와 있다.

*한국기술교육대학교 전기공학과

PID 제어기는 그 구조를 이미 알고 있는 것이기 때문에 대부분의 연구목표가 제어기의 매개변수를 어떻게 선정할 것인가에 맞춰져 있다. 그 동안 국내외의 많은 연구자들이 PID 제어기의 매개변수를 체계적으로 동조할 수 있는 알고리즘을 개발하기 위하여 노력하여 왔으며 이를 연구결과들을 그 접근 방법에 따라 살펴보면 주파수영역에서 정의되는 절점주파수, 위

를 추정하는 것이 아니라 단지 입출력사이의 감도만을 추정하면 되므로 간단한 구조와 함께 계산량의 부담도 경감된다는 이점이 있다.

Ⅱ 절에서는 PID 제어기의 매개변수 동조 알고리즘을 제안하고 Ⅲ 절에서는 알고리즘 수행에 필요한 공정의 동특성을 식별하기 위한 신경망의 구조 및 알고리즘에 대해 서술한다. Ⅳ 절에서는 제안한 PID 제어기와 신경망을 결합한 전체적인 시스템의 단위계단 함수응답을 시뮬레이션 하면서 부수되는 여러가지 현상들을 검토하며 마지막으로 Ⅴ 절에서는 본 연구를 통해 얻어진 결론을 정리한다.

II. PID 제어기의 매개변수 동조 알고리즘

전형적인 이산시간 PID 제어기의 구조는 그림 1과 같다. 여기서 $y_p(k) = G(u(i))$, $i < k$ 이고 $G(\cdot)$ 는 공정의 입출력간 동특성을 나타내는 미지의 함수이다. $C(\cdot)$ 는 PID 제어기의 전달함수이며 $e_p(k) = r(k) - y_p(k)$ 로서 기준신호와 공정 출력간의 오차이다.

연속시간 PID 제어기의 일반꼴은 다음과 같다.

$$C(s) = \frac{u(s)}{e(s)} = K_p \left(1 + \frac{1}{T_i s} + T_D s \right) \quad (1-1)$$

$$= K_p + \frac{K_I}{s} + K_D s \quad (1-2)$$

여기서 K_p 는 비례이득, T_i , T_D 는 각각 적분상수 및 미분상수이며 $K_I = K_p/T_i$, $K_D = K_p * T_D$ 이다. (1-2)식을 표본화시간 K_o 로 표본화하면 다음과 같은 이산시간 PID 제어기의 전달함수를 얻는다.

$$C(z) = \frac{u(z)}{e(z)} = K_p \left(1 + \frac{T_o z}{T_i(z-1)} + T_D \frac{(z-1)}{T_o z} \right) \quad (2)$$

(2)식에 의해 $u(k)$ 와 $e_p(k)$ 와의 관계를 구하면 다음과 같다.

$$\begin{aligned} u(k) &= u(k-1) + K_p [e_p(k) - e_p(k-1)] + K_I T_o e_p(k) \\ &+ K_D [e_p(k) - 2e_p(k-1) + e_p(k-2)]/T_o \end{aligned} \quad (3)$$

(3)식을 속도형 제어기라고 하며 여기서 K_p , K_I , K_D 들이 PID 제어기의 매개변수들이다. 본 논문에서는 제어시스템의 추종오차 $e_p(k)$ 가 결국 이 매개변수들

