

論文95-32B-9-1

빠른 학습 속도를 갖는 로보트 매니퓰레이터의 병렬 모듈 신경제어기 설계

(A Design of Parallel Module Neural Network for Robot Manipulators having a fast Learning Speed)

金正道*, 李宅鍾**

(Jeong Do Kim and Taek Chong Yi)

요약

신경회로망에서 최적 중간층 뉴런수를 구해주는 것은 아직 미 해결점으로 남아 있으나 중간층 뉴런수가 늘어나면 신경 회로망은 불안정 해진다는 것이 많은 실험에 의해 경험적으로 밝혀졌으며, 또한 중간층 뉴런수가 증가하면 해를 구할 수 있는 연결 강도의 수는 급격히 증가하여 Local-minima의 수도 기하급수적으로 증가하게 되어 많은 학습이 이루어 진다 하더라도 수렴 오차가 클수밖에 없음이 실험적으로 증명되었다.

본 논문에서는 이러한 trade-off 문제를 해결하기 위해 신경 회로망을 병렬로 연결하고 비슷한 학습 방향을 가지는 패턴을 시별 분리하여 비슷한 학습 방향을 가지는 패턴들을 따로 학습시키는 병렬 모듈 신경 제어기를 제안하였으며 여러 특성의 패턴에 대해 중간층의 뉴런수를 증가시킴이 없이 학습 수렴 속도가 현저히 개선되고 좋은 제어 특성을 얻을 수 있음을 보였다.

본 논문에서 제안된 병렬 모듈 신경 제어기의 유용성을 알아보기 위하여 직접 캐나다에서 제작된 6관절 로보트 매니퓰레이터를 사용하여 이중 커플링 현상, 중력, 관성등의 영향을 받는 3자유도만을 제어하였다. 본 실험을 위해 구동 드라이브단은 직접 제작하였으며 주 제어기로는 일반 serial 컴퓨터인 IBM-386 컴퓨터가 사용되었다.

Abstract

It is not yet possible to solve the optimal number of neurons in hidden layer at neural networks. However, it has been proposed and proved by experiments that there is a limit in increasing the number of neuron in hidden layer, because too much increment will cause instability, local minima and large error.

This paper proposes a module neural controller with pattern recognition ability to solve the above trade-off problems and to obtain fast learning convergence speed. The proposed neural controller is composed of several module having Multi-layer Perceptron(MLP). Each module have the less neurons in hidden layer, because it learns only input patterns having a similar learning directions.

Experiments with six joint robot manipulator have shown the effectiveness and the feasibility of the proposed the parallel module neural controller with pattern recognition perceptron.

* 正會員, 三陟產業大學校 制御計測工學科
(Dept. of C & I. Eng., Samchuck National Univ.)

** 正會員, 成均館大學校 電子工學科
(Dept. of Elec. Eng., Sungkyunkwan Univ.)

接受日字: 1995年4月29日, 수정완료일: 1995年9月2日

I. 서 론

BP 알고리듬을 사용하여 동역학 시스템이나 로보트 매니퓰레이터를 제어하는 것은 그 제어 대상 시스템을 거의 블랙박스(Block Box)로 볼수 있어 제어 문제에 있어 가장 이상적인 방법이라고 볼수 있다. 하지만 Back-Propagation(이하 BP) 알고리듬을 사용하는 데 있어서 Local Minima 현상, 조기포화와 중간층 뉴런수의 영향등을 해결해 주는 것이 전제로 되어 있다.

최적 중간층 뉴런수를 구해주는 것은 아직 미 해결 점으로 남아 있으나 Rumelhart,Zurada^{[1][2]}등에 의해 중간층 뉴런수가 늘어나면 신경 회로망은 불안정해진다는 것이 많은 실험에 의해 경험적으로 밝혀졌으며, 또한 중간층 뉴런수가 증가하면 해(Solution)를 구하기 위한 연결 강도의 수는 급격히 증가하여 해를 구해줄 수 있는 방법의 수가 기하 급수적으로 증가하여 Local Minimum의 수도 급격히 증가하게 되어 많은 학습이 이루어 진다 하더라도 큰 오차에 수렴할 수밖에 없게 됨이 많은 학자들에 의해 증명되었다^[1]. 그러나 제어 대상 시스템이 복잡한 수학적 관계를 가지고 있거나 많은 입력 패턴(Input Pattern)을 학습해야 할 경우에 여러가지 경우의 패턴에 대한 평균 학습이 필요하므로 중간층 뉴런수의 증가는 필연적이다. 이 문제는 제어뿐만이 아니라 패턴인식에서도 당면하고 있는 문제라 할수 있다.

이러한 Trade-Off문제를 해결하기 위해 많은 학자들이 방사형 신경회로망(RFNN), 퍼지 신경회로망과 Recurrent 신경회로망등을 제안하여 많은 문제점을 해결하였다.

본 논문에서는 일반적인 BP신경회로망을 사용하면서 이러한 Trade-Off문제를 해결하고 빠른 수렴 속도를 얻기 위해 많은 패턴에 대해 중간층 수를 늘려 주는 것이 아니라 비슷한 학습 방향을 가지는 패턴을 식별하여 비슷한 학습 방향을 가지는 패턴들은 하나의 신경회로망에서 학습시켜주고 다른 학습 방향을 가지는 패턴들은 다른 신경 회로망에서 학습시켜주며, 각 신경 회로망은 병렬로 연결시켜 패턴별 학습을 시키는 패턴 식별 모듈 신경 제어기(Pattern Recognition Module Neural Network)를 제안한다. 각 신경 제어기는 자기 패턴부분만 학습하면 되므로 많은 중간층 뉴런수를 가질 필요가 없어 상대적으로 적은 수의 뉴

런수를 사용할수 있으며, 전체 신경 제어기가 병렬 연결되어 있으므로 실제 학습에 참여하는 연결 강도의 수는 각 신경 제어기의 수만큼 밖에 되지 않는다. 그러므로 중간층 뉴런수가 증가되지 않고 많은 패턴을 학습시킬수 있으며 자기 패턴만을 학습하므로 자기 학습 방향의 연결 강도로만 학습되어 상당히 적은 오차에 수렴할수 있는 방법이다.

각 패턴을 식별하기 위해 패턴 식별 퍼셉트론(Pattern Recognition Perceptron)이 사용된다. 본 논문에서 제안된 방식은 적은 수의 연결 강도가 사용될수 있으므로 실제 구현시 병렬 처리칩(Parallel Processing Chip)이나 신경칩(Neural Chip)을 사용하지 않고도 기존의 마이크로 프로세서(Microprocessor)로도 구현 가능하다.

본 논문에서 제안된 패턴 식별 모듈 신경 제어기의 유용성을 알아보기 위하여 직접 수직 다관절 로보트 매니퓰레이터가 사용되었으며, 로보트 매니퓰레이터는 캐나다에서 제작된 6관절의 수직 다관절형 로보트 매니퓰레이터(CRS-A460)이며 이중 커플링 현상, 중력, 관성등의 영향을 받는 3 자유도만을 제어하게 된다. 본 실험을 위해 구동 회로(Drive Circuit), 주 제어기와의 인터페이스 회로(Interface Circuit)는 직접 제작하였으며 주 제어기로는 IBM-386 계산기가 사용되었다.

II. 동역학 제어를 위한 BP 신경회로망

1. BP 신경회로망의 학습구조

신경 회로망은 크게 단층 신경 회로망(Single-Layer Neural Network)과 다층 신경 회로망(Multi-Layer Neural Network)으로 분류되며 패턴 유형이 복잡한 초평면을 가지면 다층 신경회로망이 사용되어야 한다.

다층 신경회로망은 Hopfield, BP, Counter Propagation와 BAM 신경 회로망등으로 나눌수 있지만 지도학습을 사용하는 제어 시스템에서는 주로 BP 알고리듬이 사용되고 있다.

다층 신경 회로망은 입력 신호를 받는 입력층(Input Layer)과 비선형 매핑(Mapping)을 하는 중간층(Hidden Layer)과 출력값을 내는 출력층(Output Layer)으로 이루어져 있는데, 중간층은 비선형성을 보상하기 위해 사용된다.

입력층의 뉴런을 제외한 각 뉴런들의 입력패턴에 대한 출력값의 계산은 다음과 같다. 이때 k번쨰 층의 j번째 뉴런에서의 출력값, out_i^k 는 보통 비선형 활성 함수인 Sigmoid 함수를 이용하여 다음과 같이 구한다.

$$out_i^k = f(NET_i^k)$$

$$NET_i^k = \sum_i out_i^{k-1} \cdot w_{ij}^{k-1} \quad (1)$$

여기에서 k는 출력층을 의미하고 w_{ij}^{k-1} 는 (k-1)번쨰 층의 i번째 뉴런과 k번쨰 층의 j번째 뉴런간의 연결 강도의 값이며, $f(\cdot)$ 는 미분 가능한 단조 증가 함수로서 활성함수를 의미한다.

다중 신경회로망의 학습은 BP 알고리듬에 의하여 이루어 지는데, 일반적으로 사용하는 BP 알고리듬의 에너지 함수는 다음과 같다.

$$E = \frac{1}{2} \sum (목표값 - 실제값)^2 \quad (2)$$

연결 강도의 변화에 의해 에너지 함수는 줄어드는 방향으로 변화하여야 하며 식으로 나타내면 다음과 같다.

$$\Delta w_{ij}^k = \eta \cdot \delta_j^{k+1} \cdot out_i^k \quad (3)$$

일반적으로 보다 빠른 학습속도를 위해 식 3에 모멘텀(Momentum)항을 추가하게 되는데, 이 경우의 연결 강도 조절식은 다음과 같이 표현된다.

