

신경 회로망을 이용한 적응 제어 시스템의 설계

·장 태인 이형찬 양해원
한양대학교 전기공학과

Design of an Adaptive Control System using Neural Network

·Tae-in Jang Hyung-Chan Rhee Hai-Won Yang
Dept. of Electrical Eng. Hanyang Univ.

Abstract : This paper deals with the design of an adaptive controller using neural network. We present RBFMLP Neural Network which consists of serial-connected two networks - Radial Basis Function Network and Multi Layer Perceptron, and then design a controller based on proposed networks with the adaptive control system structure. The plant and parameters of the controller are identified by the neural networks. We use the dynamic backpropagation algorithm for the learning of networks. Simulations represent the superiorities of the proposed network and the controller.




그림 1. RBFMLP 신경 회로망

1. 서 론

신경망과 그에 수반되는 학습 알고리즘을 이용하여 제어 시스템을 설계하는 문헌들이 최근 많이 발표되어 왔다[1-2]. 그러나, 이들 신경망들은 대부분 다단 퍼셉트론을 그대로 이용하여 제어기를 설계하였다. 다단 퍼셉트론이 비선형 함수 관계를 갖는 플랜트의 입/출력 관계를 학습할 수 있다는 사실은 널리 알려져 있으나, 입력 패턴의 수가 많아질 수록 함수의 학습 능력은 보장할 수 없으며, 수렴속도 또한 느리게 된다. 한편, 신경망을 이용한 비선형 함수의 학습에 국부 최저점(local minimum)을 피하기 위해서 RBF(Radial Basis Function) Network를 사용하여 전역 최저점(global minimum)에 이르도록 할 수 있으나, RBF Network의 중심값을 찾는 문제는 신경망의 응용에 상당한 어려움으로 작용한다.

따라서, 본 논문에서는 신경망의 국부 최저점을 피하고 수렴성을 개선시켜 학습을 용이하도록 하기 위해 전역적으로 수렴성이 보장되어 있는 RBF Network을 다단 퍼셉트론의 전단에 놓고 그 중심값을 일정한 간격으로 잡아주어 신경망의 입력 자료를 사전에 처리하도록 하고, 그 처리된 결과를 다시 다단 퍼셉트론이 세분화 하는 RBFMLP(Radial Basis Function Network and Multi Layer Perceptron) 신경망을 제시한다.

제어기 설계에 있어서는 신경망 제어기에 전적으로 의존하기 보다는 흔히 이용되는 Narendra등의 제어기 구조[4]를 이용하면서 제어기 파라미터를 앞서 제시한 RBFMLP 신경망으로 추정하는 방식을 택하였는데, 이는 제어 목적을 신속히 달성하기 위하여 플랜트의 측정 가능한 입/출력 신호를 능동적으로 이용하는 구조이다. 제시한 알고리즘의 효용성을 보이기 위하여 선형 및 비선형 플랜트에 대하여 모의 실험을 하며, 모의 실험 결과는 제안한 신경망과 제어기의 우수성을 나타낸다.

11. 본 론

1. 신경망의 구조

본 논문에서 새롭게 제시한 신경망의 구성은 각 층마다 노드 함수(node function)가 다른 은의층을 2개 갖는 3층의 구조로 되어 있다. 첫 번째 은의층은 RBF Network에 해당하고, 두 번째 은의층부터 출력층까지는 다단 퍼셉트론의 역할을 담당한다. 신경망의 전반적인 구조는 그림 1과 같다.

입력층에서 첫 번째 은의층으로 가는 구간에는 가중치가 존재하지 않으며, 단순히 입력들이 첫 번째 은의층의 뉴런들에게 배분된다. 첫 번째 은의층에서 뉴런들의 노드 함수인 radial basis 함수들은 식 (1-1)의 가우시안 함수(gaussian function)의 형태로서 그 중심값과 폭은 그림 2와 같이 정한다. 입력값의 범위와 노드의 수에 따라 일정한 간격으로 중심값 a_j 를 정하고, 인접한 뉴런의 노드 함수들이 최대치의 50%에서 겹치도록 b_j 값을 조정한다.




그림 2. RBF Network의 노드 함수들의 중심값과 폭 결정

$$O_{h1}(j) = \exp\left(-\sum_i \left(\frac{I_i - a_{ji}}{b_j}\right)^2\right) \quad (1-1)$$

두 번째 은의층에 있는 각각의 뉴런의 출력은 전단의 출력에 대한 가중치의 합과 threshold 값과의 합에 대한 함수값의 형태로 아래의 식 (1-2)로 표현된다.

$$O_{k2}(k) = f_2(S_2(k))$$

$$S_2(k) = \sum_j W_{jk} O_{k1}(j) + \theta_{k2}(k) \quad (1-2)$$

$$f_2(x) = \frac{1}{1 + \exp(-hx)}$$

여기서, h 는 시그모이드 함수의 기울기 이고

$\theta_{k2}(k)$ 는 *threshold* 값이다.