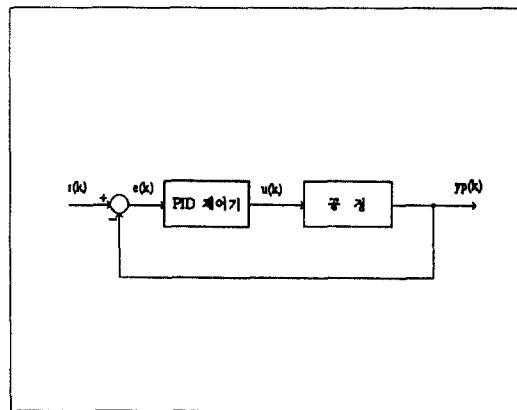


그림 1. 전형적인 PID 제어기 구조

Fig. 1 Typical PID Controller Structure

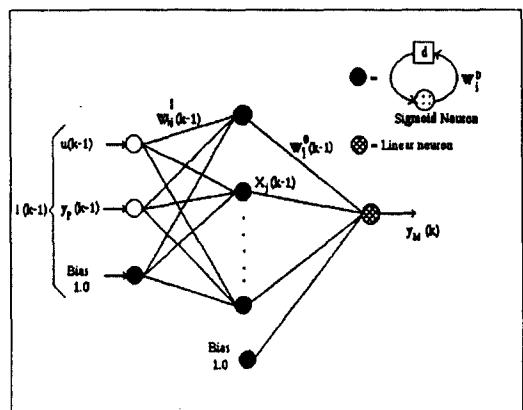


그림 2. DRNN 구조

Fig. 2 The DRNN Structure

과 관계가 있을 것이라는 점에 착안하여 전체오차의 각 매개변수들에 대한 변화율, 즉 경사도(gradient)를 구하고 전체오차가 감소하는 방향이 되도록 각 매개변수들을 조절하고자 한다. 제어의 목표를 다음의 목적함수를 최소화하는 것이라고 하자.

$$E_p = \frac{1}{2} (r(k) - y_p(k))^2 = \frac{1}{2} e_p(k)^2 \quad (4)$$

(4)식의 목적함수의 제어기 각 매개변수들에 대한 변

화율은 다음과 같이 계산된다.

$$\begin{aligned} \frac{\partial E_p}{\partial K_p(k-1)} &= -e_p(k) \frac{\partial y(k)}{\partial u(k-1)} \frac{\partial u(k-1)}{\partial K_p(k-1)} \\ &= -e_p(k) \frac{\partial y(k)}{\partial u(k-1)} [e_p(k-1) - e_p(k-2)] \quad (5-1) \end{aligned}$$

$$\frac{\partial E_p}{\partial K_I(k-1)} = -e_p(k) \frac{\partial y(k)}{\partial u(k-1)} e_p(k-1) T_o \quad (5-2)$$

$$\begin{aligned} \frac{\partial E_p}{\partial K_D(k-1)} &= -e_p(k) \frac{\partial y(k)}{\partial u(k-1)} \\ &[e_p(k-1) - 2e_p(k-2) + e_p(k-3)]/T_o \quad (5-3) \end{aligned}$$

(5)식의 값으로부터 제어기의 각 매개변수들은 다음과 같이 매 표본화 시간마다 오차가 감소하는 방향으로 적절하게 자동조절될 수 있다.

$$\mathbf{K}(k+1) = \mathbf{K}(k) + \Delta \mathbf{K}(k), \Delta \mathbf{K}(k) = -\eta_c \frac{\partial E_p}{\partial \mathbf{K}(k-1)} \quad (6)$$

여기서, $\mathbf{K}(k) = [K_p(k), K_I(k), K_D(k)]'$ 이며 η_c 는 매 단계에서의 매개변수 변화량을 조절하는 계수이다. 그런데 (5)식의 경사도 계산시 $\partial y_p(k)/\partial u(k-1)$ 는 공정의 전달함수 $G(\cdot)$ 를 모르기 때문에 직접 구할 수 없다. $\partial y_p(k)/\partial u(k-1)$ 는 바로 공정의 입력에 대한 출력의 감도로서 이 값은 직접 주어지지 않으므로 신경망에 의한 시스템 식별기(identifier)를 사용하여 이 값을 추정하고자 한다.