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

$$w_{ij}^k(n+1) = w_{ij}^k(n) + \Delta w_{ij}^k(n+1) \quad (4)$$

여기에서 n은 학습의 반복 횟수

η 는 학습률 계수로서 $0 < \eta < 1$

α 는 모멘텀(Momentum) 계수로서 $0 < \alpha < 1$

δ_i^k 는 k번쨰 층의 i 번째 뉴런의 오차항이며 다음과 같이 구해진다.

$$\delta_i^k = (target_i - out_i^{k+1}) \cdot f'(NET_i) \quad (5)$$

중간층의 경우에는 바람직한 출력값을 알 수 없으므로 다음과 같이 구하게 된다.

$$\frac{\partial E}{\partial out_i^k} = - \sum_j \delta_j^{k+1} \cdot w_{ij}^k \quad (6)$$

위의 결과를 식 (5)에 대입하면 중간층의 경우 오차

항은 다음과 같이 표시된다.

$$\delta_i^k = f'(NET_i^k) \cdot \sum_j \delta_j^{k+1} \cdot w_{ij}^k \quad (7)$$

2. 기존 BP 신경회로망의 문제점과 특징

1) 조기포화상태

BP 신경회로망에서 학습방법은 경사도법(Gradient Method)을 사용하게 되고 연결 강도의 학습은 활성함수의 기울기에 비례하게 된다.

$$\delta_k = (t_k - out_k) \cdot f'(NET_k) \quad (8)$$

식(8)과 같이 δ 를 구할 때 연결 강도의 학습은 활성함수의 기울기에 비례하게 되는데 초기에 연결 강도들의 합이 부적절하거나 너무 크게 설정된다면 현재의 오차에 상관없이 활성함수의 미분형이 0(Zero)에 가깝게 설정되어 연결 강도의 변화가 상당히 작게되어 전체의 학습에 크게 영향을 미치는 결과를 가져오게 되며 이를 조기 포화(Premature Saturation)^{[1][6]}라고 한다.

최적 초기값을 결정해 주어 빠른 학습을 이루기 위한 연구가 Widrow^[17] 등에 의해 연구되어 최적의 초기 연결 강도를 결정하는 공식화된 방법을 제시하였다.

그러나 최적의 초기 연결 강도값을 결정하는 방법은 중간층의 수가 변함에 따라 달라질 수 있으며, 2개의 중간층을 갖는 시스템의 학습과 복잡한 매핑 관계를 학습해야 하는 시스템에 대한 정형화된 공식화를 이루어 내지는 못했다. 조기 포화에 대한 문제를 연결 강도의 최적 초기값에 의해 해결하려는 방향과는 다른 연구 방향이 있는데, 전^[15]은 조기 포화를 감지하여 활성함수의 기울기를 변화시켜 조기포화상태에서 기울기를 줄여주고 있다.

2) 연속 입력 패턴에서 Local Minimum과 중간층 뉴런수의 관계

신경회로망은 제한된 연결 강도의 수가 적절히 학습하여 그 학습된 연결 강도가 모든 입력 패턴에 대한 최적의 해를 구해주어야 하는 문제를 안고 있다.

신경회로망의 연결 강도는 학습대상 시스템의 입출력 관계를 학습하게 되고 만약 입출력 관계가 상당히 복잡한 평면상에서 존재하고 있다면 많은 학습횟수를 필요로 하게 된다. 또한 입력 패턴수의 증가는 더 많은 해를 구해내야 하기 때문에 중간층 뉴런의 수도 증가해야만 연결 강도에 입출력 관계에 대한 해를 저장할

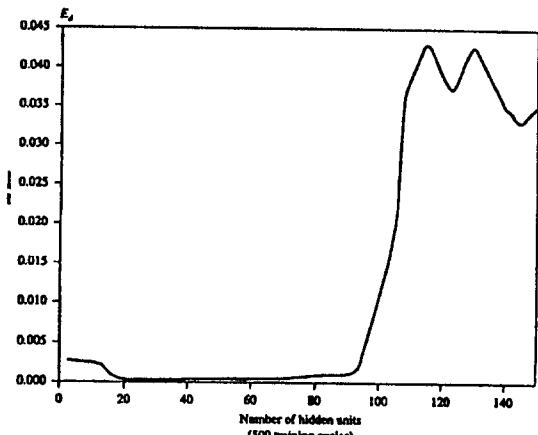
수 있다^[9].

특히 연속 입력값을 갖는 경우 대단히 많은 입력 패턴이 존재함에 따라 많은 수의 중간층 뉴런을 사용하게 되는데 연결 강도의 증가는 더 많은 Local Minimum을 만들게 된다. 이산 입력값의 경우 하나의 입력 뉴런당 2개의 입력 패턴을 가지므로 N 개의 입력 뉴런의 경우 2^N 개의 전체 입력 패턴을 가지지만 연속 입력값의 경우 -1에서 1까지로 입력값을 정규화(Normalization)하고 샘플링 시간(Sampling Time)을 0.01로 한다 하더라도 200개의 패턴이 존재하며 N 개의 입력뉴런인 경우 200^N 개의 개별 패턴이 존재한다. 하지만 200개의 패턴들은 한 패턴의 근처에서 비슷한 값으로 존재하기 때문에 200^N 개의 개별 패턴이라고 보기는 힘들기는 하지만 상당한 수의 패턴이라고 할 수 있다. 많은 입력 패턴을 효율적으로 학습하기 위하여 많은 중간층이 포함되게 되는데, 중간층이 일정수보다 많게 되면 쉽게 Local Minimum에 빠진다는 것이 Yves Chauvin에 의해 실험적으로 증명되었다. 또한 Zurada^[7]는 필기체 인식을 위한 신경회로망의 실험에서 중간층의 갯수와 RMS(Root Mean Square)오차와의 관계를 실험으로 알아보았다. Zurada의 결과를 표현하면 그림 1과 같다.

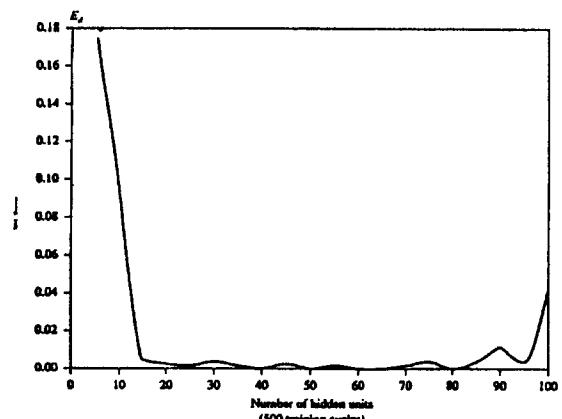
그림 1에서 중간층의 수가 일정 수를 넘어서면 오차가 기하급수적으로 증가함을 알 수 있다. 중간층의 수를 안정한 영역으로 정해주면 되지만 안정영역의 수는 학습 대상 시스템마다 다르게 설정될 수 있기 때문에 결정되어 있는 공식이 아직 존재하지 않고 있다. 특히 연속 입력 패턴의 경우에는 연속적인 많은 패턴수에 대해 해를 구해야 하기 때문에 많은 중간층을 사용할 수 밖에 없는데, 연속 입력의 경우는 많은 패턴이 존재하기는 하지만 비슷한 패턴이 샘플링 시간에 의해 구별되어 있기 때문에 가까운 샘플링 구간의 입력패턴은 비슷한 학습 방향의 연결강도를 가지게 되어 연결 강도의 수가 늘어나면 불안정해질 수 있는 조건이 될 수 있다. 그래서 일단 많은 패턴을 소단위의 그룹으로 묶어 학습 방향을 조사하기 위하여 각 입력 패턴의 부호값에 따라 구분시켜 이를 구별 패턴으로 정의하였다. 만약 각 입력이 위치, 속도와 가속도라면 +방향과 -방향의 위치, 속도와 가속도로 구별되게 된다.

전동기를 제어하기 위해 바람직한 위치와 속도, 실제 전동기의 위치와 속도를 입력받는 4개의 입력 뉴런, 3개의 중간층 뉴런과 하나의 출력층 뉴런을 가지며 각

각의 입력 패턴은 연속인 경우의 신경회로망을 가정하자. 입력은 바람직한 위치와 샘플링 시간을 0.01초로 가정하고 총 제어시간을 5초로 가정하여 전체 패턴의 수를 500개로 정의한다. 만약 각 입력의 부호값으로 패턴을 분리하면 최대 2^4 개의 구별 패턴으로 나눌 수 있으며 각 구별 패턴은 약 31개씩의 개별 패턴을 가지게 된다.



(a) 중간층이 하나인 경우



(b) 두개의 중간층인 경우

그림 1. 중간층의 뉴런갯수와 RMS오차와의 관계

Fig. 1. The Relation Between the Number of Neuron in Hidden Layer and RMS Error.

이 신경 회로망을 실제 전동기에 적용시켜 제어하고 학습시켜 보았는데, 한번은 모든 패턴을 학습시켰고 한번은 바람직한 속도의 부호를 구별 패턴으로 하여 +속도와 -속도를 나누어 학습시켰으며 20회 학습시켰을 때의 연결 강도를 그림 2에서 나타내었다. 그림 2은

실제 직류전동기를 구동 학습시켜 얻은 연결강도를 X 축에 나열한 것으로서 두 패턴은 구별 학습시킬 경우 서로 다른 부호의 방향으로 학습함을 알수 있다. 하나의 신경회로망으로 학습시킬 경우는 2개의 구별 패턴을 다 만족시키기 위한 일정한 방향의 연결 강도로 학습되기 때문에 학습시간이 오래 걸릴수 밖에 없으며, 오랜 학습이 이루어 진다 하더라도 한 구별 패턴의 내부 패턴이 많을수록 오차는 증가하며, 학습 대상 시스템이 복잡하면 한 구별 패턴에 대해서도 신경회로망이 학습하는데 많은 변화를 가져오게 되어 다른 패턴을 제대로 학습하기 힘들게 된다. 만약 1번의 구별 패턴이 학습되어 연결 강도의 방향이 결정되었을때 2번 패턴으로 넘어가면 중간층으로 들어가는 NET값의 부호가 바뀌게 되어 전체적인 재학습이 일어나게 되어 학습시간이 길어지게 된다. 또한 그림에서 알수 있는 바와 같이 한 신경회로망에서 학습한 연결 강도는 두개의 구별 패턴중 하나의 패턴과 비슷한데 이는 마지막으로 입력된 패턴들에 의해 가중치가 집중학습했음을 알수 있다. 그러므로 하나의 구별 패턴은 다른 구별 패턴에 비해 오차가 클 수 밖에 없다.

