

오차 자기순환 신경회로망에 기초한 적응 PID제어기

Adaptive PID Controller Based on Error Self-Recurrent Neural Networks

이 창 구, 신 동 용
(Chang-Goo Lee, Dong-Young Shin)

Abstract : In this paper, we are dealing with the problem of controlling unknown nonlinear dynamical system by using neural networks. A novel error self-recurrent(ESR) neural model is presented to perform black-box identification. Through the various outcome of the experiment, a new neural network is seen to be considerably faster than the BP algorithm and has advantages of being less affected by poor initial weights and learning rate. These characteristics make it flexible to design the controller in real-time based on neural networks model. In addition, we design an adaptive PID controller that Keyser suggested by using ESR neural networks, and present a method on the implementation of adaptive controller based on neural network for practical applications. We obtained good results in the case of robot manipulator experiment.

Keywords : ESR(error self-recurrent), PID(proportional integral derivative), black-box identification

I. 서론

신경회로망에 대한 연구가 현재 활발히 진행되고 있으며 비선형 시스템 인식과 제어를 포함한 다양한 분야에 적용되어 실용화되고 있다[1][2]. 일반적으로, 시스템 인식과 제어에 이용하는 신경회로망은 다층 순방향(multilayer feedforward) 구조이고 이를 위한 학습방법은 역전파(back-propagation : BP) 알고리즘이다[3]. 제어기 설계에 신경회로망을 활용하는 방법은 플랜트의 역모델을 학습하고 이를 이용하는 방법, 제어기 자체로서 신경회로망을 사용하는 방법, 신경회로망 모델에 기초하여 제어기를 설계하는 방법 등 다양한 방법들이 제시되어 왔다[4]~[6]. 최근들어 신경회로망 모델에 기초한 적응 예측제어기 설계에 대한 연구가 일반적인 제어설계 기법과 연관되어 활발히 진행되고 있다[7]~[9]. 예측 모델로 이용되는 신경회로망은 대부분 BP 알고리즘에 의하여 학습되어져 수렴 속도가 매우 빠르고 초기 연결강도(weight) 값들이나 학습 계수(learning rate)에 민감하게 반응하는 단점 때문에 실시간 제어기 설계에 있어 어려움이 많다[10]. 최근까지 제어기 설계에 필요한 견실하고 빠른 수렴특성을 지닌 신경회로망 구조와 학습방법에 대한 많은 연구들이 발표되었다. 그 대표적인 예로서, Scalero와 Tepedelenlioglu는 각각 신경회로망을 선형과 비선형 구간으로 구분하고 칼만(Kalman) 필터링 기법을 도입하여 수렴속도를 빠르게 하고 초기 연결강도값에 크게 영향을 받지 않도록 개선하였다. 그러나, 여전히 은닉층(hidden layer)의 선형 오차값을 BP 알고리즘에 의하여 계산하기 때문에 학습계수에 민감한 단점이 있다[11][12].

본 논문에서는 실시간 적응제어기 설계에 필요한 빠르고 정확한 시스템인식을 위해 바이어스(bias) 입력으로 +1 대신에 오차가 시간지연되어 케환되는 오차 자기순환(error self-recurrent: ESR) 신경회로망을 제시하였다.

ESR 신경회로망의 학습방법으로 은닉층의 목표값을 최

적기법에 의하여 직접 계산하고 연결강도는 반복 최소자승(recursive least square : RLS)법으로 추정하는 알고리즘을 개발하였다. 또한, 기존의 간접 적응제어기 설계방법과 같이 제안한 ESR 신경회로망 모델에 기초한 적응 PID제어기(ESRNN-PID)를 설계하고 강한 비선형 시스템으로 알려진 로봇 매니퓰레이터에 적용하여 좋은 결과를 보였다. 이와같은 단순 신경회로망 모델에 기초한 간접 적응제어기는 적용 대상에 따라 제어기의 구조를 변형할 필요가 없기 때문에 범용성을 갖는다. 마지막으로 신경회로망 모델을 기초한 적응제어기의 현장 적용시에 발생되는 문제점을 해결하기 위하여 초기동작 구간에서 기존 PID제어기와 ESRNN-PID제어기를 병렬 운전함으로써 실시간 제어의 가능성을 제시하였다.

II. ESR 신경회로망

최근들어 Scalero와 Tepedelenlioglu는 다층 순방향 신경회로망을 구성하는 신경소자를 그림 1과 같이 선형과 비선형 구간으로 구분하고 연결강도를 칼만 필터링 방법을 도입하여 구함으로써 초기 연결강도값에 따른 강인성을 개선하고 수렴속도를 향상시킨 학습알고리즘을 제시하였다[12].

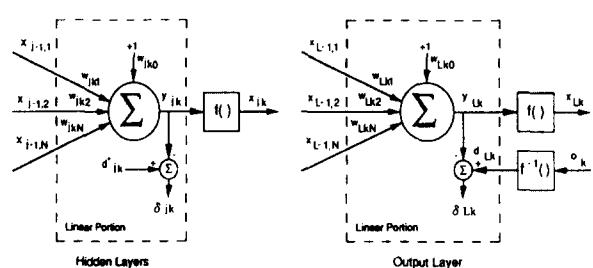


그림 1. 은닉층과 출력층에서 신경소자의 구분.