신경망에 의한 시스템 식별기는 공정에 가해진 제어입력 $u(k-1)$ 과 출력 $y_p(k-1)$ 을 이용하여 추정출력 $y_M(k)$ 을 만들어 낸 다음 이 값이 공정의 실제 출력 $y_p(k)$ 와 같아지도록 매개변수들(신경망에서는 연결가중치들)을 조절한다. 따라서 신경망이 올바로 훈련된다면 이 $y_M(k)$ 가 실제 공정의 출력 $y_p(k)$ 와 근사하게 될 것이고 직접 구할 수 없는 량인 $\partial y_p(k)/\partial u(k-1)$ 대신에 알고 있는 신경망 구조로부터 자연스럽게 얻을 수 있는 $\partial y_M(k)/\partial u(k-1)$ 를 사용할 수 있을 것이다.

III. 신경망에 의한 시스템 식별기 설계

신경망을 사용하여 미지 공정의 동특성을 식별하고자 하는 많은 연구가 수행되고 있으며 신경망을 구성하는 방식의 관점에서 보면 크게 피드포워드 신경

망구조를 사용하는 방식과 리커런트 신경망구조를 사용하는 방식으로 나누어 볼 수 있다.[3, 7]

본 논문에서는 Chao-Chee Ku 등[2]이 제안한 DRNN (Diagonal Recurrent Neural network) 구조를 사용하였는데 제어기 구성시 $\partial y(k)/\partial u(k-1)$ 계산과정을 수정하여 사용하였다. 이 구조는 한 개의 은닉층을 가지며 은닉층 뉴런들에서 각자 자신에게로만의 리커런트 연결을 갖게 하여 동특성을 모사할 수 있도록 한 단순한 구조이면서도 완전연결을 갖는 리커런트 신경망과 같은 학습효과를 얻을 수 있다. 또한 은닉층 뉴런은 시그모이드 함수에 의해 비선형특성을 갖게 하고 출력층 뉴런은 선형특성을 갖게 하여 일반적인 공정의 동특성을 용이하게 모사할 수 있도록 하였다. 그림 2에 이 신경망의 구조를 보인다. 이 신경망의 출력은 다음과 같이 계산된다.

$$S_j(k) = W_j^D(k) X_j(k-1) + \sum_{i=1}^{ni+1} W_{ji}^I(k) I_i(k), j = 1, 2, \dots, nh \quad (9-1)$$

$$X_j(k) = f(S_j(k)), j = 1, 2, \dots, nh, y_M(k+1)$$

$$= \sum_{j=1}^{nh+1} W_j^H(k) X_j(k) \quad (9-2)$$

여기서 $I(k)$ 및 $X(k)$ 는 각각 입력벡터와 은닉층의 출력벡터이며 ni 및 nh 는 입력층과 은닉층의 뉴런 갯수이고 $I_{ni+1}(k)$ 및 $X_{nh+1}(k)$ 는 입력층과 은닉층에서의 바이어스 노드로서 1. 0의 값을 갖는다. 그림 2의 구조에서 $I(k) = [u(k), y(k), y(k-1), \dots, 1.0]'$ 이다. 연결가중치 W 에 붙은 윗첨자 D, H, I 는 각각 입력층, 은닉층, 지연연결의 가중치임을 나타낸다. 식 (9-2)의 함수 $f(x)$ 는 은닉층 뉴런에서의 활성화 함수로서 다음과 같은 시그모이드 함수를 사용한다.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (10)$$

신경망 식별기의 추정오차를 줄여 나가기 위하여 다음과 같은 목적함수를 정의한다.

$$E_M = \frac{1}{2} (y_p(k) - y_M(k))^2 = \frac{1}{2} e_M(k)^2 \quad (11)$$

신경망의 가중치 학습은 다음과 같은 DBP(Dynamic Back Propagation) 알고리즘에 의해 수행된다.

