

인공신경회로망에 기초한 직류모터제어

◦ 박진현, 최영규, 박준호
부산대학교 전기공학과

Control method for DC Motor based on Neural Networks

◦ Jin-Hyun Park, Young-Kiu Choi, June-Ho Park
Dept. of Electrical Eng. Pusan Nation University

Abstract

In this paper, we assume that the dynamics of DC motor and nonlinear load are unknown. We train the inverse dynamic model of DC motor and nonlinear load using the neural network and construct speed control system based on the traind dynamic model and current control mode. Speed prediction scheme using neural network is also proposed the alleviate the time delay effect caused by the computation time of neural network. Simulation results show good performances of the control system. Finally, hardware configuration of the control system is outlined.

1. 서론

각종 산업기기에서 제어요소로 널리 사용되고 있는 직류모터의 제어 시스템에서는 대부분 일정이득을 갖는 PID제어 방식을 채택하고 있다. 그러나 이러한 제어시스템에서는 부하특성이 비선형적으로 변화할 때에 적절한 이득과 성능을 얻을 수 없으므로[1] 고성능 제어 특성을 기대하기 어렵다. 그런데 인공신경회로망은 비선형 함수를 학습할 수 있는 학습능력 [2-4]과 강인성, 병렬분산처리 등의 특성으로, 고전적 방법으로 해결하기 어려웠던 패턴인식, 음성인식, 영상처리, 그리고 최근에 와서는 동적 시스템 제어에도 이용되고 있다[5]. 제어 대상 시스템이 미지의 비선형성을 갖는 경우에 제어 입출력 패턴을 학습시킴으로써 시스템 식별을 효과적으로 할 수 있어 원하는 제어특성을 쉽게 얻을 수 있다.

본 연구에서는 직류모터 및 비선형 부하를 다중신경회로망으로 모델링하고 입출력 패턴을 수집한뒤 역전과 알고리즘을 사용하여 전류제어방식의 속도제어기를 구성하였다. 신경회로망을 이용한 직류모터제어는 다른 연구논문[4, 6]에서 발표된 바 있으나 전압제어방식을 사용하였다. 본 연구에서는 전압제어방식에서의 문제점을 제거하기 위해서 PWM 방식의 전류제어방식을 사용하였고, 실시간제어시 나타나는 제어량 계산 시간에 의한 출력 지연을 방지하기 위해서 속도 예측 신경회로망을 추가하여 미리 적절한 제어량을 계산해 줌으로써 제어의 정밀도를 높일 수 있었다. 이와같이 구성된 신경회로망 제어기의 제어 성능을 구하였다.

2. 모터 방정식과 사양 및 동작조건

직류모터의 동적 방정식은 다음과 같다.

$$K\omega_p(t) = -Raia(t) - La[di_a(t)/dt] + V_t(t) \dots\dots\dots (1)$$

$$KI_a(t) = J[d\omega_p(t)/dt] + D\omega_p(t) + T_L(t) \dots\dots\dots (2)$$

여기서 부하토크 $T_L(t)$ 는 다음과 같은 비선형 형태로 나타낸다.

$$T_L(t) = \mu \omega_p^2(t)[\text{sign}(\omega_p(t))] \quad \mu \text{는 상수} \dots\dots\dots (3)$$

본 연구에서는 전류제어 방식을 사용함으로써 전기적 시정수가 기계적 시정수에 비해 무시할 만큼 작으므로 전압제어시에 전압공급원의 전압변동과 모터 내부 저항의 온도에 따른 변화, 전류에 따른 모터 내부 인덕턴스의 변화에 의해 나타나는 문제점을 없앨 수 있다. 그리고 전류 제어시 모터의 동적 방정식(2)만 가지고도 속도를 바로 제어할 수 있는 장점이 있다.

그러므로 식(2)를 다시 고쳐 쓰면

$$\tau(t) = J[d\omega_p(t)/dt] + D\omega_p(t) + T_L(t) \dots\dots\dots (4)$$

이산시간모델로 바꾸어 쓰면 다음과 같다.

$$\omega_p(k+1) = \tau(k)T/J - \mu T/J\omega_p^2(k)[\text{sign}(\omega_p(k))] + (1-DT/J)\omega_p(k) \dots\dots\dots (5)$$

단, T는 샘플링 시간임.