중간층의 갯수를 늘여주면 전체적으로 좋은 학습이 이루어 질 수 있겠지만 중간층의 증가는 그 증가분보다 더 많은 새로운 해를 형성하게 되어 더 많은 Local Minimum이 존재할 가능성도 늘여주게 된다. 또한 신경회로망 내부의 복잡도(Complexity)를 증가시켜 주어진 문제에 대한 성질을 적절히 일반화(Generalization)시키기 어려운 문제점을 가지게 된다. 이는 Rumelhart에 의해 입증되었다.

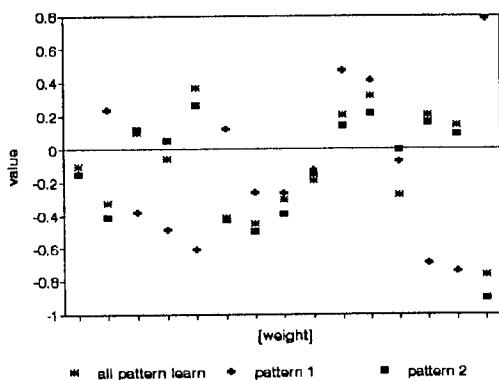


그림 2. 식별된 연결 강도의 차이

Fig. 2. The Difference of Weight on Recognized Patterns.

또한, Rumelhart에 의해 제시되지는 않았지만 일반화시키기 어려운 이유는 더 많은 해의 존재로 가장 일반적이고 최적인 해로 수렴되는 것이 아니고 현 입력 패턴에 대해서만 가장 근사적으로 적은 해를 찾아가기 때문이며 그 입력 패턴에 대한 해가 많이 존재하고 있고 다른 입력 패턴에 대해서 다른 해가 존재할 많은 가능성을 가지기 때문이라는 많은 연구 결과가 제시되고 있다.

Rumelhart^[1]는 복잡도를 줄이는 방법으로 몇가지를 제시했는데

- 1) 신경 회로망의 연결강도 수를 줄인다.
- 2) 중간층의 갯수를 줄인다.
- 3) 신경 회로망의 대칭성을 높인다.

앞에서 설명된 이유로 많은 입력 패턴의 존재에도 불구하고 중간층의 수를 계속 늘여줄수는 없는 일이다. 또한 중간층의 수를 늘여주었을 때는 전체 연결 강도의 초기 평균값이 커져 초기포화상태에 빠지기 쉬우므로 기울기를 재 조정하거나 전체 연결 강도의 초기 평균값의 크기를 줄여주어야 한다. 많은 연구자들이 기울기 조정하기 위하여 Fuzzy 이론과의 결합을 꾀하고 있다.

3) 망각특성

BP 신경회로망의 경우 일정 학습한 후 연결 강도를 고정시키고 실제 제어 모드에서 동작시켜야 하는데, 이 때 고정된 연결 강도는 모든 패턴에 대해 원하는 해를 구해 주어야 한다. 그러나 연결 강도의 학습 방향은 학습시킬때마다 계속적으로 변하며, 변하는 방향은 모든 입력 패턴에 대해 적절한 해를 구할수 있는 방향으로 변하는 방향성을 가지게 된다.

즉 어떤 패턴들이 주어졌을 때 연결 강도는 전체 패턴들의 해를 구할수 있도록 각 연결 강도들이 고유의 방향성을 가지고 학습하게 된다.

연결 강도들이 하나하나마다 자신의 방향이 설정된다 하더라도, 계속적으로 변하는 패턴이 들어올 경우 자기 학습방향으로만 계속 학습하게 되기 때문에 연결 강도의 패턴에 따라 방향은 같지만 위치는 조금씩 다르게 학습하게 된다. 그러므로 가장 최근에 학습한 데 이타에 대해 가장 잘 적응하며 학습한지 오래된 패턴에 대해서는 조금씩 잊어먹는 망각 특성을 가지고 있다. 그래서 많은 패턴이 존재하여 다양한 패턴을 학습함에 있어서는 초기 학습 패턴의 종류들은 큰 오차를

나타낼수 밖에 없는 단점을 가지게 된다. 이는 그림2에서 본 바와 같이 전체 패턴을 학습한 연결 강도가 패턴군 1에 거의 일치하고 있음을 볼수 있는데, 마지막에 학습한 패턴들에 의해 전체 연결 강도가 움직여 주어 그 전 패턴들은 어느정도씩 망각하고 있음을 의미한다.

이 문제점을 해결하기 위해 방사형 신경회로망이 제안되었고, 이 구조에서는 Local Learning의 수행으로 인해 특정 패턴에 대해 해당 뉴런만 학습함으로 인해 전체적 가중치가 수정될 필요가 없는 좋은 방법이라 할 수 있다. 하지만 일반적인 BP 신경회로망 구조에서는 미 해결 문제로 남아 있다.

3. 기존의 동역학 제어를 위한 BP 신경 제어기의 구성

그림 3은 신경 회로망을 이용하여 동역학 시스템의 역모델로의 학습과 제어를 동시에 하는 제어기의 구성도^[3]이며 기능은 다음과 같다. 원하는 케적 패턴과 케적 패턴의 미분형이 신경제어기의 입력으로 작용되고 역시 제어대상 시스템의 출력이 신경제어기의 입력으로 작용될수 있다. 선형제어기에 의한 토오크 τ_f 는 신경제어기의 연결 강도를 수정하여 에너지 함수가 감소하는 방향으로 신경제어기의 출력 토오크 τ_n 을 발생시킨다. 이 두 토오크의 합 $\tau_f + \tau_n$ 으로 로보트 매니퓰레이터의 입력으로 작용하게 된다.

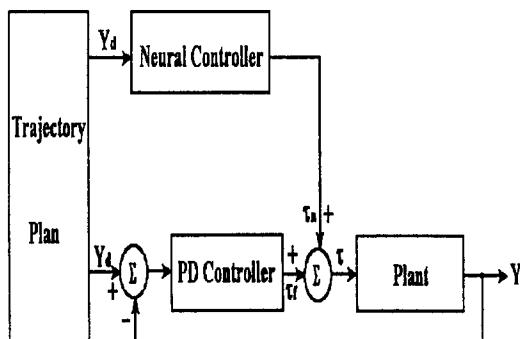


그림 3. 일반적인 On-Line신경 제어기의 구조
Fig. 3. The Scheme of Typical On-Line Neural Controller.

먼저 로보트를 학습시키기 위한 성능지수(Index of Performance)로서의 에너지 함수는

$$E = \frac{1}{2} \sum (\text{목표값} - \text{실제값})^2 \quad (9)$$

이고 목표값(Target)이나 실제 출력값은 토오크 값으로 나타날수 있기 때문에 다음과 같이 정의될수 있다.

$$E = \frac{1}{2} \sum (\tau_d - \tau_n)^2 \quad (10)$$

여기서 τ_d 는 바람직한 출력(Desired Output)을 의미한다.

에너지 함수가 정의됨에 따라 출력총의 δ 는 다음과 같다.

$$\delta_i^k = (\tau_d - \tau_n) \cdot f(NET_i) \quad (11)$$

그러나 τ_d 는 미리 계산가능하지 않기 때문에 식(11)은 사용할수 없다. 그래서 PD 제어기의 출력 τ_f 를 사용하여 에너지 함수를 재정의하여 δ 를 구하는데

$$E = \frac{1}{2} \sum \tau_f^2 \quad (12)$$

여기서 $\tau_f = K_p \cdot (Y_d - Y) + K_d \cdot (Y_d - \dot{Y})$

K_p : 비례계수

K_d : 미분계수

Y_d, Y : 바람직한 케적과 실제 케적

\dot{Y}_d, \dot{Y} : 바람직한 케적과 실제 케적의 미분형

에너지 함수가 재정의됨에 따라 출력총의 δ 는 다음과 같이 정의되어 학습에 참여하게 된다.

$$\delta_i^k = \tau_f \cdot f(NET_i) \quad (13)$$

여기서 $\frac{\partial E}{\partial out_{i,k+1}}$ 를 $-\tau_f$ 로 정의했는데 $out_{i,k+1} = \tau_n$ 로 정의되므로 실제로는 구할수 없다. 그러나, 많은 연구자들은 이 부분을 out 에 따라 재정의된 식(12)의 에너지 함수가 감소해야 하므로 근사적으로는 가능한 식으로 정의하여 사용하고 있다.

III. 제안된 패턴 식별 모듈 신경 제어기

1. 인간 뇌의 기능별 모듈

인간 뇌에는 약 140억개의 뉴런이 포함되어 있다고 알려져 있다. 하지만 물론 이것들이 전부 상호 연결되어 있는 것이 아니며, 생물학자들은 한개의 뉴런에 대한 결합수는 기껏해야 1만개 정도라고 말하고 있다.

현재 알려진 뇌의 구조에 따르면 기능에 따르는 모

둘(Module) 구조로 되어 있으며 어떤 기능을 가지는 모듈은 다른 기능을 가지는 모듈들과 상호 결합하여 통합적인 기능을 수행하게 된다. 어떤 한가지 기능을 가지는 모듈은 모듈안에서 여러개의 군(Group)으로 이루어져 있으며 각군은 서로 다른 결합수를 가지는 구조로 되어 있으며 각 군은 다시 병렬 연결 혹은 상호 연결되어 작은 기능을 수행하고 있다. 예를 들어 오른손의 기능과 왼손의 기능은 같은 모듈속에서 동작하지만 오른손과 왼손의 뉴런들은 각기 다른 결합수를 가지고 학습하며 동작하고 있는 것이다^[14]. 그럼 3은 인간 신경 뇌의 모듈 구조를 설명하고 있다. 이를 통해 우리는 동역학 시스템의 제어에 있어서 한가지 새로운 방법에 대한 암시를 얻을수 있다.