Fig. 1. Linear and nonlinear portion of the neurons in the hidden and output layers.

록 칼만기법에 의하여 이득(k)과 covariance 메트릭스(P)를 계산하고 연결강도 벡터(w_{jk})을 생성하는 것으로 다음과 같이 요약할 수 있다.

1) 출력층과 은닉층에서 목표하는 합출력을 (1), (2)에 의하여 구한다.

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

$$d_{jk} = y_{jk} + \mu \delta_{jk} \quad (2)$$

위 (2)에서 μ 는 학습계수를, 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.

$$\mathbf{k}_j = \mathbf{P}_j \mathbf{x}_{j-1} / (\lambda + \mathbf{x}_{j-1}^T \mathbf{P}_j \mathbf{x}_{j-1}) \quad (3)$$

$$\mathbf{P}_j = (I - \mathbf{k}_j \mathbf{x}_{j-1}^T) \mathbf{P}_j / \lambda \quad (4)$$

위 (4)에서 \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 (5),(6)에 의하여 생성한다.

$$w_{Lk} = w_{Lk} + \mathbf{k}_L (d_{Lk} - y_{Lk}) \quad (5)$$

$$w_{jk} = w_{jk} + \mu \mathbf{k}_j \delta_{jk} \quad (6)$$

Scalero와 Tepedelenlioglu가 제시한 학습방법은 칼만필터링 방법에 의하여 수렴속도를 개선하고 초기 연결강도 값에 견실한 장점이 있으나 은닉층의 목표값을 BP 알고리즘과 같은 방법으로 구하기 때문에 학습계수에 따라 성능이 크게 좌우되는 단점이 있다. 본 논문에서는 이와 같은 단점을 개선하기 위하여 최적기법에 의하여 은닉층의 목표값을 제공하는 한편 수렴속도를 좀더 빠르게 하기 위해 바이어스 입력으로 한 단계 이전의 추정오차가 자기순환하는 신경모델을 제시하고 이를 개념을 명확화하였다[13].

1. ESR 신경모델

그림 2 a)와 같은 일반 신경모델로 구성된 다층 순방향 신경회로망에서 외부적으로 인가되는 바이어스 입력은 일반적으로 크기가 +1이나 -1로 고정되고 연결강도(w_{jk0})만큼의 바이어스가 활성함수의 net입력을 증가하거나 감소하는 기능을 수행한다[10]. 일반 신경모델에서 바이어스(w_{jk0})의 크기와 기호는 다른 연결강도들과 함께 학습되기 때문에 그 물리적인 의미가 명확하지 않다. 또한, 바이어스 입력을 실제 적용하는 시스템에 따라 어떻게 결정할지 이에 대한 이론이 없다.

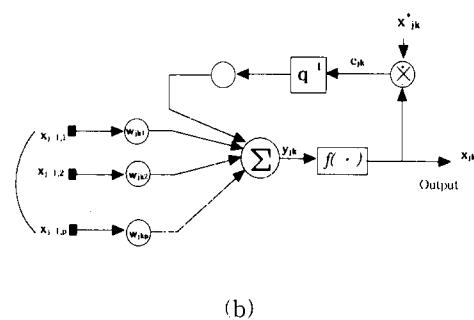
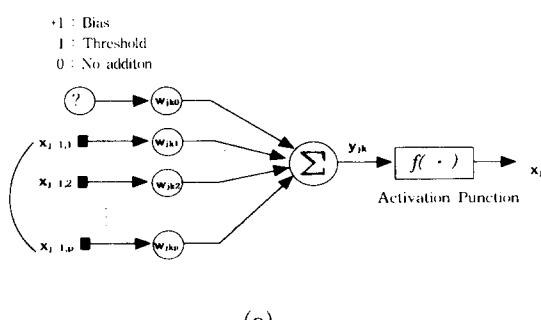


그림 2. 일반 신경모델과 오차 자기순환 신경모델.

Fig. 2. Conventional neuron model and ESR neuron model.

본 연구에서는 빠르게 변하는 동적(dynamic) 시스템을 실시간 인식하기 위해 그림 2b)와 같이 신경모델의 바이어스 입력으로 +1대신에 한 단계 이전의 추정오차($e_{jk}(t-1)$ 즉, 출력층은 $q^{-1}(o_k - x_{Lk})$, 은닉층은 $q^{-1}(x_{jk}^* - x_{jk})$)가 자기순환하는 구조를 갖도록 하고 이에 해당하는 연결강도는 μ 값으로 고정하여 이와같은 모호성을 해결하고자 한다. ESR 신경모델 구조에서는 만약 현재의 추정오차가 양수 값이면 다음 단계에서 바이어스는 양수값으로 net입력을 증가하여 망출력이 목표값에 추종하도록 한다. 반대로 현재의 추정오차가 음수값이면 바이어스는 음수값으로 net입력을 감소하여 망출력이 또한 목표값을 추종하도록 하여 궁극적으로는 수렴속도를 빠르게 하는 기능을 수행한다. ESR 신경모델은 net입력을 증감시키는데 있어 과거 오차를 의미있는 정보로 활용함으로써 자동적으로 바이어스의 크기와 기호를 설정할 뿐만 아니라 신경회로망의 출력이 기준 목표치에 빠르게 수렴하는 기능을 갖도록 한다. 오차 자기순환 다층신경회로망의 일반적인 구조는 그림 3과 같다.

