

## PID 학습제어기를 이용한 가변부하 직류서보전동기의 실시간 제어

정인석\* 홍성우 김낙교 남문현  
건국대학교 공과대학 전기공학과

### Real-Time Control of Variable Load DC Servo Motor Using PID-Learning Controller

In-Suk Chung\* Sung-Woo Hong Lark-Kyo Kim Moon-Hyun Nam  
Department of Electrical Engineering, Kon-Kuk University

#### Abstract

This paper deals with speed control of DC-servo motor using a Back-Propagation(BP) Learning Algorism and a PID controller. Conventionally in the industrial control, PID controller has been used. But the PID controller produced suitable parameter of each system and also variable of PID controller should be changed enviroment,disturbance,load.

So this paper revealed for experimental, a neural network and a PID controller combined system using developed speed characters of a Variable Load DC-servo motor. The parameters of the plant are determined by neural network perform on on-line system after training the neural network on off-line system.

#### 1. 서 론

PID제어기는 제어의 간편성 및 안정성 때문에 현재 산업 현장에서 가장 많이 쓰이는 제어기 중 하나이다. 그러나 PID제어기가 원하는 출력을 얻기 위해서는 시스템의 매개변수를 정확히 산출해야 한다. 또한 부하의 변동이 자주 발생하는 경우에는 그때마다 PID제어기의 변수들을 다시 조정해야하는 어려움이 생긴다. 이를 개선하기 위해 Lyapunov의 안정도이론을 이용한 제어기 설계, 기준모델 적응제어방법(MRAC), 자기동조 제어기(Self tuning controller)등과 같은 적응제어 기법이 도입되었으나 이러한 기법들은 시스템의 차수가 높아지거나, 매개변수의 수가 증가하면, 제어대상의 수학적 계산이 복잡해지며 시스템 모델에 대한 정확한 정보가 필요하여 실시간으로 제어하기가 힘들어진다는 단점이 있다.[1]

최근에는 이러한 문제를 해결하기 위하여 신경회로망을 이용한 제어기설계에 대한 연구가 활발히 진행되고 있다. 신경회로망은 학습능력을 가지고 있으므로 환경변화에 적응할 수 있고, 학습의 효과에 따라 성능개선 효과를 얻을 수 있다. 또한 입출력 데이터만으로도 입출력의 함수관계를 추정 할 수 있으므로 제어대상의 수학적 모델링이 거의 필요 없다.

이러한 신경망의 장점을 활용하여 Kawato는 PD제어기와 신경회로망을 병렬로 연결한 제어기를 제안했다. 이는 기존의 PID제어기에 적응능력과 학습능력을 부여한 것으로 시스템 모델이나 파라미터의 불확실성 및 부하외란의 변화에도 적절히 대처하여 PID제어기에 강인성을 증대시키려는 기법이라 할 수 있다.[2]

본 연구에서의 목적은 신경회로망 중 Rumelhart와 McCleland등에 의해 제안된 오차 역전달학습알고리즘(Backpropagation-Learning Algorithm)을 이용하여 시스템에 대한 정확한 정보 없이도 부하 변화에 대한 시스템의 출력응답을 얻어 PID제어수를 실시간으로 조정할 수 있는 PID-학습제어기를 구현하는 것이다.

#### 2. 본 론

##### 2.1 신경 회로망의 구성

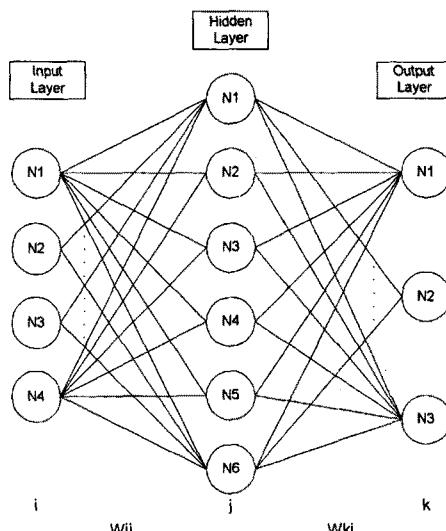


그림 1. 신경 회로망의 구성

본 연구에서 제안된 신경 회로망은 입력층(input layer) 4개, 은닉층(hidden layer) 6개, 출력층(output layer) 3개의 뉴런으로 구성된다. 4개의 입력층은 각각 위치 지령치, 출력값, 전단계의 출력값, PID제어기의 제