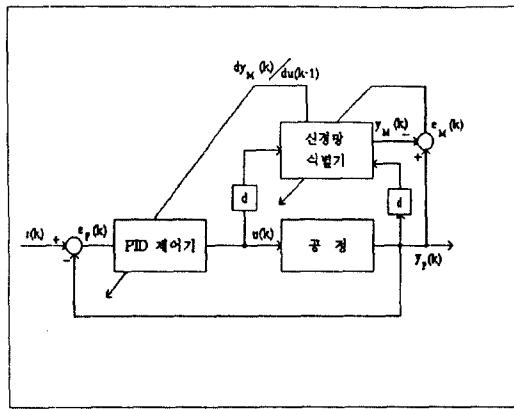


그림 3. 종합적인 제어 계통도
Fig. 3 Overall Control System

$$\Delta W^L(k) = -\eta_m \frac{\partial E_M}{\partial W^L(k-1)}, \quad W^L(k) = W^L(k-1) + \Delta W^L(k) \quad (12)$$

여기서 L 은 I, H, D 에 해당하며 각각 출력층, 은닉층 및 자연가중치임을 의미하고 η_m 은 각각 학습률이다. 목적함수의 각 가중치들에 대한 경사도는 다음과 같이 계산된다.

$$\frac{\partial E_M}{\partial W_{ji}^I(k-1)} = -e_M(k) W_j^H(k-1) Q_{ji}(k-1), \\ i=1, \dots, ni+1, j=1, \dots, nh \quad (13-1)$$

$$Q_{ji}(k) = \frac{\partial X_j(k)}{\partial W_{ji}^I(k-1)} = f'(S_j(k)) [I_i(k) + W_j^D(k) Q_{ji}(k)], \\ \frac{\partial E_M}{\partial W_j^D(k-1)} = -e_M(k) W_j^H(k-1) P_j(k-1), \quad j=1, \dots, nh, \\ P_j(k) = \frac{\partial X_j(k)}{\partial W_j^D(k)} = f'(S_j(k)) [X_j(k-1) \\ + W_j^D(k) P_j(k-1)] \quad (13-2)$$

$$\frac{\partial E_M}{\partial W_j^H(k-1)} = -e_M X_j(k-1), \quad j=1, \dots, nh+1, \quad (13-3)$$

이제 미지 공정의 입출력간 변화율 $\partial y_M(k)/u(k-1)$ 은 다음과 같이 구해질 수 있다. 이는 $\partial y_M(k)/\partial u(k-1)$ 계산시 신경망의 동특성이 반영되도록 Chao-Chee

K_u 의 식을 수정한 것이다.

$$\frac{\partial y_M(k)}{\partial u(k-1)} = \sum_{j=1}^{nh+1} W_j^H(k-1) R_j(k), \quad R_j(k) \\ = f'(S_j(k)) [W_j^D(k) R_j(k-1) + W_{j1}^I(k)] \quad (14)$$

이제 신경망에 의한 시스템 식별기와 PID 제어기를 결합한 종합적인 제어계통도를 그림 3에 보인다.

IV. 시뮬레이션 및 검토

시뮬레이션에 사용한 공정은 Zhen-Yu Zhao 등[9]이 사용했던 3, 4차 공정들로서 다음과 같은 전달함수들을 갖는다.

$$G_1(s) = \frac{4.228}{(s+0.5)(s^2+1.64s+8.456)} \quad (15-1)$$

$$G_2(s) = \frac{27}{(s+1)(s+3)^3} \quad (15-2)$$

시뮬레이션에서는 이 공정들을 표본화주기 $T_o=0.05$ 초로 이산화하였다. 그 뒤 우선 이 공정들에 구형파입력을 인가하여 얻어진 데이터로 신경망을 학습시킴으로써 신경망이 공정들의 개방 루프 동특성을 갖도록 하였다. 물론 이 학습은 제어 시스템 구성전에 오프라인으로 수행되며 학습오차는 40 epoch 정도에서 충분히 적은 값으로 수렴하였다. 이 DRNN의 수렴성은 [2]의 논문에 잘 증명되어 있다. 여기서 한 epoch이라 함은 한 주기의 구형파응답을 800 샘플로 채집한 학습데이터에 대한 한 번의 학습을 의미한다.