또한, 출력층에 있는 각각의 뉴런은 선형 뉴런으로서 각 출력은 전단의 출력들에 대한 가중치의 합과 *threshold* 값과의 합으로 구성된다.

$$O_o(l) = \sum_i W_{il} O_{k2}(k) + \theta_o(l) \quad (1-3)$$

여기서, $\theta_o(l)$ 는 *threshold* 값이다.

전체적인 신경망의 동작은 RBF Network의 basis 함수들이 입력 패턴을 *hyperellipsoids*로 1차 분류하고, 연속되어 있는 다단 퍼셉트론이 전단의 출력을 *hyperplanes*로 2차 분류하는 구조로서 RBF Network의 입력 자료를 미리 처리하는 형태이다.

2. 제어기 구조

제어 시스템의 기본 구조는 Narendra등의 제어기 구조를 바탕으로 하여 신경망을 도입한 형태이며 그림 3과 같이 플랜트, 기준 모델, 입/출력 필터인 보조 신호 발생기들, 그리고 플랜트와 제어기 파라미터를 추정하는 2개의 Identifier들로 구성된다.




그림 3. 신경망을 이용한 제어 시스템의 구조

제어 대상인 플랜트는 추정가능한 단일 입/출력 시스템이며, 보조 신호 발생기로는 식 (2-1)과 같은 입력 필터와 출력 필터가 사용된다.

$$\dot{v}_1(t) = \Lambda v_1(t) + g u(t) \quad (2-1)$$

$$\dot{v}_2(t) = \Lambda v_2(t) + g y_p(t)$$

여기서, $v_1(t), v_2(t) \in R^{n-1}$, n 은 플랜트의 차수

Λ 는 안정한 $(n-1) \times (n-1)$ 행렬이다.

제어 입력은 식(2-2)과 같이 구성 된다.

$$u(t) = \theta(t)^T \omega(t) + r \quad (2-2)$$

여기서, $\omega(t)^T = [v_1(t)^T \ y_p \ v_2(t)^T]$,

$\theta(t)^T = [\theta_1(t)^T \ \theta_{y_p}(t) \ \theta_2(t)^T]$ 이며,

r 는 기준 입력이다.

그림 3에서 Identifier1은 플랜트에 가해지는 입력과 출력의 관계를 추정하는 동시에, 플랜트에 대한 *sensitivity* 정보를 Identifier2에 전달해 주는 역할도 겸하고 있다. Identifier1이 플랜트의 입/출력 관계를 학습하였다고 가정하면 Identifier1의 입/출력 관계는 플랜트의 입/출력 관계와 같다고 볼 수 있으므로 *sensitivity* $y_u(t)$ 는 식 (2-3)과 같이 근사화 될 수 있다.

$$y_u(t) = \frac{\partial y_p(t)}{\partial u(t)} \approx \frac{\partial \hat{y}_p(t)}{\partial u(t)} \quad (2-3)$$

Identifier2의 역할은 제어기 파라미터 벡터 $\theta(t)$ 를 추정하는 것이다. 신경망의 입력으로서 식 (2-4) 형태의 *signum function*을 사용하였는데, 이는 제어기를 구성하는 데 쓰이는 신호들이 오차 평면 $e_1 = y_m - y_p = 0$ 인 *hyperplane*을 중심으로 어느 면에 위치할 것인가에 대한 정보를 가지고 신경망을 학습시키기 위한 것이다. Identifier2의 학습은 출력 오차의 제곱을 최소화 시키는 방향으로 행하여 지기 때문에 출력 오차를 오차 평면 $e_1 = 0$ 인 *hyperplane*상에 도달 하도록 제어기 파라미터를 추정하게 된다. 또한 식 (2-4)의 부호의 함수를 신경망의 입력 패턴으로 사용함으로써 전단의 RBF Network의 중심값의 범위를 분명하게 알 수 있는 잇점이 있다.

$$\text{sgn}(e_1 \cdot x) = \begin{cases} 1 & e_1 \cdot x > 0 \\ 0 & e_1 \cdot x = 0 \\ -1 & e_1 \cdot x < 0 \end{cases} \quad (2-4)$$

