

인공신경회로망에 기초한 직류모터제어에 관한 연구

(A Study on DC Motor Control based on Artificial Neural Networks)

朴 晋 玄 *, 崔 榮 圭 **

(Jin Hyun Park and Young Kiu Choi)

要 約

본 논문에서 직류모터 및 비선형 부하의 동역학 특성이 알려져 있지 않을 때에 인공신경회로망을 이용하여 직류모터 및 비선형 부하의 모델을 제안하고, 제안된 모델에 기초하여 속도 제어 시스템을 구성하였다. 또한 인공신경회로망에 기초한 속도 예측 모델을 제안하여 실시간 제어시에 발생하는 계산시간 지연 효과를 제거할 수 있었다. 그리고 임의의 갯수의 속도 변수를 가지는 모델도 제안하였는데, 모터 및 비선형 부하의 관성 토오크가 큰 경우에 매우 효과적이었다. 마지막으로, 신경망 제어방식과 일정이득을 갖는 PID제어방식을 결합한 형태의 제어기를 제안하였다. 제안된 신경 제어 시스템들이 양호한 속도 추적 특성을 갖고 있음을 컴퓨터 모의 실험 및 실제 실험으로 보였다.

Abstract

In this paper, we assume that the dynamics of DC motor and nonlinear load are unknown. We propose an inverse dynamic model of DC motor and nonlinear load using the artificial neural network and construct speed control system based on the proposed dynamic model. We also propose another dynamic model with speed prediction scheme using the artificial neural network that removes the undesirable time delay effect caused by the computation time during the real-time control. We suggest a dynamic model which has arbitrary number of speed arguments and is especially effective when the motor and load has large moment of inertia. Next, we suggest a controller that combine the neurocontrol and PID control with constant gain. We show that the proposed neurocontrol systems have capabilities of noise rejection and generalization to have good velocity tracking through computer simulations and experiments.

1. 서 론

*準會員, **正會員 釜山大學校 電氣工學科
(Dept. of Elect. Eng., Pusan Nat'l Univ.)
接受日字 : 1994年 1月 26日

각종 산업기지에서 제어요소로 널리 사용되고 있는 직류모터의 제어 시스템에서는 대부분 일정이득을 갖

는 PID제어 방식을 채택하고 있다. 그러나 이러한 제어시스템에서는 부하특성이 미지이고 비선형적으로 변화할 때에는 적절한 이득과 성능을 얻을 수 없으므로^[1] 고성능 제어 특성을 기대하기 어렵다. 미지의 비선형 제어대상에 적절히 대처하기 위한 많은 방법들이 연구되어 왔으며, 이러한 방법중 PID 계수를 제어시스템의 변화에 적절히 조절하는 적응제어 방식도 연구되었다. 그러나 적응제어 방식은 시스템의 차수가 높아지거나 매개변수의 수가 증가하면 수학적 계산이 복잡해지고 모델링이 어려워지며 많은 계산시간이 소요되므로^[2] 빠른 응답 특성을 갖는 시스템의 경우에 실시간 제어가 어렵다는 단점이 있다. 그래서 최근에 와서는 이러한 문제점을 해결하기 위하여 전문가의 경험이나 지식을 바탕으로 인간의 의사 결정과정을 모방한 퍼지제어 기법^[3,4]과 인간의 두뇌 구조를 모의하여 인지적 정보 처리 구조를 갖는 신경회로망 제어 기법이 도입되었다.

그런데 퍼지제어 기법은 전문가로부터 제어기법을 도출하는 것이 항상 가능한 것이 아니며, 복잡한 동적 특성을 갖는 제어 시스템의 경우 적절한 제어 규칙을 찾는 것이 쉽지 않다.^[5] 그러나 인공신경회로망은 이러한 전문가의 제어기법을 도출할 필요가 없고, 비선형 함수를 학습할 수 있는 학습능력^[6,7]과 왜곡되거나 잡음을 가진 입력에 대하여 바른 인식을 할 수 있는 강인성, 불완전한 입력 데이터에 의해서도 학습에 의해 일반적인 출력값을 내는 일반화 기능, 다량의 복잡한 데이터를 효과적으로 처리할 수 있는 병렬분산 처리 등의 특성을 가지고 있다. 그러므로 고전적 방법으로 해결하기 어려웠던 패턴인식, 음성인식, 영상 처리, 그리고 최근에 와서는 동적 시스템 제어에도 이용되고 있다.^[8,9] 특히 제어 대상 시스템이 미지의 비선형성을 갖는 경우에도 제어 대상에 대한 입출력 패턴을 학습시킴으로써 시스템 식별^[10,11]을 효과적으로 할 수 있어 원하는 제어특성을 쉽게 얻을 수 있다.

