

웨이브렛 신경회로망을 이용한 적응 제어 방식

정경권¹, 손동철², 이현관³, 이용구⁴, 엄기환⁵

¹동국대학교, ²유한대학, ³호남대학, ⁴한림정보산업대학

Adaptive Control Method using Wavelet Neural Network

Kyung-kwon Jung¹, Dong-seol Son², Yong-gu Lee³, Hyun-kwan Lee⁴, Ki-hwan Eom⁵

¹Dongguk University, ²Yuhan College, ³Honam University

⁴Hallym College of Information & Industry

E-mail : kwon@dgu.ac.kr

요 약

본 논문에서는 웨이브렛 신경회로망을 이용한 적응 제어 방식을 제안한다. 웨이브렛 신경망의 구조는 은닉층의 시그모이드 함수를 mother 웨이브렛 함수로 대체한 것을 제외하고는 다층 신경회로망 구조와 비슷하다. 단일 관절 매니퓰레이터를 대상으로 적응 제어 시뮬레이션을 수행한 결과 웨이브렛 신경회로망의 우수성을 확인하였다.

ABSTRACT

In this paper, a wavelet neural network for adaptive control was proposed. The structure of this network is similar to that of the multilayer perceptron(MLP), except that here the sigmoid functions are replaced by mother wavelet function in the hidden units. The simulation result showed the effectiveness of using the wavelet neural network structure in the adaptive control of one-link manipulator.

1. 서 론

신경회로망의 시작은 1943년 McCulloch과 Pitts에 의해 소개되었고, 1944년에 Hebb이 신경계의 학습은 뉴런간의 시냅스 연결 강도 변화로 이루어진다고 하였으며, 1959년 Rosenblatt에 의해 최초의 인공적 신경회로망이 소개되었다. 1960년에는 최소 평균 자승 알고리즘(LMS : Least Means Squares)으로 Widrow와 Hoff는 빠르고 정확한 학습이 되는 ADALINE(Adaptive Linear Neuron) 모델을 전개하였으며, LMS 알고리즘의 일반화는 오늘날 신경회로망 연구의 기본이 되는 오차 역전파(Error Back-Propagation) 알고리즘이다. 1969년에 Minsky와 Papert는 퍼셉트론이라는 논문에서 단층 신경회로망의 데이터 처리 능력의 한계를 증명하였으며, 1972년에는 Kohonen 과 Anderson 이 각각 기억할 수 있는 신경회로망을 개발하였다. 그 후 1980년대 이 후부터 신경회로망에 대한 연구와 응용분야는 크게 증가되고 있다[1][2].

신경회로망은 패턴 인식, 음성 인식, 화상 판단

및 제어 시스템등 많은 분야에서 응용되고 있다. 제어의 응용에서는 비선형 함수에 접근하는 능력을 가지고 있기 때문에 비선형 시스템을 모델링하고, 비선형 시스템 제어에 매우 유용하다.

이러한 다층 신경 회로망은 단순한 기능을 가진 무수히 많은 뉴런 또는 처리 소자들이 병렬 연결된 연산 구조로 학습이나 훈련을 통해 연결 강도를 조정함으로써 유연성이나 적응 능력이 뛰어나다. 이는 다층 신경회로망의 학습 기구에 의해 실현되고 있으며 일반적으로 오차 역전파 알고리즘을 많이 이용하고 있다. 오차 역전파 알고리즘은 목표 출력과 네트워크 실제 출력 사이의 차의 자승합을 목적함수로 하여 그 목적 함수의 최소점을 최급강하법으로 구한다. 이러한 오차 역전파 알고리즘의 문제점은 학습 소요 시간이 길고, 지역 최소점에 빠질 가능성이 있다[3][4].

최근에는 신경회로망의 단점을 보완하기 위하여 웨이브렛 신경회로망(wavelet neural network)이 제안되었다. 웨이브렛 신경회로망은 기존의 신경회로망과 웨이브렛 분해 사이의 구조적인 유사성과 뛰어난 함수 근사화 능력에 기인하여 웨이

브렛 이론과 신경회로망을 결합하였다. 이러한 웨이브렛 신경회로망은 문제의 유일하고 효과적인 표현을 가능케하고, 망의 초기화에 대한 이론적 배경을 제공할 수 있다. 이 웨이브렛을 이용하는 신경회로망은 시스템이 동작 중인 시간만을 입력으로 사용하므로 시스템 입·출력에 대한 정보가 전혀 필요치 않고, 동정기의 출력이 임의의 함수를 학습하도록 daughter 웨이브렛 함수와 출력 사이의 연결강도 및 웨이브렛 함수의 shift, dilation을 파라미터로서 조정하는 연구가 있었다 [5][6].

본 논문에서는 웨이브렛 함수를 신경회로망의 시그모이드 함수 대용으로 사용하는 웨이브렛 신경회로망을 이용하여 비선형 대상의 직접 적응 제어 방식을 제안한다. 제안된 제어 방식의 유용성을 입증하기 위해서 단일관절 매니플레이터를 대상으로 시뮬레이션한다.

