

신경 회로망을 이용한 DC 모터의 제어

이 화석, 박 준호, 최 영규, 황 창선
부산대학교 전기공학과

Control of a DC motor using Neural Networks

H. S. Lee, J. H. Park, Y. K. Choi, C. S. Hwang
Department of Electrical Engineering, Pusan National University

Abstract : In this paper, back-propagation neural network is used for the identification and trajectory control of a DC motor. The neural network is trained to identify the unknown nonlinear dynamics of the motor and load and the trained neural network is used for speed control of the DC motor to have good performance. Simulation results show the good performance of the control system based on the neural network under arbitrarily chosen speed trajectories.

1. 서론

인공 신경 회로망 (Artificial Neural Networks : ANN) 모델은 학습법, 적용성, 복잡 분산등의 특성을 가짐으로 인해 고전적인 방법으로는 쉽게 해결되지 않는 어려운 문제인 패턴인식, 음성인식, 영상처리등에 적용되어지고 있으며, 최근에는 동적 시스템제어에도 이용되고 있다. 전통적인 동적 시스템제어에서는 제어대상시스템의 정확한 수학적모델링을 필요로하나, 실제 시스템이 비선형이고 시변인 경우에 있어서는 그 시스템을 정확히 모델링한다는 것은 거의 불가능하며, 또한 부하특성을 완전히 파악하기도 매우 어렵다. [4]

인공 신경회로망이 비선형 함수를 학습할 수 있다는 것은 이미 잘 알려져 있고, [1, 2, 3] 제어 대상에 대한 제어입력과 출력간의 입출력 패턴을 학습시킴으로써 시스템을 동정(identification) 할 수 있다. 일단 인공 신경회로망에 의해 시스템을 동정하면 여러 고전제어 기법으로 바라는 제어목적을 이룰 수 있다.

본 논문에서는 전형적인 DC 모터의 역모델을 몇 가지 형태의 ANN으로 학습시키고 학습된 역모델을 이용하여 속도추적 제어기를 구성하며, 시뮬레이션에 의해 제어성능을 살펴보고자 한다.

2. 역전파 학습 알고리즘에 의한 신경회로망

Rumelhart 및 PDP 그룹이 개발한 다층신경회로망의 학습법으로서 가장 널리 사용되는 방법중의 하나이다. [1] 일반적으로 generalized delta rule로 알려져 있으며, 지도학습(supervised learning)의 한 방법으로써 주어진 모든 학습 패턴간의 실제 출력과 목표 출력간의 오차를 최소화하도록 뉴런간의 연결강도 및 뉴런의 임계치를 조정하는 방법이며 그방법은

아래와 같다.

식(1)과 같은 에너지함수를 최소화하는 연결강도는 식(2)와 같이 계산된다. 이때에 δ_{pj} 는 식(3-1) 및 식(3-2)와 같다.

$$E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2 \quad (1)$$

여기서 t_{pj} : 패턴 P에 대한 j 번째 출력의 목표치

$$o_{pj} = f_j(\text{net}_{pj}) = f_j(\sum_i w_{ji} o_{pi})$$

: 패턴 P에 대한 j 번째 출력의 실제치

$$\Delta p w_{ji}(n+1) = \eta \delta_{pj} o_{pi} + \alpha \Delta p w_{ji}(n) \quad (2)$$

이때 출력층에서의 δ_{pj} 는

$$\delta_{pj} = (t_{pj} - o_{pj}) f'_j(\text{net}_{pj}) \quad (3-1)$$

이고 중간층에서의 δ_{pj} 는

$$\delta_{pj} = f'_j(\text{net}_{pj}) \sum_k \Delta p w_{pk} w_{kj} \quad (3-2)$$

3. DC 모터제어를 위한 인공 신경회로망

3.1 모터 다이나믹스

모터 다이나믹스는 아래의 두식으로 주어진다.

$$K \omega_p(t) = -R_a i_a(t) - L_a [d i_a(t)/dt] + V_t(t) \quad (4)$$

$$K i_a(t) = J [d \omega_p(t)/dt] + D \omega_p(t) + T_L(t) \quad (5)$$

여기서 부하토크($T_L(t)$)는 선동기등의 부하로 나타내면 다음과 같은 형태가 된다.

$$T_L(t) = \mu \omega_p^2(t) [\text{sign}(\omega_p(t))] \quad \mu: \text{상수} \quad (6)$$

이산시간모델로 바꾸면 아래와 같다.

$$\omega_p(k+1) = \alpha \omega_p(k) + \beta \omega_p(k-1) + \gamma [\text{sign}(\omega_p(k))] \omega_p^2(k) + \delta [\text{sign}(\omega_p(k))] \omega_p^2(k-1) + \xi V_t(k) \quad (7)$$

