

# 혼합형 학습규칙 신경 회로망을 이용한 제어 방식

임종규<sup>\*</sup> · 이현관<sup>\*</sup> · 권성훈<sup>\*\*</sup> · 엄기환<sup>\*\*</sup>

<sup>\*</sup>호서전문대학교 · <sup>\*\*</sup>동국대학교

## Control Method using Neural Network of Hybrid Learning Rule

Jung-Gyu Im<sup>\*</sup> · Hyun-Kwan Lee<sup>\*</sup> · Sung-Hoon<sup>\*\*</sup> Kwon<sup>\*\*</sup> · Ki-Hwan Eom<sup>\*\*</sup>

<sup>\*</sup>Hoseo Technical College · <sup>\*\*</sup>Dongguk University

E-mail : kwon2@cakra.dongguk.ac.kr

### 요 약

본 논문에서는 역전파 알고리즘과 헵 학습규칙의 장점을 최대한 살려 이용하고, 역전파 알고리즘의 문제점인 지역 최소점에 빠지는 경우와 학습시간이 느린 단점과 헵 학습규칙의 문제점인 학습 패턴의 저장능력이 매우 제한되고 선형적 분리가 되지 않는 복잡한 문제에는 적용할 수 없다는 단점 등을 개선하기 위하여 혼합형 학습규칙을 제안한다. 제안하는 학습규칙은 입력층과 은닉층에 혼합형 학습규칙과 은닉층과 출력층에 역전파(Back-Propagation) 학습규칙을 적용한 혼합형이다.

제안한 혼합형 학습규칙을 이용한 신경회로망의 유용성을 확인하기 위하여 단일관절 매니플레이터를 이용하여 추종제어에 대한 시뮬레이션을 하여 기존의 역전파 알고리즘을 이용한 직접적용 제어 방식과 제어성능을 비교 검토한 결과 다음과 같은 특성을 확인하였다.

### ABSTRACT

The proposed algorithm used the Hybrid learning rule in the input and hidden layer, and Back-Propagation learning rule in the hidden and output layer.

From the results of simulation of tracking control with one link manipulator as a plant, we verify the usefulness of the proposed control method to compare with common direct adaptive neural network control method; proposed hybrid learning rule showed faster learning time faster settling time than the direct adaptive neural network using Back-propagation algorithm.

Usefulness of the proposed control method is that it is faster the learning time and settling time than common direct adaptive neural network control method.

### 1. 서 론

인간이 가지고 있는 신체 기능의 대부분은 뉴런(Neuron)들의 유기적 결합체인 신경회로망(Neural network)에 의하여 조절되며, 신경회로망의 중추를 이루고 있는 것은 뇌이다. 이러한 생물체의 뇌신경의 정보처리 메카니즘을 모방한 인공 신경회로망을 여러 공학적인 문제를 해결하는데 활용하고자 하는 연구가 진행되고 있다. 특히 시스템 모델링 및 제어분야도 중요한 응용대상 분야로 많은 관심을 끌었다. 현재까지는 기존의 제어기법으로 해결되지 않는 문제에 적용하여 좋은 결과를 얻고 있다.[1]

신경회로망의 학습은 크게 지도학습(supervised learning) 비지도 학습(unsupervised learning) 및 강화학습(reinforcement learning)으로 나누어 볼 수 있다. 지도학습은 입력값과 목표출력으로 이루어진 학습 샘플들을 사용하여 샘플입력에 대한 회로망의 출력값과 목표출력 사이의 오차가 최소

로 되도록 규칙에 따라 연결강도를 조정하는 방법이다. 이 학습에는 Rumelhart의 오차 역전파 알고리즘이 유명하다.[2]

비지도학습은 입력패턴에 대응하는 목표출력이 주어지지 않고, 유사한 입력 패턴들에 대해서 각 뉴런들이 유사한 출력을 생성하도록 연결강도를 조정한다. 이 학습에는 Kohonen의 자기 조직화 지도(self-organizing map)이 유명하다.