* 직류모터 사양 및 운전 범위

$$\begin{aligned} J &= 0.068 \text{ Kg m}^2 & K &= 3.475 \text{ Nm A}^{-1} \\ D &= 0.03475 \text{ Nm s} & \mu &= 0.0039 \text{ Nm s}^2 \\ T &= 40 \text{ ms} \\ -50.0 < \omega_p(k) < 50.0 & \text{ (rad/sec)} \end{aligned}$$

3. 신경회로망을 이용한 직류모터의 속도 추적

제어 시스템이 지령 속도 $\omega_m(k)$ 에 대하여 실제의 출력 $\omega_p(k)$ 가 얼마나 잘 추적하는가를 살펴 보고자 하며 다음과 같이 3가지 방법을 제시한다.

(I)안

식(5)를 다음과 같이 간략하게 나타낼 수 있다.

$$\tau(k) = f[\omega_p(k+1), \omega_p(k)] \dots\dots\dots (6)$$

단, $\tau(k)$ 는 입력 토크, $\omega_p(k)$ 는 모터의 속도이며 $f[\cdot]$ 는 비선형함수임.

위의 식(6)의 비선형 함수를 인공신경회로망으로 학습시켜서 $NI[\cdot]$ 이라는 함수로 근사 시킬 수 있다.

$$\hat{\tau}(k) = NI[\omega_p(k+1), \omega_p(k)] \dots\dots\dots (7)$$

학습후 실제 직류모터의 제어 입력은 $\omega_p(k+1)$ 대신에 지령 속도 $\omega_m(k+1)$ 를 대입한 아래 식(8)과 같고 학습된 신경회로망을 이용한 제어기 구조는 아래 그림 1과 같다.

$$\hat{\tau}(k) = N1[\omega_m(k+1), \omega_p(k)] \dots\dots\dots (8)$$




그림 1. (I)안에 기초한 제어기의 구조

비선형함수 $f[\cdot]$ 를 학습하기 위하여 학습쌍은 그림 2와 같은 임의의 토오크를 가하여 구한 속도를 40ms로 샘플링 하여 구하였다.

학습방법은 역전파 알고리즘을 사용하였고, 입력, 은닉층, 출력 뉴런을 각각 2개, 10개, 1개로 구성하였다. 학습률 파라메타 η 와 모델링 파라메타 α 는 표 1과 같다.

지령속도 $\omega_m(k+1)$ 를 그림 3과 같이 가하였을 경우 추적하는 속도 $\omega_p(k)$ 는 지령속도를 잘 추적함을 보인다. 그러나 여기서 속도추적에 시간지연이 나타나는 것은 센서의 계측 시간과 제어량 계산 시간에 기인한다.

표 1. 학습 파라메타 η 와 모델링 파라메타 α

횟수	200,000	200,000	500,000	500,000	700,000
학습률	0.5	0.4	0.3	0.15	0.01
모델링	0.1	0.1	0.25	0.35	0.4




그림 2. 학습데이터를 구하기 위한 토오크




그림 3. 지령속도에 대한 추적속도 (I)

(II)안

위의 방법은 모터의 실시간 제어시 신경회로망의 계산 시간과 센서의 계측 시간의 시간지연 문제가 발생하게 된다.

실시간 제어시의 이러한 문제점을 해결하기 위하여 k 라는 시간 이전에 $\omega_p(k)$ 를 예측할 수 있는 신경회로망을 따로 구성하고, 시간 k 직전에 시간 k 에서 요구되는 제어량 계산을 완료하여 시간지연을 없앴으로써 제어의 정밀도를 높일 수 있다.

즉 식(5)에서 현재상태 $\omega_p(k)$ 를 예측하는 $\hat{\omega}_p(k)$ 를 아래식처럼 구할 수 있다.

$$\hat{\omega}_p(k) = g[\tau(k-1), \omega_p(k-1)] \dots\dots\dots (9)$$

여기서 예측치 $\hat{\omega}_p(k)$ 를 신경회로망으로 구성하고 (I)안에서 제안한 제어를 합쳐 제어기를 아래 그림 4와 같이 구성하였다.




그림 4. (II)안에 기초한 제어기의 구조

시뮬레이션 결과는 (I)안과 같은 지령속도를 가하였을 경우이며 그림 5에 나타내었다. 이 역시 잘 추적함을 보이나 (I)안의 결과 보다는 오차의 폭이 약간 커짐을 보인다.




그림 5. 지령속도에 대한 추적속도(II)

(III)안

(II)안은 신경회로망이 2개 이므로 계산시간이 2배가 된다. 그러므로 (II)안에서 제안한 신경회로망 2개를 하나의 신경회로망으로 구성하여 계산시간을 줄일 수 있다.