시뮬레이션을 위해 사용한 DC 모터사양 및 ANN을 학습하기 위해 주어진 동작조건은 아래와 같다. [5]

(1) DC 모터사양

$$J = 0.068 \text{ Kg m}^2 \quad K = 3.475 \text{ Nm A}^{-1}$$

$$R_a = 7.56 \Omega \quad L_a = 55 \text{ mH}$$

$$D = 0.03475 \text{ Nm s} \quad \mu = 0.0039 \text{ Nm s}^2$$

$$T = 40 \text{ ms}$$

(2) 동작조건

$$-30.0 < \omega_p(k) < 30.0 (\text{rad/s})$$

$$|\omega_p(k-1) - \omega_p(k)| < 1.0 (\text{rad/s})$$

$$|V_t(k)| < 100 (v)$$

3.2 DC 모터의 추적제어

제어시스템의 목적은 모터의 출력 $\omega_p(k)$ 가 미리 선택한 기준모델의 출력인 $\omega_m(k)$ 를 추적하는 것이다. 제어시스템의 구조는 여러 가지의 형태로 나타낼 수 있으나 여기에서는 기준모델을 이용한 제어형태와 이와 유사한 구조에 대한 고찰을

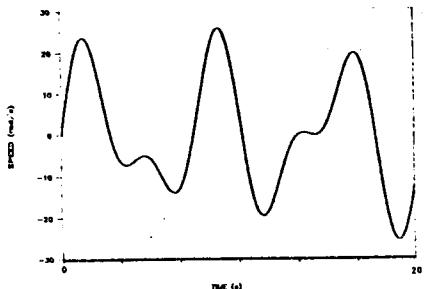


그림 2. 주어진 $\omega_m(k)$ 에 대한 제어성능(I)

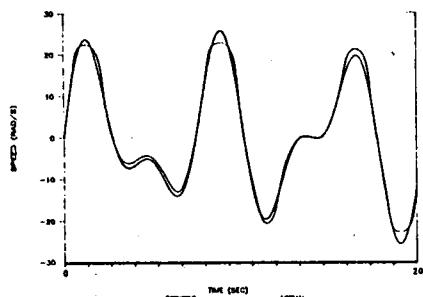


그림 4. 주어진 $\omega_m(k)$ 에 대한 제어성능(II)

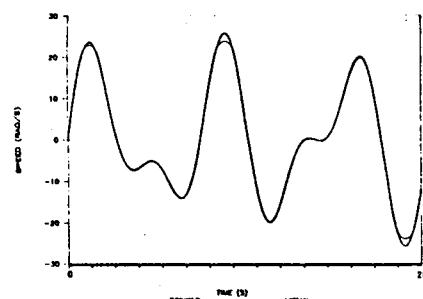


그림 6. 주어진 $\omega_m(k)$ 에 대한 제어성능(III)

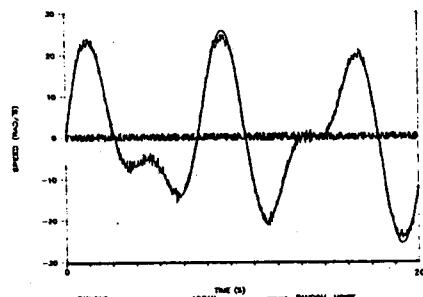


그림 7. (III)안에서 측정오차가 있을 때의 제어성능

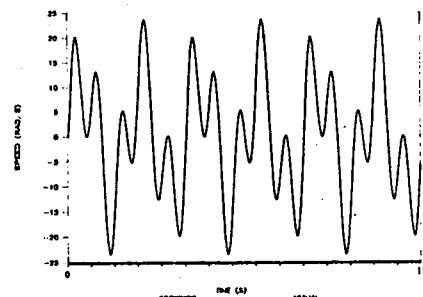


그림 8. 여러 궤적에 대한 제어성능

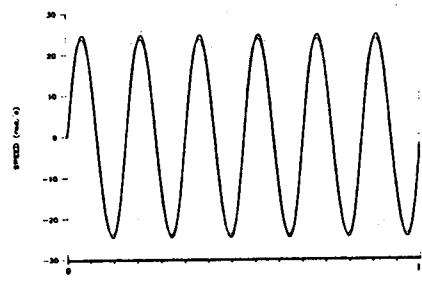


그림 9. 여러 궤적에 대한 제어성능

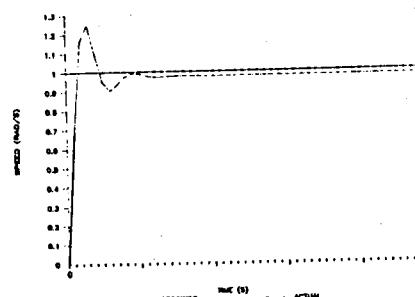


그림 10. (III)안의 단위계단응답

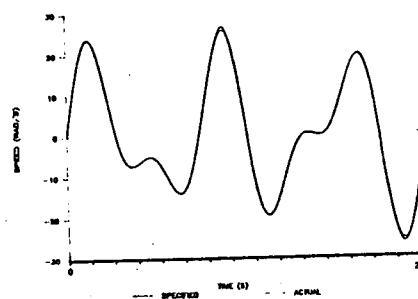


그림 12. 주어진 $\omega_m(k)$ 에 대한 제어성능(IV)

