

신경제어기를 이용한 직접구동모터의 속도제어

조정호*, 이동욱, 김영태
동국대학교 전기공학과

Speed Control of a Direct Drive Motor Using a Neuro-Controller

Jeong-Ho Cho*, Dong-Wook Lee, Young-Tae Kim
Department of Electrical Engineering, Dongguk University

Abstract

This paper presents a neuro-control algorithm for the speed control of a direct drive motor without the knowledge of the dynamics of the motor and the characteristics of a nonlinear load. In the field of motor control, it is not possible to directly use the back-propagation method in order to train a network since the desired output of the network is not known. Hence, we propose an extended back-propagation algorithm to force the closed loop system to give desired results. Experimental results show that the proposed neuro-controller can reduce the unknown load effects and have the good velocity tracking capabilities.

I. 서론

직접구동모터(Direct Drive Motor : DDM)는 지속적이고 유연한 동작 특성을 가지고 있으며 기어(gears)에 의해 발생하는 Backlash나 Deadzone이 없고 감속기어(reduction gears)도 불필요하다는 특징을 갖고 있기 때문에 Motion Control System과 같은 고성능 모터가 요구되는 산업 자동화 분야에서 엑츄에이터나 로봇의 관절 등으로서 폭넓게 이용되고 있다. 반면, 부하가 직접 모터 축에 연결되어 있으므로 부하로 인한 외란을 감쇄하지 못하고 모터의 백돌로크가 직접 전달되며, 또한 부하 변동에 따른 동역학 모델의 매개변수들의 변화에 의하여 원하는 응답을 정확히 구할 수 없다는 문제점을 지니고 있다.[1] 이러한 문제점을 고려한 제어방법으로 충분한 제어특성을 얻을 수 없어서 새로운 제어기의 필요성이 강하게 대두된다. 한편, 최근에 와서는 이러한 문제점을 해결하기 위하여 전문가의 경험이나 지식을 바탕으로 인간의 의사 결정 과정을 모방한 퍼지제어기법과 인간의 두뇌 구조를 모의하여 인지적 정보 처리 구조를 갖는 신경회로망 제어기법이 도입되었다.

이에 본 논문에서는 최근 관심이 증대되고 있는 신경회로망을 이용하여 DDM의 효과적인 속도제어를 이루고자 한다. 제어기로 사용되는 신경회로망은 DDM 내부의 동역학 모델을 전혀 고려하지 않고 단지 모터의 바람직한 속도와 실제 속도의 정보만을 이용하여 필요한 제어입력을 발생하게 되며, 이 때 계산되는 오차를 줄이는 방향으로 온라인 학습된다. 온라인 제어 분야에서는 일반적인 학습 알고리듬과는 달리 원하는 학습패턴을 미리 알 수 없으므로 기존의 역전파(Back-Propagation) 학습 알고리듬을 확장하여 적용한다.[2][3][4][5] 본 논문에서 제시하는 제어방법의 타당성과 제어대상인 DDM의 부하변화에 적절히 적용할 수 있는가에 대하여 컴퓨터 모의 실험을 통하여 보여준다.

II. 시스템 구성

전체 시스템은 제어대상인 DDM과 제어기인 신경제어기로 구성된다.

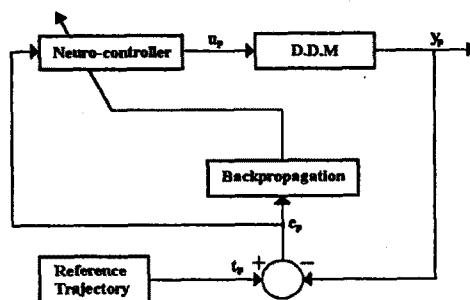


그림 1. 제어 시스템의 블록선도
Fig 1. Block diagram of the control system

1. DDM의 상태 공간 모델

일반적으로 DDM에 대한 동역학 방정식 모델은 아래와 같이 표현된다.

여기서,

$$J\ddot{e} + D\dot{e} = \tau \quad (1)$$

J : 부하와 회전자의 관성 모멘트

D : 점성 마찰 계수

τ : 모터의 입력 토크(제어기 입력)

e : 모터의 출력 변위각(제어기 출력)

식 2.1은 다음과 같은 상태 공간 모델로 나타낼 수 있다.

$$\dot{x} = Ax + Bu \quad (2)$$

$$y = Cx$$

여기서, $x = (x_1, x_2)^T$, $x_1 = e$, $x_2 = \dot{e}$, $u = \tau$

$$A = \begin{bmatrix} 0 & 1 \\ 0 & -D/J \end{bmatrix}, B = \begin{bmatrix} 0 \\ 1/J \end{bmatrix}, C = [0 \ 1]$$

이다.

