

단층 GMDP를 이용한 자기동조 PID 제어기의 구성

正會員 薛在勛*, 秋淵圭*, 林永道*

Implementation of self-Tuning PID Controller using Single layered GMDP

Jae Hoon Sul*, Yeon Gyu Choo*, Young Do Lim* Regular Members

要 約

적용제어 이론 또는 PID 제어기의 파라미터 동조는 다양한 시스템에서 응용되어왔다. 그러나 본 논문에서는 신경망의 비선형 매핑능력을 이용하여 역전파 단층 GMDP 신경망 알고리즘을 바탕으로 실시간 자기동조 PID 제어기의 동조 방법을 제안하였다. 기존의 다층 퍼셉트론이 복잡 다양한 시스템의 제어에 강력하게 응용 되어왔다. 그들 회로구조의 다층화와 복잡성 그리고 학습 알고리즘에 있어서의 루프시간이 실제적인 문제를 일으킨다. 따라서 이러한 결점을 보완할 수 있는 단층의 일반화된 다중 수상돌기 적(GMDP : Generalized Multi-Dendrite Product) 유니트라 불리는 신경망 모델로 PID제어기의 파라미터를 자기동조하여 모터의 속도제어에 대한 실시간 처리를 실시하여 기존의 다층 퍼셉트론(MLP : Multilayered Perceptron)를 사용했을 때와 성능을 비교 평가하였다. 학습규칙은 기존의 역전파 학습방법이 GMDP 신경회로망에 적용되어졌다.

ABSTRACT

Adaptive control theory or parameter tuning of PID controller is applied in various systems. But in this paper, using a nonlinear mapping capability of NNs, we derive a real time tuning method of PID controller based on a Back-Propagation method of single layered GMDP NN's algorithm. Multilayered Perceptrons are known to applicatively powerful for complex system controls. But the uniformity in their network structures, learning algorithms and loop time creates practical problems. Thus this paper evaluates the capability between MLP(Multilayered Perceptron) and GMDP(Generalized Multi-Dendrite Product) for performing real time velocity control. Backpropagation is applied to the GMDP as learning method.

*東亞大學校 電子工學科

Dept. of Electronics Engineering, Dong-A Univ.

論文番號 : 95075-0220

接受日字 : 1995年 2月 20日

I. 서 론

최근 몇년동안, 다층 퍼셉트론은 응용의 수월함, 풀이 의 일반화 그리고 문제크기에 대한 제한을 두지 않는다는 것과 같은 현저한 형태적인 덕택으로 다양한 응용분야에 성공적으로 적용되어 왔었다. 그러나, 복잡한 비선형 문제의 경우 다층 퍼셉트론은 실질적인 문제점이 나타났다. 예를들어 많은 유니트가 요구되었으며 그리고 학습속도 또한 상당히 느려졌다. 이것은 부분적으로 기본적인 함수, 즉 직접 연결된 두개의 뉴런들 사이가 선형적으로 연결되었다는 데 기인된다. 반면에 비선형 시냅스 연결을 갖는 단층 교차 신경회로망은 이러한 문제점을 완화시킬 수 있다는 것으로 알려졌다.²⁾ 이러한 접근의 유형들은 sigma-pi 유니트, 적(product) 유니트, 함수적 연결 회로망 그리고 pi-sigma 회로망이 있다. 그들의 주된 관심은 중간층(hidden layer)을 없애므로 학습과정 속도를 향상시킬 수 있다는 가정에 바탕을 두었다. 그러나 각각의 신경모델은 효과적인 학습알고리즘의 복잡해짐과 회로구조에 있어서의 불일치성으로 인한 난해한 점이 있다. 결과적으로 다층 순방향 신경망과 같은 다양한 모델들을 단순한 구조 체제하에서 통일화하는 것이 요구되었다. 최근 Chen과 Bastani는 다층 수상돌기 회로망이라는 다층 순방향 신경망중에서 더 일반화된 모델을 제안했다.³⁾ 이 모델은 계산적 이론의 바탕에서 더 강력하고 더 효율적인 접근을 발견하려는 기존에 언급된 모델들과는 달리 생물학적인 면을 강조하여 수상돌기 각각이 국부적인 활성화를 갖고 전체 활성화에 기여하는 다중 수상돌기를 사용하는 것을 주된 내용으로 담고 있다. 이 모델은 고전적인 합 유니트의 벡터적인 시냅스 연결이 필요하고 곱을 이용하는 활성화 함수로서 가장 간단한 비선형 형태인 다중 활성화 적(MAP : Multi Activation Product) 유니트로 확대한다. Chen과 Bastani는 이 신경망 부류가 매핑함수로서 사용될 때 sigma-pi 회로망과 같다는 것을 증명했다.¹³⁾

본 논문에서는 고전적인 PID 제어기에 GMDP 신경회로망 알고리즘을 적용시켜 효율적인 시스템 제어를 하고자 하였다. PID 제어기는 시스템 제어영역에 있어서 고전적인 적응 알고리즘으로 강인함을 요구하고 동작 범위가 넓은 경우 효율적이며 부분적으로는 함수의 간결성으로 인하여 시스템 응용에 있어서 우의를 차지하고 있

다.