본 연구에서는 직류모터 및 비선형 부하의 역모델을 몇가지 형태의 다층 신경회로망으로 모델링하고 입출력 패턴을 수집한뒤 역전파 알고리즘을 사용하여 전류제어방식의 속도제어를 구성하였다. 신경회로망을 이용한 직류모터제어는 다른 연구논문^[7,12]에서 발표된 바 있으나 전류제어방식이 아닌 전압제어방식을 사용하였다. 본 연구에서는 전압제어방식의 사용시 전압공급원의 전압변동과 모터 내부 저항의 온도에 따른 변화와 전류에 따른 모터 내부 인덕턴스의 변화 등에 의해 발생하는 문제점들을 제거하기 위해서 PWM의 전류제어방식을 사용하였다. 또한 실시

간제어시 나타나는 제어량 계산 시간에 의한 출력 지연을 방지하기 위해서 속도 예측 신경회로망을 추가하여 미리 적절한 제어량을 계산해 줌으로써 제어의 정밀도를 높일 수 있는 방법을 제시하였고, 신경회로망 제어가 학습시에 잡음이 섞인 학습 데이터 일때에 발생하는 학습 문제를 입력층의 뉴우런 갯수를 늘림으로써 가능하게 하였다. 그리고 신경회로망 제어기에 PID 제어기법을 추가한 제어기도 제시하였으며, 신경회로망의 학습오차가 크거나 속도 예측시 잡음의 영향에 의하여 나타나는 토오크 오차를 정밀하게 보상할 수 있도록 하였다. 신경회로망을 이용한 여러가지 제어 알고리즘의 성능을 컴퓨터 모의 실험과 실제 실험을 통하여 비교하였고, 일정이득을 갖는 종래의 PID 제어기의 성능과도 비교, 평가분석하였다.

II. 인공신경회로망을 이용한 속도추적

1. 직류모터 및 비선형 부하모델

직류모터 및 부하는 그림 1과 같다. 부하로는 아래 식 (3)과 같은 비선형 특성을 갖는 양방향성 팬(fan)을 제작하여 부착하였다.

직류모터의 동적 방정식은 다음과 같이 표현될 수 있다.

$$K\omega_p(t) = -R_a \cdot i_a(t) - L_a \frac{di_a(t)}{dt} + V_r(t) \tag{1}$$

$$K i_a(t) = J \frac{d\omega_p(t)}{dt} + D \cdot \omega_p(t) + T_L(t) \tag{2}$$

여기서 부하토크 $T_L(t)$ 은 다음과 같은 비선형 형태이며, μ 는 상수이다

$$T_L(t) = \mu \omega_p^2(t) \operatorname{sgn}(\omega_p(t)) \tag{3}$$




그림 1. 모터 및 양방향성 팬 부하
Fig. 1. Motor and bidirectional fan load.

전압 조절에 의한 제어시에 전압공급원의 전압변동과 모터 내부 저항의 온도에 따른 변화, 전류에 따른 모터 내부 인덕턴스의 변화에 의해 제어상의 문제가 발생하는데 본 연구에서는 이러한 문제를 전류제어 방식을 사용하여 제거하였다. 그리고 전류 제어시 모터의 동적방정식(2)만 갖고도 속도를 바로 제어할 수 있는 장점이 있다.

식(2)를 다시 고쳐 쓰면 다음과 같다

$$\tau(t) = J \frac{d\omega_p(t)}{dt} + D \cdot \omega_p(t) + \mu \omega_p^2(t) \operatorname{sgn}(\omega_p(t)) \quad (4)$$

위의 토오크 방정식을 이산시간모델로 바꾸어 쓰면

$$\begin{aligned} \omega_p(k+1) = & \frac{T}{J} \tau(k) - \mu \frac{T}{J} \omega_p^2(k) \operatorname{sgn}(\omega_p(k)) \\ & + (1 - \frac{D \cdot T}{J}) \omega_p(k) \end{aligned} \quad (5)$$

이고, 단 T는 샘플링 시간을 나타낸다.