“로보트 매니퓰레이터와 같은 복잡한 비선형 시스템을 제어함에 있어서도 입력 패턴을 기능별로 모듈화하여 병렬로 연결하거나 상호 연결한다면 전체 패턴을 한 가지 신경회로망에서 학습시키는 것보다 더 빠르고 정확하게 학습 가능할 수도 있다”^[12]

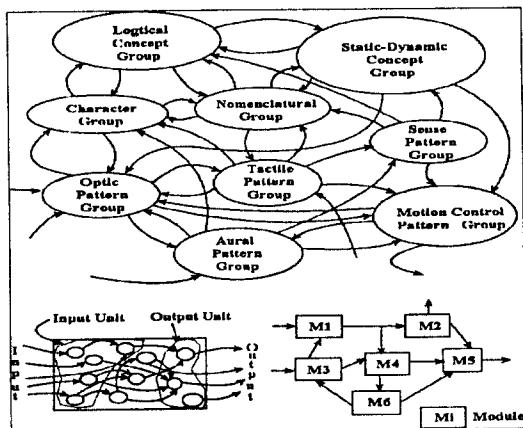


그림 4. 생물학적 신경조직의 모듈 구조

Fig. 4. The Module of Biological Nervous Structure.

2. 연결강도 학습 방향에 따른 패턴 식별

신경제어기의 입력 뉴런에 인가되는 입력은 조인트 1,2,3의 바람직한 위치와 속도가 사용된다. 우리가 하나의 동작을 제어함에 있어 샘플링 시간이 0.005초라고 하고 한 동작이 이루어지는 시간을 5초라 가정하면 전체 입력 패턴은 1000개의 패턴으로 이루어 질수 있으며 로보트 매니퓰레이터가 상당히 복잡하고 다양한 형태의 비선형성을 내포하고있는 복잡한 수학적 시변 시

스템이므로 신경제어기가 로보트 매니퓰레이터를 매핑하는데는 상당한 횟수의 학습이 필요할 것이다. 또한 신경회로망은 로보트 매니퓰레이터의 복잡한 매핑을 이루어야 하기 때문에 일반적인 BP 구조에서는 상당한 수의 중간층 뉴런수가 필요할 것이나 이는 앞에서 설명한 많은 문제점들을 야기시킬 수 있다.

로보트 매니퓰레이터는 복잡한 수학적 모델로 표현되는 강한 비선형성을 내포하고 있기 때문에 연결 강도가 서로 다른 방향으로 학습하는 많은 패턴으로 식별될수 있다.

본 논문에서 실제 로보트 매니퓰레이터에 적용시키기기에 앞서 3 자유도 수직 다관절 로보트 매니퓰레이터의 시뮬레이션(Simulation)을 통해 같은 학습 방향을 가지는 패턴을 식별해 보았다. 조인트 1,2,3의 위치, 속도, 가속도에 따라 +와 -의 부호로 나눌 경우 총 패턴의 수는 2^9 개라고 할수 있다. 상당히 많은 패턴이므로 이중에서 거의 비슷한 학습 방향을 가지는 것을 식별하기 위하여 먼저 위치와 속도와 가속도에 따라 패턴을 식별하여 학습시켰을 때의 연결 강도 학습방향을 알아보았다.

표 1. 식별 패턴별 연결 강도의 변화

Table 1. The Change of Weights on Recognized Patterns.

조 인트 패턴	위 치	속 도	가 속 도			
				1	2	3
1	동일 부호	동일 부호	+ + -	+ + -	- - -	각 패턴별로 연결 강도의 학습 방향 이 큰 차이가 없 었음
2	동일 부호	+ + -	+ + -	동일 부호	- - -	각 패턴별로 연결 강도의 학습 방향 이 큰 차이를 보 이고 있음
3	+ + +	+ - -	동일 부호	동일 부호	- - -	각 패턴별로 연결강 도의 학습방향이 1 번보다는 차이가 있 았지만 2번에 비해 큰 차이는 없었음

표 1은 그결과를 나타낸 것이다. 본 논문에서는 학습 방향이 크게 다르지 않은 위치와 가속도에 대해서는 서로 충분히 결충하여 서로에 적합한 해를 구할수 있다고 가정하여 유사한 방향성을 가진 같은 종류의 패턴으로 식별하였다.

신경 제어기에 인가되는 입력패턴중 같은 종류의 패

턴으로 식별하기 위해 조인트 1,2,3의 바람직한 속도 θ_{d1} , θ_{d2} , θ_{d3} 를 중심으로 식별하면 아래의 표2 와 같다.

표 2. 조인트 각속도에 의한 패턴의 식별
Table 2. Recognition of Patterns by Joint Angle Velocity.

패턴	θ_{d1}	θ_{d2}	θ_{d3}
1	+	+	+
2	+	+	-
3	+	-	+
4	+	-	-
5	-	+	+
6	-	+	-
7	-	-	+
8	-	-	-

서로 학습 방향이 비슷한 패턴끼리 학습하도록 하고, 서로 학습 방향이 다른 패턴은 별도로 학습시키는 모듈별 학습방법을 사용하고, 각 모듈은 서로 병렬로 연결한다면 학습해야 할 전체 패턴의 수가 식별될 수 있으므로 각 모듈의 중간층의 수를 줄여도 충분히 학습이 가능하며, 중간층의 수를 줄임으로서 Local Minimum의 수를 감소시켜 오차가 0(Zero)에 더 접근할 수 있을 것이다. 또한 병렬로 연결됨으로서 전체 연결 강도의 수의 합은 증가하겠지만, 학습에 참여하는 연결 강도는 항상 적은 수를 가질 수 있으므로 신경회로망의 복잡도는 상당히 감소되어 일반화 특성은 증가하고, 이에 따라 한 동작을 학습한 후에는 학습하지 않은 비슷한 패턴을 추종할 수 있는 능력은 증가될 것이다.

3. 패턴 식별 모듈 신경회로망

패턴 식별 모듈 신경 제어기는 제어 대상 시스템이 복잡한 수학적 입출력 관계를 가지고 상당히 많은 입력 패턴을 가지고 있을 때 사용되며 표 1과 2에서 살펴 본 각 식별 패턴들을 각각 학습시키기 위하여 식별 패턴마다 별도로 다층 신경 회로망을 두고 병렬로 연결해 학습시켜 식별 패턴마다 자기 고유의 학습방향을 가지도록 하는 방식이 제안된다.

그림 5는 패턴 식별 모듈 신경 회로망의 구조를 나타낸다.

패턴 식별 모듈 신경 제어기는 인간의 뇌구조에서의 신경 조직과 흡사한 면을 가지고 있는데, 3-1절에서 설명한 바와 같이 인간 신경조직은 모듈과 군 구조로 되어 있으며 하나의 뉴런의 결합수는 제한되어 있으며 하나의 군에 있는 뉴런은 다른 군에서의 뉴런의 학습에 영향을 미치지 않고 별도로 학습하며 병렬 연결되거나 직렬연결되는 상호 결합성을 가질 뿐이다. 인간이 오른쪽을 학습하는 것과 왼쪽을 학습하는 것이 다르게 되어 있으며 단지 소뇌에 병렬로 연결되어 있는 것과 같이, 패턴 식별 모듈 신경 회로망도 속도의 0(Zero)을 중심으로 오른쪽과 왼쪽으로 나누어 병렬로 학습시키는 방법을 이용하고 있는 것이다.

패턴 식별 모듈 신경회로망은 다음의 3가지 부분으로 구성된다.

- 1) 병렬 다층 신경 모듈
- 2) 패턴 식별 퍼셉트론
- 3) 식별 패턴 출력층의 세가지 부분이다.

여기서 i 는 출력층의 수(3자유도 로보트 매니퓰레이터인 경우 $i=3$)를 의미하며 MLP는 다층 퍼셉트론을 의미한다.

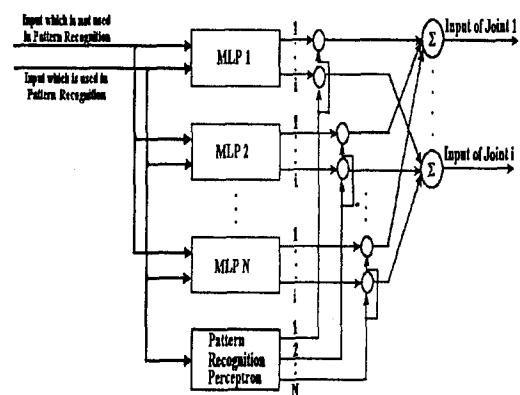


그림 5. 패턴 식별 모듈 신경회로망

Fig. 5. Pattern Recognition Module Neural Network.

1) 병렬 다층 신경 모듈

병렬 다층 신경 모듈은 일반 다층 퍼셉트론이 병렬 연결되는 구조인데, 각각의 퍼셉트론은 패턴 식별 퍼셉트론에 의해 식별된 구별 패턴만을 학습하게 된다.

병렬 다층 신경 모듈 부분의 입력은 일반 다층 퍼셉-

트론과 동일하며 단 디층 퍼셉트론의 수 N 은

$$N = 2^n$$

여기서 n 은 패턴 식별에 사용되는 입력의 수

2) 패턴 식별 퍼셉트론

패턴 식별 퍼셉트론은 패턴 식별에 사용될 입력들이 N 개라면 각 입력들이 +와 -로 구성되므로 2^N 개의 식별 신호를 만들어 주는 퍼셉트론이다.