PID제어기의 형태는 오차 $e(n)=r(n)-y(n)$ 를 갖는 페루프 시스템으로 구성되며 PID 제어기는 비례제어기, 적분제어기, 미분제어기 세부분으로 나뉘어진다. PID 제어기에서 파라미터 결정방법은 시스템의 요구되는 출력에 대하여 적절한 시스템 입력을 얻기위해 PID 제어기에 있어서 최적의 파라미터 변수를 선택해야 한다. 기존에는 시스템 엔지니어들이 시스템을 동작시키기 위해 수동적으로 PID 제어기를 동조시켰다. 자기동조가 규칙성을 제공한 후 시스템 제어 문제에 있어서 상당한 가능성을 보였고 불확실성, 비선형성 그리고 시변 파라미터들을 다룸에 있어서 비교적 융통성 있는 접근방법을 보여 주었다. 드디어 이러한 흥미로운 사항이 신경망을 이용한 자기동조 제어기의 설계에 주목하게 되었다.¹¹⁾ 따라서 본 논문에서는 자기동조 PID 제어기의 파라미터들을 GMDP 신경회로망 알고리즘으로 제어시킴으로 기존의 다층 퍼셉트론에 의한 제어결과와 비교 분석하고자 한다.

II. PID 제어기

PID 제어기는 세계의 다른 제어기들(비례, 적분, 미분제어기)로 구성된다. 여기서 각각의 제어기들은 다른 동작을 제공한다. 각각의 기능을 살펴보면 다음과 같다.

P(비례) 제어기 : 시스템 출력이 설정값에 빨리 도달하도록 제어기 입력을 만들어 낸다. 그러나 이때 제어기 입력의 포화에 기인하는 상수 오프셋을 발생시킨다.

I(적분) 제어기 : 위의 상수 오프셋을 극복하도록 하는 역할을 한다.

D(미분) 제어기 : 시스템 출력이 설정값에 도달하는 동안 시스템 출력의 진동을 감소시키는 역할을 한다.

위의 각 제어기들은 식(1)에서의 각 제어파라미터 K_p , K_I , K_D 로 역할을 분담하여 실행된다.

이산시간 제어시스템에 있어서의 속도형 디지털 PID 알고리즘은 식(1)과 같다.⁶⁾

$$\begin{aligned}
 u(n) = & u(n-1) \\
 & + K_p(e(n) - e(n-1)) \\
 & + K_I e(n) \\
 & + K(e(n) - 2e(n-1) + e(n-2))
 \end{aligned} \quad (1)$$

여기서, $u(n)$ 은 이산시간 n 에서의 제어입력, K_P , K_I , K_D 는 PID제어기의 비례, 적분, 미분 파라미터이다.

식(1)에 $e(n) = r(n) - y(n)$ 을 대입하고 Z변환 하면 식(2)인 속도형 PID제어기 구성으로 나타낼 수 있다.

$$U(z) = -K_P Y(z) + K_I \frac{R(z) - Y(z)}{1 - z^{-1}} - K_D(1 - z^{-1}) Y(z) \quad (2)$$

이산시간 속도형 제어 시스템에서 디지털 PID제어기 블록도는 그림1과 같다.⁽⁶⁾

PID 제어기는 아날로그 시스템에 있어서, 스텝 응답 데이터에 바탕을 둔 PID 제어기의 파라미터들을 결정하는 간단한 방법들이 Ziegler와 Nichols에 의해 발전되어 있었다. Ziegler-Nichols 동조규칙은 다른 많은 시스템을 모의실험 해봄으로써 경험적으로 발전되어 왔다.⁽¹⁾ 이산시간 시스템에 있어서 Takahashi는 Ziegler-Nichols 방법에 바탕을 둔 특별한 방법을 소개했다. 그러나 Ziegler-Nichols 동조규칙은 폐루프 시스템에 너무나 약하게 영향을 준다는 결점을 가지고 있다. 어떠한 시스템에서도 정교한 제어 수행을 얻기 위해서는 PID 제어기의 다양한 파라미터들이 시도되어야 하고 수동적으로 동조 되어야 한다. 이러한 수동적인 동조방법은 적절한 제어기 파라미터를 얻기 위해 시행착오

로 인한 시간 소요가 많으므로 효과적이지 못한 결점이 있다. 이에 자기동조 제어방법이 나타나기 시작했다. 자기동조 제어기의 큰 장점으로는 시스템을 효율적으로 제어하기 위해 적절한 제어기 파라미터를 추정할 수 있다.⁽⁷⁾ 그림 2는 자기동조 제어기의 블록도를 나타내고 있다.