식(9)를 식(6)에 대입하여 아래식으로 구해낼 수 있다.

$$\tau(k) = F[\omega_p(k+1), \omega_p(k-1), \tau(k-1)] \dots\dots\dots (10)$$

학습후 제어입력으로는 아래와 같고 (III)안에서 제안한 신경회로망 구조는 그림 6과 같다.

$$\hat{\tau}(k) = N2[\omega_m(k+1), \omega_p(k-1), \tau(k-1)] \dots\dots\dots (11)$$




그림 6. (III)안에 기초한 제어기의 구조

그림 7과 같은 시뮬레이션 결과는 (I)안과 같은 지령속도를 가하였을 경우이며, (II)안의 결과보다 더 우수함을 나타내었다. 그림 8은 ± 1 (rad/sec)사이의 난수를 발생시켜 인공 신경회로망이 잡음제거능력 및 강인성을 가짐을 보였다. 그림 9는 지령속도를 계단 입력을 주었을 경우 추적 결과이다.




그림 7. 지령속도에 대한 추적속도(II)




그림 8. ± 1 (rad/sec) 사이의 난수를 발생시 지령속도에 대한 추적속도

4. 하드웨어 구조




그림 9. 하드웨어 블록 선도

그림 9와 같이 제어 대상인 직류모터의 구동시스템을 구성하여 본 연구에서 제안하는 제어알고리즘을 적용한다.

직류모터 구동을 위한 전력회로는 그림 10과 같이 PWM 전류 제어기 구성은 아래 그림 11과 같이 구성하였다.




그림 10. 직류모터 구동을 위한 전력회로

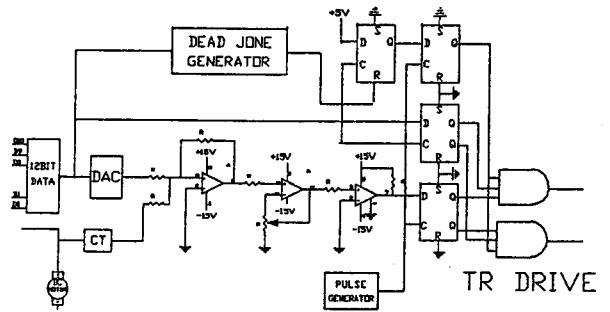


그림 11. PWM 전류 제어기

5. 결론

직류모터의 속도 제어기를 신경회로망을 이용하여 구할 수 있었다. 이는 신경회로망이 직류모터와 부하의 비선형 특성을 동정하여 임의의 속도 궤적을 잘 추적함을 보였다. 이는 기존의 PID 제어 기법으로 고정밀 제어성능을 얻는 것이 어려웠으나 신경회로망을 이용하여 가능성을 제시 하였다.

인공신경회로망은 특히 잡음제거능력도 뛰어나 측정오차가 발생시에도 임의의 주어진 속도를 잘 추적함을 보였다. 현재 실험장치가 완성 단계에 있으므로 이러한 제어 알고리즘이 조만간에 실험적으로도 성능평가가 될 것으로 기대된다.

6. 참고 문헌

- [1] Lee, M. H., Lee, S. Y. and Park, C. H. "Identification and control of nonlinear dynamic systems using higher order neural networks," KITE Journal of electronics engineering, Vol.3, pp 73-77, May, 1992.
- [2] J. L. McClelland, D. E. Rumelhart and the PDP reserch group, "Parallel distributed processing : Exploitations of the microstructure of cognition," Vol II, Badford books, Cambridge, MA, 1986.
- [3] K. S. Narendra and K. Parthasarathy, "Identification & control of dynamical systems using neural networks," IEEE Transactions on Neural Networks, Vol. 1, pp 4-27, Mar, 1990.
- [4] Siri Weerasooriya and M. A. El-Sharkawi, "Identification and control of a dc motor using back-propagation neural networks," IEEE Transaction on Energy Conversion, Vol.6, no.4, pp 663-669, Dec, 1991.
- [5] M. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki, "Feedback-error learning neural network for trajectory control of a robotic manipulation," Neural Networks, Vol.1, pp 251-256, 1988.
- [6] 이화석, 박준호, 최영규, 황창선 "신경회로망을 이용한 DC 모터의 제어" 대한전기학회, 하계학술대회 논문집(A), pp 239-241, 1992.