강화학습은 외계로부터 입력을 얻어 이것에 기초로 출력을 생성하여 환경내에서 행동한 후 여러 가지 행동에 대하여 강화신호를 얻는다. 이 학습은 특히 우주공간이나 바다 등의 통신이 곤란한 환경에서 자율적인 행동의 획득이 가능하며, Watkins의 학습이 유명하다.[3]

최초의 학습규칙인 헵(Hebb)의 규칙은 신경회로망의 연결강도를 조정하는 가장 단순한 형태의 학습규칙이다. 비지도 학습인 헵의 학습규칙은 신경회로망에 적용한 홉필드 네트워크(Hopfield

Network)와 Kosko가 제안한 BAM(Bidirectional Associative Memory)등이 있다. 그러나 이 신경 회로망 모델은 단층구조(single layer)로 구성되므로 학습률이나 특징추출 기능은 우수하지만 학습 패턴의 저장능력이 매우 제한되고 선형적 분리가 되지 않는 복잡한 문제에는 적용할 수 없는 문제점이 있다.

일반적으로 지도학습에 많이 사용되는 하나 이상의 은닉층을 갖는 다층 신경회로망의 대표적인 학습규칙은 역전파(Backpropagation)알고리즘이다. [4]

이것은 미분가능한 비선형 활성화함수를 가진 다층 퍼셉트론(perceptron)에 LMS(Least Mean Square) 방법을 확장하여 적용한 것이다. 이것을 일반화된 델타규칙(delta rule)이라고도 한다.

역전파 알고리즘은 출력층의 오차를 역전파 형식으로 전파하여 신경회로망의 연결강도를 조정하므로서 비선형 사상을 모형화 할 수 있는 학습력과, 불확정 시스템을 제어할 때 매우 훌륭한 잠재력을 가지고 있다. 그러나 역전파 알고리즘 학습시간이 길어 속도가 느리며, 지역 최소점에 도달할 수 있으며, 연결강도 및 바이어스(bias)의 초기값에 따라 크게 변화하는 문제점이 있다.[5]

본 논문에서는 역전파 알고리즘과 헵 학습규칙의 장점을 최대한 살려 이용하고, 역전파 알고리즘의 문제점인 지역최소점에 빠지는 경우와 학습시간이 느린 단점과 헵 학습 규칙의 문제점인 학습 패턴의 저장 능력이 매우 제한되고 선형적 분리가 되지 않는 복잡한 문제에는 적용할 수 없다는 단점 등을 개선하기위하여 혼합형 학습규칙을 제안한다. 제안하는 학습규칙은 입력층과 히든층에 혼합형 학습규칙과 히든층과 출력층에 역전파(Back-Propagation)학습규칙을 적용한 혼합형이다. 제안하는 학습규칙의 유용성을 확인하기 위하여 단일 관절 매니플레이터에 적용하여 시뮬레이션을 통하여 일반적인 역전파 알고리즘과 비교 검토한다.

## II. 본 론

### 다층 신경회로망의 학습 규칙

#### 2-1. 헵의 학습 규칙(Hebbian Learning Rule)

헵의 규칙은 1949년 헵(Donald O. Hebb)에 의해 만들어진 최초의 신경망 규칙으로 어떤 순간에 서로 연결된 두 개의 신경세포가 동시에 활성화되었다면 그것들 사이의 연결 가중치를 증가시켜 주어야 한다.