2. 학습 알고리즘

Scalero 학습 알고리즘의 단점을 개선함과 동시에 앞 절에서 제시한 ESR 신경회로망의 바이어스 입력으로 이용되는 은닉층의 오차를 계산하기 위해 은닉층의 목표값(x_{jk}^*)을 최적기법에 의하여 구하고 연결강도는 RLS에 의하여 추정하는 학습알고리즘을 개발하였다.

ESR 신경회로망의 학습방법은 은닉층의 목표값을 최적기법에 의하여 구하고 연결강도는 RLS법에 의하여 추정하는 것으로 요약할 수 있다. 이의 설명을 간략화하기 위하여 하나의 은닉층을 갖는 다층 신경회로망을 생각하여 보자. 입력, 은닉, 출력 층의 노드수가 각각 N,P,M이라 하고 성능지수를 (7)과 같이 표시하도록 하자.

$$E = \frac{1}{2} \sum_{k=1}^M (d_{Lk} - x_j^T w_{Lk})^2 \quad (7)$$

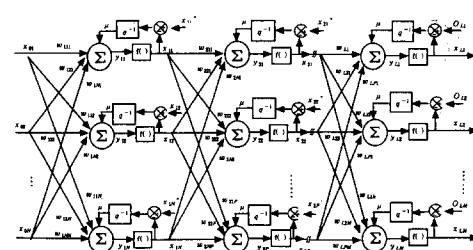


그림 3. 오차 자기순환 신경회로망.

Fig. 3. Error self-recurrent neural.

여기에서 o_k , $d_{Lk} = f^{-1}(o_k)$ 는 각각 출력층 k 노드의 목표값과 선형목표값이고, \mathbf{w}_{Lk} 는 은닉층과 출력층의 k 번째 노드 사이의 연결강도 벡터로 (8)과 같다. 또한, \mathbf{x}_j 는 은닉층의 출력벡터이고 (9)와 같다.

$$\mathbf{w}_{Lk} = [w_{Lk0}, w_{Lk1}, \dots, w_{LkP}]^T \quad (8)$$

$$\mathbf{x}_j = [\chi_{j0}, \chi_{j1}, \dots, \chi_{jP}]^T \quad (9)$$

제안한 ESR 신경회로망 구조에서는 w_{Lk0} 는 양수값(μ)으로 고정되었고 χ_{j0} 는 바이어스 입력($e_{Lk}(t-1)$)이며 이에 해당하는 목표값이 필요하지 않으므로 (7)을 (10)과 같이 표시하고 $\mathbf{w}_{Lk} = [w_{Lk1}, w_{Lk2}, \dots, w_{LkP}]^T$, $\mathbf{x}_j = [\chi_{j1}, \chi_{j2}, \dots, \chi_{jP}]$ 로 각각 나타낸다.

$$E = \frac{1}{2} \sum_{k=1}^M (d_{Lk} - \mu e_{Lk}(t-1) - \mathbf{x}_j^T \mathbf{w}_{Lk})^2 \quad (10)$$

(10)에서 출력층의 연결강도 매트릭스가 최적의 값으로 학습되어 졌다고 보고 은닉층의 출력에 대한 (10)을 최소화하는 최적의 출력값을 구하여 이를 은닉층의 목표값으로 정한다. \mathbf{x}_j 에 대한 함수 E의 최소화 결과는 (11)과 같이 표시할 수 있으며 이를 매트릭스 형태로 다시쓰면 (12)과 같다.

$$\frac{\partial E}{\partial \mathbf{x}_j} = 0$$

$$\Rightarrow \sum_{k=0}^M (d_{Lk} - \mu e_{Lk}(t-1)) \mathbf{w}_{Lk} = \sum_{k=0}^M \mathbf{w}_{Lk} \mathbf{w}_{Lk}^T \mathbf{x}_j \quad (11)$$

$$\mathbf{W}_L \mathbf{d}_L = \mathbf{W}_L \mathbf{W}_L^T \mathbf{x}_j \quad (12)$$