본 연구에서 제어 시스템이 지령속도 $\omega_m(k)$ 에 대하여 실제의 출력 $\omega_p(k)$ 가 얼마나 잘 추적하는가를 살펴 보고자 한다.

2. 간단한 속도 제어기 모델

이산시간모델로 바꾼 식(5)를 다음과 같이 간략하게 나타낼 수 있다.

$$\tau(k) = F[\omega_p(k+1), \omega_p(k)] \quad (6)$$

단, $\tau(k)$ 는 입력 토오크이고 $\omega_p(k)$ 는 모터의 속도이며 $F[\cdot]$ 는 비선형함수를 나타낸다.

위의 식(6)의 비선형 함수를 인공신경회로망으로 학습시켜서 $N_1[\cdot]$ 이라는 함수로 근사시킬 수 있다.

$$\hat{\tau}(k) = N_1[\omega_p(k+1), \omega_p(k)] \quad (7)$$




그림 2. 간단한 속도 제어기 모델에 기초한 제어 시스템

Fig. 2. Control system based on the simple velocity controller model.

학습후 실제 직류모터의 제어 입력은 $\omega_p(k+1)$ 대신에 지령속도 $\omega_m(k+1)$ 를 대입한 식(8)과 같이 학습된

신경회로망을 이용한 제어기 구조는 그림 2와 같다.

$$\hat{\tau}(k) = N_1[\omega_m(k+1), \omega_p(k)] \quad (8)$$

3. 속도 예측 신경망을 갖는 제어기 모델

간단한 속도 제어기 모델은 모터의 실시간 제어시 신경회로망의 계산 시간과 센서의 계측 시간의 시간 지연 문제가 발생하게 된다. 실시간 제어시의 이러한 문제점을 해결하기 위하여 현재속도 $\hat{\omega}_p(k)$ 를 예측할 수 있는 신경회로망을 따로 구성하여, 시간지연 효과를 없애므로써 제어의 정밀도를 높일 수 있다.




그림 3. 이산시간 영역에서 나타낸 토오크

Fig. 3. Torque in the discrete time domain.

그림 3에서와 같이 $k-1 < t < k-1+\epsilon$ 구간에서 $\omega_p(k)$ 의 예측치 $\hat{\omega}_p(k)$ 를 계산하고, $k-1+\epsilon < t < k$ 구간에서 제어 입력 $\hat{\tau}(k)$ 를 계산하여 낸다.

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

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

예측치 $\hat{\omega}_p(k)$ 를 신경회로망으로 구성하고 제어방식 (A)에서 제안한 제어기와 결합하여 그림 4와 같이 구성하였다.




그림 4. 속도 예측 신경망을 갖는 제어기 모델에 기초한 제어 시스템

Fig. 4. Control system based on the controller model with velocity prediction neural network.

4. 합성한 제어기 모델

속도 예측 신경망을 갖는 제어기 모델은 신경회로망이 2개 이므로 계산시간이 약 2배 정도 된다. 그러므로 속도 예측 신경망을 갖는 제어기 모델에서 제안한 신경회로망 2개를 하나의 신경회로망으로 구성하여 계산시간을 줄일 수 있다.

식(9)를 식(6)에 대입하여 아래식으로 구해낼 수 있다.

$$\tau(k) = H[\omega_p(k+1), \omega_p(k-1), \tau(k-1)] \quad (10)$$

위의 비선형함수를 인공신경회로망으로 학습시켜서 $N_3[\cdot]$ 라는 함수로 근사 시킬 수 있다. 학습후 제어 입력으로는 아래식 (11)과 같고 합성한 제어기 모델의 신경회로망 구조는 그림 5와 같다.

$$\hat{\tau}(k) = N_3[\omega_p(k+1), \hat{\omega}_p(k-1), \hat{\tau}(k-1)] \quad (11)$$




그림 5. 합성한 제어기 모델에 기초한 제어 시스템
Fig. 5. Control system based on the combined controller model.