시뮬레이션에 사용된 신경망은 2 개의 입력 뉴런 ($ni=2$)과 5 개의 출력 뉴런 ($nh=5$)을 가지며 학습시 η_m 의 값은 0.1을 사용하였고 각 연결가중치의 초기값으로는 -1 과 $+1$ 사이의 임의의 값을 사용하였다. $ni=2$ 이므로 입력벡터는 $I(k)=[u(k), y(k), 1.0]'$ 가 사용되었다.

이렇게 3, 4차 공정의 동특성을 학습한 신경망들을 PID 제어기의 이득동조에 사용하였으며 그림 4, 5는 각각 임의의 초기치들로부터 출발한 제어기 매개변수들이 어느 정도 동조되고 난 뒤의 3차 및 4차 공정의 구형파응답을 Ziegler-Nichols PID와 비교해 보인 것이다. 여기서 제어기 매개변수의 초기치는 애초 제

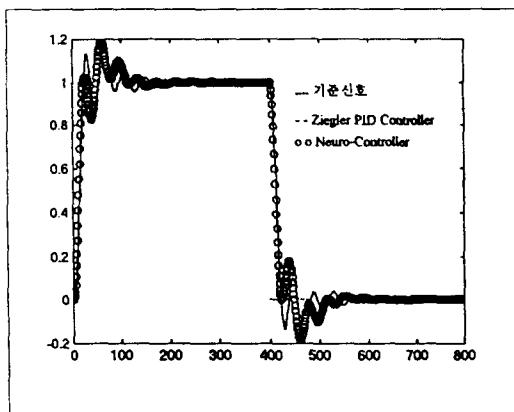


그림 4. 3차공정의 구형파응답
Fig. 4 Pulse response of 3rd order system

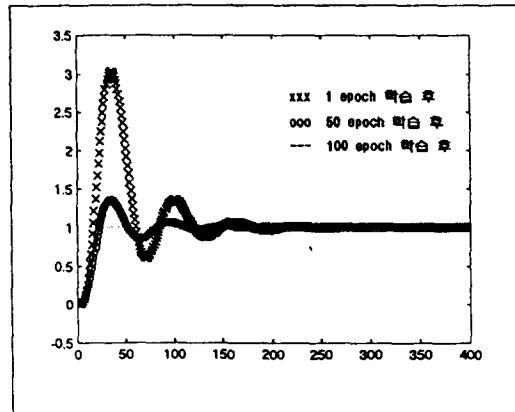


그림 7. 학습진행에 따른 응답변화(4차)
Fig. 7 Response progress during Training

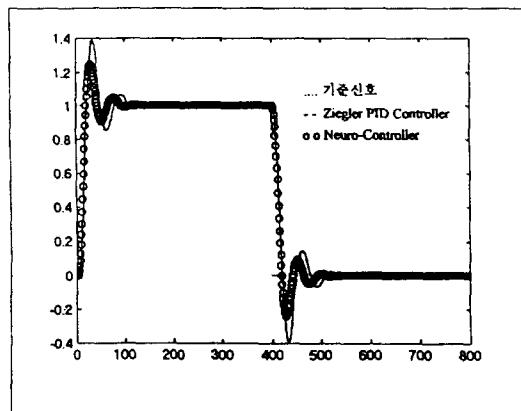


그림 5. 4차공정의 구형파응답
Fig. 5 Pulse response of 4th order system

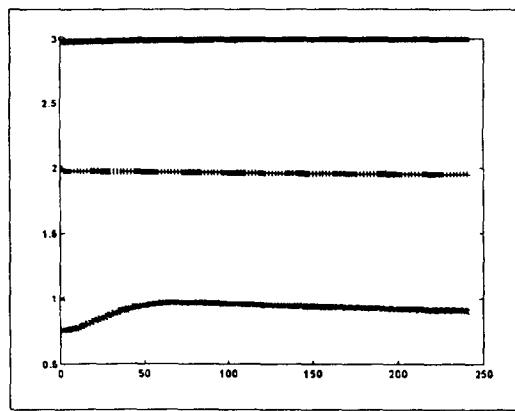


그림 8. 학습진행에 따른 PID 이득 변화
Fig. 8. PID gain progresses during Training

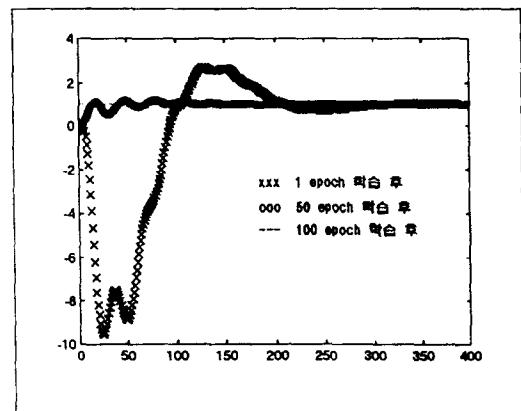


그림 6. 학습진행에 따른 응답변화(3차)
Fig. 6 Response progress during Training