(11)에서 $\mathbf{W}_L = [\mathbf{w}_{L0}, \dots, \mathbf{w}_{Lk}, \dots, \mathbf{w}_{LM}]$ 은 $P \times M$ 차원의 출력층의 연결강도 매트릭스이며, $\mathbf{d}_L = [d_{L1} - \mu e_{L1}(t-1), \dots, d_{Lk} - \mu e_{Lk}(t-1), \dots, d_{LM} - \mu e_{LM}(t-1)]^T$ 는 출력층의 선형목표값과 바이어스의 편차로 구성된 $M \times 1$ 벡터이다. 즉, (12)은 M개의 방정식으로 P개의 알려지지 않은 값을 구하는 문제이다. 은닉층의 최적 목표값($\mathbf{x}_j^* = [\chi_{j1}^*, \dots, \chi_{jP}^*]$, ..., χ_{jM}^*)은 $P \geq M$ 인 경우에 (12)를 만족하는 해는 하나 이상이 있을 수 있으며 minimum norm 방법을 이용하여 (13)과 같이 구할 수 있다.

$$\mathbf{x}_j^* = \mathbf{W}_L (\mathbf{W}_L^T \mathbf{W}_L)^{-1} \mathbf{d}_L \quad (13)$$

다만, (13)에서 $\mathbf{W}_L^T \mathbf{W}_L$ 는 nonsingular 매트릭스가 되어야 하며 만약 singular인 경우에는 pseudoinverse 개념을 적용하여 계산한다. (13)으로 표현된 은닉층의 목표값으로부터 은닉층 k 노드의 선형 목표값은 (14)와 같이 구한다.

$$d_{jk}^* = f(\mathbf{x}_{jk}^*)^{-1} \quad (14)$$

ESR 신경회로망을 위한 학습알고리즘을 요약하면 은닉층의 선형 목표값은 (2) 대신에 (14)에 의하여 출력층부터 역방향으로 구하고 바이어스 입력에 대한 연결강도($w_{jk0} = \mu$)가 고정되었으므로 이를 제외한 입력벡터에 대하여 RLS방법에 의하여 이득(3)과 covariance 매트릭스(4)를 계산한다. 마지막으로 바이어스 입력에 해당하는 연결강도를 제외한 연결강도들은 (15)에 의하여 갱신한다.

$$\mathbf{w}_{jk} = \mathbf{w}_{jk} + \mathbf{k}_j (d_{jk}^* - y_{jk} + \mu e_{jk}(t-1)) \quad (15)$$

III. 시스템인식과 시뮬레이션

ESR 신경회로망과 학습 알고리즘을 평가하기 위하여

시스템인식 실험을 수행하였다. 다층 순방향 신경회로망을 이용하여 동적 비선형 시스템을 인식하기 위해 그림 4와 같이 플랜트 출력과 제어입력을 시간지연시켜 신경회로망 입력으로 순환하도록 하였다.

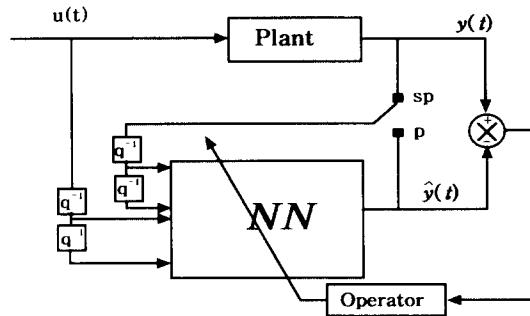


그림 4. 비선형 동적 시스템을 위한 인식 방법

Fig. 4. Identification method for nonlinear dynamic systems.

실험을 위한 플랜트는 비선형 시스템 모델로서 여러 논문에서 인용된 (16)으로 선정하고 입력신호는 $u(t) = 0.5\sin(2\pi t/50) + 0.5\sin(2\pi t/70)$ 로 발생하여 수행하였다.

$$y(t) = 0.8u(t-1)y(t-1)y(t-2) + 0.25e^{u(t-1)} / (1 + y^2(t-1) + y^2(t-2)) \quad (16)$$

신경회로망은 5-7-1구조로 하고 연결강도의 초기값은 0~0.5사이의 랜덤한 값으로 주어졌으며 BP와 Scalero 알고리즘에서 학습계수(μ)는 0.05로 선정하였다. RLS추정을 위해 초기 covariance 매트릭스값은 10000I 제공하고 망각인자는 0.98로 하였다. 그림 5와 6은 기존 신경회로망에 각각 BP알고리즘과 Scalero 알고리즘에 의한 망출력을 보여 주었다. 그림에서 보듯이 Scalero 알고리즘이

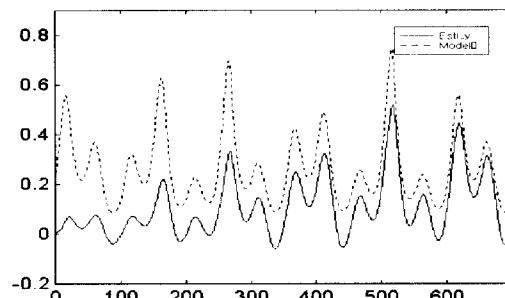


그림 5. BP에 의한 신경회로망 출력(bias 입력이 +1).

Fig. 5. Neural network output by BP algorithm(bias input is +1).