식별신호는 일종의 디코더(Decoder) 출력으로서 2개의 식별용 입력이라 할 때 다음의 수식으로 표현된다.

$$s_1 = \operatorname{sgn}(x_1) \cdot \operatorname{sgn}(x_2)$$

$$s_2 = \operatorname{sgn}(x_1) \cdot \operatorname{sgn}(-x_2)$$

$$s_3 = \operatorname{sgn}(-x_1) \cdot \operatorname{sgn}(x_2)$$

$$s_4 = \operatorname{sgn}(-x_1) \cdot \operatorname{sgn}(-x_2)$$

여기서 x_1, x_2 는 입력, s_1, s_2, s_3, s_4 는 식별신호

이를 그림으로 나타내면 그림 9와 같다.

패턴 식별 퍼셉트론은 두 부분으로 구성되는데 하나는 부호판별층이고 다른 하나는 승산기 부분이다. 전단에서의 $A'(x), B'(x)$ 는 활성함수로서 다음과 같다.

$$A'(x) = \operatorname{sgn}(x)$$

$$B'(x) = \operatorname{sgn}(-x)$$

부호판별층과 승산기 사이의 연결선은 단지 활성함수의 출력값만을 연결해주는 역할을 한다.

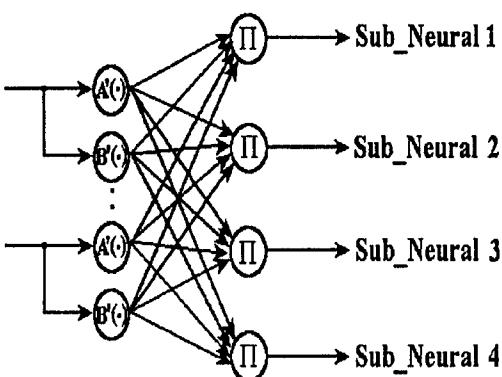


그림 6. 패턴 식별 퍼셉트론

Fig. 6. Pattern Recognition Perceptron.

3) 식별 패턴 출력층

이 부분은 승산기와 가산기로 구성되는데 병렬로 연결된 출력층과 패턴 식별 퍼셉트론을 승산해줌으로서 해당 패턴에 대한 출력층만이 선택되도록 하는 층이다.

학습은 선택된 연결 강도만이 학습에 참여함으로서 각 패턴이 식별가능하다. 학습방법은 선택된 연결 강도에 한하여 BP 방법에 의해 행하여 진다.

IV. 로보트 매니퓰레이터와 제어 시스템 구성

1. 제어대상 로보트 매니퓰레이터의 제원

제어 대상 로보트 매니퓰레이터는 캐나다에서 제작된 6축의 다관절로 이루어진 산업용 및 교육용 로보트 매니퓰레이터이다. 그림 7은 본 논문에서 제어하고자 하는 로보트 매니퓰레이터인 CRS A460의 외관이다.

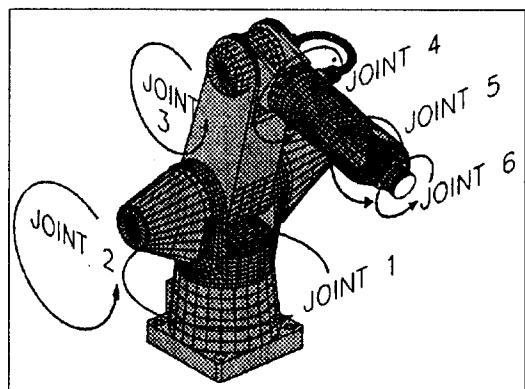


그림 7. A460 로보트 매니퓰레이터

Fig. 7. A460 Robot Manipulator.

각 조인트는 하모닉 드라이브(Harmonic Drive)를 이용하여 감속하며 1, 2, 3축이 100 : 1의 감속비를 가진다. 3번째 조인트는 벨트를 이용해 3번째 링크에 동력을 전달하며 본 논문에서는 1, 2, 3축만을 제어한다. 조인트 1, 2, 3의 전동기중에서 2, 3의 전동기는 자체 브레이크(Brake)를 내장하고 있으며 동작시 브레이크를 풀어주고 동작 완료시 걸어주어야 한다. 브레이크는 25V에서 온-오프된다.

2. 제어 시스템 구성

본 논문에서는 로보트 매니퓰레이터의 위치 제어를 위해 IBM-PC 386을 이용하여 제어기를 구성하였으며, PC와 로보트 매니퓰레이터 시스템 간의 매개 역할을 할 수 있도록 인터페이스 회로를 제작하여 실험에 사용하였으며 이들의 동작을 살펴보면 다음과 같다.

제어 시스템의 중심 역할을 담당하는 IBM-PC에서는 제어 프로그램의 작성과 실행 그리고 수정 작업과

제어가 이루어지며, 프로그램의 실행 결과를 그래픽 처리하여 PC의 모니터에 출력될 수 있도록 한다. 프로그램 가능 타이머인 8253에서는 매 5 msec의 샘플링 시간마다 인터럽트(Interrupt) 신호를 발생시키며, PC는 이에 따라 로보트 매니퓰레이터 전동기 회전축의 각변위를 측정하게 된다. 또한 로보트 매니퓰레이터의 내부의 전동기의 구동 펄스인 PWM 파형도 8253의 출력 포트를 통해서 출력된다.

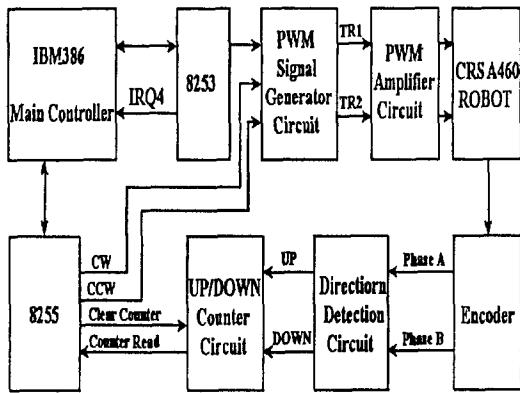


그림 8. 로보트 매니퓰레이터 위치 제어 시스템의 구성도

Fig. 8. Block Diagram of Position Control System for Robot Manipulator.

PWM 증폭기를 통해 로보트 매니퓰레이터의 전동기가 회전하게 되면 그때의 로보트 매니퓰레이터의 위치는 엔코더(Encoder)의 출력 펄스를 방향 판별이 가능한 과정들로 바꾼 후에 그 펄스의 갯수를 UP/DOWN 카운터를 통해 계수함으로서 검출할 수 있다. 엔코더의 펄스 계수는 역시 방향 판별 회로의 UP/DOWN 카운터를 통해 이루어지며 그 결과는 매 샘플링마다 8255로 전달되는데 조인트마다 12 bit로 계수하게 된다. 로보트 매니퓰레이터의 조인트 1,2,3의 각 전동기의 엔코더는 1회전당 1000펄스를 출력하므로 8bit 계수 할 경우 빠른 속도의 경우 펄스 계수이 불가능하여 제어 불가능 상태가 발생할 수 있다. 병렬 입출력 장치인 8255에서는 카운터에 초기 클리어(Clear) 신호를 가해 주는 일과, 카운터의 계수된 값을 읽어내는 역할을 하며 또한 PWM 신호 발생기의 정방향 회전과 역방향 회전에 대한 방향 지령도 출력하게 되며 또한 브레이크 제어신호를 출력하고, 4개의 8255 PPI, 3개의 8253이 사용되었다.

또한 본 논문에서는 로보트 매니퓰레이터를 구동하기 위한 증폭 회로로서 펄스폭 변조(Pulse Width Modulation, 이하 PWM) 방식을 사용하였으며 양방향성 모드로 동작시켜 +방향과 -방향을 동시에 제어 할수 있도록 하였다.

V. 실험 결과

본 논문에서 제시된 모듈 신경 제어기의 성능을 평가하기 위하여 직접 3 자유도의 수직 다관절 로보트 매니퓰레이터의 학습 위치 제어가 실행되었다. 본 논문의 제어 방법은 로보트 매니퓰레이터를 블랙 박스로 보고 제어하므로 로보트의 동적 모델링은 필요하지 않다.

본 논문에서 제시된 방법의 유용성을 알아보기 위하여 기존 방법과 비교하였는데 비교를 위한 궤적은 XY 좌표상에서 반지를 7cm의 원을 그리도록 하였으며 그 궤적 조건은 다음과 같다.

$$\begin{aligned}
 x_d &= 0.485 + 0.07 \cdot \sin\left(\frac{\pi}{3} \cdot t\right) \\
 y_d &= 0.07 \cdot \cos\left(\frac{\pi}{3} \cdot t\right) \\
 z_d &= 0
 \end{aligned} \quad (14)$$

원 지름 : 14cm

샘플링 시간 : 5 msec

총 샘플링 갯수 : 1200 개

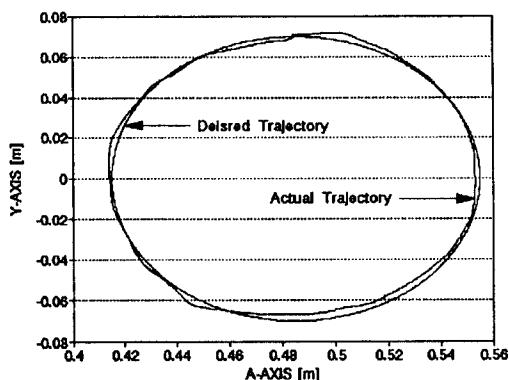
총 시간 : 6초

1. 기존 BP 신경제어기와 모듈 신경제어기의 비교실험

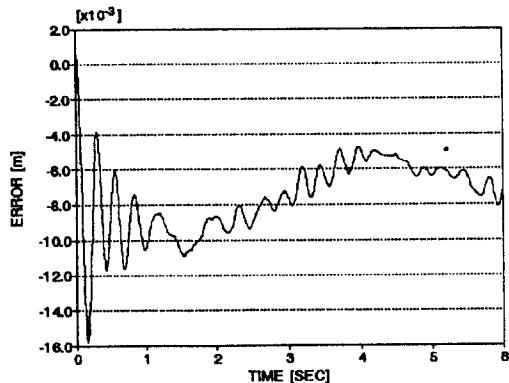
그림 9는 PD 제어기만을 사용했을 때의 결과를 나타낸 것이다. PD 제어기만으로 제어할 때 전체적으로 큰 오차가 나타나고 있음을 알수 있다.