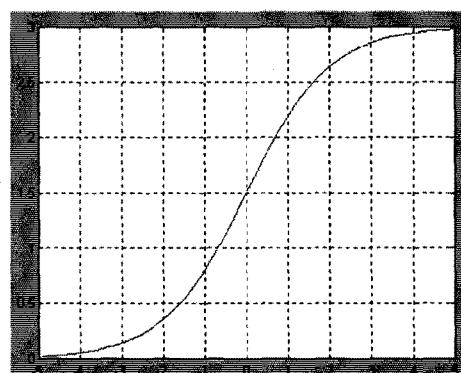


그림2 시그모이드 함수 ( $f(x) = \frac{3}{1 + \exp(-x)}$ )

어 입력값을 나타낸다.

출력층은 PID계수인  $K_p, K_I, K_D$ 에 해당하는 세 개의 뉴런으로 구성된다. 이때  $W_{ji}, W_{kj}$ 는 각각 은닉층에서 입력층으로의 가중치, 출력층에서 은닉층으로의 가중치를 나타낸다. 신경망의 학습은 모멘텀 항을 갖는 역전달 학습법(Backpropagation-Learning)이며 중간층과 출력층에는 시그모이드 함수가 사용된다.

## 2.2 PID제어기와 이득조절을 위한 역전달학습 알고리즘

### 2.2.1 PID제어기

연속시간에서의 PID제어기는 식 2.1과 같다.

$$U(t) = K \left\{ e(t) + \frac{1}{T_I} \int e(t) dt + T_D \cdot \frac{de(t)}{dt} \right\} \quad (2.1)$$

이 식을 샘플링 주기  $T$ 로 이산화(discrete)하면 식 2.2와 같다.

$$U(n) = K \left\{ e(n) + \sum_{m=0}^{n-1} \frac{T}{T_I} e(m) + \frac{T_D}{T} (e(n) - e(n-1)) \right\} \quad (2.2)$$

이때  $T_I$ 는 적분시간,  $T_D$ 는 미분시간,  $U(n)$ 은 이산시간 n시점에서의 제어 입력이고 적분은 합으로, 미분은 1계의 퇴행차분으로 근사화 하였다. 이때  $K_p, K_I, K_D$ 는 PID 제어기의 비례, 적분, 미분의 파라미터를 나타낸다.

식 2.2로부터 이산시간 PID제어기에서 1샘플링 주기의 변화분인 제어기 출력값은 식 (2.3)으로 나타낼 수 있다.[3]

$$\Delta u(n) = u(n-1) + K_p(e(n) - e(n-1)) + K_I e(n) + K_D(e(n) - 2e(n-1) + e(n-2)) \quad (2.3)$$

### 2.2.2 오차 역전달학습 알고리즘

(Backpropagation-Learning Algorithm)

Rumelhart 등에 의해 개발된 BP모델은 다층, 전향 적용 신경회로망으로 처리단자간의 연결강도를 gradient descent 방법에 의해 반복적으로 결정함으로서 학습된다. 학습은 먼저 신경회로망의 초기화를 위해 각 연결강도 값을 임의의 작은 값으로 설정한다.