2. 신경제어기

신경망 제어는 플랜트의 모델 없이도 학습에 의하여 고속 정확한 제어가 가능하고 플랜트 특성 변화에 잘 적응하며 병렬성으로 인하여 실시간 제어도 가능하다. 또한 플랜트를 black box로 보고 제어하기 때문에 플랜트가 바뀌어도 입출력

이 바뀔 뿐 동일한 제어방식을 사용하므로 범용제어기 역할을 하는 점에서 무한한 잠재력이 있다.

2.1 제어기의 기본구조

제어시스템은 목표값과 실제 출력값과의 오차를 입력으로 하는 확장된 역전파 학습 알고리듬을 이용하여 학습시키는 방식을 사용하였다. 이 방식의 장점은 온라인(on-line)으로 학습하면서 제어를 수행한다는 점이다.

그림1에 신경회로망을 이용한 DDM 속도 제어기의 전체 블록선도를 나타내었다. y_p 는 모터의 실제 속도이며, t_p 는 모터의 원하는 속도 채적이다.

2.2 온라인 학습알고리듬

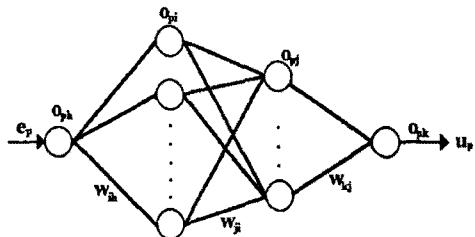


그림2. 3층 신경회로망의 구조

Fig2. The structure of 3-layer neural network

확장된 BP알고리듬은 기존의 BP알고리듬과 달리 신경망 가중치 변화를 유발하는 오차항이 신경망 출력(o_{pk})이 아닌 플랜트 출력(y_p)으로부터 유도된다. 이와 같은 방법을 이용하는 이유는 오차항 계산에 필요한 제어법칙을 알 수 없기 때문이다. 확장된 BP알고리듬을 이용한 신경망의 학습과정은 다음과 같다.

먼저, 각 층의 뉴런들을 이어주는 연결강도(weights)를 임의의 작은 값으로 초기화 한다. 일반적으로 연결강도의 초기치는 -1에서 +1사이의 랜덤한 값으로 설정한다. 다음으로 입력 값을 신경망에 인가하여 실제의 신경망 출력값을 계산하게 된다. 이때 k 번째층의 출력값 o_{pk} 는 보통 비선형 활성함수(activation function)인 Bipolar Sigmoid함수를 이용하여 구한다.

$$o_{pk} = f(net_{pk}) = \frac{1 - \exp(-net_{pk})}{1 + \exp(-net_{pk})} \quad (3)$$

$$net_{pk} = \sum_i w_{ki} \cdot o_{pi} \quad (4)$$

여기서, k 는 출력층을 의미하고 w_{ki} 는 j 층 뉴런들과 k 층 뉴런들간의 연결 가중치의 값이며, $f(\cdot)$ 는 미분가능한 단조 증가함수이다. 일단 신경망의 출력값이 결정되면 시스템의 입력으로 직접 인가하게 되며 입력값으로 하여금 시스템의 출력값이 계산된다. 실제 출력값과 바람직한 출력값사이의 오차를 구하여, 그 오차를 감소시키는 방향으로 연결강도를 조절하는데, 이때 연결강도 조절 학습은 출력층에서 시작하여 입력층으로 역전파(Back-propagation)하면서 시행되며 바람직한 출력값(t_p)과 시스템의 실제 출력값(y_p) 사이의 오차함수를 다음과 같이 정의한다.

$$E_p = \frac{1}{2} e_p^2 = \frac{1}{2} (t_p - y_p)^2 \quad (5)$$

학습의 목표는 위의 오차식을 최소화하는 것인데 여기서 시스템 입력의 변화량에 대한 출력의 변화량으로 플랜트 자코비안(plant Jacobian) $\partial y_p / \partial u_p$ 이 요구된다. 이것은 다음과 같은 확장된 일반화 델타규칙(generalized delta rule)에 의해 이루어진다.

$$u_p = o_{pk} + \mu \cdot \Delta_{pk} \quad (6)$$

$$\Delta_{pk} = -\frac{\partial E_p}{\partial u_p} = -\frac{\partial E_p}{\partial y_p} \cdot \frac{\partial y_p}{\partial u_p} = e_p \cdot \frac{\partial y_p}{\partial u_p} \quad (7)$$

