

論文95-32B-12-12

학습 성능의 개선을 위한 복합형 신경회로망의 구현과 이의 시각 추적 제어에의 적용

(Implementation of Hybrid Neural Network for
Improving Learning ability and Its Application to
Visual Tracking Control)

金景敏*, 朴重租*, 朴貴泰**

(Kyong-Min Kim, Joong-Jo Park, and Gwi-Tae Park)

요 약

본 논문에서는 신경회로망의 학습 성능을 개선하기 위한 복합형(hybrid) 신경회로망이 제안되어진다. 자기 조직화 신경회로망 모델의 특성과 역전파 학습방법을 사용하는 다층퍼셉트론 모델의 특성을 결합하여 새로 제안되는 모델은 학습시간의 단축과 학습에의 감소의 장점을 가지고 있다. 제안된 복합형 신경회로망은 학습시 계산 시간을 단축하기 위해 중간층의 노드수를 점차 줄어나가며, 그리고 퍼지 소속값을 사용한다. 이 퍼지값은 중간층에서 각 노드의 반응 범위(responding region)을 학습할 때 사용된다. 본 논문에서는, 제안된 복합형 신경회로망의 효율성을 입증하기 위해 XOR 함수와 3Bit Parity의 부울 대수, 그리고 2축 로보트의 역기구학의 해에 대해 적용하여 기존의 역전파 학습방법(BP)과 비교되어진다. 그리고 끝으로 제안된 신경회로망은 PUMA560 로보트 매니퓰레이터의 시각제어에 적용되어진다.

Abstract

In this paper, a hybrid neural network is proposed to improve the learning ability of a neural network. The union of the characteristics of a Self-Organizing Neural Network model and of multi-layer perceptron model using the backpropagation learning method gives us the advantage of reduction of the learning error and the learning time. In learning process, the proposed hybrid neural network reduces the number of nodes in hidden layers to reduce the calculation time. And this proposed neural network uses the fuzzy feedback values, when it updates the responding region of each node in the hidden layer. To show the effectiveness of this proposed hybrid neural network, the boolean function(XOR, 3Bit Parity) and the solution of inverse kinematics are used. Finally, this proposed hybrid neural network is applied to the visual tracking control of a PUMA560 robot, and the result data is presented.

I. 서 론

* 正會員, 高麗大學校 電氣工學科

(Dept. of Electrical Eng. Korea Univ.)

** 正會員, 高麗大學校 電氣工學科, 서울大學校 ERC-
ACI 研究委員

(Dept. of Electrical Eng. Korea Univ.)

接受日字: 1995年1月20日, 수정완료일: 1995年11月17日

오래전부터 사람들은 인간의 뇌(brain)가 계산하는 능력이 있다고 믿어왔다. 계산하는 능력으로서의 뇌를 보는 관점은 1940년대의 인공두뇌학(Cybernetics)을 발전시키는 계기가 되었으며, 1960년대의 퍼셉트론(Perceptron)과 같은 단순한 형태의 신경망을 연구하

도록하는 촉매가 되었다.

신경회로망은 어떤 문제에 대해서는 기대 이상의 훌륭한 해결점을 제공하였으며 전통적인 인공지능 기법으로 해결할 수 없었던 문제들의 해결 가능성을 보여주었다. 현재 신경회로망 연구의 가장 두드러진 동기는 인간 두뇌의 기능과 유사한 신경회로망이 실현될 것 같은 가능성이다. 그러나 현재의 신경회로망 모델들은 지금까지 많은 발전이 있어 왔지만 실제 인간의 신경 시스템과는 아직까지도 많은 차이가 있다. 신경회로망은 위상(topology), 처리 소자(Processing Element, PE)의 특성, 학습 규칙(learning rule) 등으로 특징지워지며, 많은 간단한 병렬 처리 소자들로 이루어진다^[1]. 신경회로망은 인간의 두뇌구조를 모방한 병렬 분산 처리(Parallel Distributed Processing, PDP)의 원리에 의거하여 임의의 입력력 데이터간의 mapping을 수행하므로 모든 계산을 대치할 수 있으며, 기존의 컴퓨터처럼 방정식이나 정확한 알고리즘에 의존하지 않고 학습 능력과 보간에 의한 일반화 능력에 의존하므로 선형보다는 비선형 함수를 구현하는데 더 유리하다^[2].