그림 10은 연결 강도의 증가에 따른 학습 오차의 변화를 나타내고 있으며 식(15)에서 나타난 원 궤적을 50회 학습시킨 결과이며, 표 3은 일반적인 BP 신경제어기의 각종 계수값들을 나타내고 있으며 두개의 중간층을 가진 신경 회로망을 사용하고 있다. 중간층 뉴런수 증가에 따른 영향을 알아보기 위하여 1)번과 2)번의 뉴런수를 가진 신경 회로망이 사용되며 1)번과 2)번이 동일한 계수를 사용하도록 하였다. 활성함수는 Scott의 활성함수를 사용한다.

중간층 뉴런수가 많은 것이 조인트 2와 3에서 오차가 더 빨리 줄어들기는 하나 어느 정도의 불안정성을 가지는 것을 알수 있다.



(a) XY평면에서의 원 궤적

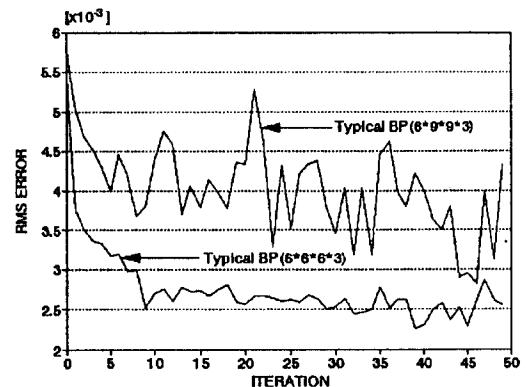


(b) Z평면에서의 궤적(오차)

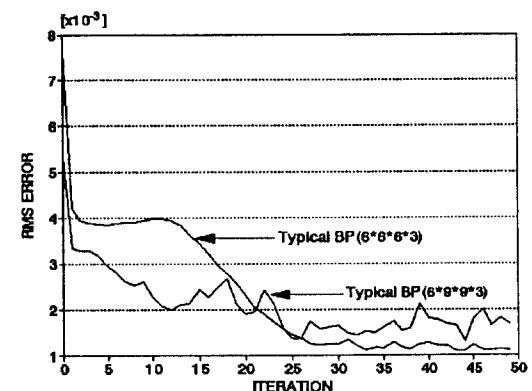
그림 9. PD 제어기만을 사용했을 때의 궤적
Fig. 9. The Trajectory When using PD Controller only.

연결 강도가 늘어나면 초기치의 값을 줄여주어야 하며 활성함수의 값도 줄여주어야 하고 학습률 및 모멘텀 계수등도 전부 줄여 주어야 하는데, 본 실험에서는 표 3의 1)번과 2)번을 같은 계수들을 가지고 실험하였다.

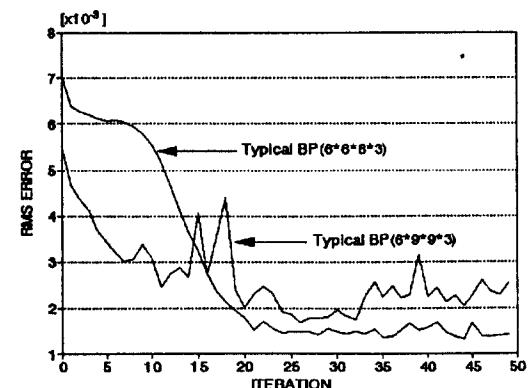
물론 6,9,9,3의 경우 학습률,모멘텀 계수와 활성함수의 기울기등을 조절해주면 그림 6-2에서 나타난 것보다 상당히 좋은 결과를 보이며 거의 수렴 오차가 6,6,6,3의 경우와 비슷해 지지만 약간의 계수 조정에도 민감하게 반응하며. 특히 활성함수의 기울기가 약간만 변화해도 상당한 불안정성을 가지는 것을 본 논문의 그림으로 나타내지는 않았지만 실험과정에서 얻은 결론이다.



(a) 조인트 1의 학습 RMS 오차



(b) 조인트 2의 학습 RMS오차



(c) 조인트 3의 학습 RMS오차

그림 10. 일반적 BP 신경제어기의 중간층 뉴런수 증가에 의한 학습 RMS오차 비교
Fig. 10. The Comparison of Learning RMS Error with Increasing the Number of Neuron in Hidden Layer of Typical BP Neural Controller.

표 3. 일반적인 BP 신경 제어기의 계수

Table 3. The Coefficient of Typical BP Neural Controller.

	입력총	중간총1	중간총2	출력총
뉴런 수	1) 6 2) 6	6 9	6 9	3 3
입 력	바람직한 조인트 위치 1,2,3 바람직한 조인트 속도 1,2,3			
학 습 률	0.006			
모멘텀 계수	0.008			
활성함수 기울기	1.0			
비례 계수	800			
미분 계수	100			

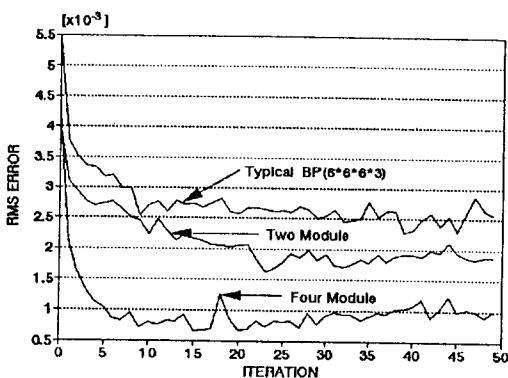
중간층 증가에 따른 연결 강도의 수는 다음과 같다.

$6 \times 6 \times 6 \times 3 : 90$ 개의 연결 강도 수

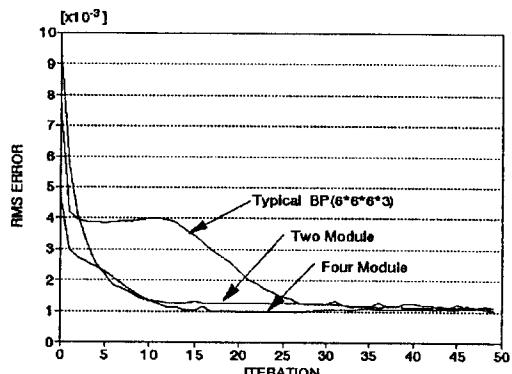
$6 \times 7 \times 7 \times 3 : 112$ 개의 연결 강도 수

$6 \times 9 \times 9 \times 3 : 162$ 개의 연결 강도 수

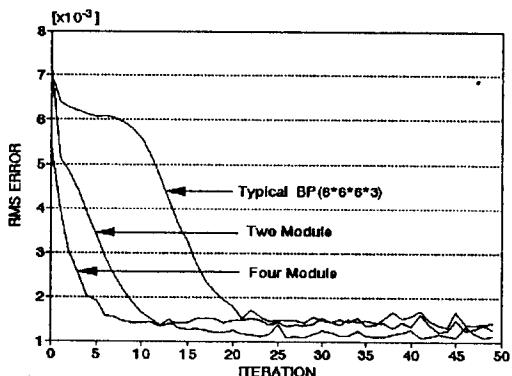
2개의 중간층이 사용될 경우 각 중간층에서 2개씩의 뉴런이 증가해도 연결 강도의 수는 1.8배 정도로 크게 증가한다. 연결 강도의 증가는 주어진 해에 접근할 수 있는 방법이 기하급수적으로 증가하므로 빠르게 수렴할 수 있는 조건이 되지만 해를 구할 수 있는 방법의 수를 증가시켜 Local Minima를 증가시키고 일반화 특성을 감소시켜 큰 오차에 수렴하게 하는 단점을 지니게 된다.



(a) 조인트 1



(b) 조인트 2



(c) 조인트 3

그림 11. 일반적 BP 신경 제어기와 패턴 식별 모듈 신경 제어기의 학습 RMS오차 비교

Fig. 11. The Comparison of Learning RMS Error Between Typical BP Neural Controller and Pattern Recognition Module Neural Controller.

그림 11은 일반적인 BP 방법과 패턴 식별 모듈 신경 제어기의 50회 학습 RMS 오차를 비교한 것이다. 비교 대상 케이스는 식(14)의 원 케이스이며 각 신경 회로망의 조건은 표 4에서 나타내었다. 패턴 식별 모듈 신경 제어기의 경우에서 패턴 식별을 각 조인트의 속도로 할 경우에 최대 8개의 패턴으로 나눌 수 있으나 본 논문에서는 실제 병렬 처리를 하는 것이 아니고 샘플링 시간내에서 직렬 계산 처리하여 제어하므로 표 4와 같이 2개와 4개로 나누어 구성법 1과 2로 표현하였다.

그림 11에서 보는 바와 같이 병렬로 나누어 학습시킨 모듈 제어기가 자기 패턴만 학습하게 되므로 자기 자신의 고유 방향을 가지고 빠르게 학습하게 됨을 보

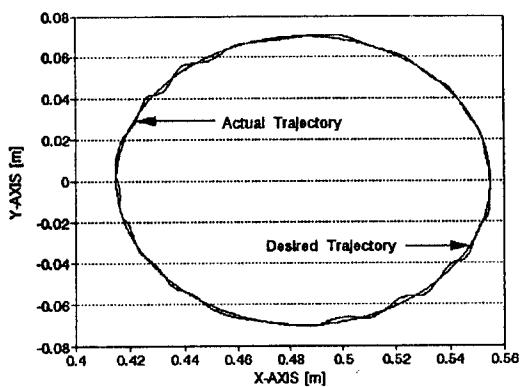
여주고 있다. 그림에서 보면 조인트 1, 2, 3이 모두 10 번만에 일정 오차에 수렴하는 것을 볼 수 있으며, 조인트 1의 경우 일반적인 BP 방법보다 상당히 적은 오차에 수렴하고 있다는 것을 볼 수 있다.