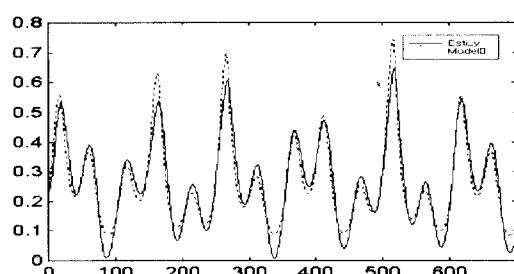


그림 6. Scalero 방법에 의한 신경회로망 출력(bias 입력이 +1).

Fig. 6. Neural network output by Scalero's algorithm(bias input is +1).

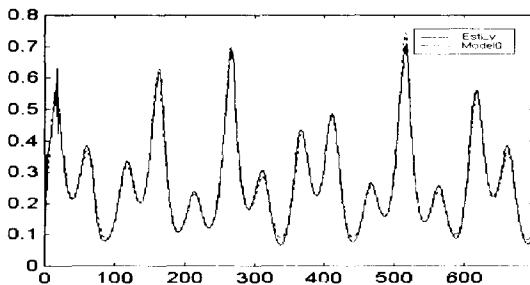


그림 7. 제시된 방법에 의한 신경회로망 출력(bias 입력이 +1).

Fig. 7. Neural network output by proposed algorithm (bias input is +1).

기존의 BP 알고리즘보다 빠른 수렴특성을 보였으나 여전히 시간이 경과한 후에 수렴함을 알 수 있고 추정오차가 존재한다. 그림 7은 기존 신경회로망에 제안한 학습알고리즘에 의한 시스템인식 결과로써 기존 방법들보다 좀더 빠르게 수렴하고 정확함을 확인할 수 있다.

그림 8과 9는 ESR 신경회로망에 앞서와 같은 조건下에서 각각 BP 알고리즘과 Scalero 알고리즘에 의한 망 출력을 보여 주었다. 그림에서 보듯이 ESR 신경회로망이 일반 신경회로망보다 빠른 수렴특성을 보였다. 그림 10은 ESR 신경회로망에 제안한 학습 알고리즘에 의한 시스템인식 결과로써 기존 방법들보다 좀더 빠르게 수렴하고 정확함을 확인할 수 있었다. 그림 7과 그림 10에서 초기의 채터링 현상이 발생하나 다른 학습방법들도 모델에 따라 나타나는 현상으로 빠른 수렴특성의 장점에 비하면 큰문제가 되지 않는다. 그림 8, 9, 10을 그림 5, 6, 7과 비교하여 보면은 ESR 신경모델이 수렴속도를 빠르게 하는 기능을 갖는다는 것을 보여준다.

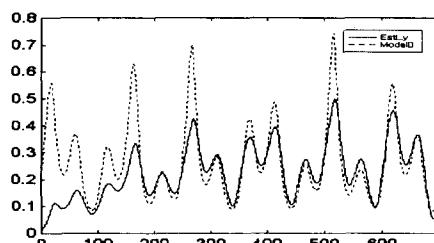


그림 8. BP에 의한 신경회로망 출력 (bias 입력이 $e_{jk}(t-1)$).

Fig. 8. Neural network output by BP algorithm (bias input is $e_{jk}(t-1)$).

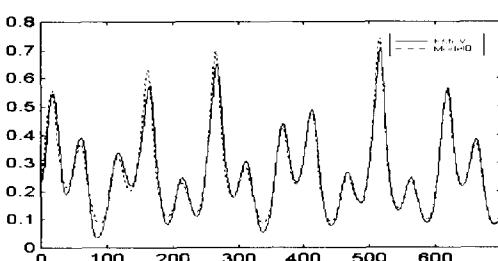


그림 9. Scalero 방법에 의한 신경회로망 출력(bias 입력이 $e_{jk}(t-1)$).

Fig. 9. Neural network output by Scalero's algorithm(bias input is $e_{jk}(t-1)$).

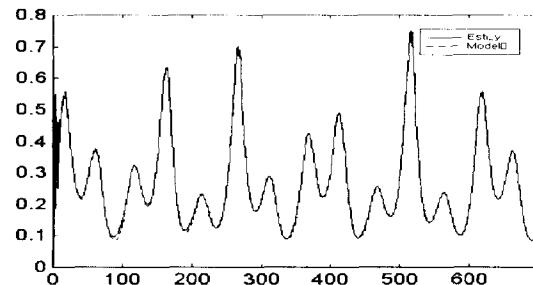


그림 10. 제시된 방법에 의한 신경회로망 출력(bias 입력이 $e_{jk}(t-1)$).

Fig. 10. Neural network output by proposed algorithm(bias input is $e_{jk}(t-1)$).