5. 다입력 제어기 모델

속도 예측 제어기 모델과 합성한 제어기 모델에서 플랜트의 제어 신호인 $\hat{\tau}(k)$ 가 다시 신경회로망의 제어 입력 $\hat{\tau}(k-1)$ 로 들어가게 된다. 샘플링 시간이 아주 짧거나 관성이 매우 큰 경우에는 큰 토크가 입력되어도 속도의 변화폭이 매우 작으므로 신경회로망의 학습 결과 $\hat{\tau}(k)$ 가 입력 $\hat{\tau}(k-1)$ 에 크게 지배를 받게 되어, $\hat{\tau}(k)$ 가 오차를 가지게 될 경우 다음 스텝(step)에서 더 큰 오차를 유발할 수 있게 된다.

그러므로 이러한 문제를 줄이기 위해서 신경회로망을 토크 $\hat{\tau}(k)$ 가 없는 형태로 표현한다.

식(5)에서 $\omega_p(k-1)$, $\tau(k-1)$, $\tau(k-2)$ 를 구해 낸다.

$$\omega_p(k-1) = I_1[\tau(k-2), \omega_p(k-2)] \quad (12-a)$$

$$\tau(k-1) = I_2[\tau(k), \omega_p(k-1)] \quad (12-b)$$

$$\tau(k-2) = I_3[\omega_p(k-1), \omega_p(k-2)] \quad (12-c)$$

식(12)를 식(10)에 대입하면 아래 식과 같다.

$$\tau(k) = J_1[\omega_p(k+1), \omega_p(k), \omega_p(k-1), \omega_p(k-2)] \quad (13)$$

위의 과정을 되풀이 함으로써 아래식과 같이 일반화된 식을 만들 수 있다.

$$\tau(k) = J_2[\omega_p(k+1), \omega_p(k), \omega_p(k-1), \omega_p(k-2), \dots, \omega_p(k-n)] \quad (14)$$

단, n은 양수

그러므로 제어방식 (D)에서의 제어신호는 식 (15)과 같다.

$$\hat{\tau}(k) = N_4[\omega_p(k+1), \omega_p(k), \omega_p(k-1), \omega_p(k-2), \dots, \omega_p(k-n)] \quad (15)$$

단, n은 양수

이는 간단한 속도 제어기 모델 역시 다입력 제어기 모델의 한방법으로서, 간단한 속도 제어기 모델로 신경회로망의 학습이 어려울 경우 학습 시킬 수 있는 방법으로 제시할 수 있다. 그림 6은 입력항이 4개인 경우의 제어기 구조를 나타내었다.




그림 6. 다입력 제어기 모델에 기초한 제어 시스템
Fig. 6. Control system based on the multi-input controller model.

6. 신경망-PID 제어기 모델

신경망 제어방식과 일정이득을 가지는 PID제어방식을 결합한 형태로 제어기를 구현할 수 있다. 그러므로 다입력 제어기 모델과 귀환 이득을 갖는 비례-적분 제어기를 사용하여 나타내면 제어 신호는 아래식 (16)과 같이 나타난다.

$$\tau(k) = N_4[\omega_m(k+1), \omega_p(k), \omega_p(k-1), \omega_p(k-2)] + K_p e(k) + T K_i \sum_{j=0}^k e(j) + \frac{K_d}{T} (e(k) - e(k-1)) \quad (16)$$

단, T는 샘플링 시간을 나타내며, K_p , K_i , K_d 는 이득, $e(k)$ 는 $\omega_m(k) - \omega_p(k)$ 를 나타낸다. 시스템이 진동이 일어나지 않는 안정한 상태에서 동작하도록 이득값을 정하여, 신경망 제어기에 사용되는 신경회로망의 학습오차가 크거나 속도 예측시 잡음에 의하

여 나타나는 지령 토크에 의한 속도 오차를 보상할 수 있다. 그림 7는 신경망-PID 제어기 모델에 기초한 제어기의 구조를 나타내었다.




그림 7. 신경망-PID 제어기 모델에 기초한 제어 시스템

Fig. 7. Control system based on the neural network-PID controller model.