어시스템이 불안정영역에 있지 않도록 적당한 값을 잡아 주어야 하는데[6] 본 시뮬레이션에서는 Ziegler-Nichols PID와 비교를 위해 3차 공정에 대해서는 $K_{PO} = 2.0$, $K_{IO} = 2.0$, $K_{DO} = 0.5$ 를 사용하였고 4차 공정에 대해서는 $K_{PO} = 3.0$, $K_{IO} = 2.0$, $K_{DO} = 1.0$ 으로 하였다. Ziegler-Nichols PID 제어기의 3, 4차 공정에 대한 이득들은 각각 $K_p = 2.19$, $K_i = 2.13$, $K_D = 0.565$ 및 $K_p = 3.072$, $K_i = 2.272$, $K_D = 1.038$ 이었다. 또한 η_m 및 η_c 값들로는 모두 0.1을 사용하였다.

그림 4와 그림 5에서 보듯이 3, 4차 시스템 모두에서 제안한 제어기의 출력이 Ziegler-Nichols PID 제어기의 출력보다 상승시간, 세틀링시간 및 오버슈트

면에서 우수함을 알 수 있다. 특히 4차 공정에 대해서는 현저한 특성개선을 볼 수 있다. 3차 공정의 경우는 공정 자체의 극점들이 허수축에 가까운 곳에 위치하고 있어서 상승시간이 조금 개선되면서 특히 언더슈트가 악화되고 있음이 보인다.

그림 6, 7은 전혀 학습되지 않은 신경망을 사용하여 $\partial y(k)/\partial u(k-1)$ 를 추정하게 하고 그 값을 사용하여 PID 제어기의 이득들을 동조시키는 경우 시간이 경과함에 따라 공정의 출력이 어떻게 변하는지를 보여주고 있다. 3, 4차 모두 제어이득의 초기치로는 위에서 사용한 값을 사용하였다. 그림을 보면 학습이 상여유도, 이득여유도 등에 의해 제어기 매개변수들을 동조시키는 방법[8]이나 시간영역에서 시간에 가중치를 둔 오차의 제곱들을 적분한 값을 성능지표함수로 사용하고 적절한 최적화 과정을 거쳐 제어기의 매개변수를 동조시키는 방법[5]이 있고 제어기를 포함한 전체 폐루프 시스템의 극점의 위치가 원하는 장소에 있도록 제어기의 매개변수들을 동조시키는 극배치형[10] 등이 있다.