IV. 신경회로망에 기초한 적응 PID 제어기

1. ESR 신경회로망을 이용한 적응 PID 제어기 설계 및 실험

신경회로망 모델을 이용한 제어기 설계에 대한 연구는 Morris, Keyser 등에 의하여 최근 까지 많은 연구결과들이 발표되었다[14][15]. 그러나, 대부분의 제어기 성능이 신경회로망 모델에 민감하기 때문에 빠른 학습능력을 갖지 못하는 신경망모델에 기초한 제어기는 실시간 제어에 이용하지 못하는 실정이다[6]-[10]. 지금까지 대부분의 연구결과들은 오프라인으로 제어대상 플랜트를 학습한 고정된 신경회로망 모델에 기초하여 제어기를 설계하였기 때문에 적응제어기 개념과 거리가 있다. 본 논문에서는 이러한 단점을 개선하기 위해 실시간 시스템인식이 가능하도록 새로운 신경회로망을 제시하였고 이를 기초한 적응 PID제어기(이하: 적응 ESRNN_PID제어기)를 개발하였다. 본 장에서는 Keyser가 제안한 신경 예측모델을 이용한 적응 PID제어기 설계에 대한 개념을 간략하게 설명하고 본 논문에서 제시한 ESR 신경회로망 모델에 기초한 적응 PID제어기를 설계하고 그 성능을 평가한다. 일반적으로 SISO 비선형 시스템을 신경회로망에 의하여 한단계 이전의 비선형 예측모델로 표현하면 (17)과 같다.

$$y^{nm}(t+1) = f[\mathbf{w}_L^T f[\mathbf{w}_{L-1}^T \dots f[\mathbf{w}_1^T \mathbf{x}_1]]] \quad (17)$$

단, $\mathbf{x}_1 = [y(t), \dots, y(t-n+1), u(t), \dots, u(t+1-m)]^T$
PID제어기는 산업현장에 지속적으로 널리 이용되는 제어기이다. 불연속 PID제어기는 일반적으로 (18)와 같이 표현할 수 있으며 제어계수 K_i 를 적절히 조절하는 것을 동조라고 한다. 본 논문에서는 신경회로망 모델에 기초하여 온라인으로 K_i 를 조절하는 적응 자기동조 PID제어기를 설계하고자 한다.

$$u(t) = u(t-1) + K_1 e(t) + K_2 e(t-1) + K_3 e(t-2) \quad (18)$$

만약에 신경회로망 모델이 정확하다고 한다면 예측제어 개념하에서는 케환신호로서 플랜트출력대신에 신경회로망의 출력을 이용한다. 즉, 제어오차를 $e(t) = r(t+1) - y^{nm}(t+1)$ 로 설정하고 신경모델 예측출력이 제어기에 케환하도록 하면 예측 제어기처럼 동작한다. 여기에서 $r(t)$ 는 기준목표값이다. 또한, PID제어기의 계수는 (19)와 같은 성능지수를 설정하고 이를 최소로 하도록 gradient descent 방법을 적용하여 조절한다.

$$J = 1/2 [e(t)]^2 = 1/2 [r(t+1) - y^{nm}(t+1)]^2 \quad (19)$$

$$\begin{aligned} K_i(t) &= K_i(t-1) - \lambda \frac{\partial J}{\partial K_i(t)} \\ &= K_i(t-1) + \lambda e(t) \frac{\partial y'''(t+1)}{\partial u(t)} \frac{\partial u(t)}{\partial K_i(t)} \quad (20) \end{aligned}$$

제어신호 $u(t)$ 에 대한 $y'''(t+1)$ 의 미분은 신경회로망 모델(17)로부터 쉽게 구할 수 있다. 즉, 적용 PID제어기는 (17)에 의하여 모델을 예측하고 (18)에 의하여 제어신호를 발생한다. 제어기의 계수는 (20)에 의하여 온라인 동조함으로써 적응성을 갖도록 하였다. 개발한 적용 PID제어기의 성능평가를 위한 플랜트로서 로봇의 서보실험 모델을 널리 사용되는 (21)을 선정하고 Ziegler-Nichols 동조법에 의하여 설계된 일반 PID제어기, BP신경회로망 모델에 기초한 적용 PID제어기 및 ESR 신경회로망 모델에 기초한 적용 PID제어기를 온라인으로 실험하였다.

$$\begin{aligned} y(t) = & 0.2y^2(t-2) + 0.2y(t-1) + 0.25y(t-2) \\ & + 0.25u(t-1) + 0.45 \sin(0.5(y(t-1) \\ & + y(t-2))) \cos(0.5(y(t-1) + y(t-2))) \quad (21) \end{aligned}$$

그림 11은 Ziegler-Nichols 동조식에 의하여 설계된 일반 PID제어기에 의한 응답으로써 일정한 크기의 정상상태 오차가 있고 운전조건과 플랜트가 변화할 경우에 적응성이 떨어짐을 확인할 수 있다. 그림 12는 실시간으로 인식된 BP 신경회로망 모델에 기초하여 설계된 적용 PID제어기에 의한 응답이다. 초기에는 시스템인식이 매우 부정확하여 제어성능이 떨어지며 연결강도의 초기값에 따라 제어기가 발산하는 경우도 있다. 그러나 연결강도값이 임의의 한정된 값으로 수렴하면 시간이 흐름에 따라 적응성을 갖음을 확인할 수 있다. 그림 13은 본 논문에서 제시한 ESR 신경회로망 모델을 이용한 적용 PID제어기로 매우 빠른 추적(tracking) 능력을 보여 주었다. 특히, 안정하고 빠른 수렴특성을 지녀 신경회로망 모델에 기초한 실시간 적용 제어기의 설계가 가능하도록 하였다.