조인트 1은 조인트 2와 3의 움직임에 따라 관성과 원심력등의 영향을 많이 받게 되어 가장 제어하기 어려운 부분이므로 전체 패턴에 대한 평균 학습을 해야 하는 BP 신경 제어기의 경우 큰 오차를 보이게 된다.

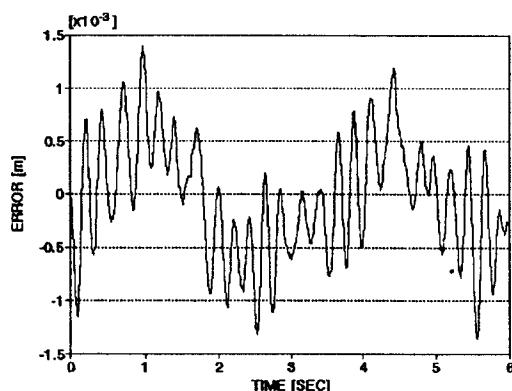
표 4. 일반적 BP제어기와 모듈 신경 제어기의 계수 및 패턴 식별

Table 4. The Coefficients of Typical BP Controller and Module Neural Controller, and Pattern Recognition.

	일반적 BP	구성법 1 (2 모듈)	구성법 2 (4 모듈)
뉴런수	6 6 6 3	$2 \times (6 6 6 3)$	$4 \times (6 6 6 3)$
패턴 분리		$\theta_1, \theta_2, \theta_3$	$\theta_1, \theta_2, \theta_3$
	1	+ + + + - + + + - + - -	1 + + + + - +
	2	- + + - - + - + - - - -	2 + + - + - -
			3 - + + - - +
			4 - + - - - -
비례-미 분 계수	표1과 동일	표 1과 동일	표 1과 동 일
학습률 모멘텀 계수	"	"	"
활성 함수, 기울기	"	"	"



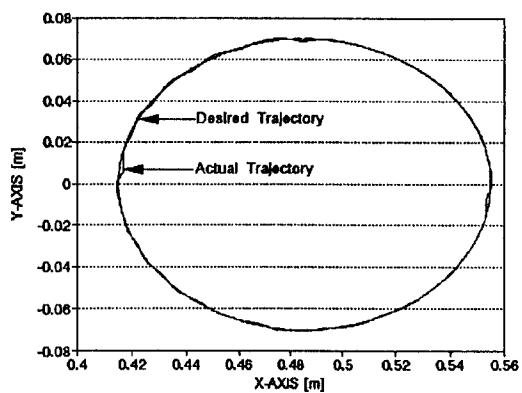
(a) XY평면에서의 원



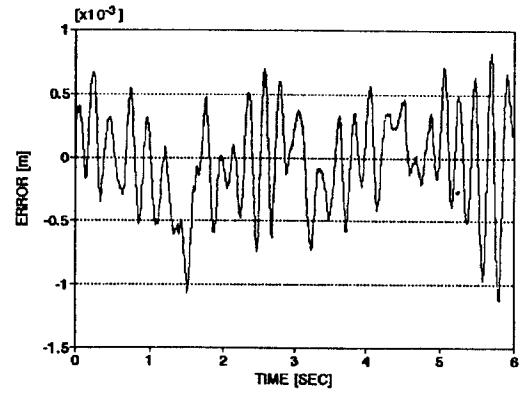
(b) Z축 오차

그림 12. 일반적인 BP신경 제어기의 직각 좌표상의 궤적과 오차

Fig. 12. The Trajectory and Errors with Typical BP Neural Controller at Cartesian Coordinates.



(a) XY평면에서의 원



(b) Z축 오차

그림 13. 패턴 식별 모듈 신경 제어기의 직각 좌표상에서의 궤적과 오차

Fig. 13. The Trajectory and Errors with Pattern Recognition Module Neural Controller at Cartesian Coordinates.

그림 12는 일반적인 BP신경 제어기의 직각 좌표상에서의 50번 학습후 오차와 위치에 대한 그림이다. 그림 13은 패턴 식별 모듈 신경 제어기에 대한 그림이다. 이 후에 사용된 모든 패턴 식별 모듈 신경제어기는 모두 4 모듈을 사용하고 있다. 두 그림에서 보면 패턴 식별 모듈 신경 제어기가 원 궤적을 거의 완벽하게 추종하고 있음을 알수 있다. 다만 신경 회로망이 바뀌는 부분에서 약간의 오차가 생기는 것을 알수 있다.

x,y,z축의 오차도 거의 일반적인 BP신경 제어기보다 훨씬 적은 오차를 보이고 있음을 알수 있다. z축의 최대 오차가 0.0005m 정도이므로 이는 0.5mm정도에 해당하므로 거의 무시할수 있는 오차에 가깝다. 직각 좌표계상의 값은 각 조인트 전동기에서의 엔코더 출력을 받아 오프-라인(off-line)으로 변환시켜 나타낸 값이다.

표 5는 그림 12와 13에서 나타난 직각 좌표계상에서의 일반적인 BP 신경 제어기와 패턴 식별 모듈 제어기의 오차를 RMS 오차로 표시하였다.

표 11. 50번 학습 후 직각 좌표상에서의 RMS 오차 비교

Table 11. The Comparoson of RMS Errors at Cartesian Coordinates After Learning.

	X축 오차	Y축 오차	Z축 오차
일반적 BP	0.000341	0.00124	0.000556
패턴 식별 모듈	0.000343	0.00044	0.000382

2. 일반화 특성

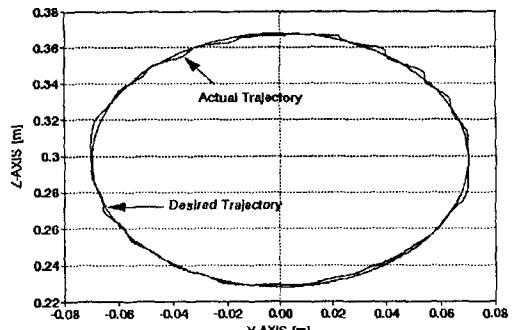
신경 회로망의 고유 특성중에서 가장 중요한 성질은 일반화 특성이라 할수 있다. 일반화 특성은 어떤 한 패턴을 학습 한 후에 비슷한 다른 패턴을 큰 오차없이 제어할수 있다는 특성인데, 본 논문에서는 일단 식 (3)으로 표현된 원 궤적을 50번 학습시켰으며 학습이 끝난 후에 연결 강도를 고정시켜 다른 궤적을 학습시켜 보았다.

식(3)으로 표현된 궤적을 학습한 후에 연결 강도를 고정시켜 2가지의 궤적을 동작시켜 보았는데 궤적의 선택은 가능한 학습한 궤적과는 어느 정도 다르게 선택하였으며 아래와 같다.

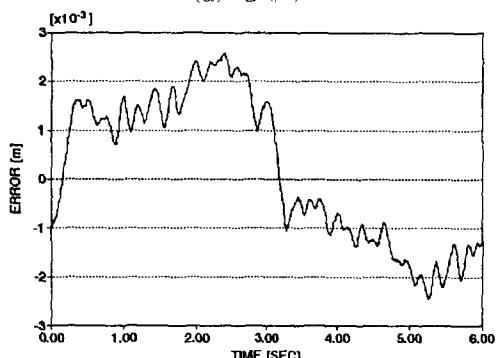
1) 궤적 1 : 다른 원 궤적

$$\begin{aligned}x_d &= 0.36 \\y_d &= 0.2 \cdot \sin\left(\frac{\pi}{3} \cdot t\right) \\z_d &= 0.298 + 0.07 \cdot \cos\left(\frac{\pi}{3} \cdot t\right)\end{aligned}\quad (15)$$

2) 궤적 2 : 궤적 계획법을 사용하여 약 600g의 부하를 달고 아래의 위치로 5초에 이동
 $(0^\circ, 0^\circ, 90^\circ) \rightarrow (57.3^\circ, 40.1^\circ, 45.84^\circ) \rightarrow (0^\circ, 0^\circ, 90^\circ)$



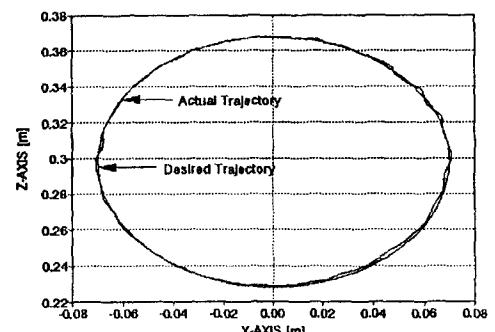
(a) 원 궤적



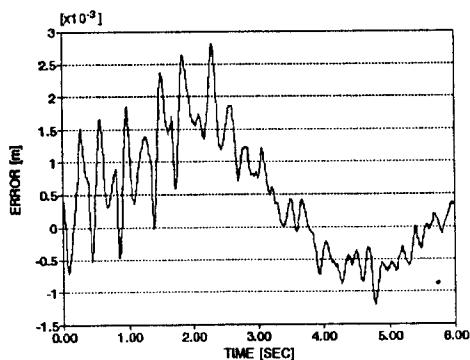
(b) z축 위치 오차

그림 14. 학습 후 궤적 1의 추종 (일반적 BP 신경 제어기)

Fig. 14. The Tracking of Trajectory 1 after Learning.
(Typical BP Neural Controller)



(a) 원 궤적



(b) z축 위치 오차

그림 15. 학습 후 궤적 1의 추종 (패턴 식별 모듈 신경 제어기)

Fig. 15. The Tracking of Trajectory 1 after Learning.
(Pattern Recognition Module Neural Controller)

그림 14와 그림 15는 일반적인 신경제어기와 제안한 패턴 식별 모듈 신경 제어기에 의한 원 궤적의 추종을 비교한 그림이다. 그림 14와 그림 15 둘다 학습 한 적이 없는 궤적이기는 하지만 어느 정도 잘 추종하고 있음을 볼수 있다. 하지만 그림 5-9의 경우가 좀 더 정확한 원에 추종되고 있음을 볼 수 있다.