입력패턴  $i$ 가 신경회로망에 입력되어 전향전달(forward propagation)되면 각 단자의 활성값은 식 2.4과 같이 미분가능, 비감소 활성함수 의해 결정된다.

$$f(\text{net}_{pj}) = \frac{3}{(1 + \exp(-\text{net}_{pj}))} \quad (2.5)$$

$$\text{net}_{pj} = \sum W_{ij} a_{pi} \quad (2.6)$$

이때  $a_{pi}$ 는 패턴  $p$ 에 의한  $i$ 의 활성값,  $W_{ij}$ 는 단자  $i$ 와 단자  $j$ 간의 가중치이고, 식(2.5)에 의한 신경회로망의 실제출력과 각 입력패턴에 대응되는 출력패턴과의 오차는 다음 식에 의해 결정된다.

$$\text{출력단자: } \delta_{pj} = f'(\text{net}_{pj})(t_{pj} - O_{pj}) \quad (2.7)$$

$$\text{중간단자: } \delta_{pj} = f'(\text{net}_{pj}) \sum \delta_{pk} W_{kj} \quad (2.8)$$

$$f'(\text{net}_{pj}) = O_{pj}(1 - O_{pj}) \quad (2.9)$$

$t_{pj}$ 는 출력패턴이다. 식 2.8과 식 2.9에 의해 구해진 오차는 다음규칙에 의해서 학습된다.

$$W_{ij} = W_{ij} + \Delta W_{ij} \quad (2.8)$$

$$\Delta W_{ij} = \eta \delta_{pj} \cdot O_{pj} + \alpha \Delta W_{ij} \quad (2.9)$$

여기서,  $\eta$ 는 학습률로  $0 < \eta < 1$ ,  $\alpha$ 는 모멘텀 계수로  $0 < \alpha < 1$ 이다.[4]

## 2.3 PID 학습제어기 구조

PID-학습제어기의 구조는 다음과 같다. 초기에 신경회로망(BP Neural)은 PID제어기의 초기의 이득값을 얻기 위해 off-line으로 학습을 하게된다. 이때 입력층 각 뉴런에는 기준신호의 지령값과 플랜트 초기 출력값( $y=0$ )이 초기 PID 제어 입력값( $u=0$ ), 전단계 출력값( $y=0$ )이 입력되며 출력값인 각각의 PID 이득값을 얻기 위해 역전달 학습알고리즘에 의하여 은닉층과 출력층 사이의 가중치와 출력층과 은닉층 사이의 가중치가 조절되게 된다.

학습이 끝나면 Motor(plant)를 구동시켜 부하변화에 따른 출력과 PID제어기의 출력 등에 따라 신경회로망(BP Neural)의 가중치가 변화하게 된다. 따라서 이 가중치 변화에 따라 PID 이득값이 변하게되어 on-line 학습이 가능하며 또한 부하변화에 따른 Motor(plant)의 실시간 제어가 가능하게 된다.

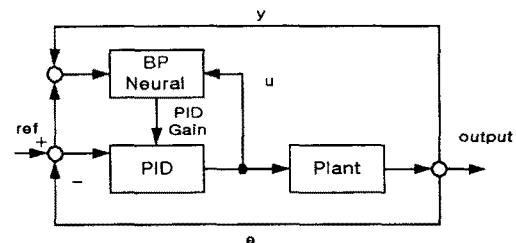


그림 3 PID-학습제어기의 구조

## 2.4 실험장치 구성

본 연구에서 실험은 IBM 컴퓨터의 프린터 포트에 연결된 DC-Servo Motor를 사용하여 속도제어실험을 하였다.

실험은 PID제어기와 PID-Learning 제어기로 정역회전실험을 수행하여 기준신호(ref)에의 추종성능을 비교하였다. 또한 Generator을 연결한 Motor에 PID제어기와 PID-Learning 제어기로 정속운전 실험을 하며 Generator에 연결된 부하를 변화시켜 기준신호에 추종하는 성능을 관찰하고자 하였다.