헵의 기본적인 아이디어를 수식으로 표현해 보면, 한 유니트  $u_i$ 가 다른 유니트  $u_j$ 로부터 입력을 받으면 두 유니트 모두 활성화된 상태에서  $u_i$

에서  $u_i$ 로의 연결강도  $w_{ij}$ 는 더욱 더 강해진다. 이것을 식으로 나타내면,

$$\Delta w_{ij} = \eta a_i o_j \quad (2.1)$$

이고, 여기서  $\eta$ 는 학습률을 나타내는 비례상수이고,  $a_i$ 는 뉴런  $i$ 의 출력이며,  $o_j$ 는 뉴런  $j$ 의 출력이다. 일반적으로,

$$\begin{aligned} h(o_j(t), w_{ij}) &= o_j(t) \\ g(a_i(t), t_i(t)) &= \eta (t_i(t) - a_i(t)) \end{aligned} \quad (2.2)$$

로 나타낸다. 여기에서  $t_i(t)$ 는  $u_i$ 의 교사입력이고,  $h$ 는 연결강도  $w_{ij}$ 의 함수이며,  $g$ 는 교사입력  $t_i$ 의 함수를 나타낸다. 이것을 바로 위드로우-호프(Widrow-Hoff)법칙이라고 하는데, 학습의 양은 실제 활성화량과 목표입력과의 차이에 비례하기 때문에 델타 규칙(Delta rule)이라고도 한다.

$$\Delta w_{ij} = \eta (t_i(t) - a_i(t)) \cdot o_j(t) \quad (2.3)$$

이것은 퍼셉트론의 학습 규칙으로 사용되고 그로스버그(Grossberg) 모델에서는 다음의 식이 사용된다.

$$\Delta w_{ij} = \eta (a_i(t) - o_i(t) - w_{ij}) \quad (2.4)$$

위에서 살펴본 바와 같이 헵의 학습 규칙은 나중에 개발된 다른 신경망 모델들의 학습 규칙의 토대가 된다는 것을 알 수 있다.

#### 2-2. 역전파(Back-Propagation) 알고리즘

신경회로망은 외부로부터 주어지는 정보에 따라서 뉴런 사이의 연결 강도와 바이어스를 조정하고, 외부의 정보를 신경회로망 내부에 반영한다.

일반적으로, 신경회로망을 이용한 제어 시스템에서는 설계가 쉽고, 학습이 용이한 지도 학습방법이 많이 사용되며 특히, 비선형 시스템의 제어기로 사용할 수 있는 역전파 알고리즘(back-propagation algorithm)이 많이 사용된다. 역전파 알고리즘은 주어진 신경회로망의 학습법칙으로서 제어 대상인 플랜트(plant)의 주어진 입력에 대하여 원하는 출력을 내도록 연결강도를 어떻게 변화시킬 것인가를 결정하여 학습하게 된다.[6][7][8]

일반적으로 사용되는 역전파 신경회로망은 선형 뉴런의 입력층과 출력층 사이에 하나 이상의 비선형 뉴런층으로 구성된 은닉층(hidden layer)을 갖는 다층구조(multi-layer)의 회로망으로 하나의 은닉층을 갖는 역전파 알고리즘의 다층 신경회로망 구조는 그림 2.1과 같다.




그림 2.1. 역전파 알고리즘의 다층 신경회로망의 구조

입력층의 입력 신호들은 은닉층의 뉴런을 거쳐 출력층으로 전달되는 전방향 신경회로망이다. 출력층의 출력신호는 신경회로망이 추종하고자 하는 목표출력 신호와 비교되어 오차가 발생하고, 이 오차의 제곱을 최소화하도록 출력층으로부터 은닉층을 거쳐 입력층으로 역전파 방식으로 연결 강도를 조정한다.

역전파 학습 알고리즘은 연결강도 공간상에 주어지는 오차의 제곱을 높이로 하는 곡면에 대하여 오차의 제곱이 가장 많이 감소하는 방향으로 연결강도를 조정하는 gradient descent법을 기반으로 하고 있다.