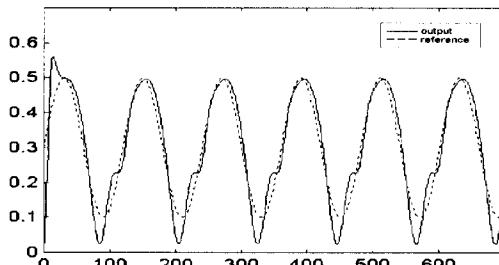


그림 11. 일반 PID제어기에 의한 플랜트 출력.
Fig. 11. Plant output of a conventional PID controller.

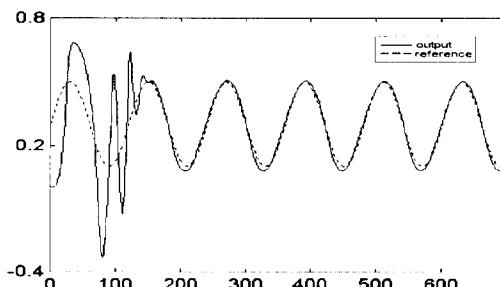


그림 12. BP 신경회로망에 기초한 PID제어기에 의한 플랜트 출력.
Fig. 12. Plant output of a PID controller based on BP neural networks.

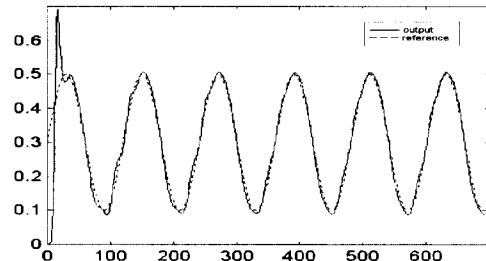


그림 13. ESR 신경회로망에 기초한 PID제어기에 의한 플랜트 출력.
Fig. 13. Plant output of a PID controller based on ESR neural networks.

2. 적용 ESRNN_PID 제어기 구현

신경회로망 모델에 기초한 적용 PID제어기는 초기제어국면동안에 연결강도의 학습정도에 따라 성능이 좌우되므로 우수한 적응능력에도 불구하고 실제 산업현장에 실시간으로 적용하는데 문제가 있을 수 있다. 이러한 문제점을 해결하기 위하여 그림 14에서와 같이 초기제어시 일정기간 동안 일반 PID제어기로 제어함과 동시에 병렬로 신경회로망에 기초한 제어기를 학습하고 스위칭하면 신경회로망 모델을 이용한 적용 PID제어기의 실시간 현장적용에 대한 문제점을 해결 할 수 있다.

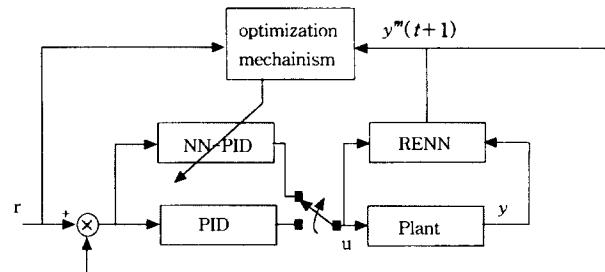


그림 14. ESR 신경회로망에 기초한 PID제어기의 구현.
Fig. 14. Implementation of a PID controller based on ESR neural networks.

그림 15는 앞서 제시한 방법과 같이 50스텝까지 일반 PID제어기로 제어함과 동시에 병렬로 적용 ESRNN_PID 제어기를 학습하고 전환한 경우의 제어응답으로써 매우 안정적이고 적응성 있는 결과를 얻었다. 초기국면에서 안정적인 운전을 할 수 있었으나 그림 13에 비하여 적응성이 떨어짐을 확인할 수 있었다. 이와같은 이유는 PID제어 계수가 임의의 값으로 초기제어 국면에서 수렴하고 그후에 매우 작은량만 변화하기 때문이다.

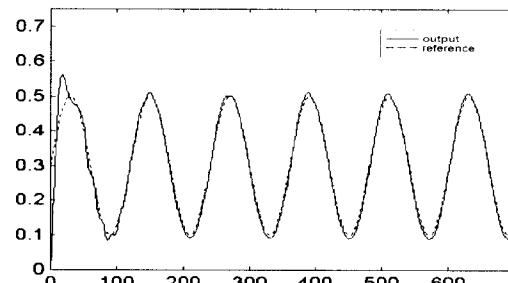


그림 15. 제어기의 병렬 구현에 의한 제어응답.
Fig. 15. Control response by parallel implementation of the controller.