III. 실험 및 결과

그림 8과 같이 제어 대상인 직류모터의 구동시스템을 구성하여 본 연구에서 제안하는 제어알고리즘을 적용한다. PIO인터페이스 카드는 속도 검출을 위해 들어온 엔코더의 펄스신호로부터 속도를 검출하여 디지털 포트의 buffer에 저장한다. 전력 스위칭 모듈(power switching module)은 H-bridge converter 구조를 사용하였고 스위칭 소자는 IGBT를 사용하였다. IGBT의 스위칭 주파수는 20KHz이며, 컴퓨터에서 나오는 전류지령은 D/A (digital~analog~converter)를 통하여 $\pm 5V$ 사이의 아날로그로 나오게 하였다. 사용된 직류 서보 모터의 사양은 정격출력이 200W이며, 정격 전압이 직류 75V, 정격 전류 3.3 A 이다. 속도 검출을 위한 센서는 1000(pulse/revolution)의 incremental encoder가 부착되어 있다. 직류모터의 속도검출을 위해 F/V(frequency voltage converter)를 이용한 아날로그로 처리하려 하였으나 직류 모터 운전중 스위칭에 의한 심한 잡음의 영향으로 정확한 속도를 측정할 수 없었다. 그러므로 잡음에 강인한 디지털 회로를 사용하였으며, 속도 검출시 밀도 향상을 위하여 1000(pulse/revolution)의 encoder~ pulse를 2000(pulse/revolution)으로 만들어 사용하였다. 지령토크에 대한 실험토크의 비교를 위해 전류 센서로는 홀영향에 의한 전류 변환기(LEM current transducer)를 사용하였다. 그리고 직류단의 전압 또는 전류가 과도하게 높을 경우 모터 및 회로 소자의 보호를 위하여 직류단에 보호회로를 구성하였다.

실험에 앞서 모의 실험 결과는 본 논문에서 제안한 제어기가 일정이득의 PID제어 보다 다른 지령속도와 랜덤한 센서잡음을 첨가하였을 경우 매우 좋은 결과를 보였다. 모의실험은 속도 예측시간과 신경망 제어기의 계산시간을 고려하였다. 학습에 사용한 지령속도에 대하여 간단한 속도 제어기 모델과 다입력 제어기 모델은 속도추적시 시간지연 효과가 나타났다. 속도 예측 신경망을 갖는 제어기 모델은 간단한 속도 제어기 모델에 비하여 시간지연은 없어나, 약간의 추적 오차가 발생하였으며 이것은 신경회로망 2개를 사용함에 따른 학습오차의 증폭에 의한 것으로 판단된다. 합성된 제어기 모델은 속도 예측 신경망을 갖는 제어기 모델 보다 더 좋은 결과를 보였다. 신경망-PID 제어기 모델은 다입력 제어기 모델에서 생기는 시간지연을 PID 제어를 사용하여 보상할 수 있었다. 일정이득의 PID 제어기는 다입력 제어기 모델과 신경망-PID 제어기 모델의 속도 추적 보다 더 좋은 속도추적 결과를 나타내도록 계인을 조정하였다. 다른 지령속도에 대하여 위의 두 신경망 제어방식은 $\pm 1.98\%$ 의 속도오차가 발생하였으나, 일정이득의 PID 제어는 $\pm 7.21\%$ 의 속도오차가 발생하였다. $\pm 1(\text{rad/sec})$ 사이의 랜덤한 센서 잡음을 첨가하였을 경우 다입력 제어기 모델과 일정이득의 PID 제어기의 속도추적오차를 비교하면 신경망 제어 모델은 $\pm 4.16\%$ 의 속도오차를 보였고 일정이득의 PID 제어기는 $\pm 10.51\%$ 의 속도오차를 나타내었다. 이는 모의 실험이 모터 및 부하의 조건이 가장 이상적이며, 특히 신경회로망의 학습이 잘 되었고 속도 예측의 오차가 없기 때문이었다.

그러나 실제 실험상 시스템의 관성 모멘트가 작은 경우 간단한 속도 제어기 모델 구조만으로도 제어가 가능하나 본 실험에서 사용한 모터 및 부하는 관성 모멘트가 비교적 커서 간단한 속도 제어기 모델의 입출력 패턴만으로 신경회로망을 학습하기 힘들었다.

