

신경 회로망 제어기를 이용한 직류 서보 전동기의 위치제어

이 준탁, 이 권순, 이 상석, 박 철영

동아대학교 전기공학과

Position Control of DC Servo Motor Using Neural Network Controller

Joon Tark Lee, Kwon Soon Lee, Sang Seuk Lee, Cheul Young Park

Dept. of Electrical Engineering Dong-A University

Abstract- In this paper, a class of neural-network controllers with two inputs of error and error change, is applied to the position control of D.C. servo system. The proposed controller is learned by error back-propagating error information to compensate the weighting value using its previous derivatives and to decrease exponentially a series of self learning coefficients. Through the simulations and implementations, the effectiveness and superiority to the conventional fuzzy controller is proved.

1. 서 론

신경 회로망은 학습하는 능력이 있으므로, 외부 환경이나 시스템의 구조를 알지 못하더라도 시변하는 제어환경에 잘 적용할 수 있다.

또한, 병렬 분산 처리가 가능하여 임의의 입출력 데이터 맵핑을 수행하기 때문에 실시간 처리가 가능하다. 이러한 특성으로 인해 패턴인식, 화상처리, 음성인식등의 어려운 해석문제를 다룰 수가 있다.

비선형 시스템의 고전적인 제어 방식은 수학적 모델링에 근거하였지만, 시스템이 비선형 요소와 시변 파라미터를 많이 포함하고 있는 경우에는 수학적 모델링이 어렵고, 정확한 제어가 거의 불가능하였다.

신경 회로망은 이와같은 수학적 모델링 없이도, 비선형 함수의 학습능력과 시변 파라미터에 대해 강인하기 때문에, 시변 특성 변화가 많은 제어 문제를 다루기가 용이하다.

따라서, 본 논문에서는 시스템의 오차와 오차의 변화량을 입력으로 하는 신경 회로망 제어기를 구성하여, 서보 시스템의 위치제어에 적용해 보고자 한다. 이 제어기는 오차 최소화 학습법중의 하나인 Back-Propagation 을 이용하여 시스템을 학습하고, 고효율의 학습을 위해 가중치에 대한 전향 변화분의 보상하고, 학습률의 지수함수적 조절에 의해 수렴 속도를 향상시켜 실시간 제어 가능성을 제시한다. 또한, 이러한 이론에 기초하여 직류 서보 전동기의 위치제어용 신경 회로망 제어기를 Hardware 로 실현 시킴으로써, 종래의 퍼지 제어기등에 비해

우수한 동특성이 얻어짐을 보이고자 한다.

2. Back-Propagation 알고리즘

Back-Propagation 알고리즘은 Rumelhart에 의해 1986년에 제안 되었던 교사 신호가 있는 학습방법으로서, 이 학습방법은 감률(1976년)와 Tsypkin(1966년)에 의해 제안된 확률적 강하법(確率的 降下法)이라고 불리는 평가 기준 최소화 학습의 특수한 경우에 해당된다. Back-Propagation 알고리즘은 구성하기가 용이하고, 학습률에 따른 수렴성이 우수하여 신경 회로망으로 구현하는 제어 문제에 많이 사용되고 있다.

일반적으로 신경 회로망은 그림 1.과 같이 구성할 수 있다.




그림 1. 신경 회로망의 구조.

여기서, 중간층 j의 출력을 H_j , 출력층 k의 출력을 O_k , 출력층 k의 음세트를 θ_k , 중간층 j의 음세트를 θ_{j1} , 중간층 j와의 결합계수는 V_{kj} 이며, 중간층과 입력층간의 결합계수는 W_{j1} 이다.

각 뉴런들은 가변 가중치로 연결된다. 즉, 신경 회로망 내의 i번째 뉴런의 출력 I_i 가 결합계수 W_{j1} 와 가중합에 의해 뉴런j의 입력이 되고, 음세트 θ_{j1} 와 출력을 규격화하는 함수 F에 의해 j의 출력 O_j 는 식(1)로 나타낼 수 있다.

$$O_j = F \left(\sum_i W_{j1} \cdot I_i + \theta_j \right) \quad (1)$$

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

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

학습 목표는 출력층에 있어서의 교사 신호 T와의 오차를 δ_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 k의 내부 포텐셜을 $P_k (= \sum V_{kj} H_j + \gamma_k)$ 로 고쳐서면, 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)와 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 감소시키기 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 정의하면, 식(8)은 다음과 같이 고쳐 쓸 수 있다.

$$\Delta V_{kj} = \alpha_v \cdot \delta^k \cdot H_j \quad (10)$$

같은 방법으로 입력층에서 중간층으로의 결합 계수 W_{ji} 의 갱신치 ΔW_{ji} 에도 최급강하법을 사용한다. 중간층의 내부 포텐셜을 $Q_j (= \sum W_{ji} I_i + \theta_j)$ 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.

