

Back-Propagation 신경 회로망을 이용한 비선형 시스템의 자기 학습 제어

박 철영, 송 호신*, 이 준타*, 박 영식**

* 동아대학교 전기공학과

** 동의대학교 전산통계학과

Self-learning control of nonlinear system using Back-propagation neural networks.

©C.H. Park*, H.S. Song*, J.T. Lee*, Y.S. Park**

* Dept. of Electrical Eng., Dong-A University

** Dept. of Computer Science & Statistics., Dong-eui University

Abstract

A new algorithm is proposed to identify the structure and the parameters of the nonlinear discrete-time plant with only the unknown dynamics and the weak informations about its structure. The proposed algorithm is constructed with the compensation method of weighing values using its previous derivatives and with the efficient technique updating self-learning coefficients. The result in this application is thought to prove the effectiveness of the algorithm proposed in this paper and its superiority to the conventional ones.

1. 서 론

1943년 신경회로를 Boolean Logic으로 해석하려 한 McCulloch & Pitts로부터 오늘날까지 신경회로에 대한 연구는 수많은 모델 및 학습이론, 구현, 응용에서 많은 발전을 가져왔다.

신경 회로망의 공학 분야에 응용되기 시작한 것은 1960년대였으며, 당시에는 주로 패턴 인식 문제를 다루었다.

신경 회로망의 응용분야중 제어 분야는 음성이나 영상 인식 보다는 입력 데이터량이 적고 접근하기가 용이하다. 그 이유는 대부분의 제어문제는 명확히 정의 되기 때문이다. 신경 회로망을 이용한 제어는 Plant의 모델 없이도 학습하여 고속, 정확한 제어가 가능하고, 또 Plant 특성 변화에 잘 적응하며 병렬성으로 인하여 실시간 제어도 가능하다. 이러한 기대속에 STR과 신경 회로망을 접목시키는 방법^[2]을 제안했고, 신경 회로망으로 적용제어^[3]를 시도하기도 하였다. 또한, 비선형 시스템의 동특성을 신경 회로망을 이용하여 동정^[4]하거나, 시스템 emulator를 역으로 부가하여 제어하는 방법^[5], plant 제어기를 신경 회로망으로 구성하여 제어 하는 방법^[6]등의 연구가 행해졌다. 그러나, 이 알고리즘은 시스템의 비선형성, 시간지연, 진동, parameter 시변특성등에 완전히 적용하기는 어려울 뿐만 아니라, 반복학습에 따른 시간 지연 및 Local Minimum 상태에 머무는 결점이 지적되고 있다.

본 논문에서는 학습 시간의 지연이 적고 Global Minimum에 도달할 수 있도록 종래의 학습법을 개량하

여, Plant의 동특성이 미지이고, Plant의 구조에 대한 미약한 정보만이 주어진 경우의 비선형 시스템 제어문제에 응용 가능성을 보이고자 한다. 또한, 가중치의 전장 변화분이 보상 및 학습률의 조정에 의해 수렴 속도를 향상시켜 실시간 제어의 가능성을 제시하고, 이를 Cramer의 Delta-제어기와 비교 검토하여 그 타당성을 고찰하고자 한다.

2. 종래의 학습 알고리즘

Back-Propagation 신경 회로망은, 입력층, 중간층, 출력층으로 되는 계층형 구조를 가지는 Network으로, Rumelhart에 의해 1986년에 제안 되었던 교사 신호가 있는 학습방법이다. 이 학습방법은 간접(1976년)과 Tsypkin(1966년)에 의해 제안된 확률적 강하법(確率的降低法)이라고 불리지는 평가 기준 최소화 학습의 특수한 경우에 해당된다.

일반적으로 신경 회로망은 그림 1.과 같이 구성할 수 있다.




그림 1. 신경 회로망의 구조.

여기서, 중간층 j 의 출력을 H_j , 출력층 k 의 출력을 O_k , 출력층 k 의 음세트를 0_{kj} , 중간층 j 의 음세트를 0_{jj} , 중간층 j 와의 결합계수는 V_{kj} 이며, 중간층과 입력층간의 결합계수는 W_{ji} 이다.