Ⅲ. 다층 퍼셉트론 (Multilayered Perceptron)의 개요

다층 퍼셉트론은 비선형 프로세싱 요소(뉴우런)들로 이루어진 입력층, 출력층 그리고 적어도 하나의 중간층으로 구성된 다층 신경회로망이다.⁽⁸⁾ 학습 알고리즘은 역전파 (Backpropagation)방식을 사용하였다. 그림 3은 다

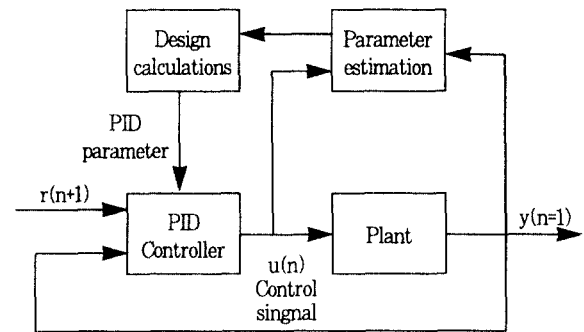


그림 2. 자기동조 제어기의 블록도.
Fig. 2. Block diagram of a self-tuning Controller(STC).




그림 1. 속도형제어 PID제어기 블록도.
Fig. 1. Block diagram realization of the velocity form digital PID control scheme.




그림 3. 다층 퍼셉트론 신경모델.
Fig. 3. The structure of multilayered perceptron.

층 퍼셉트론의 내부구조를 나타내었다.

다층 퍼셉트론 구조에 있어서 입출력 뉴런들 사이의 관계는 식(3), (4)와 같다.

$$net_k = \sum w_{kj} out_j \tag{3}$$

$$out_k = f(net_k) \tag{4}$$

여기서, net_k 는 출력층 뉴우런으로의 모든 입력.

out_k 는 출력층 뉴우런의 출력.

w_{kj} 는 중간층과 출력층 사이의 가중치.

$f(\cdot)$ 는 뉴우런의 활성화 함수.

역전파 알고리즘에서 평가함수를 최소화 하기 위해 식 (5)와 같이 나타낼 수 있다.

$$J = \frac{1}{2} \sum_k (tr_k - out_k)^2 \tag{5}$$

여기서, tr_k 는 설정치.

out_k 는 출력층 뉴우런의 출력치.

가중치 수정을 위한 가중치 증분 계산은 식(6)와 같다.

$$\Delta w_{kj}(n) = -\eta \frac{\partial J}{\partial w_{kj}} + \alpha \Delta w_{kj}(n-1) \tag{6}$$

여기서, η 는 학습율.

α 는 모멘트 계수.

식(6)에서 $\frac{\partial J}{\partial w_{kj}}$ 항은 식(7)과 같이 연쇄법칙(Chain rule)을 이용하여 풀어질 수 있다.

$$\frac{\partial J}{\partial w_{kj}} = \frac{\partial J}{\partial out_k} \frac{\partial out_k}{\partial net_k} \frac{\partial net_k}{\partial w_{kj}} \tag{7}$$

IV. GMDP(Generalized multi-dendrite product)의 개요

다중 수상돌기 신경모델은 생물학적인 고려에서 시작 된다. 뉴우런에서 받아들여지는 영역, 즉 수상돌기 나무가 전기적 분산시스템이라는 것이 이미 알려졌다. 이런 결과로 일반화된 다중 수상돌기 적(GMDP : Generalized multi-dendrite product) 유니트가 다중 수상돌기를 가지고 있어서 활성화 규칙이 수상돌기들 사이에서 분산화 될 수 있다. 각각의 수상돌기는 같은

수의 시냅스 입력들을 받아 들인다. 그리고 각각의 축색 돌기(axon)연결도 또한 다중 가치를 가질 수 있다. 그림 4는 GMDP 신경모델의 구조를 나타낸다.⁽³⁾