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

결국, 중간층 j의 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.

3. 수정된 학습 알고리즘

이상과 같이 종래의 Back-propagation 알고리즘은 Local Minimum과 학습 시간의 지연으로 인하여 실시간 제어에 응용이 어려웠다. 따라서, 학습시간을 단축하고, 실시간 제어가 가능하도록 하기 위한 알고리즘을 제시한다. 식(10)과 식(12)에서와 같이 결합계수의 수정량은 오차에의 기여량으로부터 구하지만, 학습의 고속화를 위하여 가중치의 전회 변화분을 고려하는 방법을 적용하면 다음과 같이 쓸 수 있다.

출력층과 중간층 사이의 가중치 변화는 식(13)으로 나타낼 수 있다.

$$\begin{aligned} V_{kj}(k+1) &= V_{kj}(k) + \alpha_v \\ &\cdot \{ \Delta V_{kj}(k+1) + \beta_v \cdot (V_{kj}(k) - V_{kj}(k-1)) \} \end{aligned} \quad (13)$$

중간층과 입력층 사이의 가중치 변화는,

$$\begin{aligned} W_{ji}(k+1) &= W_{ji}(k) + \alpha_w \\ &\cdot \{ \Delta W_{ji}(k+1) + \beta_w \cdot (W_{ji}(k) - W_{ji}(k-1)) \} \end{aligned} \quad (14)$$

같다.

또한, 출력층과 중간층의 offset의 변화는 아래와 같다.

$$O_{kj}(k+1) = O_{kj}(k) + \mu_{kj} \delta^k(k+1) \quad (15)$$

$$\theta_{ji}(k+1) = \theta_{ji}(k) + \mu_{ji} \delta^j(k+1) \quad (16)$$

그리고, 학습 계수를 지수함수적으로 감소시키는 방법을 도입하여 각층 사이의 학습 계수는 식(20)과 식(21)로 조정된다.

$$\alpha_{k,j,i}(k+1) = \alpha_{k,j,i,0} \cdot \text{EXP}(-C_{k,j,i} / \lambda) \quad (17)$$

$$\beta_{k,j,i}(k+1) = \beta_{k,j,i,0} \cdot \text{EXP}(-D_{k,j,i} / \lambda) \quad (18)$$

여기서, 아래 첨자 'k,j,i'는 출력층과 중간층을 나타내고, 'o'는 학습초기의 값을 의미한다. 또한, $C_{k,j,i}$, $D_{k,j,i}$ 는 각 뉴런에 대한 학습계수의 기울기를 나타낸다.

4. 제한하는 Neural-Networks 제어기

본 논문에서 사용한 신경 회로망 제어기는 지령치와 플랜트의 오차와 지령치의 변화분과 플랜트의 변화분의 오차를 입력으로하고, 이들 오차의 합을 가지고 학습을 행하게 된다. 이를 그림 2에 나타내었다.




그림 2. 제한하는 신경 회로망 제어기의 구조.

5. 시뮬레이션 및 실험 고찰

신경 회로망 제어기를 가진 직류 서보 시스템의 구조는 그림 3와 같으며, 본 실험에 사용한 직류 서보 전동기의 사양은 표 1과 같다.