각 뉴런들은 가변 가중치로 연결된다. 즉, 신경 회로망 내의 i 번째 뉴런의 출력 I_i 가 결합계수 W_{ji} 와 가중합에 의해 뉴런 j 의 입력이 되고, 음세트 0_{ij} 와 출력을 규격화하는 함수 f 에 의해 j 의 출력 I_j 는 식(1)로 나타낼 수 있다.

$$O_j = f \left(\sum_i W_{ji} \cdot I_i + \theta_j \right) \quad (1)$$

본 논문에서는 비선형 뉴런에 사용된 출력함수는 hyperbolic tangent이며, 이것은 유연한 step function 와 유사하다.

$$f(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (2)$$

출력 함수 $f(x)$ 의 미분치는 식(3)과 같다.

$$f'(x) = 1 - f^2(x) \quad (3)$$

학습 목표는 출력층에 있어서의 교사 신호 T 와의 오차를 $\delta_k (= T - O_k)$ 로 두고, 그 2승 오차 E_p 를 최소화하는 것이다. 2승 오차 E_p 와 출력 O_k 의 변화에 대한 E_p 의 영향 $\delta E_p / \delta O_k$ 는 각각 식(4)와 식(5)로 표현된다.

$$E_p = \sum_k (T_k - O_k)^2 / 2 \quad (4)$$

$$\delta E_p / \delta O_k = - (T_k - O_k) = -\delta_k \quad (5)$$

출력층 k 의 내부 포텐셜을 $P_k (= \sum V_{kj} \cdot H_j + \gamma_k)$ 로 고쳐 쓰면, 그 출력은 $O_k = f(P_k)$ 로 되고, 결합 계수 V_{kj} 의 미소 변화에 대한 출력 O_k 로의 영향 $\delta O_k / \delta V_{kj}$ 는 식(3)에서부터,

$$\begin{aligned} \delta O_k / \delta V_{kj} &= f'(P_k) \cdot H_j \\ &= (1 - O_k^2) \cdot H_j \end{aligned} \quad (6)$$

로 표현된다. 따라서, 결합 계수 V_{kj} 의 2승 오차 E_p 에의 영향 $\delta E_p / \delta V_{kj}$ 는 식(5)과 식(6)으로부터,

$$\begin{aligned} \delta E_p / \delta V_{kj} &= \delta E_p / \delta O_k \cdot \delta O_k / \delta V_{kj} \\ &= -\delta_k \cdot (1 - O_k^2) \cdot H_j \end{aligned} \quad (7)$$

로 된다. 2승 오차 E_p 를 감소 시키기 위한 결합 계수의 갱신치 ΔV_{kj} 는 최급강하법을 사용하면 식(8)이 얻어진다.

$$\begin{aligned} \Delta V_{kj} &= -\alpha_v \cdot (\delta E_p / \delta V_{kj}) \\ &= \alpha_v \cdot \delta_k \cdot (1 - O_k^2) \cdot H_j \end{aligned} \quad (8)$$

여기서, α_v 는 학습률로서 $0 < \alpha_v < 1$ 값이다.

또, 오차는 δ_k 로서,

$$\begin{aligned} \delta_k &= -\delta E_p / \delta P_k \\ &= \delta_k \cdot (1 - O_k^2) \end{aligned} \quad (9)$$

로 정의 하면, 식(8)은 다음과 같이 고쳐 쓸 수 있다.

$$\Delta V_{kj} = \alpha_v \cdot \delta_k \cdot H_j \quad (10)$$

같은 방법으로 중간층에서 출력층으로의 결합 계수 W 에의 갱신치 ΔW 에도 최급강하법을 사용한다. 중간층의 내부 포텐셜을 $Q_j (= \sum W_{ji} \cdot I_i + \theta_j)$ 로 하면, 그 출력 $H_j = f(Q_j)$ 로 나타낼 수 있고, 결합 계수 W_{ji} 의 미소 변화에 대한 2승 오차 E_p 에의 영향은 식(11)로 표현된다.

$$\delta E_p / \delta W_{ji} = - \sum_k \delta_k \cdot V_{kj} \cdot (1 - H_j^2) \cdot I_i \quad (11)$$

결국, 중간층 j 의 오차를 σ_j 로 두면 결합 계수의 갱신치는 식(12)로 된다.

$$\Delta W_{ji} = \alpha_w \cdot \sigma_j \cdot I_i \quad (12)$$

여기서, α_w 는 학습률로서 $0 < \alpha_w < 1$ 값이다.

이상의 Back-Propagation 알고리즘을 이용한 일반적인 신경 회로망 제어기의 구조는 그림 2에 나타내었다.




그림 2. 신경 회로망 제어기의 구조.

이 제어기는 지령치와 plant의 출력이 신경 회로망 제어기의 입력이 되어 제어량을 출력한다. 또한, 지령치와 plant의 출력간의 오차로서 역 전파 알고리즘을 통해 학습을 한다.

