

GMDP 신경망을 이용한 PID 적응 위치 제어기에 관한 연구

A study on the PID adaptive position controller using GMDP Neural Network

주연구, 임영도
동아대학교 전자공학과

요 약

본 논문은 일반화된 다층 수상돌기 적 (GMDP : Generalized Multi Dendrite Product) 유닛트 신경망모델을 이용한 PID 적응 위치제어기를 구성하여 직류 서어보 전동기의 위치제어를 실시간 처리 하였다.

제안한 제어기를 위치제어에 적용시켜 실험한 결과 기존의 MLP 신경망 제어기를 이용한 것 보다도 샘플시간을 줄일 수 있다는 장점으로 정밀한 제어가 가능하다는 것을 확인할 수 있었다. 학습규칙은 기존의 역전파 학습방법이 GMDP 신경회로망에 적용 되었다.

I. 서 론

최근 몇년동안, 다층 퍼셉트론은 여러가지 장점으로 인해 다양한 응용분야에 성공적으로 적용되어 왔었다. 그러나, 복잡한 비선형 문제의 경우 다층 퍼셉트론은 많은 유닛트가 요구되고 학습 속도도 느리다는 실질적인 문제점이 나타났다. 반면에 비선형 시냅스 연결을 갖는 단층 고차 신경회로망은 중간층(hidden layer)을 없애므로 학습과정 속도를 향상시킬 수 있다는 가정에 바탕을 두고 다층 퍼셉트론의 문제점을 완화시킬 수 있다.^[2]

최근 Chen과 Bastani는 다층 수상돌기 회로망이라는 다층 피드포워드 신경망중에서 더 일반화된 GMDP 신경 모델을 제안했다.^[3] 이 모델은 생물학적인 면을 강조하여 수상돌기 각각이 국부적인 활성화를 갖고 전체 활성화에 기여하는 다층 수상돌기의 사용을 주된 내용으로 담고 있다.

본 논문에서는 PID제어기의 각 파라미터들을 GMDP 신경회로망 알고리즘으로 추종시켜 제어시킴으로써 기존의 다층퍼셉트론 신경망모델을 이용했을 때와 비교 분석하고자 한다.

II. PID 제어기

PID 제어기의 형태는 오차 $e(n) = r(n) - y(n)$ 를 갖는 폐루프 시스템으로 구성된다. PID 제어기에서 각 제어파라미터 결정방법은 요구되는 시스템 출력에 대하여 적절한 시스템 입력을 얻기 위해 최적의 파라미터 값을 선택해야 한다.

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

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

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

III. 신경회로망의 개요

3-1. MLP(Multi Layered Perception)의 개요

다층 퍼셉트론은 비선형 프로세싱 요소(뉴우런)들로 이루어진 입력층, 출력층 그리고 적어도 하나의 중간층으로 구성된 다층 회로망이다.^[4] 그림 1은 다층 퍼셉트론의 내부구조를 나타내었다. 다층 퍼셉트론 구조에 있어서 입출력 뉴런들 사이의 관계는 식(2), (3)과 같다.

$$net_k = \sum w_{kj} out_j \quad (2)$$

$$out_k = f(net_k) \quad (3)$$

여기서, net_k 는 뉴우런으로의 입력, out_k 는 뉴우런의 출력, w_{kj} 는 가중치, $f(\cdot)$ 는 활성화 함수이다.

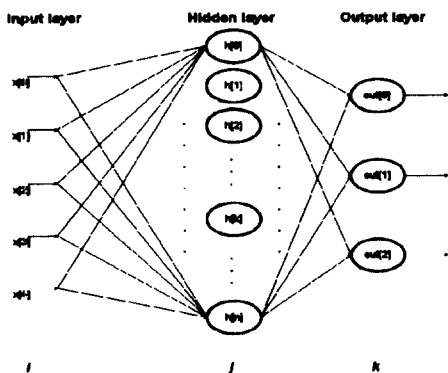


그림 1. 다층 퍼셉트론 신경모델.




그림 2. GMDP 신경모델.

3-2. GMDP(Generalized multi-dendrite product)의 개요

다중 수상돌기 신경모델은 뉴우런에서 받아들여지는 영역, 즉 수상돌기가 전기적 분산시스템이

라는 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 들이고, 축색돌기(axon)연결도 다중 가치를 가질 수 있다. 그림 2는 GMDP 신경모델의 구조를 나타낸다.^[2]

각각의 수상돌기는 국부적인 비활성화 값을 발생하는 비활성화 함수 p_k 와 국부적인 활성화 함수 f_k 를 갖는다. j 번째 뉴런의 k 번째 수상돌기에 있어서 국부적인 비활성화 값은 식(4)와 같다.

$$net_j^{(k)} = \sum_i w_{ji}^{(k)} x_i \quad (4)$$

여기서, x_i 는 i 번째 뉴런의 출력이고, $w_{ji}^{(k)}$ 는 i 번째 뉴런의 축색돌기에서 j 번째 뉴런의 k 번째 수상돌기와 연결된 가중치이다.