### III. 제안한 혼합형 학습규칙

일반적인 역전파 알고리즘은 식 3-1과 같다.

$$\Delta W_{ji} = \eta \delta_j O_i \quad (3-1)$$

$\Delta W_{ji}$ 는 뉴런 i에서 뉴런 j사이의 연결강도의 변화량,  $\eta$ 는 학습계수,  $\delta_j$ 는  $O_j(1 - O_j)E_j$ 이며,  $O_j$ ,  $O_i$ 는 뉴런 i, j의 실제 출력값이다.  $E_j$ 는 출력층인 경우에는 뉴런 j의 목표값  $t_j$ 와 실제값  $O_j$ 의 차이  $t_j - O_j$ 이며, 은닉층인 경우에는  $\sum_R \delta_R W_{Rj}$ 이다.

Heb 학습 규칙은 식 3-2와 같다.[9][10]

$$\Delta W_{ji} = \eta O_j O_i \quad (3-2)$$

식 (3-1)과 식(3-2)를 결합하면 식 (3-3)이 된다.

$$\Delta W_{ji} = \eta O_j O_i [(1 - \beta) + \beta E(1 - O_j)] \quad (3-3)$$

식(3-3)은 혼합 학습 법칙이며  $\beta$ 는 하이브리드 학습시 사용되어지는 역전파 알고리즘과 Heb의 크

기의 비를 결정해준다.

식(3-8)에서는  $\beta$ 에 의하여 역전파 알고리즘의 영향력이 억제된다. 즉 오차 감소율에 기반한  $W_{ji}$ 의 조종폭이 알맞게 되지 못하므로 인식률이 나 패턴분류가능이 역전파 알고리즘보다 우수하지 못한 원인으로 볼 수 있다. 따라서 식(3-3)을 다음과 같이 수정한다.

$$\Delta W_{ji} = \eta O_j O_i (1 - O_j) + \alpha O_i O_j \quad (3-4)$$

여기서  $\alpha$ 는 임의의 상수(헤비율)며, 문제점으로는  $W_{ji}$ 가 발산할 수 있다는 점이다. 이는  $W_{ji}$ 가 수렴해감에 따라 각 뉴런들이 일정한 값들로 출력을 내게되고 그에 따라  $\Delta W_{ji}$ 도 적절히 작아져야한다. 그러나 헤브항은  $O_i$ 와  $O_j$ 의 곱에 의해 여전히  $\Delta W_{ji}$ 를 큰 값으로 유지시킬 수 있다는 점에서 생겨나는 가능성이다. 역전파 알고리즘의 경우 이러한 발산은 델타항  $\delta_j$ 에 의해 적절히 제어되는데 헤브항은 그렇지 못하다.

이러한 문제점을 제거하기 위해서 헤브항에도 발산하지 않게 델타항을 넣은 식(3-5)를 제안한다.

$$\begin{aligned} \Delta W_H &= \Delta W_{BP} + \Delta W_{HEBB} \delta_j \\ &= \eta O_j O_i (1 - O_j) E_j + \alpha O_i O_j \delta_j \end{aligned} \quad (3-5)$$

여기서  $\delta_j = |O_j(1 - O_j)E_j|$ 이다.

역전파 알고리즘은 오차가 적어지는 방향으로 학습되므로 오차가 적어지면  $\delta_j$ 도 적어진다. 따라서 헤브항도  $\delta_j$ 로 그 크기를 제어한다면  $W_{ji}$ 가 무한히 증가하지 않을 뿐아니라 입력과 출력의 상관관계에 따라  $\Delta W_{ji}$ 는 적절히 수렴해갈 수 있다. 식(3-5)에서  $\Delta W_H$ 는 새로운 하이브리드 학습 법이며  $\alpha$ 는  $\Delta W_{BP}$ 에 대한  $\Delta W_{HEBB}$ 의 비를 나타내는 상수로 헤브율(Hebb rate)이다. 헤브율  $\alpha$ 가 0이면 BP 학습이 되고  $\alpha$ 가 너무 크면 Hebb 학습만 된다.[11]

### IV. 시뮬레이션

제안한 제어방식의 유용성을 입증하기 위하여 식(4-1)로 표현되는 단일 관절 매니퓰레이터에 대하여 IBM-PC Pentium 상에서 MATLAB언어를 사용하여 시뮬레이션하여 기존의 역전파 알고리즘을 이용한 직접 적용 제어 방식과 비교 검토한다.