로보트 매니퓰레이터는 조인트 1, 2, 3중에서 조인트 1이 다른 조인트들 보다 더 복잡한 식으로 구성되는 관성 및 가속도등의 영향을 가장 크게 받는 시스템이므로 패턴 식별 모듈 신경 제어기가 로보트 매니퓰레이터의 동 특성을 더 잘 학습했다고 사료되며 더 좋은 일반화 특성을 가졌다고 생각된다. 그림 15은 입력 패턴이 바뀌는 시간 구간에서, 4개의 패턴 식별뉴런에 의해 스위칭되므로 각 패턴에 대해 학습한 연결 강도가 일반적인 BP신경제어기처럼 과도기적인 학습에 의해 변화함이 없이 그대로 사용되므로 전체적으로 안정하게 궤적을 추종함을 볼수 있다.

표 6은 부하에 관한 일반화 특성을 알아보기 위한 실험으로 일단 원 궤적을 부하없이 50번 학습시킨 후에 거의 학습한 적이 없는 궤적 계획법에 의한 패턴을 600g의 부하를 달고 5초에 동작시킨 것으로 역시 일반적인 BP 신경 제어기와 제안된 패턴 식별 모듈 신경 제어기의 일반화 특성을 비교한다. 이 실험에서도 두 가지 제어기구조 모두 궤적을 잘 추종함을 알수 있으나, 제안한 제어기가 조인트 1과 3에서 더 좋게 추종함을 알수 있다.

표 6. RMS 오차 비교 (궤적 3)

Table 6. The Comparison of RMS Error.
(Trajectory 3)

궤적 2	조인트 1 오차	조인트 2 오차	조인트 3 오차
일반적 BP	0.007411	0.004782	0.007732
폐던 식별 모듈	0.007329	0.005201	0.005702

VI. 결 론

기존의 신경 제어기의 문제점을 개선시키기 위해 다층 신경망으로 구성되고 BP 알고리듬에 의해 학습하는 신경 회로망의 내부 연결 강도가 입력 패턴에 대하여 어떤 방향으로 학습하는가 하는 학습 방향을 분석하여 패턴 식별 모듈 신경 제어기를 설계하였으며 적용 가능성을 증명하기 위해 로보트 매니퓰레이터에 직접 적용하여 실험하였다.

로보트 매니퓰레이터는 상당히 복잡한 출력 관계를 가지고 있으며 공간상에서 위치 궤적과 속도 궤적에 대하여 무한대에 가까운 많은 입력 패턴이 존재하고 있다. 제어 대상 시스템이 복잡한 수학적 관계를 가지고 있거나 많은 입력 패턴을 학습해야 할 경우에 신경 회로망은 여러가지 경우의 패턴에 대한 평균 학습이 필요하므로 중간층 뉴런수의 증가는 필연적이다. 그러나 앞에서 설명된 많은 이유로 많은 패턴 수에도 불구하고 중간층의 뉴런 수를 일반적인 BP방법을 사용하는 신경 제어기에서는 계속 증가시켜줄 수는 없는 일이다.

본 논문에서는 이러한 Trade-Off문제를 해결하고 빠른 수렴 속도를 얻기 위해 패턴 식별 모듈 신경 제어기를 제안했다. 제안된 패턴 식별 모듈 신경 제어기는 많은 패턴에 대해 중간층 수를 늘려 주는 것이 아니라 유사한 학습 방향을 가지는 패턴을 식별하여 비슷한 학습 방향을 가지는 패턴들은 하나의 신경회로망에서 학습시켜주고 다른 학습 방향을 가지는 패턴들은 다른 신경회로망에서 학습시켜주며, 각 신경 회로망은 별별로 연결시켜 주어 패턴별 학습을 시키는 방법을 사용하였다. 본 논문에서는 속도 궤적에 따라 패턴을 식별하였으며, 패턴의 식별은 패턴 식별 퍼셉트론이 사용된다.

각 신경 제어기는 전체 패턴중에서 유사한 학습 방향을 가지는 패턴부분만 학습하면 되므로 많은 중간층 뉴런수를 가질 필요가 없어 상대적으로 적은 수의 뉴런수를 사용할수 있으며, 전체 신경 제어기가 병렬 연결되어 있으므로 실제 학습에 참여하는 연결 강도의 수는 각 신경 제어기의 수만큼 밖에 되지 않는다. 그러므로 중간층 뉴런수가 증가되지 않고 많은 패턴을 학습시킬수 있으며 유사한 학습 방향의 패턴만을 학습하므로 자기 학습 방향의 연결 강도로만 학습되어 상당히 적은 오차에 수렴할수 있으며 빠른 학습이 가능한 방법이다.

로보트 매니퓰레이터의 실제 적용 실험에서, 기존의 신경 제어기보다 제안된 신경 회로망을 가진 제어기가 더 적은 오차를 나타내었으며, 상당히 빠른 학습 수렴 속도를 가짐을 볼수 있었다. 50회 정도의 학습이면 거의 바람직한 궤적을 추종하는 것을 볼 수 있었으며 또한 50회 학습 후 연결 강도를 고정시키고 학습한 패턴과는 다른 원 궤적 패턴과 빠른 속도, 부하등에 대한 제어 실험에서도 큰 오차없이 잘 동작함을 볼수 있었다. 즉 일반화 특성 문제에서도 좋은 성능을 가짐을 알수 있었다.

특히 본 논문에서는 실제 로보트 매니퓰레이터에 적용한 실험이므로 제안된 신경 회로망이 실제 로보트에 적용 가능함을 알수 있었으며, 현재의 로보트 매니퓰레이터에 큰 설계의 변경이 없이 적용될수 있기 때문에 실제 로보트 매니퓰레이터를 동작시키는데 있어 현실적이고 편리하게 적용될수 있을 것이다.

위의 연구 결과를 바탕으로 향후 연구되어야 할 부분들은 다음과 같다.

- 1) 유사한 학습 방향을 가지는 패턴들의 보다 세밀한 분류와 식별을 위해 보다 많은 실험과 다양한 방법으로 실험이 이루어져야 한다.
- 2) 부하에 대한 강인성(Robustness)을 가지게 하기 위하여 더 많은 부하 실험이 이루어 져야 하며 더 좋은 일반화 특성을 위해 많은 궤적 패턴에 대한 실험이 필요하다.
- 2) 신경 회로망이 바뀌는 부분에서 나타나는 큰 오차의 문제를 해결해야 한다.

참 고 문 헌

- [1] D. E. Romehart, J. McClelland, "Parallel Distributed Processing", MIT Press, 1988
- [2] Miller, Sutton, and Werbers, Edotors, "Neural Networks for control" . The MIT Press, 1980
- [3] G.Josin, D.Chatny and D.white, " Robot Control using neural network", IEEE 2nd Int. Conf. on neural network, Vol 2 pp. 625-631,July,1988
- [4] M.Kawato, H.Miyamoto, T.Setoyama and R.suzuki," Feedback Error Learning Neural Network for Trajectory Control of a Robotic Manipulator",Neural Networks, Vol 1, pp. 251-265, 1988
- [5] W. Scott and Stornetta, "An Improved Three-layer, Back-Propagation Algorithm". IEEE 1st Int.Conf.on Neural Network, Vol 2 pp. 637-643 June, 1987.
- [6] J.Chen and P. Mars, "Stepsize Variation Methods for Accelerating the Back- Propagation Algorithm, IJCNN, Vol 1, pp I-601-I-634, 1989
- [7] J.M.Zurada , " Introduction to Artificial Neural systems ", West publising co., 1992
- [8] D.Nguyen and b.Widrow, "Improving the learning speed of 2-Layer Neural Network by Choosing Initial Values of the Adaptive Weight", IJCNN, San Diego, California, Vol 3,pp 21-26, June, 1990
- [9] T.Kohonen, "Self-organization and association Memory." Springer Verlag, 1984
- [10] H. Ritter, T. Marhnetz and K. Schulten, "Neural Computation and Self -organizing Maps.", Addison-Wesley Publishing company, 1991.
- [11] A. Waibel ,H. Sawai ,and K. shikano , "Modularity And Scaling in Large Phonemic Neural Network.", IEEE Trans. on Account speech, Signal Processing Vol.37, pp. 1888-1897, Dec. 1989.

- [12] F. Nadi, "Topological Design of Modula Neural Networks.", Artificial Neural Networks Vol.1 pp. 213-218, 1991.
- [13] T.Fukuda and T.shibara,"Theory and Application of Neural Network for Industrial Control Systems ", IEEE Trans. on Industrial Electronics Vol. 39, No. 6, pp. 472-489, Dec. 1992.
- [14] D.Ottoson."Phisiology of the Nervous Systems." The Macmillan Press, Ltd., 1983.
- [15] 전홍태 .김종두, "퍼지-신경망 기법을 이용한 로보트 매니퓰레이터의 빠른 학습 제어.", 91 신경망 및 퍼지 시스템 응용 워크샵, pp. 287-300, 1991
- [16] 김정도, 최준성, 정동근, 이택종, "신경제어기를 이용한 DC서보 모터의 위치 제어.", 대한전자공학회 논문집, Vol. 29-B, No. 5, pp. 83-94, 1992
- [17] B.Widrow and S.Stearns,"Adaptive Signal Processing". Prentice-Hall, Inc, 1985.

저자소개



金 正 道(正會員)

1962年 9月 26日生. 1987年 성균관대학교 전자공학과 졸업.
1990年 2月 성균관대학교 대학원 전자공학과 졸업(공학석사).
1994年 2月 성균관대학교 대학원 전자공학과 졸업(공학박사). 1995年 3月 ~ 현재 삼척산업대학교 제어계측공학과 전임강사. 주관심 분야는 로보틱스, 신경망, 퍼지제어, 적응제어 및 마이크로 프로세서 응용 등임.

李 宅 鐘(正會員) 第 29 卷 B 編 第 12 號 參照

현재 성균관대학교 전자공학과 교수