하나의 뉴우런은 뉴우런 활성화를 생성하는 시냅스 연결들로부터 모든 입력의 출력함수 F 에 의해 표현되고, 활성화 함수 g 와 비활성화 함수 p 의 조합으로 일반화 된다. GMDP 유니트의 비활성화 함수 p_k 는 비선형 함수인 곱(Π)이 사용된다. o_j 는 중간층 또는 출력층의 출력이고, 식(5)와 같이 구해진다.

$$\begin{aligned} o_j &= F_j(net_j) \\ &= g_j\left(\prod_{k=1}^n f_j^{(k)}(net_j^{(k)})\right) \end{aligned} \quad (5)$$

여기서, 함수 F_j 는 j 번째 GMDP 유니트의 활성화 함수 g 와 비활성화 함수 Π 의 조합이다.

학습규칙은 j 번째 유니트에서 원하는 출력 t_j 와 o_j 사이에서의 최소자승오차식에 의해 식(6)과 같이 나타낼 수 있다.

$$E = \frac{1}{2} \sum_j (t_j - o_j)^2 \quad (6)$$

오차를 최소로 하기 위하여는 식(7)과 같이 가중치를 음의 gradient방향으로 수정되도록 해야 한다.

$$\Delta w_{ji}^{(k)} = -\eta \frac{\partial E}{\partial w_{ji}^{(k)}} \quad (7)$$

여기서, η 는 학습율이다.

델타규칙에 따라, 식(7)은 식(8)로 표현된다.

$$\Delta w_{ji}^{(k)} = \eta \delta_{ji}^{(k)} o_i \quad (8)$$

여기서, $\delta_{ji}^{(k)}$ 는 j 번째 유니트가 있는 층에 의존하는 오차항으로서 출력층의 경우 식(9)와 같이 구해진다.

$$\delta_{ji}^{(k)} = (t_j - o_j) g_j' \left(\prod_{k=1}^n f_j^{(k)}(net_j^{(k)}) \right) \times f_j^{(k)'}(net_j^{(k)}) \prod_{l \neq k} f_j^{(l)}(net_j^{(l)}) \quad (9)$$

IV. GMDP 신경망을 이용한 PID 적용 제어기

제안된 학습방법은 PID 파라미터를 적절하게 취하는 적응제어 시스템에 바탕을 두고, 다층 퍼셉트론과 단층 GMDP 신경망 모델로 파라미터를 수정하도록 한다.

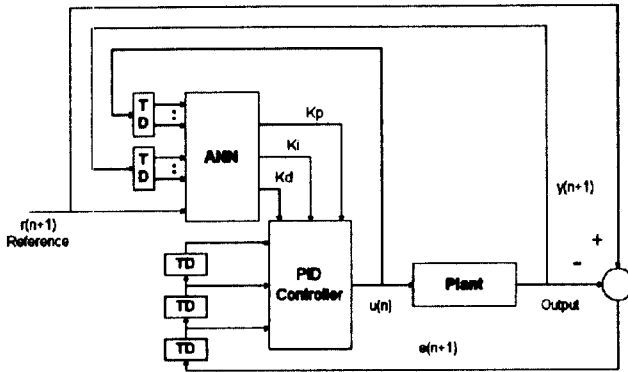


그림 3. GMDP 신경망모델을 이용한 자기동조 PID제어기의 구조.

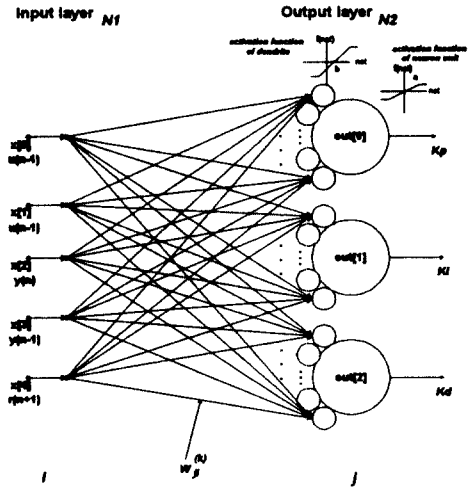


그림 4. GMDP 신경망모델의 구조

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 3와 같다.