단일 관절 매니퓰레이터의 운동방정식은 식

(4-1)과 같다.

$$m l^2 \ddot{\theta} + B \dot{\theta} + m g l \cos(\theta) = \tau \quad (4.1)$$

여기서,  $\theta, \dot{\theta}, \ddot{\theta}$  는 각각 매니플레이터의 각변위, 각속도, 각가속도를 나타내고,  $\tau$ 는 매니플레이터의 입력으로서 관절에 가해지는 토크이며,  $m, l, B, g$ 는 각각 매니플레이터 링크의 질량, 길이, 마찰계수, 중력가속도를 나타내며, 값은 각각  $m = 0.1[\text{kg}]$ ,  $l = 1[\text{m}]$ ,  $B = 0.4[\text{kg} \cdot \text{m}^2/\text{s}]$ ,  $g = 9.8[\text{m}/\text{s}^2]$ 이다.

#### 4-1. 기존의 역전파 알고리즘을 이용한 직접 적용 제어방식

구성한 신경회로망은 입력 7개, 1개와 20개의 뉴런을 갖는 은닉층 2개, 1개의 뉴런을 갖는 단일 출력층으로 구성하며 제어기의 파라미터가 되는 연결강도와 바이어스항의 수는 69개로 한다. 각 연결강도의 초기 값은  $[-0.1 \sim 0.1]$ 사이의 랜덤값, 반복최소자승법에 사용된 이득 매트릭스  $I(0)$ 는  $10000 \times I$ , 적응이득  $\lambda_1(k), \lambda_2(k)$ 는 1을 사용한다.


선형 부분을 추정 제어하는 부분에서의 학습율은 반복최소자승법이 학습되지 않은 초기 신경회로망의 출력에 의한 잘못된 추정과 발산을 방지하기 위해 0.0001로 낮게 잡고 뉴런의 함수는 선형 함수를 사용한다. 비선형 부분을 추정 제어하는 부분에서의 학습율은 반복 최소자승법이 학습되지 않은 초기 신경회로망의 출력에 의한 잘못된 추정을 방지하기 위해 0.006으로 크게 잡고 뉴런의 활성화 함수는 식 (4-3)의 시그모이드 함수를 사용한다.

$$y = f(z) = \left( \frac{2}{1 + e^{(-z)}} - 1 \right) \quad (4-3)$$


기준궤적은 식(4-4)으로 주고, 초기상태는 위치 0, 속도 0으로 한 경우의 시뮬레이션결과는 그림 4.1 과 같다.

$$y_d = \frac{1}{2} \sin\left(-\frac{\pi}{12} t\right) \quad (4-4)$$

기존의 역전파 알고리즘을 이용한 직접적용 제어방식은 초기의 학습능력이 매우 떨어지고 학습 속도도 느림을 알 수 있다.[12]



(a) 응답곡선




(b) 오차 곡선

그림 4.1 기존의 역전파 알고리즘을 위한 직접 적용 제어방식


#### 4-2. 제안한 학습규칙을 이용한 직접적용제어 방식

제안한 학습규칙을 이용한 직접적용제어방식의 신경회로망의 구성은 기존의 역전파 알고리즘을 위한 직접적용방식의 조건과 동일하게 입력 7개, 1개와 20개의 뉴런을 갖는 은닉층 2개, 1개의 뉴런을 갖는 단일 출력층으로 구성하며 제어기의 파라미터가 되는 연결 강도와 바이어스항의 수는 69개로 한다. 역전파 알고리즘의  $\eta$ 는 0.0085, 렉의 학습규칙에서의 학습율  $\eta_1$ 은 0.0009, 연결강도와 바이어스 항은 임의의(random)값을 사용한다. 기준궤적은 기존의 방식과 같이 식(4-4)으로 주고 초기상태는 위치 0, 속도 0으로 한 경우의 시뮬레이션 결과는 그림 4.2와 같다.