출력함수는 활성화 함수 g 와 비활성화 함수 p 의 조합으로 일반화 된다. 그림 4에서 시냅스 가중치 $w_j^{(k)}$ 는 j 번째 뉴런의 축색돌기에서 j 번째 뉴런의 k 번째 수상돌기와 연결된 가중치이다. 각각의 수상돌기는 국부적인 비활성화 값을 발생하는 비활성화 함수 p_k 를 가진다. 여기서 합함수 Σ 는 모든 수상돌기에서 국부적인 비활성화 함수로써 사용된다. j 번째 뉴런의 k 번째 수상돌기에 있어서 국부적인 비활성화 값은 식(8)과 같다.

$$net_j^{(k)} = \sum_i w_i^{(k)} x_i \quad (8)$$

여기서, x_i 는 i 번째 뉴런의 출력.

부가적으로, 각각의 수상돌기는 base 함수로 불리는 국부적인 활성화 함수 f_k 를 가진다. 개개의 신경세포에서의 계산하는 능력에 있어서 우리는 단일 GMDP 유닛을 독립적인 수상돌기가 각각 국부적인 활성화를 갖고 전체 활성화에 기여하는 하나의 회로망으로 스스로 기능하도록 할 수 있다.⁽³⁾⁽⁴⁾ 따라서 GMDP 유닛은 병렬로써 정보를 처리할 수 있다. 하나의 뉴우런은 뉴우런 활성화를 생성하는 시냅스 연결들로부터 모든 입력의 출력함수 F 에 의해 표현된다. 비선형 시냅스 연결이 뉴우런으로 하여금 입력 활성화로부터 더 많은 흥미로운 정

보를 이끌어 내는 것으로 잘 알려져 있다. 그러므로 단순한 비선형 함수인 곱(Π)이 GMDP 유닛의 비활성화 함수로서 사용된다. 적합한 활성화 함수 선택이 신경망의 능력에 직접적으로 관계되는 것으로 중요하다. 학습규칙으로는 델타규칙이 이 신경모델에 직접적으로 적용될 수 있다. 역전파는 다층 순방향 신경망에 있어서 가장 성공적인 학습방법이다. GMDP 신경모델을 위해 이 학습 형태의 확장이 유도된다.

base 함수와 활성화 함수는 둘다 연속적이고 전영역에서 미분가능하며 그리고 입력패턴과 원하는 출력을 구성하는 패턴 p 는 회로에 적용되어 진다고 가정하자. 여기서 t_j 는 출력층의 j 번째 유닛에서의 원하는 출력이다. 그리고 o_j 는 중간층 또는 출력층의 j 번째 유닛에서의 실제 출력을 나타낸다. 이 때 o_j 는 식(9)와 같이 구해진다.

$$o_j = F_j(net_j) = g_j \left(\prod_{k=1}^n f_k(net_j^{(k)}) \right) \quad (9)$$

여기서, 함수 F_j 는 j 번째 GMDP 유닛의 활성화 함수 g 와 비활성화 함수 Π 의 조합이다. 그리고 $net_j^{(k)}$ 는 j 번째 유닛의 k 번째 수상돌기의 국부 비활성화 net 값이다.

학습규칙은 t_j 와 o_j 사이에서의 최소자승오차식에 바탕을 둔다. 식(10)과 같다.

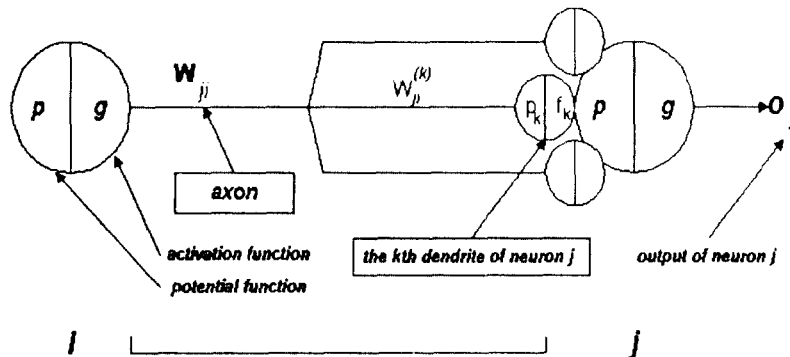


그림 4. GMDP 신경모델.
Fig. 4. The generalized multi-dendrite product(GMDP) neuron model.

$$E = \frac{1}{2} \sum_j (t_j - o_j)^2 \tag{10}$$

오차를 최소로 하기 위하여는 식(11)과 같이 가중치를 음의 gradient 방향으로 수정되도록 해야한다.

$$\Delta w_{ij}^{(k)} = -\eta \frac{\partial E_j}{\partial w_{ij}^{(k)}} \tag{11}$$

여기서, $w_{ij}^{(k)}$ 는 i 번째 유니트에서 j 번째 유니트의 가중치 벡터중 k 번째 요소이다. η 는 음의 gradient 하강법에 따르는 학습율이다.