이러한 일반적인 신경 회로망 제어기와는 달리, Cramer의 Delta-제어기는 지령치와 plant 출력간의 오차가 신경 회로망 제어기의 입력이 되어 제어량을 출력한다. Cramer의 Delta-제어기의 구조는 그림 3과 같다.




그림 3. Cramer의 Delta-제어기의 구조.

식(9)와는 달리 Cramer의 Delta-제어기에서는 다음의 상태 오차를 정의하게 된다.

$$\varepsilon = (x_d - x_a) + (x_d - x_a) + \dots \quad (13)$$

여기서, x_d , x_a 는 각각 지령치와 plant 출력이며,

x_d , x_a 는 지령치와 plant 출력의 변화분이다.
따라서, Delta-error는 다음으로 정의된다.

$$\delta_k = \varepsilon \cdot O_k \cdot (1 - O_k^2) \quad (14)$$

다시, 식(13)을 식(14)에 대입하여

$$\delta_k = [(x_d - x_a) + (x_d - x_a) + \dots] \cdot O_k \cdot (1 - O_k^2) \quad (15)$$

과 같이 쓸 수 있다.

3. 제안하는 학습 알고리즘

이상과 같이 종래의 Back-propagation 알고리즘은 Local Minimum과 학습 시간의 지연으로 인하여 제어에

용용이 어려웠다. 따라서, 학습 시간을 단축하고, 자기 학습에 있어 실시간이 가능하도록 하기 위한 알고리즘을 제시한다. 또한, 학습 계수를 지수함수적으로 감소시켜 학습 효율을 높이는 방법을 제시한다. 먼저 가중치의 전회 변화분을 고려하는 방법으로 다음과 같이 쓸 수 있다. 출력층과 중간층 사이의 가중치 변화는 식(16)으로 나타낼 수 있다.

$$V_{kj}(k+1) = V_{kj}(k) + \alpha_{kj}(k) \cdot (\Delta V_{kj}(k+1) + \beta_{kj}(k) \cdot (V_{kj}(k) - V_{kj}(k-1))) \quad (16)$$

중간층과 입력층 사이의 가중치 변화는,

$$W_{ji}(k+1) = W_{ji}(k) + \alpha_{ji}(k) \cdot (\Delta W_{ji}(k+1) + \beta_{ji}(k) \cdot (W_{ji}(k) - W_{ji}(k-1))) \quad (17)$$

같다.

또한, 출력층과 중간층의 offset의 변화는 아래와 같다.

$$\theta_{kj}(k+1) = \theta_{kj}(k) + \mu_{kj} \cdot \delta^k(k+1) \quad (18)$$

$$\theta_{ji}(k+1) = \theta_{ji}(k) + \mu_{ji} \cdot \delta^j(k+1) \quad (19)$$

그리고, 학습 계수를 지수함수적으로 감소시키는 방법을 도입하여 각종 사이의 학습 계수는 식(18)과 식(19)로 조정된다.

$$\alpha_{kj, ji}(k+1) = \alpha_{kj0, ji0} * \text{EXP}(-C_{kj, ji}/\lambda) \quad (20)$$

$$\beta_{kj, ji}(k+1) = \beta_{kj0, ji0} * \text{EXP}(-D_{kj, ji}/\lambda) \quad (21)$$

여기서, 아래 첨자 'kj, ji'는 중간층과 출력층을 나타내고, '0'은 학습초기의 값을 의미한다. 또한, C_{kj, ji}, D_{kj, ji}는 각 뉴런에 대한 학습계수의 기울기를 나타낸다.

4. 자기 학습 제어를 위한 신경 회로망

여기서 제시한 시스템은 SISO형 재환 선형 시스템으로 식(22)로 표현된다.

$$y_{k+1} = f(y_k, y_{k-1}, \dots, y_{k-p}, u_k, u_{k-1}, \dots, u_{k-p}) + g \cdot u_k \quad (22)$$

여기서, y 는 출력, u 는 입력, g 는 영이 아닌 상수이다.

만일 식(22)의 $f(\cdot)$, g 들다를 알고 있다면, 아래와 같은 제어를 행할 수 있고, 시스템 출력 y_{k+1} 는 목표 출력 d_{k+1} 를 정확히 추적할 것이다.

$$u_k = \frac{d_{k+1} - f(\cdot)}{g} \quad (23)$$

현재, $f(\cdot)$ 과 g 를 미지의 값으로 가정한다면, 신경 회로망은 이러한 힘수와 적절한 제어를 하기 위해 '학습' 을 해 나갈 것이다.