속도 예측 신경망을 갖는 제어기 모델과 합성된 제어기 모델은 신경회로망을 학습 후 제어기로서 사용시 시스템의 제어신호 $\hat{\tau}(k)$ 가 신경회로망의 제어 입력 $\hat{\tau}(k-1)$ 에 크게 지배 받는데, 실제 실험에서는 오차를 포함한 $\hat{\tau}(k-1)$ 가 들어감으로 더 큰 오차를 유발하여 양호한 속도추적 특성을 얻기가 어려웠다. 그러므로 안정한 시스템의 제어를 위해서 신경회로망의 학습 오차를 줄여야 한다.

다입력 제어기 모델은 신경망 제어기만을 사용한 제어방법 중 실험적으로 양호한 결과를 나타내었다. 특히 시스템의 관성 모멘트가 큰 경우에도 신경회로망의 학습이 가능하였다. 신경회로망은 그림 9와 같

이 학습하였다. 그림 10이하의 실험 결과는 실험 데이터 과일을 plotting program으로 출력한 것이다. 학습후 신경회로망을 제어기로서 구성하여 학습한 지령속도에 대한 추적속도는 아래 그림 10과 같다. 그림 11은 일정이득을 갖는 PID 제어 기법에 의한 속도 제어의 결과이다. PID의 계수 선정은 주어진 속도 명령에 대하여 다입력 제어기 모델보다 오히려 우수한 특성이 나오도록 조절하였다. 물론 신경회로망을 더욱 정밀하게 학습 시키면 그림 11보다 우수한 특성을 얻을 수 있다. 임의의 $\pm 10(\text{rpm})$ 의 랜덤한 계측 잡음을 첨가하였을 경우 그림 12에서 보여지는 것 같이 신경회로망 제어기는 잡음제거능력이 있어 지령속도를 잘 추적함을 보인다. 그러나 일정이득의 PID 제어는 그림 13에서와 같이 잡음에 의한 정상상태 오차가 발생하여 지령속도를 잘 추적하지 못함을 보였다. 다른 지령속도에 대하여 신경망 제어기는 신경회로망의 특징인 일반화 기능에 의하여 그림 14와 같이 비교적 잘 추적하나, 일정이득의 PID 제어기는 그림 15와 같이 다입력 제어기 모델보다 속도추적 특성이 좋지 못했다.

신경망-PID 제어기 모델에 의한 제어는 다입력 제어기 모델과 일정이득의 PID 제어기 보다 더 정밀하게 지령속도를 추적했다. 그림 16은 지령속도에 대한 추적속도를 나타낸다. 다입력 제어기 모델에서 신경회로망의 학습시 오차와 속도 계측 오차에 의해 나타나는 정상상태 오차를 신경회로망과 PID를 합성한 제어기 모델에서 PID 제어기를 첨가하여 보상해서 가장 좋은 속도추적 특성을 나타내었다. 임의의 $\pm 10(\text{rpm})$ 의 랜덤한 계측 잡음을 첨가하였을 경우에도 그림 17과 같이 보였다. 그림 18은 다른 지령속도에 대한 추적 속도를 나타낸다. 역시 다입력 제어기 모델에 의한 제어보다 더 정밀한 추적속도 결과를 보였다. 표 1에서 앞에서 제안한 여러 신경제어방식의 특징과 속도 추적결과를 보였다.




그림 8. 직류모터 속도 제어를 위한 하드웨어 블록선도
 Fig. 8. Hardware block diagram for dc motor speed control.

표 1. 제안한 여러 신경제어방식의 비교
 Table 1. Comparison with proposed neuro-control schemes.