델타규칙에 따라, 식(11)은 식(12)로 표현될 수 있다.

$$\Delta w_{ij}^{(k)} = \eta \delta_j^{(k)} o_i \tag{12}$$

여기서, $\delta_j^{(k)}$ 는 j 번째 유니트가 있는 층에 의존한다. 오차항은 출력층의 경우 식(13)과 같이 구해진다.

$$\delta_n^{(k)} = (t_n - o_n) g'_j \left(\prod_k f_j(\text{net}_n^{(k)}) \right) \times f'_j(\text{net}_n^{(k)}) \prod_k f'_j(\text{net}_n^{(k)}) \tag{13}$$

V. 신경망을 이용한 적응 자기동조 제어기

다양한 신경망을 이용한 자기동조 제어방법들이 몇몇 제어시스템의 파라미터값들을 조정하기 위하여 효과적

인, 강인한 그리고 최적의 방법을 얻기 위해 제안되어져 왔다.^[1] 제안된 학습방법은 PID 파라미터를 적절하게 취하는 적응제어 시스템에 바탕을 두고, 다층 퍼셉트론과 단층 GMDP 신경망 모델로 파라미터를 수정하도록 한다. 기본적인 개념은 PID 제어기의 파라미터를 조정하기 위한 신경망 모델의 학습신호인 오차신호($e(n) = r(n) - y(n)$)를 어떻게 이용할 것인가에 있다.

신경망을 이용한 자기동조 PID제어기의 구조는 그림 5와 같다. 파라미터 수정을 위한 신경망과 제어기의 연결은 $\frac{\partial J}{\partial w}$ 가 연쇄법칙에 의해 설명될 수 있을 때 신경망의 가중치들은 역전파된 학습신호에 의해 수정될 수 있다. 연쇄법칙을 이용하여 가중치를 수정할 수 있다는 이러한 특별한 특성이 신경망 알고리즘과 다른 제어 알고리즘을 결합하는데 확장될 수 있다. 더 구체적으로 표현하자면 여기에 제안된 방법은 범용적인 PID 제어기의 파라미터값들을 조정하도록 적용된다. 평가함수는 식(5)로부터 식(14)로 다시 표현될 수 있다.

$$J = \frac{1}{2} (r(n+1) - y(n+1))^2 \tag{14}$$

1. PID 제어기 파라미터 수정을 위한 다층 퍼셉트론 신경모델의 구조와 알고리즘

다층 퍼셉트론 신경모델의 구조

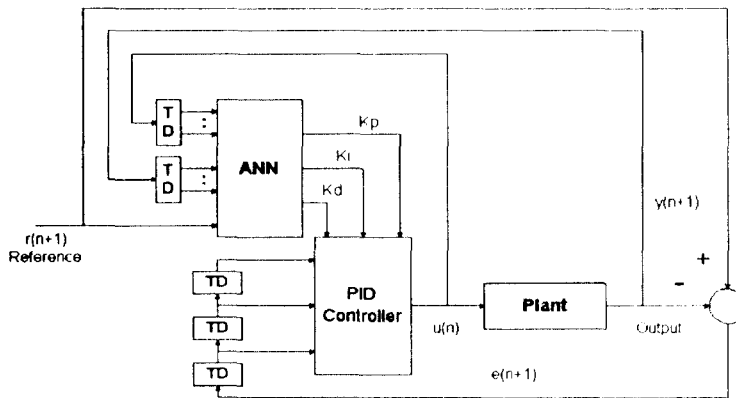


그림 5. 신경망을 이용한 자기동조 PID제어기의 구조.
Fig. 5. The learning scheme of the neuromorphic self-tuning PID controller.

K_p, K_i, K_d 를 적응적으로 조정하기 위하여 입력, 중간 그리고 출력층에 N_1, N_2, N_3 뉴우런을 갖는 그림 6과 같은 구조를 이용한다.⁽¹¹⁾ 입력과 출력층에 있어서 뉴우런 활성화 함수를 선형함수로 선택하고 중간층의 뉴우런 활성화 함수를 Sigmoid 함수로 선택한다.