식(23)과 같은 비선형 Plant를 학습에 의해 $f(\cdot)$ 과 g 를 동정하게 된다.

$$\text{Plant } y_{k+1} = f(y_k) + g \cdot u_k \quad (24)$$

신경 회로망에 의하여 시스템을 모델화하면, 그림 3와 같으며, 동정된 Plant는 식(25)로 나타낼 수 있다.

$$\text{Model } y^{\hat{*}}_{k+1} = f^{\hat{*}}[y_k, W(k)] + g^{\hat{*}} \cdot u_k \quad (25)$$

여기서, 첨자 $\hat{*}$ 는 실 Plant의 동정 값이다.




그림 4. 비선형 시스템의 신경 회로망 모델.

$f^{\hat{*}}[y_k, W(k)]$ 의 모델은 입력층과 출력층의 뉴런수는 1개로 하고 중간층의 뉴런 수는 20 개로 하여 구성하였다. 또한 g 의 모델은 입력 u_k 에 대한 가중치로 두었다.

본 논문의 제어 불록도는 그림 5에 나타내었다. 제어목표는 plant의 출력 y_{k+1} 가 지령치 d_{k+1} 를 추적하는 것이다. 시점 k 에서 제어기의 출력 u_k 는 plant와 신경망 model에 동시에 부가된다.

제어입력 u_k 는 식(23)을 이용하면, 아래와 같다.




그림 5. 신경 회로망을 이용한 자기 학습 제어.

$$u_k = \frac{d_{k+1}}{g^{\hat{*}}} - \frac{f^{\hat{*}}[y_k, W(k)]}{g^{\hat{*}}} \quad (26)$$

제어기는 지령치와 모델에서 구한 plant의 동정치 $f^{\hat{*}}$ 와 $g^{\hat{*}}$ 를 이용하여 식(26)에 따라 제어입력 u_k 가 결정된다.

모델의 출력과 plant의 출력치와의 오차를 역 전파 학습 알고리즘에 의하여 실 plant를 동정한다.

모델 출력 $y^{\hat{*}}_{k+1}$ 는 신경 회로망의 가중치에 의존하며, 실 plant의 출력은 신경 회로망의 교사신호로 사용된다.

출력오차 $e_{k+1} = y_{k+1} - \hat{y}_{k+1}$ 라 두면, 자승오차 E_k 는 식(27)과 같다.

$$E_k = 1/2 e^2_{k+1}$$

$$= 1/2 (y_{k+1} - \hat{y}_{k+1})^2 \quad (27)$$

E_k 를 감소시키는 방향으로 역 전파 알고리즘에 따라 신경망의 가중치가 조정된다.

5. 시뮬레이션 결과 및 검토

모델 plant의 초기 가중치 $w_{ij}(0), v_{kj}(0)$ 는 -1.0에서 1.0까지 랜덤하게 선택하였으며, offset의 초기값도 동일한 범위에서 랜덤하게 결정하였다. 시뮬레이션에 사용한 plant는 식(28)과 같다.

$$y_{k+1} = 0.8 * \sin(2\pi y_k) + 1.2 * u_k \quad (28)$$




그림 6. dk 가 정현파인 경우.

제어 지령으로 정현파를 부가한 경우를 그림 6에 나타내었다. Delta-제어기의 의한 plant의 출력은 미약한 수렴성만 보일 뿐, 초기 진동이 720회의 학습 후에도 지속되는 반면, 제안한 알고리즘의 경우, 초기 진동이 멎고, 약 300회의 반복 학습후 급속히 지령치에 수렴하였다. 이때의 초기 학습 계수 $\alpha_{kj0}, j_{10}, \beta_{kj0}, j_{10}$ 는 각각 0.4, 0.99이며, offset 학습률 μ_{kj}, μ_{ji} 는 0.9로 하였다.




그림 7. dk 가 제형파인 경우.

제형파의 지령치를 부가한 경우를 그림 7에 나타내었다. Delta-제어기에서는 720회의 학습후에도 거의 수렴하지 않고 큰 오차가 나타나는 반면, 제안한 알고리즘은 학습 시작부터 미약한 오차를 보이며, 약 300회의 학습후부터 지령치에 거의 수렴함을 알수 있다.

이때의 초기 학습 계수 $\alpha_{kj0}, j_{10}, \beta_{kj0}, j_{10}$ 의 각 값은 각각 0.12, 0.99이며, μ_{kj}, μ_{ji} 는 0.9로 고정하였다.