신경망들을 학습시키는 데 있어서 Identifier1과 Identifier2는 각각 성능 지수 식 (2-5)와 식 (2-6)를 최소화 하는 방향으로 역전달 (Dynamic Backpropagation) 알고리즘을 사용하여 학습된다.

$$E_1 = \frac{1}{2}(y_p - \hat{y}_p)^2 \quad (2-5)$$

$$E_2 = \frac{1}{2}(y_m - y_p)^2 \quad (2-6)$$

3. 역 전달 알고리즘

3.1 Identifier1에 대한 역 전달 알고리즘

(1) 역 전달 알고리즘

Identifier1은 플랜트의 입/출력 관계를 학습하여야 하기 때문에 식 (2-5)의 성능 지수를 최소화 하는 방향으로 학습이 진행되고 Identifier1의 출력 \hat{y}_p 가 추정해야할 목표값은 플랜트의 출력인 y_p 이다.

$$\frac{\partial E_1}{\partial \hat{y}_p} = -(y_p - \hat{y}_p)$$

$$\frac{\partial \hat{y}_p}{\partial S_o(l)} = 1$$

$$\hat{y}_p = S_o(l) = \sum_i W_{il} O_{k2}(k) + \theta_o(l), \quad l = 0$$

$$\frac{\partial S_o(l)}{\partial \theta_o(l)} = 1$$

$$\frac{\partial S_o(l)}{\partial W_{il}} = O_{k2}(k)$$

$$\frac{\partial S_o(l)}{\partial O_{k2}(k)} = W_{il}$$

$$\frac{\partial O_{k2}(k)}{\partial S_{k2}(k)} = O_{k2}(k) (1 - O_{k2}(k))$$

$$O_{k2}(k) = f_2(S_{k2}(k))$$

$$S_{k2}(k) = \sum_j W_{jk} O_{k1}(j) + \theta_{k2}(k)$$

$$\frac{\partial S_{k2}(k)}{\partial \theta_{k2}(k)} = 1$$

$$\frac{\partial S_{k2}(k)}{\partial W_{jk}} = O_{k1}(j)$$

(3-1)

$$\frac{\partial S_{k1}(j)}{\partial u} = \sum_j (-2 \frac{u - a_j}{b_j^2})$$

$$\frac{\partial u}{\partial \theta_{11}} = v_{11}, \quad \frac{\partial u}{\partial \theta_{1r}} = \gamma_r, \quad \frac{\partial u}{\partial \theta_{21}} = v_{21}$$

(3-4)

(2) 가중치 갱신 규칙

신경망의 가중치를 갱신하기 위하여 식 (3-2)과 같은 최급하강 (gradient decent)법을 사용한다.

$$W(t + \Delta t) = W(t) - \eta_1 \left(\frac{\partial E_1}{\partial W} \right) \quad (3-2)$$

$$\Delta W(t) = -\eta_1 \left(\frac{\partial E_1}{\partial W} \right)$$

$$\Delta \theta_0(l) = -\eta_1 \frac{\partial E_1}{\partial \theta_0(l)}$$

$$= -\eta_1 \frac{\partial E_1}{\partial \hat{y}_p} \frac{\partial \hat{y}_p}{\partial S_0(l)} \frac{\partial S_0(l)}{\partial \theta_0(l)}, \quad l = 0$$

$$\Delta W_{jk} = -\eta_1 \frac{\partial E_1}{\partial W_{jk}}$$

$$= -\eta_1 \frac{\partial E_1}{\partial \hat{y}_p} \frac{\partial \hat{y}_p}{\partial S_0(l)} \frac{\partial S_0(l)}{\partial W_{jk}}$$

$$\Delta \theta_{k2}(k) = -\eta_1 \frac{\partial E_1}{\partial \theta_{k2}(k)}$$

$$= -\eta_1 \frac{\partial E_1}{\partial \hat{y}_p} \frac{\partial \hat{y}_p}{\partial S_0(l)} \frac{\partial S_0(l)}{\partial O_{k2}(k)} \frac{\partial O_{k2}(k)}{\partial S_{k2}(k)} \frac{\partial S_{k2}(k)}{\partial \theta_{k2}(k)}$$

$$\Delta W_{jk} = -\eta_1 \frac{\partial E_1}{\partial W_{jk}}$$

$$= -\eta_1 \frac{\partial E_1}{\partial \hat{y}_p} \frac{\partial \hat{y}_p}{\partial S_0(l)} \frac{\partial S_0(l)}{\partial O_{k2}(k)} \frac{\partial O_{k2}(k)}{\partial S_{k2}(k)} \frac{\partial S_{k2}(k)}{\partial W_{jk}} \quad (3-3)$$