입력층과 중간층의 유니트인 N_1 과 N_2 의 개수는 시스템의 복잡성에 따라서 융통성 있게 조정될 수 있고, N_3 는 PID 파라미터 수인 3개로 고정된다. 따라서 신경망의 출력인 out_0, out_1, out_2 를 각각 K_p, K_i, K_d 로 가정해야 한다.

다층 퍼셉트론 신경모델의 알고리즘

- ① 가중치를 먼저 0과 1 사이의 임의의 값으로 초기화 한다.
- ② 가중치를 수정한다.

$$\Delta w_{kj}(n) = \eta \delta_k out_j + a \Delta w_{kj}(n-1)$$




그림 7. 다층 퍼셉트론 신경모델의 역전파학습도.
Fig. 7. The backpropagation flowchart of MLP neuron model.




그림 6. PID 제어기 파라미터 수정을 위한 다층 퍼셉트론 신경모델의 구조.
Fig. 6. The structure of the MLP neuron model for updating the parameter of the PID controller.

$$\delta_k = e(n+1) \operatorname{sign} \left(\frac{\partial y(n+1)}{\partial u(n)} \right) \times \frac{\partial u(n)}{\partial \text{out}_k} f'(net_k)$$

$$w_{kj}(n) = w_{kj}(n-1) + \Delta w_{kj}(n)$$

$$\Delta w_{kj}(n) = \eta \delta_j \text{out}_i + \alpha \Delta w_{kj}(n-1)$$

$$\delta_j = f'(net_j) \sum_k \delta_k w_{kj}$$

$$w_{ij}(n) = w_{ij}(n-1) + \Delta w_{ij}(n)$$

여기서, $\left| \frac{\partial y(n+1)}{\partial u(n)} \right|$ 는 학습율 η 에 포함된다.

③ $\sum \frac{1}{2} e(n+1)^2 > \epsilon$ 이면 ①로 반복 수행.

2. PID 제어기 파라미터 수정을 위한 GMDP 신경모델의 구조와 알고리즘

GMDP 신경모델의 구조

GMDP는 입력층과 출력층으로 그림 8과 같은 단층 구조로써 출력층 뉴런인 활성화 함수를 선형함수로 선택하고 수상돌기의 활성화 함수도 선형함수로 선택한다. 수상돌기의 수는 시스템의 복잡성에 따라서 융통성 있게 고정될 수 있고, 다층 퍼셉트론과 마찬가지로 출력층 뉴

런 유닛의 갯수는 PID 파라미터 수인 3개로 고정되며 신경망의 출력인 out_0, out_1, out_2 를 각각 K_p, K_I, K_D 로 될것이다.

GMDP 신경모델의 알고리즘

- ① 가중치를 먼저 0과 1 사이의 임의의 값으로 초기화한다.
- ② 가중치를 수정한다.




그림 9. GMDP 신경모델의 역전파학습도.
Fig. 9. The backpropagation of GMDP neuron model.




그림 8. PID 제어기 파라미터 수정을 위한 GMDP 신경 모델의 구조.
Fig. 8. The structure of the GMDP neuron model for updating the parameter of the PID controller.

$$\Delta w_j^{(k)}(n) = \eta \delta_j^{(k)} out_i + \alpha \Delta w_j^{(k)}(n-1)$$

$$\delta_n^{(k)} = e(n+1) \text{sign} \left(\frac{\partial y(n+1)}{\partial u(n)} \right) \frac{\partial u(n)}{\partial out_i} \times g_i' \left(\prod_{k=1}^n f_i(net_n^{(k)}) \right) f_i'(net_n^{(k)}) \prod_{k=1}^n f_i'(net_n^{(k)})$$

$$w_j(n) = w_j(n-1) + \Delta w_j(n)$$

여기서, $\left| \frac{\partial y(n+1)}{\partial u(n)} \right|$ 는 학습을 η 에 포함된다.

③ $\sum \frac{1}{2} e(n+1)^2 > \epsilon$ 이면 ①로 반복 수행.

Ⅵ. 실험

앞에서 MLP와 GMDP의 차이점과 각각의 알고리즘을 분석해 보았다. 이러한 기본적인 개념을 가지고서 실시간 처리 실험을 해봄으로써 더 명확한 사실을 알아내고자 한다.

실험을 위한 시스템 구조는 그림 10과 같다. 제어기와 제어기 파라미터를 조정하는데 필요한 신경망은 PC-586에서 C 프로그램으로 구성하고 모터의 구동회로는 정역이 가능하도록 power OP 앰프(APEX PA21)를 사용하고, A/D와 D/A 컨버터로는 ACL-711B I/O 보드를 사용하였다. 실험에 사용된 모터의 사양은 다음 표 1과 같다.