여기서, μ 는 학습율과는 다른 적응인자(adaptation factor)로서 $0 < \mu < 1$ 인 실수를 나타낸다.

$$\delta_{pk} \triangleq -\frac{\partial E_p}{\partial u_p} \quad (8)$$

$$\Delta_{pk} w_{kj} = -\frac{\partial E_p}{\partial w_{kj}} = -\frac{\partial E_p}{\partial net_{pk}} \cdot \frac{\partial net_{pk}}{\partial w_{kj}} = \delta_{pk} \cdot o_{pj} \quad (9)$$

$$\begin{aligned} \delta_{pk} &= -\frac{\partial E_p}{\partial net_{pk}} = -\frac{\partial E_p}{\partial o_{pk}} \cdot \frac{\partial o_{pk}}{\partial net_{pk}} \\ &= -\frac{\partial E_p}{\partial o_{pk}} \cdot f'(net_{pk}) = -\frac{\partial E_p}{\partial u_p} \cdot \frac{\partial u_p}{\partial o_{pk}} \cdot f'(net_{pk}) \quad (10) \\ &= \delta_{pk} \cdot f'(net_{pk}) \end{aligned}$$

식(9)는 다음과 같이 표시된다.

$$\frac{\partial E_p}{\partial w_{kj}} = -\delta_{pk} \cdot o_{pj} \quad (11)$$

그러므로, E_p 가 감소되기 위해서는 가중치 조절은 다음과 같이 이루어져야 한다.

$$w_{kj} = w_{kj} + \eta \cdot \Delta_{pk} w_{kj} \quad (12)$$

여기서, η 는 학습율을 나타낸다.

중간층의 경우에는 바람직한 출력값을 알 수 없으므로 다음과 같이 구하게 된다.

$$\Delta_{pk} w_{ji} = -\frac{\partial E_p}{\partial w_{ji}} = -\frac{\partial E_p}{\partial net_{ji}} \cdot \frac{\partial net_{ji}}{\partial w_{ji}} = \delta_{ji} \cdot o_{ji} \quad (13)$$

$$\begin{aligned} \delta_{ji} &= -\frac{\partial E_p}{\partial net_{ji}} = -\frac{\partial E_p}{\partial o_{ji}} \cdot \frac{\partial o_{ji}}{\partial net_{ji}} = -\frac{\partial E_p}{\partial o_{ji}} \cdot f'(net_{ji}) \\ &= -\frac{\partial E_p}{\partial net_{pk}} \cdot \frac{\partial net_{pk}}{\partial o_{ji}} \cdot f'(net_{ji}) \\ &= [\delta_{pk} \cdot w_{kj}] \cdot f'(net_{ji}) \quad (14) \end{aligned}$$

$$w_{ji} = w_{ji} + \eta \cdot \Delta_{pk} w_{ji} \quad (15)$$

III. 모의 실험 결과

신경제어기는 입력층 1개, 첫 번째 은닉층 10개, 두 번째 은닉층 5개, 그리고 출력층 1개로 구성되었으며 제안된 신경제어기의 동적 성능을 알아보기위해 DDM에 적용하여 컴퓨터 모의실험을 수행하였다. 모의실험에 사용된 모터의 파라미터는 다음과 같다.

$$\begin{aligned} \text{최대 토크}(T) &= 39.5[N \cdot m] \quad \text{회전자 관성}(J) = 0.0077[kg \cdot m^2] \\ \text{점성마찰계수}(D) &= 0.31 [N \cdot s/m] \end{aligned}$$

그림3은 1회 학습후 기준속도에 대한 신경제어기의 추적속도를 나타내고, 그림4는 10회 학습후 신경제어기의 응답을 나타내었다. 처음 학습한 경우보다 학습을 통하여 원하는 채적에 잘 접근함을 알 수 있다. 즉, 학습횟수가 증가함에 따라 오차가 점점 감소함으로 부하의 변화 혹은 모터 파라미터의 변화가 없는 경우에는 좋은 성능을 나타낼 수 있다. 그림5는 2.5초에서 3초까지와 3.5초에서 4초사이에 회전자 관성을 $1.3 [kg \cdot m^2]$ 로 점성 마찰 계수를 $0.5 [N \cdot s/m]$ 로 변화시켰을때의 기준속도에 대한 추적속도를 나타낸 것으로 부하 외란에 강하고 정상상태 오차가 거의 없음을 보여준다. 그림6은 한 번도 학습해 본적이 없는 일이라도 기준에 했던 작업과 유사한 일이라면 근사적으로 작업수행이 가능하다는 학습

된 신경제어기의 일반화 특성을 나타낸다.