V. 결론

본 논문에서는 다층 신경회로망의 학습속도를 개선하기 위해 바이어스 입력으로 +1 대신에 오차가 시간지연되어 자기 순환하는 신경모델로 구성된 새로운 ESR 신경회로망을 제시하였다. ESR 신경회로망의 학습방법으로 은닉층의 목표값은 최적기법을 이용하여 직접 계산하고 각각의 연결강도값은 RLS에 의하여 추정하는 알고리즘을 개발하였다. 여러가지 실험결과에 의하면 제안한 방법이 초기 연결강도에 크게 영향을 받지 아니하고 기존 학습방법의 학습계수 설정에 따른 문제를 해결함과 동시에 수렴속도를 빠르게 함으로써 신경회로망 모델에 기초한 실시간 제어기 설계를 용이하게 하였다. ESR 신경회로망 모델을 이용하여 Keyser가 제시한 적용 PID를 설계하고 로봇 매니퓰레이터 제어에 실험하여 좋은 성능을 보였다. 특히, 신경회로망에 기초한 적용 PID제어기의 실시간 현장적용을 위하여 기존 PID제어기와 병렬구조를 갖도록 하고 초기제어 구간동안 오프라인으로 학습한후에 전환하도록 하였다. 앞으로 ESR신경망을 이용한 다양한 제어기 설계에 대한 연구와 함께 안정도 증명이 요구된다.

참고문현

- [1] K. S. Narendra and Patthasarathy, "Identification and control of dynamical systems using neural networks," *IEEE Trans. Neural Networks*, vol. 1, pp. 4-27, 1990.
- [2] H. Wabgaonkar and A. Stubberud, "A system identification technique based on neural networks," *Proc. IEEE Int. Conf. Systems Engineering*, Kobe, Japan, pp. 352-356, Sept., 1992.
- [3] D. E. Rumelhart and J. L. McClelland, *Parallel Distributed Processing*, vol. 1, MIT Press, 1986.
- [4] M. J. Wills et. al, "Artificial neural networks in process estimation and control," *Automatica*, vol. 28, no. 6, pp. 1181-1187, 1992.
- [5] K. J. Hunt, D. Sbararo and P. J. Gawthrop, "Neural networks for control systems - A survey," *Automatica*, vol. 28, no. 6, pp. 1083-1112, 1992.
- [6] A. J. Morris, G. A. Montague and M. J. Willis, "Artificial neural networks : studies in process modelling and control," *Trans IChemE*, vol. 72, Part A, pp. 3-19, Jan., 1994.
- [7] A. Draeger, S. Engell and H. Ranke, "Model predictive control using neural networks," *IEEE Control system*, pp. 61-66, Oct., 1995.
- [8] B. S. Dayal, P. A. Taylor and J. F. Macgregor, "The design of experiments, training and implementation of nonlinear controllers based on neural networks," *The Canadian J. of ChemE*, vol. 72, pp. 1066-1079, 1994.
- [9] H.-T. Su and T. J. McAvoy, "Neural model predictive control of nonlinear chemical process," *Int. Symposium on Intelligent Control, Chicago*, pp. 358-364, Aug., 1993.
- [10] S. Haykin, *Neural Networks : A Comprehensive Foundation*, Macmillan College Publishing Company Inc., NY, 1994.
- [11] S. Singhal and L. Wu, "Training feedforward networks with the extended Kalman algorithm," *Proc. IEEE Int. Conf. Acoustic, Speech, Signal Processing*, pp. 1187-1190, May, 1989.
- [12] R. S. Scalero and N. Tepedelenlioglu "A fast new algorithm for training feedforward neural networks," *IEEE Trans. Signal Processing*, vol. 40, pp. 202-210, 1992.
- [13] 이창구, "오차순환 신경회로망을 이용한 빠른 시변 비선형 시스템의 인식과 제어," *대한전기학회 논문지*, 제48권, 제12호, pp. 1793-1799, 1997.
- [14] G. A. Montague, M. J. Willis and Morris, "Artificial neural network model based control," ACC'94, pp. 2134-2138, 1994.
- [15] R. D. Keyser and Yonghong Tan, "Adaptive PID control with neural network based predictor," *CONTROL'94*, pp. 1490-1494, 1994.

이 창 구



1958년 12월 25일생. 1981년 전북대 전기공학과 졸업(공학사). 1991년 동대학원 전기공학과 졸업(공학박사). 1983년~1992년 한국전자통신연구소 선임연구원. 1996년 1월~12월 Alberta대학 방문교수. 현재 전북대학교 전기전자

제어공학부 조교수.



신 동 용

1961년 5월 28일생. 1984년 전북대학교 공대 전기공학과 졸업. 1990년 동대학원 전기공학과 졸업(석사). 1991년~1992년 국립보건원 방사선표준부 연구사. 1993년~현재 동대학원 박사과정 수료. 1993년~현재 한라전문대 방

사선과 전임강사.