6. 참고문헌

- [1] J. L. McClelland, D. E. Rumelhart and the PDP research group, "Parallel Distributed Processing: Exploitations of cognition", Vol.1., Badford books, Cambridge, MA, 1986.
- [2] K. S. Narendra and Parthasarathy " Identification & control of dynamical systems using neural networks", IEEE Transactions on Neural Networks, Vol.1, pp 4-27, Mar., 1990.
- [3] S. Weerasooriya M. A. El-Sharkawi "Identification and control of a DC motor using back-propagation neural networks", IEEE Transactions on Energy Conversion, Vol.6, No.4, pp 663-669, Dec., 1991.
- [4] 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.
- [5] M. A. El-Sharkawi and Siri Weerasooriya " Development and implementation of self-tuning controller for DC motors ", IEEE Transactions on Energy Conversion, Vol.5, No.1, Mar., 1990.

시뮬레이션을 통해 보이고자 한다. 이를 위해 안정한 2차기준 모델을 가정한다. [2]

$$\omega_m(k+1) = 0.6\omega_m(k) + 0.2\omega_m(k-1) + r(k) \quad (8)$$

3.2.1 DC 모터의 동정 및 제어

(I) 안

식 (7)을 다시 쓰면 아래와 같다.

$$\omega_p(k+1) = f[\omega_p(k), \omega_p(k-1)] + \xi V_t(k) \quad (9)$$

학습후 추정되는 모터속도는 아래와 같다.

$$\hat{\omega}_p(k+1) = N[\omega_p(k), \omega_p(k-1)] + \xi \hat{V}_t(k) \quad (10)$$

학습결과는 임의의 제어입력에 대해서 추정치와 목표출력 값을 비교함으로써 평가할 수 있다.

$V_t(k) = 50 * \sin(2\pi kt/7) + 45 * \sin(2\pi kt/3) \quad \forall kt \in [0, 20]$
off-line으로 학습된 ANN을 이용한 제어기구조가 그림 1 이다.

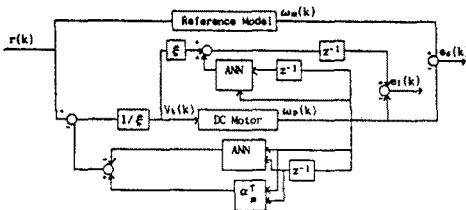


그림 1. (I) 안의 ANN에 기초한 제어구조

비선형함수인 $f[\cdot]$ 를 있다고 가정하고, (9)식에서의 k번 제시간 제어입력 $V_t(k)$ 을 아래 식으로 놓는다.

$$V_t(k) = \{-f[\omega_p(k), \omega_p(k-1)] + 0.6\omega_p(k) + 0.2\omega_p(k-1) + r(k)\}/\xi \quad (11)$$

(8), (9), (11)식을 이용하여 추적오차 차분방정식을 구하면 (12)식과 같다.

$$E_c(k+1) = 0.6E_c(k) + 0.2E_c(k-1) \quad (12)$$

그리고 기준모델이 점근적 안정이므로 임의의 초기조건에서 추적오차는 시간이 무한대일때 0이 된다. 그러나 실제 $f[\cdot]$ 는 알 수 없는 값이므로 학습된 ANN을 이용하여 제어입력 $V_t(k)$ 를 추정할 수 있다.

$$\hat{V}_t(k) = \{-N[\omega_p(k), \omega_p(k-1)] + 0.6\omega_p(k) + 0.2\omega_p(k-1) + r(k)\}/\xi \quad (13)$$

ANN의 제어성능을 평가하기위해 임의의 궤적에 대하여 $\omega_p(k)$ 와 $\omega_m(k)$ 를 비교하였다. (그림 2)

$$\omega_m(k) = 10 * \sin(2.0\pi kt/4) + 16 * \sin(2.0\pi kt/7) \quad \forall kt \in [0, 20]$$

그러나 여기에서는 등의 값을 미리 알고 있다고 생각한 것이며 이보다 더 일반적인 구조가 아래에 제안된다.