실험에 있어서 학습방법은 MLP와 GMDP의 경우로 나누어 실험하였다. MLP의 내부는 입력층의 유닛트 개수를 5개로 하고 중간층을 10개로 그리고 출력층을 3개

표 1. 모터 사양
Table 1. Motor's features

| 사 양 | | 크 기 |
|--------|-----|----------------|
| 입 력 | 전 압 | 40[V] |
| | 전 류 | 5.3[A] |
| 최대 rpm | | 1200[rpm] |
| TORQUE | | 12.2[Kg·Cm] |
| TG 출력 | | 3[V]/1000[rpm] |

의 유닛트로 구성하였다. 중간층의 활성화 함수는 sigmoid 함수를 택하였고 출력층은 선형함수를 취하였다. 그리고 GMDP는 입력층의 유닛트를 5개로, 출력층 유닛트를 3개로 하여 MLP와 같도록 하였다. 그리고 수상돌기의 수는 3개와 6개로 실험을 실시하였다.

MLP와 GMDP의 성능 평가

첫번째 실험은 GMDP와 MLP의 수렴특성에 관한 실험을 실시하였다. 그림 11은 설정치를 800(rpm)으로 하여 100회 학습시의 MLP와 GMDP의 수렴특성곡선 및 학습 후의 출력파형을 보여준다. 이 실험결과에서는 MLP보다도 GMDP로 구성된 신경모델이 설정치에 더 빨리 수렴함을 알 수 있었다.

두번째 실험은 MLP와 GMDP의 학습패턴시간을 일정하게 하고 각각 설정치를 200, 720, 360(rpm)으로 가변시키면서 실험을 실시하였다. 그림 12는 MLP와

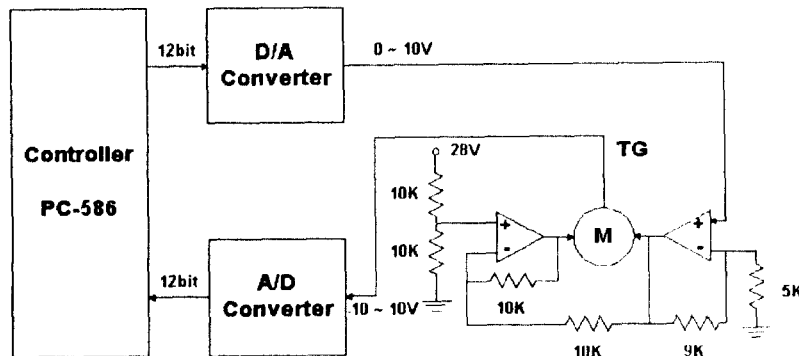





그림 10. 속도제어를 위한 시스템 구조.
Fig. 10. The structure of the system to control the velocity.



(i)



(ii)



(iii)

그림 11 MLP와 GMDP의 학습곡선과 출력파형. (i) 학습곡선 (ii) MLP 출력 (iii) GMDP 출력
 Fig. 11. Learning curves and output of the MLP and GMDP. (i) Learning curves (ii) MLP's output (iii) GMDP's output

GMDP 신경모델을 각각 15회 학습시켰을 때의 출력파형과 PID파라미터를 나타내었다. 표2는 MLP와 GMDP로 구성된 신경모델의 1회 학습패턴시간에 대한 각각의 샘플시간을 나타내었다. 여기서 GMDP의 알고리즘 단순화에 의해 MLP보다도 더 짧은 샘플시간을 얻을 수 있음을 알 수 있었다.

표 2. 샘플링시간 비교

Table 2. Comparison between MLP and GMDP's sampling time.

| 구분 | 학습패턴시간(sec) /1회 | 샘플수(step) /1회 | 샘플시간 [msec] |
|------|--------------------|------------------|----------------|
| MLP | 2.88423 | 6000 | 0.481 |
| GMDP | " | 8880 | 0.325 |



이러한 학습에 대하여 두 신경모델에 외란을 가함으로써 강인함을 조사하였다. 그림 13은 이미 15회 학습된 후의 가중치에 대하여 외란을 가하였을 때의 출력파형을 보여준다. 이때 가해진 외란은 MLP를 이용한 제어기에

서는 출력에 이산시간(nT) 1500 에서 3500 까지 그리고 GMDP를 이용한 제어기에서는 출력에 이산시간(nT) 2220 에서 5180 까지 최대출력의 10%정도로 가하였다.