그림에서와 같이 제안된 제어방식은 기존의 제어방식보다 빠른 학습속도와 정밀도가 매우 우수한 성능을 나타내고 있다.



(a) 응답곡선



(b) 오차곡선

그림 4.2 제안한 학습규칙을 이용한 직접적용제어방식의 특성곡선

## V. 결 론

본 논문에서는 다층신경회로망 역전파 학습규칙의 문제점인 지역 최소점에 빠지는 경우와 학습시간이 느린 단점과 렉스 학습규칙의 문제점인 학습패턴의 저장능력이 매우 제한되고 선형적 분리가 되지않는 복잡한 문제에는 적용할 수 없는 문제점을 개선하기 위하여 혼합형 학습규칙을 제안하였다. 제안한 학습규칙은 입력층과 히든층에는 혼합학습규칙을 출력층과 히든층에는 역전파 알고리즘을 적용한 혼합형 학습규칙이다.

제안한 혼합형 학습규칙을 이용한 신경회로망의 유용성을 확인하기 위하여 단일 관절 매니플레이터를 이용하여 추종제어에 대한 시뮬레이션과 실험을 하여 기존의 역전파 알고리즘을 이용한 직접적용제어방식과 제어성능을 비교 검토한 결과 다음과 같은 특성을 확인하였다.

1. 제안한 혼합형 학습규칙을 이용한 신경회로망 제어방식이 기존의 역전파 알고리즘을 이용한 직접 적용제어방식보다 학습속도가 빠르다.

2. 기존의 역전파 알고리즘을 이용한 직접적용

제어방식보다 정정시간이 빠르고 정상상태 오차가 감소되었다.

이 후의 연구과제로 본 논문에서 보다 더 연구되어야 할 문제는 다음과 같다. 초기의 불안정한 상태를 빨리 줄일 수 있는 알고리즘의 개발이 필요하다. 또한 이 학습규칙을 패턴인식이나, 수기 (finger printing) 문자 인식, 교통 감시 시스템 등에 적용시키는 연구가 이루어져야 할 것이다.

## 참고문헌

- [1] A.J.Koivo, Fundamentals for Control of Robotic Manipulators, JOHN WILEY & SONS, INC., 1989.
- [2] K.S.Narendra and A.M.Annaswamy, Stable Adaptive Systems, Prentice-Hall, Inc., 1989.
- [3] K.J.Astrom and B.Wittenmark, ADAPTIVE CONTROL, ADDISON-WESLEY PUBLISHING COMPANY, 1989.
- [4] A.J.Koivo and T.H.Guo, "Adaptive Linear Controller for Robotic Manipulators", IEEE Trans. on Automatic Control, Vol. AC-28, No. 2, Feb. 1983.
- [5] A.P.Sage and C.C.White III, OPTIMUM SYSTEMS CONTROL, Prentice-Hall, Inc., 1977.
- [6] K.J. Hunt, G.R. Irwin and K. Warwick (Eds) "Neural Network Engineering in Dynamic Control System", WILEY, 1995
- [7] K.S. Narendra, K. Parthasarthy, "identification and Control of Dynamical Systems Using Neural Networks", IEEE Trans, Neural Network, vol.1, No.1, March 1990, pp4-27
- [8] Hagan, Demuth, Beale, "Neural Network Design", PWS Publishing Company, 1995
- [9] Terence David Sanger, Optimal unsupervised learning in a single-layer linear feedforward neural network, Neural Networks. 2:459-473,1989
- [10] Terence David Sanger, Optimal unsupervised learning in feedforward neural network, Neural Networks. MIT AI LabTech. Report 1086, 1989.
- [11] K.J.Astrom and B.Wittenmark, "On Self Tuning Regulators", Automation, Vol.9, pp.185-199, Mar. 1973.
- [12] A. Isidori, Nonlinear Control Systems, Springer-Verlag, 1989