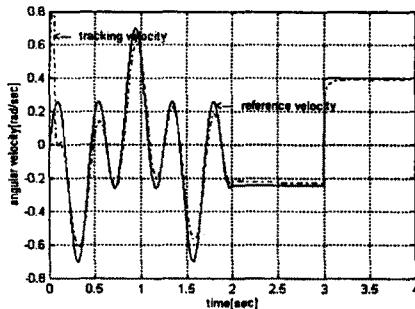


그림3. 1회 학습후 신경제어기의 기준속도와 추적속도.
Fig3. Reference and tracking velocity of a neurocontroller
after the 1st training.

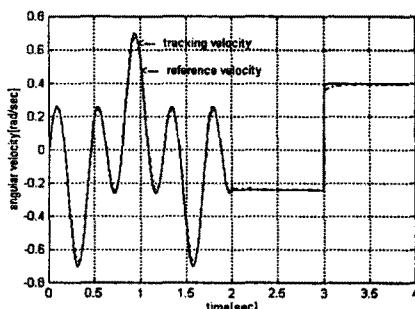


그림4. 10회 학습후 신경제어기의 기준속도와 추적속도.
Fig4. Reference and tracking velocity of a neurocontroller
after the 10th training.

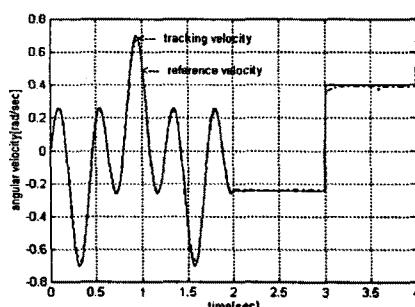


그림5. 부하 존재시의 기준속도에 대한 추적속도.
Fig5. Tracking velocity for reference velocity
when the load applied.

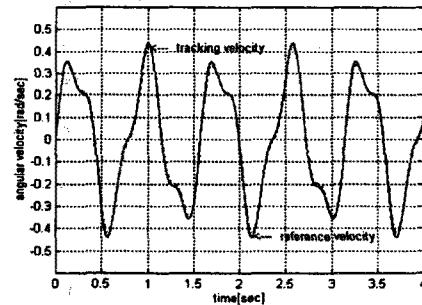


그림6. 다른 기준속도에 대한 신경제어기의 추적속도.
Fig6. Tracking velocity for different reference velocity
in neurocontroller.

IV. 결 론

본 논문에서는 DDM의 속도제어기를 신경회로망을 이용하여 구성하였고, 온라인 제어를 수행함에 있어서 문제시 되었던 역전파 학습알고리듬을 확장시킨 형태의 신경제어 알고리듬을 제안하여 그 유용성을 입증하였다. 모의실험 수행결과로부터 훈련된 신경제어기는 무부하시 기준궤적을 잘 추적함을 볼 수 있었으며, 또한 외란을 가했을 때 즉, 모터의 파라미터를 변화하였을 때에도 임의의 주어진 속도를 비교적 잘 추적하는 강인성을 보여 주었고, 기준궤적과 다른 궤적일 지라도 기준궤적 학습시에 얻어진 연결강도만을 이용하여 주어진 궤적을 추적하게 됨을 확인하였다. 추후 연구 과제로는 제안된 신경제어기를 실제 시스템에 적용하여 실험적 검증을 한다면 제어기의 타당성을 분석하는데 있어서 보다 향상된 가치를 얻을 것으로 기대된다.

참고문헌

- [1] Katsuhisa Furuta, Kazuhiro Kosuge, and Kenichi Kobayashi, "VSS-Type Self-Tuning Control of Direct-Drive Motor," Proc. of IECON, pp. 281-286, 1989.
- [2] K. S., Narendra and K. Parhasarathy, "Identification and Control of Dynamical Systems Using Neural Networks," IEEE Trans. on Neural Networks, pp.4-27, 1990.
- [3] Sigeru Omatsu, "Adaptive Control by Neural Networks," Proc. of Int. Conf. on Neural Info. Proc., pp.275-280, 1995.
- [4] Toshio Fukuda and Takanori Shibata, "Theory and Applications of Neural Networks for Industrial Control Systems," IEEE Trans. on Indust. Elec., pp.472-489, vol.39, Dec.1992.
- [5] K. J. Hunt, D. Sbarbaro, R. Zbikowski, and P. J. Gawthrop, "Neural Networks for Control Systems - A Survey," Automatica, vol.28, pp.1083-1112, 1992.