그러나 이런 방법들은 제어대상 공정의 구조(차수, 지연시간등)에 대한 사전지식이 필요하거나 동조과정에 복잡한 수치해석적 최적화 기법이 필요하여 동조과정을 자동화하기 어렵다는 단점이 있다. 최근에는 PID 제어기의 매개변수동조과정을 퍼지추론과정에 포함시켜 동조하게 하든지[1, 9] PI 제어기의 골격을 퍼지제어기에 융합시키거나 혼합시켜 PID 제어기의 장점을 취합과 아울러 동조문제를 해결하려는 시도가 있어 왔다[4]. 그러나 퍼지추론에 의한 접근 방법 역시 전문가의 지식을 얻기가 힘들고 설계자체가 체계적이지 못하여 많은 시행착오가 수반되는 약점이 있다.

Roman W.Swiniarski[6]은 신경망의 학습기능을 사용하여 PID의 매개변수들을 자동설정 하려고 하였는데 이 방법은 제어대상 공정의 계단함수에 대한 개방루프(open loop)응답을 신경망의 입력으로 하고 신경망의 출력이 바로 그 계단응답에 대한 Ziegler-Nichols 방법의 PID 제어기의 매개변수가 되도록 제어기를 훈련시킴으로써 임의의 공정으로부터 얻어진 계단응답이 입력될 때 빠른 속도로 그 공정에 알맞은 PID 제어기의 매개변수가 계산되어서 나오도록 한 것이다. 이 방법은 신경망이 갖는 소위 패턴 정합기능을

이용한 것으로 이것 역시 온라인으로 그때 그때의 시스템 환경에 따라 매개변수들을 조정하는 기법은 아니다.

신경망을 제어에 적용하는데는 제어기 구성에 신경망을 어느 정도로 포함시키는가에 따라 신경망만으로 구성하는 방식, 종래의 제어기와 병렬로 신경망 제어기를 혼합시키는 방식, 종래의 제어구조의 일부를 신경망으로 학습시키는 방식 등이 있을 수 있는데 일반적으로는 신경망을 그대로 제어기구성에 활용하는 방법이 많이 사용되고 있고 나름대로의 우수한 제어가능성을 입증하고 있으나 대부분의 경우 신경망의 학습신호를 얻기 위해 또 하나의 신경망이 필요하게 되어 구조가 복잡해진다.

본 논문에서는 인공신경망의 학습기능을 이용하여 전적으로 미지인 공정에 대해서도 설정된 제어목표가 달성될 수 있고 외란과 공정의 동특성변화에도 능동적으로 대처할 수 있게 스스로 학습을 수행하면서 제어기의 매개변수들을 온라인으로 조정해 나가는 제어기구조를 제안하고자 한다. 본 논문에서 시도하고자 하는 방법은 기존의 PID 제어기 구조를 그대로 유지하고 있으며 미지 공정의 동특성을 식별(identification)하기 위한 하나의 신경망만을 사용하는데 이 신경망 식별기는 공정의 상태변수나 매개변수 전체 진행됨에 따라 제어출력이 크게 개선되고 있음을 알 수 있다.

그림 8은 미학습 신경망으로 이득동조를 할 경우 4차 공정에 대한 PID 이득들의 동조양상을 보여준다. 이득들이 Ziegler-Nichols 이득과는 약간 다른 값들로 수렴하고 있음을 볼 수 있다.

전체 제어시스템의 응답은 신경망과 제어이득의 초기치에 따라 큰 영향을 받는다. 즉 초기치들이 잘못 설정될 경우 애초 시스템이 불안정영역에 있게 되고 그 경우에는 학습의 의미가 없어진다. 또한 많은 시뮬레이션 결과, 제어기 이득들의 수렴속도가 비교적 느렸으며 계속적인 학습에 의해 계속 응답의 상승시간을 단축시키고 오버슈트와 언더슈트를 줄이기 위해 과도한 제어입력이 발생될 수 있음을 알 수 있었다. 이런 현상을 피하기 위해서는 제어기출력에 리미터를 달고 이 리미터의 비선형성을 공정의 동특성에 포함시켜 신경망으로 학습하게 하면 될 것이다.