제어 방식	특징	지령속도 평균오차	10rpm의 계측노이즈 발생시 평균오차	임의의 지령속도에 대한 평균오차
PID 제어방식	<ul style="list-style-type: none"> 제한급 정밀히 어려움 다른 지령속도에 대한 계인급의 변율이 필요 랜덤노이즈에 대해 장인회적 잡음 	52.81 rpm (Fig. 11)	132.30 rpm (Fig. 13)	72.88 rpm (Fig. 15)
간단한 속도 제어기	<ul style="list-style-type: none"> 구조가 가장 간단 시간지연이 많음 	-	-	-
속도 계측 신경잡음을 갖는 제어기 모델	<ul style="list-style-type: none"> 구조가 복잡 시간지연이 많음 신경망학습에 따른 오차 존재 	-	-	-
합성된 제어기 모델	<ul style="list-style-type: none"> 구조가 간단 시간지연이 없음 잡음이 랜시스템에 대하여 학습이 어려움 신경망 학습에 따른 오차 발생 	-	-	-
다입력 제어기 모델	<ul style="list-style-type: none"> 시간지연이 많음 변율이 랜시스템에 대해서도 학습이 어려움 신경망 제어기중 가장 양호한 속도 추종 	62.47 rpm (Fig. 10)	70.21 rpm (Fig. 12)	31.39 rpm (Fig. 14)
신경회로망과 PID를 합성한 제어기 모델	<ul style="list-style-type: none"> 시간지연이 없음 변율이 랜시스템에 대해서도 학습이 어려움 신경망학습에 따른 오차를 PID 제어기로 감소 	29.36 rpm (Fig. 16)	46.79 rpm (Fig. 17)	29.78 rpm (Fig. 18)




그림 9. 다입력 제어기 모델에서의 신경회로망의 학습 결과
 Fig. 9. Learning result of neural network for multi-input controller model.




그림 10. 다입력 제어기 모델의 지령속도와 추적속도
 Fig. 10. Command and tracking velocity of multi-input controller model.




그림 11. PID 제어기의 지령속도와 추적속도
 Fig. 11. Command and tracking velocity of PID controller.




그림 12. 10 rpm 사이의 랜덤한 센서 잡음을 발생시 지령속도에 대한 다입력 제어기 모델의 추적속도
 Fig. 12. Tracking velocity of multi-input controller model for command velocity when generate random sensor noise in 10 rpm.




그림 13. ±10 rpm 사이의 랜덤한 센서 잡음을 발생시 지령속도에 대한 PID 제어방식의 추적속도
 Fig. 13. Tracking velocity of PID control for command velocity when generate random sensor noise in ±10 rpm.

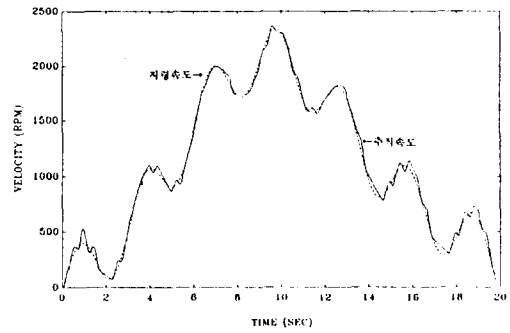


그림 14. 다른 지령속도에 대한 다입력 제어기 모델의 추적속도
 Fig. 14. Tracking velocity for different command velocity in multi-input controller model.




그림 15. 다른 지령속도에 대한 PID 제어기의 추적속도
 Fig. 15. Tracking velocity for different command velocity in PID controller.




그림 16. 신경회로망과 PID를 합성한 제어기 모델의 지령속도와 추적속도
 Fig. 16. Command and tracking velocity of controller model combined neural network with PID.




그림 17. ±10 rpm 사이의 랜덤한 센서 잡음을 발생시 지령속도에 대한 신경회로망과 PID를 합성한 제어기 모델의 추적속도
 Fig. 17. Tracking velocity of control lermodel combined neural network with PID for command velocity when generate random sensor noise in ±10 rpm.




그림 18. 다른 지령속도에 대한 신경회로망과 PID를 합성한 제어기 모델의 추적속도
 Fig. 18. Tracking velocity for different command velocity in controller model combined neural network with PID.

IV. 결론

본 논문에서는 직류모터의 속도 제어를 신경회로망을 이용하여 구성하였고, 신경회로망이 직류모터와 부하의 비선형 특성을 동정하여 임의의 지령속도를 잘 추적함을 보였다.