(II) 안

식 (7)은 또한 다음과 같이 쓸 수 있다.

$$V_t(k) = g[\omega_p(k+1), \omega_p(k), \omega_p(k-1)] \quad (14)$$

여기서 ANN의 입력은 $[\omega_p(k+1), \omega_p(k), \omega_p(k-1)]$ 이고 출력은 $g[\cdot]$ 이다. ANN으로 학습후 추정되는 결과식은 아래와 같다.

$$\hat{V}_t(k) = N[\omega_p(k+1), \omega_p(k), \omega_p(k-1)] \quad (15)$$

선택한 기준모델이 점근적 안정이므로, 추적오차가 0으로 수렴한다고 가정하면 (k+1)번째 시간의 속도는 아래식으로 추정될 수 있다.

$$\omega_p(k+1) = 0.6\omega_p(k) + 0.2\omega_p(k-1) + r(k) \quad (16)$$

이 예측치와 ANN을 이용한 전체블록다이아그램이 그림 3이며 이때 제어입력은 (17)식으로 추정된다.

$$\hat{V}_t(k) = N[\hat{\omega}_p(k+1), \omega_p(k), \omega_p(k-1)] \quad (17)$$

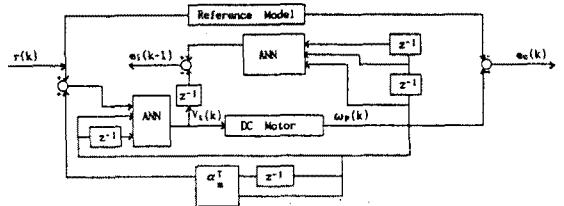


그림 3. (II) 안의 ANN에 기초한 제어구조

그 평가는 (I)에서와 같은 $\omega_m(k)$ 에 대하여 시뮬레이션 했다. (그림 4) 이 경우에서는 부하및 모터파라메타의 어떤 값도 안다고 가정하지 않았다는 것이 중요한 사항이다.

(III) 안

(II)에서 제안한 구조에서 기준모델을 제거하고 기준입력으로 $\omega_m(k+1)$ 을 인가한 블록다이아그램이 그림 5이며, (II)에서와 같은 $\omega_m(k)$ 에 대해서 시뮬레이션했다. (그림 6) 이때의 제어입력은 (18)식으로 추정된다.

$$\hat{V}_t(k) = N[\omega_m(k+1), \omega_p(k), \omega_p(k-1)] \quad (18)$$

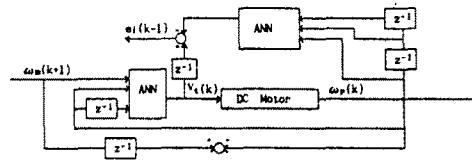


그림 5. 기준모델이 제거된 제어구조

실제 전기구동시스템에서는 측정오차가 포함되며 이때에도 $\omega_p(k)$ 가 임의의 기준모델출력을 잘 추적하는지를 평가하는 것은 중요한 고려사항이다. 이런 점에서 볼때 잠음제거능력을 가진 ANN이 측정오차가 있을 때에도 정확한 추적제어를 할 수 있을 것으로 여겨 진다. ANN의 잠음제거능력 및 제어성능을 평가하기위해 $1/\xi$ (rad/s)의 난수를 발생시켜 시뮬레이션했다. (그림 7) 그외 그림 8,9는 임의의 $\omega_m(k)$ 에 대한 시뮬레이션 결과이며 그림 10은 단위계단응답특성을 나타낸다.

(IV) 안

(III)에서와 유사하게 (I)구조에 대한 변경이 그림 11이며 같은 $\omega_m(k)$ 에 대하여 제어성능을 평가하였다. (그림 12) 이때의 제어입력은 (19)식으로 추정된다.

$$\hat{V}_t(k) = \{-N[\omega_p(k), \omega_p(k-1)] + \omega_m(k+1)\}/\xi \quad (19)$$

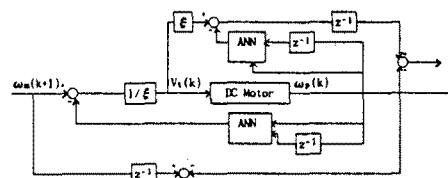


그림 11. 기준모델이 제거된 제어구조

5. 결론

신경회로망을 이용해서 구성한 제어기의 DC모터 속도추적 제어가 가능함을 보였다. 또한 신경회로망이 모터및 부하간의 비선형특성을 찾아낼 수 있다는것을 보였고, 측정오차가 존재 할때에도 주어진 임의의 궤적을 잘 추적함을 보임으로써 잠음 제거능력과 강인성을 가지는 것도 확인할 수 있었다. 그리고 동정시 학습된 ANN을 이용해서 제어기를 구성함으로써 ANN의 일반성(generalization)도 보였다.