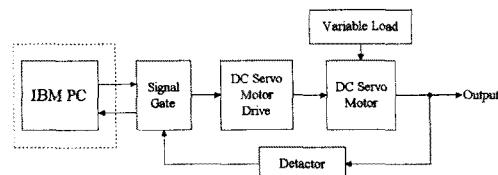


그림 4 실험장치 구성도

### 3. 실험 결과 및 결 론

#### 3.1 무부하 PID 제어기와 PID-학습제어기 실험

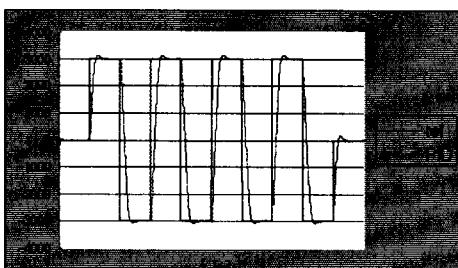


그림5 PID 제어기

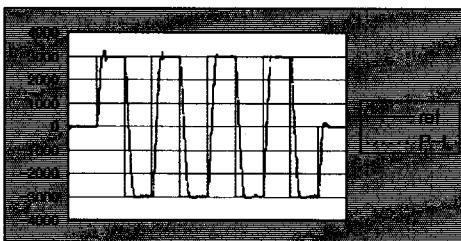


그림6 PID-학습제어기

#### 3.2 가변부하시 PID제어기와 PID-학습제어기 실험

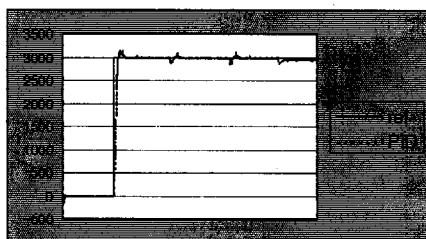


그림7. 가변부하 PID 제어기

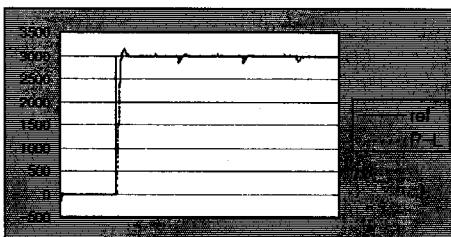


그림8. 가변부하 PID-학습제어기

#### 3.3 결 론

실험 3.1의 결과는 무부하시 PID제어기와 PID학습제어기의 정역회전을 실험한것으로 그림상에서 PID제어기는 오버슈트가 거의 일정하게 계속되나 PID-학습제어기에서는 이러한 오버슈트가 차츰 줄어들을 알 수 있다. 실험 3.2의 가변부하는 Motor 축에 Generator을 연결하고 이 Generator에는 전구를 연결하여 시간에 따라 3개의 전구를 순차적으로 점등하는 부하를 사용하여 실험하였다.

실험 결과 오버슈트후에 부하수에 따라 추종하는 성능이 떨어지는 PID제어기와는 달리 PID-학습제어기는 더 좋은 성능을 보여줌을 알 수 있었다..

향후 연구로는 지금까지 무부하와 선형가변부하에만 PID-학습 제어기를 적용해 봤으나 그외의 비선형 가변부하에서도 이 제어기를 적용해 봄으로써 기존의 PID제어기보다 훨씬 더 뛰어난 성능을 가짐을 보이고자 한다.

#### (참 고 문 헌)

- [1] 박귀태, 이기상, 김성호, 박태홍 “페턴인식에 의한 새로운 자동조정 PI제어기”, 전기학회 논문지, 40권, 7호, pp.696-697. 1991년
- [2] M.Kawato, Y. Uno, M.Isope, and R.Suzuki. "Hierarchical Neural Networks Model for Voluntary Movement with Application to Robotics," IEEE Control System Maga., pp. 8-16, 1988
- [3] 임영도, 이상부 “퍼지, 신경망, 유전진화” pp.107-169, 영과일 1997
- [4] 김대수 “신경망 이론과 응용”, pp. 91-143. 하이테크정보 1993
- [5] Maureen Caudill and Charles Butler " Understanding Neural Networks " pp. 169-218. 1992. Massachusetts Institute of Technology