그림 8. dk 가 정현파와 제형파로 합성된 경우.




그림 9. dk 가 삼각파인 경우.

정현파와 삼각파 지령치를 혼합한 경우의 출력과 삼각파만의 지령치로 부가한 경우의 출력 파형을 각각 그림 8과 그림 9에 보이고 있다.

Delta-제어기에서는 학습시에 계속적인 진동이 나타나는 반면, 제안한 알고리즘은 학습 시작부터 적은 오차를 보이며, 모두 약 300회의 학습 후 거의 지령치에 수렴함을 알 수 있다.

이때, 초기 학습 계수 $\alpha_{kj0}, j_{10}, \beta_{kj0}, j_{10}$ 의 각 값은 각각 0.35, 0.5이며, μ_{kj}, μ_{ji} 는 0.9로 두었다.

이상의 시뮬레이션으로 적용성이 강한 자기 학습 신경 회로망을 부가한 알고리즘은 초기 수렴성이 강하며, 지령치의 변화에도 잘 적용하고, 학습 시간에 대한 속용성이 뛰어남을 알수 있다. 또한, 전회의 가중치 보상법과 학습 계수의 지수함수적 감소법이 자기 학습 제어에 대단히 유용함을 알 수 있다.

6. 결 론

본 논문에서는 Back-propagation 신경 회로망을 이용하여 구조에 대한 미약한 정보만으로 미지의 Plant를 동정하는 자기 학습 제어를 제안하였다. 자기 학습하는 신경 회로망의 실시간 제어를 위해 전회의 가중치를 보

상하는 방법과 학습 계수의 지수합수적 감소법을 사용하여 구현하였다. 그리고, 제안한 알고리즘이 종래의 delta-Controller보다는 적용성이 우수하고, 수렴성이 뛰어난 자기 학습 제어임을 입증하였다.
제안한 알고리즘의 특징은,

1. 전회 가중치를 보상하고, 학습 계수를 지수합수적 으로 감소시키는 학습 방법에 의해 plant의 수렴 특성을 개선하였으며,
2. 미지의 plant를 자기 학습 신경 회로망으로 구성하고, 역 전파 알고리즘에 따라 실 시간 plant 동정 을 수행하였다.
3. 또한, 다양한 plant의 지령치에도 불구하고, 본 알 고리즘은 적용성이 뛰어난 자기 학습 제어를 구현 하였다.

본 알고리즘의 뛰어난 특성을 시뮬레이션을 통하여 입증하였지만, 향후 경험적으로 선택한 중간층의 갯수, 초기 학습 계수의 최적화등에 관한 연구가 따라야 할 것으로 사료된다.

참고문헌

1. Stefen Hui, Stanislaw H.Zak, "Analysis of Single Perceptrons Learning Capability", 1990 American Control Conference, Vol.1, pp.809-814, 1990.
2. Fu-chuang Chen, "Back-Propagation Neural Networks for Nonlinear Self-Tunning Adaptive Control", IEEE Control System Magazine, Vol.4, pp.44-48, 1990.
3. Reynold Chu, Manoel Tenorio, "Neural Networks for System Identification", 1989 Amerian Control Conference, Vol. 1, pp.916-921, 1990.
4. Min Ho Lee, Soo Young Lee, Cheol Hoon Park, "Identification and Control of Nonlinear Dynamic Systems Using Higher Order Neural Networks", 1992 KITE, Vol. 3, NO.1, 1992.5.
5. Derrick H.Nguyen, Bernard Widrow, "Neural Networks for Self-learning Control Systems", IEEE Control Magzine, Vol.4, pp.18-23, 1990.4.
6. John E.Cramer, Baxter F.Womack, "Adaptive Control Using Neural networks", 1990 American Control Conference, Vol.1, pp.681-686, 1990.
7. 오세영, "신경회로의 로보트 및 자동화 응용", 전자공 학회지, 18권, 10호, pp.740-748, 1991.10.
8. Shigeyasu, Haruyo, "On Learning Control using Neural Networks", 1991 KACC, pp.1348-1353, 1991.10.
9. 박민용, 최항식 譯, "뉴로 컴퓨터", 大英社, 1991, pp.17-73.
10. Philip D.Wasserman, "Neural Computing theory and practice", VAN NOSTRAN REINHOLD, 1989, pp.43-60.
11. James A.Freeman, David M.Skapura, "Neural Networks Algorithm, Applications, and Programming Techniques", Addison-Wesley Publishing Company, 1991.