제어 모터 및 부하의 관성 토오크가 작은 경우에는 간단한 속도 제어기 모델의 제어 알고리즘으로 제어할 수 있으며 계산시간이 짧아 샘플링 시간이 매우 짧은 실시간 제어에 용이하고, 속도 예측 신경망을 갖는 제어기 모델과 합성한 제어기 모델의 제어 알고

리즘 역시 신경회로망의 학습이 정밀하며, 속도 측정 정도가 높으면 정밀한 제어가 가능할 것으로 기대된다. 제어모터 및 부하의 관성 토오크가 큰 경우 간단한 속도 제어기 모델의 제어 알고리즘 방법으로 신경회로망의 학습이 어려웠고, 속도 예측 신경망을 갖는 제어기 모델과 합성한 제어기 모델의 경우에는 학습은 가능하였으나 토오크 성분의 오차로 인하여 제어가 어려웠다. 그러나 다입력 제어기 모델의 제어 알고리즘을 사용할 경우 신경회로망의 학습이 용이하였고 제어가 잘 되는것을 확인할 수 있었다. 그리고 신경회로망의 학습이 잘 되지 않은 곳에서의 토오크 오차를 보상하는 신경회로망과 PID를 합성한 제어기 모델이 가장 정밀하게 제어됨을 보였다. 특히 학습에 사용되지 않은 다른 지령속도에 대해서도 신경회로망의 일반화 특성에 의해 신경망제어방식이 일정이득의 PID 제어방식 보다 더 잘 추적함을 보였다. 또한 인공신경회로망 제어기는 잡음제거능력도 뛰어나 측정 오차가 발생할 때에도 임의의 주어진 속도를 비교적 잘 추적함을 보였다.

신경회로망 제어기의 더 광범위한 사용을 위하여 신경회로망의 정밀한 학습 방법에 대한 연구와 정밀한 속도계측을 위한 계측회로에 대한 연구가 요망된다.

* 본 연구는 한국전력공사의 지원에 의하여 수행되었음.

參 考 文 獻

[1] M. H. Lee, S. Y. Lee and C. H. Park "Identification and control on nonlinear dynamic systems using higher order neural networks," KITE Journal of Electronics Engineering, vol.3, pp. 73-77, May 1992.
 [2] Karl Johan Astrom and Bjorn Wittenmark, Adaptive Control, Addison-Wesley, 1992.
 [3] 이광형, 오길록, "퍼지이론 및 응용 I 권 II 권," 홍릉 과학 출판사, 1992
 [4] 菅野道夫(著), 박민용, 최항식(譯), "퍼지 제어 시스템," 대영사, 1990
 [5] Bark Kosko, Neural Networks and Fuzzy System, Prentice-Hall, 1992.
 [6] J. L. McClelland, D. E. Rumelhart and the PDP research group, Parallel Distributed Processing : Explorations of

- the Microstructures of Cognition, MIT Press, Cambridge, MA, 1986.
- [7] Siri Weerasooriya and 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.
- [8] 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.
- [9] Takayuki Yamada and Tetsuro Yabuta, "Dynamic System Identification Using Neural Networks," IEEE Transaction on System, Man, and Cybernetics, vol. 23, no.1, pp. 204-211, January/February 1993.
- [10] Marilyn McCord Nelson and W. T. Illingworth, A Practical Guide to Neural Nets, Addison-Wesley, 1991.
- [11] James. A. Freeman and David M. Skapura, Neural Networks Algorithms, Application, & Programming Techniques, Addison-Wesley, 1991.
- [12] 이화석, 박준호, 최영규, 황창선 "신경회로망을 이용한 DC 모터의 제어," 대한전기학 회, 하계학술대회 논문집(A), pp. 239-241, 1992

 著者紹介



朴 晋 玄(準會員)

1967年 3月 2日生, 1992年 부산대학교 전기공학과 졸업(공학사). 1994年 부산대학교 대학원 전기공학과 졸업(공학석사). 현재 부산대학교 대학원 전기공학과 박사과정



崔 榮 奎(正會員)

1957年 6月 18日生, 1980年 서울대학교 전기공학과 졸업(공학사). 1982年 한국과학기술원 전기 및 전자공학과 졸업(공학석사). 1987年 한국과학기술원 전기 및 전자공학과 졸업(공학박사). 현재 부산대학교

교 전기공학과 부교수