II. 다층 신경회로망

역전파 신경회로망(back-propagation neural network)은 선형 뉴런의 입력층과 출력층 사이에 하나 이상의 중간층, 즉 비선형 뉴런으로 구성된 은닉층을 갖는 다층 구조의 회로망이다. 입력층의 입력신호들은 은닉층의 뉴런을 거쳐 출력층으로 전달되는 전방향 회로망이다. 출력층의 출력신호는 신경회로망이 추종하고자 하는 목표 출력신호와 비교되어 오차신호를 발생하고, 이 오차의 제곱을 최소화하도록 출력층으로부터 은닉층을 거쳐 입력층으로 역전파되어 연결강도를 조정한다.

역전파 학습 알고리즘은 연결 강도 공간상에 주어지는 오차의 제곱을 높이로 하는 곡면에 대하여 오차의 제곱이 가장 많이 감소하는 방향으로 연결강도를 조정하는 gradient descent 법을 사용한다.

다층 신경회로망의 구조는 그림 1과 같다.




그림 1. 다층 신경회로망

은닉층 각 뉴런의 입력으로 가해지는 가중합은

각각 net_j 이라 정의하면

$$net_j = \sum_{i=1}^n w_{ji} \cdot x_i \quad (1)$$

이다. 이 뉴런의 입력은 일반적으로 활성화 함수 $f(\cdot)$ 를 통과하여 뉴런의 출력이 된다.

은닉층 뉴런의 출력은 식(2)와 같다.

$$out_j = f(net_j) \quad (2)$$

사용하는 함수 $f(\cdot)$ 는 다음과 같은 시그모이드(sigmoid) 함수이다.

$$f(net) = \frac{2}{1 + e^{-net}} - 1 \quad (3)$$

출력층 뉴런의 입력신호를 net_k 라 하면

$$net_k = \sum_{j=1}^m w_{kj} \cdot out_j \quad (4)$$

이다. 출력층 뉴런의 출력 out_k 는

$$out_k = f(net_k) \quad (5)$$

로 되고, 이것이 바로 신경회로망의 출력이 된다.

역전파 신경회로망은 전방향 신경회로망의 출력 out_k 가 임의의 목표 함수 d_k 를 학습하기 위하여 out_k 와 d_k 사이의 오차가 최소화되도록 gradient descent법에 의해 출력층에서 은닉층, 은닉층에서 입력층으로 오차를 역전파하면서 연결강도를 조정한다.

이 목적함수 E 가 w_{kj} , w_{ji} 에 대하여 최소화되도록 gradient descent 법을 적용한다.

사용되는 목적함수는 식(6)이다.

$$E = \frac{1}{2} \sum_{k=1}^l [d_k - out_k]^2 \quad (6)$$

신경회로망의 초기 연결강도는 랜덤하게 주어지고, k 번째 샘플링순간에 연결강도 $w(k)$ 가 식(6)의 목적함수를 최급하강 하도록 조정된 결과를 $\Delta w(k)$ 라 하면 $k+1$ 번째의 연결강도 $w(k+1)$ 은 식(7)로 된다.

$$w(k+1) = w(k) + \Delta w(k) \quad (7)$$

III. 제안한 웨이브렛 신경회로망 제어 방식

웨이브렛 신경회로망은 그림 1과 같이 입력층, 은닉층, 출력층으로 구성되는 3층 구조를 갖는다. 특히 인공 뉴런의 비선형 함수로 이용되는 일반적인 시그모이드 함수 대신에 웨이브렛 함수를 이용하였으며, 이러한 인공 뉴런은 은닉층에서만 존재한다.

은닉층 뉴런의 입·출력은 다음과 같다.

$$net_j = \sum_{i=1}^n w_{ji} \cdot x_i \quad (8)$$

$$out_j = \Psi_{a,b}(net_j) \quad (9)$$

$\Psi_{a,b}(net_j)$ 는 웨이브렛 함수로 식(10)과 같다.




그림 2. mother 웨이브렛 $\Psi(t)$

$$\Psi_{a,b}(net_j) = \Psi\left(\frac{net_j - b_j}{a_j}\right) \quad (10)$$

$\Psi(t)$ 는 그림 2와 같은 mother 웨이브렛을 사용하였다.

$$\Psi(t) = \cos(0.6t) \exp\left(-\frac{t^2}{100}\right) \quad (11)$$

여기서 b_j, a_j 는 shift, dilation이다.

그림 3은 웨이브렛 신경망을 이용한 제어 시스템의 구조이다.