3.2 Identifier2에 대한 역전달 알고리즘

(1) 역전달 알고리즘

Identifier2가 학습하여야 할 성능 지수는 식 (2-5)이고, 플랜트를 통하여 직접 오차가 역전달될 수 없으므로 식 (2-3)의 sensitivity를 이용하여 Identifier2를 학습시킨다.

$$\frac{\partial E_2}{\partial \hat{y}_p} = -(y_m - \hat{y}_p)$$

$$\approx -(y_m - y_p)$$

$$\frac{\partial \hat{y}_p}{\partial O_{k1}(j)} = \sum_{i=0,k} \left(\frac{\partial E_2}{\partial \hat{y}_p} \frac{\partial \hat{y}_p}{\partial S_0(l)} \frac{\partial S_0(l)}{\partial O_{k2}(k)} \frac{\partial O_{k2}(k)}{\partial S_{k2}(k)} \frac{\partial S_{k2}(k)}{\partial O_{k1}(j)} \right)$$

$$\frac{\partial O_{k1}(j)}{\partial S_{k1}(j)} = O_{k1}(j)$$

$$O_{k1}(j) = f_1(S_{k1}(j))$$

$$f_1(x) = \exp(x), \quad S_{k1}(j) = -\left(\frac{u - a_j}{b_j} \right)^2$$

(2) 가중치 갱신 규칙

Identifier2의 가중치는 식 (3-2)을 이용하여 갱신되고, Identifier1을 거쳐 전달된 오차는 아래의 식 (3-5)와 같다.

$$\frac{\partial E_2}{\partial u} = \sum_j \left[\sum_{l=0,k} \left(\frac{\partial E_2}{\partial \hat{y}_p} \frac{\partial \hat{y}_p}{\partial S_0(l)} \frac{\partial S_0(l)}{\partial O_{k2}(k)} \frac{\partial O_{k2}(k)}{\partial S_{k2}(k)} \frac{\partial S_{k2}(k)}{\partial O_{k1}(j)} \frac{\partial O_{k1}(j)}{\partial S_{k1}(j)} \frac{\partial S_{k1}(j)}{\partial u} \right) \right]$$

$$\frac{\partial E_2}{\partial \theta_{11}} = \frac{\partial E_2}{\partial u} \frac{\partial u}{\partial \theta_{11}}$$

$$\frac{\partial E_2}{\partial \theta_{1r}} = \frac{\partial E_2}{\partial u} \frac{\partial u}{\partial \theta_{1r}}$$

$$\frac{\partial E_2}{\partial \theta_{21}} = \frac{\partial E_2}{\partial u} \frac{\partial u}{\partial \theta_{21}}$$

(3-5)

4. 컴퓨터 모의 실험

비선형 플랜트[5] 및 선형 플랜트[6]에 대하여 컴퓨터 모의 실험을 하여 제시한 알고리즘의 효율성을 보인다. 각각의 경우에 대해 플랜트와 기준 모델의 출력, Identifier1의 오차, 그리고 Identifier2의 출력인 제어기 파라미터들을 50초 까지 나타내었다. Identifier1은 각 층의 노드 수가 1-10-10-1 인 신경망이고 Identifier2의 각 층의 노드 수는 3-10-10-3이다. 샘플링 시간은 0.01 second로서 1초에 100개의 sample들을 가지고 학습을 하도록 하였으며, 입력측에 $|d| \leq 0.1$ 인 random noise를 가해준다.

경우 1. [5]

플랜트 :

$$\dot{x}_1 = (1+a(t))x_2$$

$$x_2 = -\sin x_1 - 2 \sin x_2 + u$$

$$z = 6x_1 + x_2 - z$$

$$y = z$$

$$a(t) = \pm 0.5, \text{ 주기 } 0.1 \text{ 인 구형파}$$

$$\varepsilon = 0.02$$

기준 모델 :

$$W_m(s) = \frac{s+1.5}{(s+1)(s+2)}$$

Identifier1에 대한 설계 파라미터 값은 $\eta_1=0.3, h=0.5$, RBF Network의 중심값의 범위 $-100 \sim 100$ 이고, Identifier2에 대한 설계 파라미터 값은 $\eta_2=0.3, h=0.5$, RBF Network의 중심값의 범위는 $-2 \sim 2$ 이며, $\Lambda = -1, g = 1.5$ 이다.