파라미터 수정을 위한 신경망과 제어기의 연결은 $\frac{\partial L}{\partial w}$ 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. GMDP는 입력층과 출력층으로 그림 4와 같은 단층구조로써 출력층 뉴런의 활성화 함수를 선형함수로 선택하고 수상돌기의 활성화 함수도 선형함수로 선택한다. 수상돌기의 수는 시스템의 복잡성에 따라서 융통성 있게 고정될 수 있다.

GMDP신경모델을 이용한 PID제어기 파라미터를 추종하기 위한 알고리즘은 다음과 같다.

단계 1. 가중치를 먼저 0과 1 사이의 랜덤한 값으로 초기화 한다.

단계 2. 가중치를 수정한다.

$$\Delta w_{ij}^{(k)}(n) = \eta \delta_{ij}^{(k)} out_i + \alpha \Delta w_{ij}^{(k)}(n-1)$$

$$\delta_{ij}^{(k)} = e(n+1) \text{sign} \left(\frac{\partial y(n+1)}{\partial u(n)} \right) \frac{\partial u(n)}{\partial out_i} \cdot g_i' \left(\prod_{k=1}^n f_j^{(k)}(net_{ij}^{(k)}) \right) f_j^{(k)'}(net_{ij}^{(k)}) \prod_{k=1}^n f_j^{(k)'}(net_{ij}^{(k)})$$

$$w_{ji}^{(k)}(n) = w_{ji}^{(k)}(n-1) + \Delta w_{ji}^{(k)}(n)$$

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

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

V. 실험 및 결과

앞 절에서 GMDP의 알고리즘을 분석해 보았다. 이러한 기본적인 개념을 가지고서 실시간 처리 실험을 해봄으로써 더 명확한 사실을 알아내고자 한다. 실험을 위한 시스템으로는 그림 5와 같이 제어기와 제어기 파라미터를 조정하는 데 필요한 신경망을 PC-586에서 C프로그램하고 모터의 구동회로는 정역이 가능하도록 OP 앰프를 사용하였다.

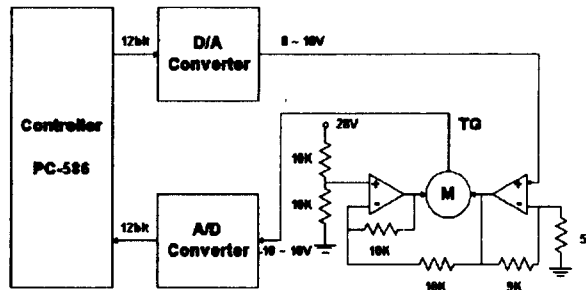


그림 5. 위치제어를 위한 시스템 구조.

실험에 있어서 학습방법은 MLP와 GMDP의 경우로 나누어 실험하였다. MLP의 내부는 입력층의 유닛 갯수를 5개로 하고 중간층을 10개로 그리고 출력층을 3개의 유닛으로 구성하였다. 중간층의 활성화 함수는 sigmoid함수를 택하였고 출력층은 선형함수를 취하였다. 그리고 GMDP는 입력층의 유닛수를 5개로, 출력층 유닛수를 3개로 하여 MLP와 같도록 하였다. 설정치는 1[radian], 0.3[radian], 0.8[radian]으로 각 2000스텝씩하여 제어하여 보았다.




그림 6. 무부하시 MLP를 이용한 결과.




그림 7. 무부하시 GMDP를 이용한 결과




그림 8. 부하시 MLP를 이용한 결과.




그림 9. 부하시 GMDP를 이용한 결과

VI. 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 구현했던 것을 단층 GMDP 신경모델로 구현함으로써 단층 신경망으로 인한 알고리즘의 샘플시간을 줄일 수 있다는 장점으로 MLP를 이용한 제어기보다도 GMDP를 이용한 제어기에서 더 많은 학습수를 얻을 수 있어 정밀한 제어를 가능하도록 해준다. 앞으로 계속해서 연구되어야 할 방향은 초기치 신경망의 파라미터 선정에 관한 것과 지역최소치를 극복할 수 있는 부가적인 알고리즘 분석이 필요하다.

VII. 참고문헌

- [1] Saiful Akhyar and Sigeru Omatu, "Neuromorphic Self-Tuning PID Controller," *IEEE*, vol. 1, pp. 552-557, 1993.
- [2] 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.
- [3] Yiwei Chen and Farokh bastani, "ANN with Two-dendrite Neurons and its Weight Initialization," *proc. IJCNN*, vol. III, pp. 139-146, June. 1992.
- [4] Jacek M. Zurada, "Multilayer Feedforward Networks," *Introduction to Artificial Neural Systems*, West publishing Company, pp. 175- 206, 1992.
- [5] K. J. Astrom and B. Wittenmark, "Adaptive control : Self-Tuning Control," *Computer-controlled systems*, Prentice-Hall Inc. pp. 438-440, 1990.