그림 3. 제안한 웨이브렛 신경회로망을 이용하는 제어 시스템

목적함수 E 를 식(12)와 같이 정의하여 오차가 최소가 되도록

$$E = \frac{1}{2} [y_d - y]^2 \quad (12)$$

입력층과 은닉층 사이의 연결강도 w_{ji} , 은닉층과 출력층 사이의 연결강도 w_{kj} , shift b_j , dilation a_j 는 각각 목적함수가 최소화 되도록 식(13), 식(14), 식(15), 식(16)과 같이 gradient descent 법을 가하여 조정한다.

$$w_{ji}(t+1) = w_{ji}(t) - \eta \frac{\partial E}{\partial w_{ji}} \quad (13)$$

$$w_{kj}(t+1) = w_{kj}(t) - \eta \frac{\partial E}{\partial w_{kj}} \quad (14)$$

$$b_j(t+1) = b_j(t) - \eta \frac{\partial E}{\partial b_j} \quad (15)$$

$$a_j(t+1) = a_j(t) - \eta \frac{\partial E}{\partial a_j} \quad (16)$$

여기서 η 는 학습률을 나타낸다.

IV. 시뮬레이션

제안한 비선형 제어 방식의 유용성을 입증하기 위하여 식(17)로 표현되는 단일 관절 매니플레이터에 대하여 시뮬레이션을 수행하였다.

$$ml^2 \ddot{\theta} + B \dot{\theta} + mgl \cos(\theta) = \tau \quad (17)$$

여기서 $\theta, \dot{\theta}, \ddot{\theta}$ 는 각각 매니플레이터의 각 변위, 각속도, 각가속도를 나타내고, τ 는 매니플레이터의 입력으로 관절에 가해지는 토크이며, m, l, B, g 는 각각 매니플레이터의 질량, 길이, 마찰계수, 중력 가속도를 나타내며, 값은 각각 $m=0.1[\text{kg}], l=0.5[\text{m}], B=0.4[\text{kg} \cdot \text{m}^2/\text{s}], g=9.8[\text{m}/\text{s}^2]$ 의 사양을 갖는다. 식(17)의 시스템을 상태 공간 모델로 표현하면 식(18)이 된다.

$$\dot{x}_1 = x_2$$

$$\dot{x}_2 = -\frac{g}{l} \cos(x_1) - \frac{B}{ml^2} x_2 + \frac{1}{ml^2} \tau \quad (18)$$

식(18)에 대하여 Runge-Kutta fourth order 알고리즘을 이용하고, 10[ms] 시간 간격으로 하여 식(19)의 기준 궤적에 대하여 제어를 수행하였다.

$$y_d = \frac{1}{2} \sin(t) \quad (19)$$

그림 5, 그림 6은 다층 신경회로망의 출력과 오차곡선이고, 그림 7, 그림 8은 제안한 웨이브렛 신경회로망의 출력과 오차곡선이다. 제안한 제어 방식이 초기 오차의 크기가 작고 수렴속도가 좋은 것을 확인하였다.




그림 5. 다층 신경회로망의 출력




그림 6. 다층 신경회로망의 오차곡선




그림 7. 제안한 방식의 출력




그림 8. 제안한 방식의 오차곡선

V. 결론

본 논문에서는 웨이브렛 함수를 신경회로망의 시그모이드 함수 대용으로 사용하는 웨이브렛 신경회로망을 이용하여 비선형 대상의 직접 적응 제어 방식을 제안하였다. 제안된 제어 방식은 의 유용성을 입증하기 위해서 단일관절 매니플레이터를 대상으로 위치제어를 수행한 결과 다층 신경회로망을 이용한 직접 제어 방식보다 오차가 작고 수렴 시간이 짧다는 것을 확인하였다.

앞으로의 연구 방향은 새로운 학습 알고리즘의 개발과 안정도의 수학적 증명, 다양한 비선형 플랜트를 대상으로 시뮬레이션 및 실험을 수행하는 것이다.

참고문헌

- [1] T. Fukuda and T. Shibata, "Theory and Application of Neural Networks for Industrial Control Systems," IEEE Trans. on Industrial Electronics, vol. 39, no. 6, Dec. 1992.
- [2] M. Yuan, G. S. Hong, and A. N. Poo, "Neural Adaptive Controller: Application Robot Manipulator," The Third International Conference on Automation, Robotics and Computer Vision, pp.1734-1737, 1994.
- [3] F. C. Chen, "Back-propagation Neural Network for Nonlinear Self-tuning Adaptive Control," IEEE International Symposium on Intelligent Control 1989, pp.274-279, 1989.
- [4] K. S. Narendra, K. Parthasarathy, "Identification and Control of Dynamical Systems using Neural Networks," IEEE Trans. on Neural Networks, vol. 1, no. 1, pp.4-27, March, 1990.
- [5] H. H. Szu and S. Kadambe, "Neural network adaptive wavelets for signal representation and classification," OPTICAL ENGINEERING, vol. 31, no. 9, pp.1907-1916, 1992.
- [6] J. Zhang, G. G. Walter, Y. Miao, and W. N. W. Lee, "Wavelet Neural Networks for Function Learning," IEEE Trans. on Signal Processing, vol. 43, no. 6, June, 1995.