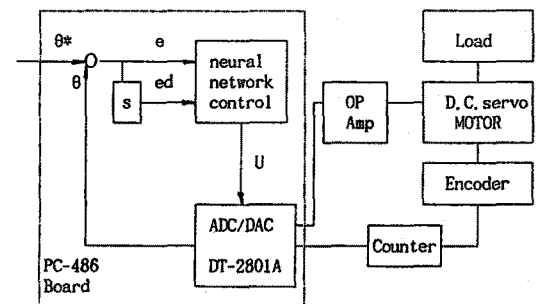


그림 3. 신경 회로망 제어기를 가진 직류 서보 시스템의 구조


표 1. 직류 서보 전동기의 사양

D, C, Servo Motor	
$R_a=1.3$ [Ω]	$L_a=0.00170$ [H]
$J=0.00016$ [$\text{kg}\cdot\text{cm}^2\text{sec}^2$]	$B=0.002727$ [$\text{kg}\cdot\text{cm}/\text{sec}$]
$K_b=0.04098$ [$\text{V}\cdot\text{s}/\text{rad}$]	$K_t=K_b=0.086875$ [$\text{kg}\cdot\text{cm}/\text{A}$]
Rated Voltage $U_n=15.0$ [V]	Rated Torque $T_n=2.35$ [$\text{kg}\cdot\text{cm}$]
Rated Current $I_n=3.56$ [A]	Rated Speed $N_n=3000$ [rpm]
Rated Power $P_n=60$ [W]	TAMAGAWA SEIKI NO: TS1415N4


시뮬레이션은 상태 방정식화된 직류 서보 전동기에 일정한 지령치를 부가한 경우와 시간에 따라 가변하는 지령치를 부가한 경우에 대해 고찰하고자 하며, 이를 퍼지 제어기로 구동된 직류 서보 시스템과 비교해 보고자 한다.

본 시뮬레이션에 사용한 신경 회로망은 중간층의 갯수가 7개인 3층의 계층구조를 가진 회로망이며, 중간층에 사용한 비선형 함수로는 hyperbolic tangent를 이용하였다.

지령치가 시간에 따라 변하는 경우의 서보 시스템 응답을 그림 4에 나타내었다.



a. 퍼지 제어기인 경우



b. 신경 회로망 제어기인 경우

그림 4. 지령치가 가변인 경우

퍼지 제어기의 경우에는 220[ms] 부근에서 입상하지만, 지령치에 수렴하지 않았다. 또한, 퍼지 제어기의 경우에는 시변 지령치에 대한 scale factor 조정 없이는 잔류편차의 문제를 해결하기가 곤란하다. 신경 회로망 제어기의 경우에는 초기의 미소 오버슈트외에는 오버슈트 없이 180[ms] 부근에서 빠른 입상을 하고, 잔류편차도 없이 지령치에 도달하였다.

이상의 시뮬레이션으로 제안한 신경 회로망 제어기가 시스템의 특성이 복잡한 직류 서보 전동기의 위치제어에의 응용 가능성이 있음을 알 수 있었다. 또한 일정한 지령치에서는 속응성이, 시간에 따라 변하는 지령치에서는 수렴성이 퍼지 제어기에 비하여 우수함을 알게 되었다.

6. 결 론

본 논문에서는 시스템의 오차와 오차의 변화량을 입력으로 하는 신경 회로망 제어기를 구성하여, 서보 시스템의 위치제어에 적용하였다. 이 제어기는 오차 최소화 학습법중의 하나인 Back-Propagation을 이용하여 시스템을 학습하게 된다.

또한, 학습 시간의 단축 및 실시간 제어를 실현하기 위해 가중치에 대한 전향 변화분의 보상법과 학습 계수의 지수함수적으로 조정하여 신경회로망 제어기로 서보 시스템의 위치제어에 응용한 결과, 종래의 퍼지 제어기에 비해 오버슈트나 잔류편차 없이 정상상태에 수렴함을 알 수 있었다.

본 알고리즘의 특성을 시뮬레이션과 실험을 통해 입증하였지만, 향후 병렬 processor에 의한 실현과 초기 학습 계수의 최적화 등에 관한 연구가 따라야 할 것으로 사료된다.

7. 참 고 문 헌

1. Stefen Hui, Stanislaw H. Zak, "Analysis of Single Perceptrons Learning Capability", American Control Conference, Vol.1, pp.809-814, 1990.
2. Derrick H. Nguyen, Bernard Widrow, "Neural Networks for Self-learning Control Systems", IEEE Control Magazine, Vol.4, pp.18-23, 1990.4.
3. John E. Cramer, Baxter F. Womack, "Adaptive Control Using Neural networks", American Control Conference, Vol.1, pp.681-686, 1990.
4. Shigeyasu, Haruyo, "On Learning Control using Neural Networks", KACC, pp.1348-1353, 1991.10
5. Philip D. Wasserman, "Neural Computing theory and practice", VAN NOSTRAN REINHOLD, 1989, pp.43-60.
6. James A. Freeman, David M. Skapura, "Neural Networks Algorithm, Applications, and Programming Techniques", Addison-Wesley Publishing Company, 1991.