실험에서 본 결과로는 PID제어기의 파라미터 추정을 위해 GMDP로 구성하였을 경우 MLP와 비슷한 수렴 특성을 가지며 외란에 대하여도 MLP에서 보여준 것과 같은 강인함을 보여주었다. 지금까지 실험을 통해 본 결과로는 GMDP로 제어기 파라미터를 추정하였을 때 루프시간이 짧으므로 더 많은 학습을 함으로써 학습수를 줄일 수 있다는 것을 알 수 있었다.

VII. 결 론

본 논문에서는 PID제어기의 파라미터를 조정하기 위하여 기존의 MLP 신경모델과 새로운 신경모델인 GMDP 신경모델을 제안하였다. 실험결과에서 보았듯이 PID 파라미터 동조를 위하여 다층 MLP 신경모델로



(i)




그림 12. 학습 15회 때의 출력 (i) MLP의 시스템 출력과 PID 계수. (ii) GMDP의 시스템 출력과 PID 계수.
 Fig. 12. The output at 15th iteration. (i) MLP's plant output and PID parameters. (ii) GMDP's plant output and PID parameters.




그림 13. 학습 15회 학습후 외란을 주었을 때의 출력 (i) MLP (ii) GMDP.
 Fig. 13. The output at ensured disturbance at 15th iteration. (i) using MLP (ii) using GMDP.

구현했던 것을 단층 GMDP 신경모델로 구현함으로써 같은 기능을 수행하는 물론이고 단층 신경망으로 인하여 샘플시간을 줄일 수 있다는 장점으로 MLP를 이용한 제어기보다도 GMDP를 이용한 제어기에서 더 많은 학습수를 얻을 수 있어 정밀한 제어를 가능하도록 해준다. 앞으로 다층 신경모델로 구현되었던 것을 보다 효율적으로 학습을 수행하기 위하여 MLP를 응용한 각분야에서 GMDP 신경모델로 적용시켜야 할 것이다. 그리고 범용성에 대한 연구가 계속적으로 연구되어야 할 것이다.

參考文獻

1. Saiful Akhyar and Sigeru Omatu, "Neuromorphic Self-Tuning PID Controller," *IEEE*, vol. 1, pp.552-557, 1993.
2. Yoan Shin and Joydeep Ghosh, "The Pi-sigma Network : An Efficient Higher-Order Neural Network for Pattern Classification and Function Approximation," *proc. IJCNN*, vol. I, pp.13-18, July, 1991.
3. Shengtun Li, Yiwei Chen and Ernst L. leiss, "GMDP : a Novel Unified Neuron Model for Multilayer Feedforward Neural Networks," *proc. ICNN*, Orlando, vol. 1, pp.107-112, 1994.
4. Yiwei Chen and Farokh bastani, "ANN with Two-dendrite Neurons and its Weight Initialization," *proc. IJCNN*, vol. III, pp.139-146, June, 1992.
5. Jacek M. Zurada, "Multilayer Feedforward Networks," *Introduction to Artificial Neural Systems*, West publishing Company, pp.175-206, 1992.
6. Katsuhiko Ogata, "Pulse transfer function of a digital PID controller," *Discrete time control systems*, Prentice-Hall Inc., pp.199-207, 1987.
7. K. J. Astrom and B. Wittenmark, "Adaptive control : Self-Tuning Control," *Computer controlled systems*, Prentice-Hall Inc. pp.438-440, 1990.
8. M. M. Nelson and W. T. Illingworth, "How do Neural Networks Work?," *A practical guide to Neural Nets*, Addison-Wesley Publishing Company, Inc., pp.36-58, March, 1991.

薛在勳(Jae Hoon Sul) 정회원



1968년 8월 24일생
 1994년 2월 : 동아대학교 전자공학과
 1994년 3월~현재 : 동아대학교 대학원 전자공학과 석사과정

※주관심 분야 : 신경망제어, 마이크로프로세서

林永道(Young Do Lim) 정회원



1949년 9월 20일생
 1973년 2월 : 동아대학교 전자공학과 졸업(공학사)
 1978년 2월 : 동아대학교 대학원 전자공학과 졸업(석사)
 1987년 8월 : 동아대학교 대학원 전자공학과 졸업(박사)

1988년 3월~현재 : 동아대학교 전자공학과 부교수

※주관심 분야 : 신경망제어, 퍼지제어, 전력전자, 고주파유도 가열

秋淵圭(Yeon Gyu Choo) 정회원



1962년 1월 22일생
 1987년 2월 : 부산공업대학교 전자공학과 졸업(공학사)
 1990년 2월 : 동아대학교 대학원 전자공학과 졸업(석사)
 1994년 2월 : 동아대학교 대학원 전자공학과 박사과정 수료

※주관심 분야 : 신경망제어, 적응제어