경우 2. [6]

플랜트 :

$$W_p(s) = \frac{1}{(s+1)^2}$$

기준 모델 :

$$W_m(s) = \frac{1}{(s+1)(s+2)}$$

Identifier1에 대한 설계파라미터 값은 $\eta_1=0.5, h=0.5$, RBF

Network의 중심값의 범위 -200~200 이고, Identifier2에 대한 설계 파라미터 값은 $\eta_2=0.5$, $h=0.5$, RBF Network의 중심값의 범위 -2~2이며, $\lambda = -1$, $g = 1.5$ 이다.


경우 1일 때, 기준 입력 $r = \pm 3$, 주기 4인 구형파에 대한 모의 실험 결과가 그림 4에 나타나 있다. 그림 4의 (a)에서는 플랜트의 출력이 기준 모델의 출력을 6~7 주기 이내에 추종함을 알 수가 있으며, 그림 4의 (b)는 Identifier1의 오차가 빠르게 0으로 근접함을 보여 준다. 그림 4의 (c)는 Identifier2에 의해 추정된 제어기 파라미터의 시간에 따른 변화를 나타낸다.

경우 2일 때, 기준 입력 $r = 1 + 5 \sin t$ 에 대한 컴퓨터 모의 실험 결과가 그림 5에 나타나 있다. 역시 플랜트의 출력이 5~6주기 이내에 기준 모델의 출력을 추종하고, 제어기 파라미터들이 일정한 값으로 수렴함을 알 수 있다.


이들 결과로 부터 제시한 신경망은 선형 플랜트는 물론이고 비선형 시변 플랜트를 학습할 수 있는 능력이 있고 수렴속도 또한 매우 빠름을 알 수가 있다. 또한 제어기를 구성하는 데 있어서 플랜트의 입/출력 정보를 능동적으로 이용함으로써 플랜트의 출력이 기준 모델의 출력을 신속히 추종함을 알 수 있다.

III. 결 론


신경망을 이용하여 제어기를 설계하는 문제를 다루었다. Radial Basis Function Network과 Multi Layer Perceptron을 직렬로 연결하여 새로운 특성을 갖는 RBFMLP 신경망을 제안하였고, 이를 적용 제어 시스템과 결합하여 제어기를 구성하였다.



(a) 기준 모델의 출력(y_m)과 플랜트의 출력(y_p)



(b) Identifier1의 오차($y_p - \hat{y}_p$)




(c) Identifier2의 출력들($\theta_1, \theta_2, \theta_3$)

그림 4. 비선형 시변 플랜트에 대한 모의 실험 결과


제한한 신경 회로망은 Radial Basis Function Network과 Multi Layer Perceptron의 각각의 단점을 보완하여 수렴성을 개선한 것으로써 그 효율성을 컴퓨터 모의 실험을 통하여 입증 하였으며, 제어기 설계에 있어서는 신경망의 출력만으로 플랜트를 제어하기 보다는 신경 회로망으로 제어기 파라미터를 추정하도록 학습을 시켜 플랜트에 가해지는 입/출력 정보를 적극적으로 이용한 효율적인 방식을 택하여 제어 목적을 신속히 달성하도록 하였다.

참고 문헌


- [1] K. S. Narendra and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks", IEEE Trans. on Neural Networks, Vol. 1, No. 1, pp. 4-27, March 1990.
- [2] P. Antsaklis(Eds.), "Special Issue on Neural Network in Control Systems", IEEE Control Systems Magazine, Vol. 10, No. 3, pp. 3-87, April 1990.
- [3] C. C. Ku and K. Y. Lee, "System Identification and Control using Diagonal Recurrent Neural Networks", Proceeding 1992 American Control Conference, pp. 545-549.
- [4] K. S. Narendra and L. S. Valavani, "Stable Adaptive Controller Design - Direct Control", IEEE Trans. on Automatic Control, Vol. AC-23, No. 4, pp. 570-582, August 1978.
- [5] L. Hsu and R. R. Costa, "Variable Structure Model Reference Adaptive Control using Only Input and Output Measurements", Int. J. Control, Vol. 49, No. 2, pp. 399-416, 1989.
- [6] R. Digirolamo and S. Donley, "Flight Control Law Synthesis Using Neural Network Theory", NADC-91004-60, Naval Air Development Center, Warminster, PA, 1990.
- [7] K. J. Hunt, D. Sbarbaro, R. Zbikowski and P. J. Gawthrop, "Neural Networks for Control Systems - A Survey", Automatica, Vol. 28, No. 6, pp. 1083-1112, 1992.



(a) 기준 모델의 출력(y_m)과 플랜트의 출력(y_p)



(b) Identifier1의 오차($y_p - \hat{y}_p$)



(c) Identifier2의 출력들($\theta_1, \theta_2, \theta_3$)

그림 5. 선형 시변 플랜트에 대한 모의 실험 결과