V. 결 론

본 논문에서는 PID 제어기설계에 있어서 가장 문제가 되는 제어기 매개변수의 자동설정을 위한 방법을 제안하였다. 미지의 공정에 대해서도 온라인으로 매개변수가 자동조정될 수 있도록 하기 위하여 신경망의 학습기능을 이용하여 공정의 동특성을 추정하고 그때 얻어지는 정보를 사용하여 전체 제어 시스템의 오차가 감소되도록 PID 제어기의 각 이득들을 조절한다. 3차 및 4차 공정에 대한 시뮬레이션 결과 제안한 신경망 제어기는 기존의 PID 제어기구조를 그대로 유지하면서 약간의 알고리즘 추가에 의해 종래의 Ziegler-Nichols 제어기 보다 상승시간은 물론 오버슈트, 언더슈트를 크게 개선시킬 수 있음을 보여주었다. 앞으로의 과제는 전체 제어 시스템의 오차수렴성에 대한 증명과 제어기 이득의 수렴속도 개선 및 제어목표함수에 적절한 제한조건을 포함시킴으로써 과도한 제어입력이 발생하지 않도록 하는 것 등이 될 것이다. 특히 제어기 및 신경망 모두 랜덤한 초기치를 가짐으로써 발생할 수 있는 시스템의 불안정성을 피하는 강인한 방법이 연구되어야 할 것이다.

참 고 문 헌

1. C. W. de Silva, "Simulation studies of an analytical fuzzy tuner for a PID servo", Proc. ACC, pp. 2100-2105, 1991.
2. Chao-Chee Ku and Kwang Y. Lee, "System identification and control using diagonal recurrent neural networks," Proc., ACC, pp. 545-549, 1992.
3. Kumpati S. Narendra, Kannan Parthasarathy, "Identification and control of dynamical systems using neural networks," IEEE Tr., Neural Networks, vol. 1, no. 1, pp. 4-27, Mar, 1990.
4. M. Mizumoto, "Realization of PID controls by fuzzy control methods," Proc. IEEE, pp. 709-715, Feb, 1992.
5. M. Zhuang, D. D. Atherton, "Optimal PID controller settings using integral performance criteria," Proc., ACC, pp. 3042-3043, 1991.
6. Roman W. Swiniarski, "Novel neural network based self-tuning PID controller which uses pattern recognition technique," Proc. ACC, pp. 3023-3024, 1990.
7. Si-Zhao Qin, Hong-Te Su, and Thomas J. McAvoy, "Comparison of four neural net learning methods for dynamic system identification," IEEE Tr., Neural Networks, vol. 3, no. 1, pp. 122-130, Jan, 1992.
8. Tor Steinar Schei, "Closed-loop tuning of PID controllers," Proc. ACC, pp. 2971-2975, 1992.
9. Zhen-Yu Zhao, et al., "Fuzzy gain scheduling of PID controllers," IEEE Tr. on Sys., man and Cyber., vol. 23, no. 5, pp. 1392-1398, Sep. 1993.
10. 남문현, 이규영, "직류 서어보 전동기제어를 위한 직접 극배치 PID 자기 동조 제어기의 설계," 전자공학회논문지, 제27권, 제2호, pp. 55-64, 1990, 2.

정 종 대(Jong Dae Jung)

정회원

1956년 9월 19일 생.

1990년: 서울대학교 대학원 전자공학과 졸업(공학박사)

1985년~1993년: 수원대학교 전자계산학과 조교수

1993년~현재: 한국기술 교육대학교 전기공학과 부교수

※주관심 분야: 적용제어 및 인공신경망 응용, 제어 및 문자인식 등