일반적으로 대부분의 제어문제는 복잡한 비선형 함수를 계산해야 하지만 입력과 출력의 관계는 명확히 정의되므로 신경회로를 이용한 제어는 기존의 제어방식들의 문제를 해결할 수 있으리라 기대되고 있다. 즉, 기존의 제어방식들은 제어하고자 하는 플랜트의 정확한 모델이 필요하고, 복잡한 제어이론에 의하여 제어기를 설계해야하며, 모델링에 따른 오차를 극복하기 어렵고, 플랜트나 주위 환경의 변화에 적응하기 힘들며, 계산에 많은 시간이 필요하다는 단점이 있다. 그러나, 신경회로망을 이용한 경우에는 신경회로망의 대규모 병렬성과 학습능력에 의해 플랜트의 모델이 거의 혹은 전혀 필요치 않으며, 제어 이론에 관한 지식도 거의 필요하지 않으며, 플랜트나 주의 환경이 변화하는 경우에도 학습에 의하여 적용할 수 있고, 학습에 의하여 제어 성능이 점점 더 향상되며, 병렬성에 의하여 실시간 계산이 가능하며, 정보의 분산저장으로 인하여 일부 소자가 고장이 난 경우에도 제어 성능이 크게 나빠지지 않는 장점이 있다^{[3] [4]}.

본 논문에서는 이러한 신경회로망의 장점을 로보트 매니퓰레이터의 시각 추적 제어에 이용하였다. 로보트 매니퓰레이터의 시각 추적 제어는 로보트의 end-effector를 통하여 취득한 영상으로부터 로보트 매니퓰레이-

터의 현재의 위치와 가고자하는 위치의 편차를 구하여 이를 보상하기 위하여 로보트의 각 관절에 인가할 제어 입력을 구해야 하므로 로보트의 정확한 모델에 의한 비선형 함수를 풀어야 한다. 이 문제는 기존의 제어 이론을 이용할 경우 로보트의 정확한 기구학적 특성을 알아야 하며, 각 로보트에 대하여 설계된 제어기는 단지 그 로보트 모델에만 적용될 수 있으며, 로보트의 자유도가 증가함에 따라 계산시간이 증가하는 단점이 있다. 기존의 신경회로망들 중에는 역전파 학습방법(Back propagation learning rule, BP)^[5]을 이용하는 다층 구조의 신경회로망이 가장 널리 이용되고 있다. 이 신경 회로망은 임의의 함수관계를 학습에 의하여 나타낼 수 있지만, 항상 원하는 해답을 얻을 수 있다는 점이 보장되어 있지 않으며 더욱이 해답을 얻게 되는 경우에도 오랜 학습기간을 거쳐야 한다는 단점으로 인하여 그 응용이 제한되어왔다.

본 논문에서는 이러한 느린 학습 속도를 개선하여 신경회로의 응용 범위를 넓히기 위한 새로운 알고리즘을 제안하였다. 이 알고리즘은 신경회로망의 모델중 하나인 다층 Perceptron에서 중간층을 이루는 PE의 구조를 변화시켜서 입력값에 따라 중간층 PE들중의 일부가 적절한 방식에 의해 선택되고, 선택된 PE들로 이루어진 작은 규모의 회로가 그 때의 입력값의 범위에 대한 부분적인 함수관계를 학습하도록 하는 것이다. 즉, 임의의 입력이 인가되는 경우에 동작하는 PE들은 입력값의 범위에 의해 선택적으로 결정되는 것이다. PE를 선택하는 알고리즘으로는 Self-Organizing Neural Net(SONN)^[1]의 원리를 이용하였다.

제안된 알고리즘을 컴퓨터 시뮬레이션을 통하여 기존의 BP 회로와 학습속도를 비교하였고, 로보트 매니퓰레이터의 시각 추적 제어문제에 적용하였다. 컴퓨터 시뮬레이션을 통하여, 제안된 알고리즘이 기존의 BP 알고리즘에 비하여 같은 횟수의 학습을 시행했을 경우 더 작은 학습에러가 남는 가의 여부를 확인하여, 제안된 알고리즘의 유효성을 확인하였고, 제어하고자하는 로보트에 대한 정보가 전혀 없어도 신경회로망의 학습에 의하여 제어가 가능함을 확인하였다.

II. 새로 구성한 복합형 신경회로망

1. 다층 퍼셉트론과 역전파 학습방법

다층 퍼셉트론은 입력층과 출력층 사이에 하나 이상

의 중간층이 존재하는 신경회로망으로 Fig. 1에 나타낸 것과 같은 계층구조를 갖는다. 역전파 학습방법은 교사학습법의 대표적인 학습방법으로서, 단층 퍼셉트론의 학습에 이용되는 delta rule을 일반화시킨 것으로서 중간층의 노드들은 어떠한 출력들을 내보내야 하는지를 미리 알 수가 없으므로 출력층의 노드들로부터 오차에 관한 정보를 역으로 전달받아서 자신의 학습에 이용한다.

전체적인 알고리즘은 크게 각각의 노드가 자신의 출력을 구하는 순방향 계산과정과 출력층에서 오차를 구한 후 이를 역으로 전달시키면서 노드들 사이의 weight를 조절하는 역방향 계산과정으로 구분된다.

Fig. 2에 역전파 학습알고리즘을 단계별로 정리하였다.

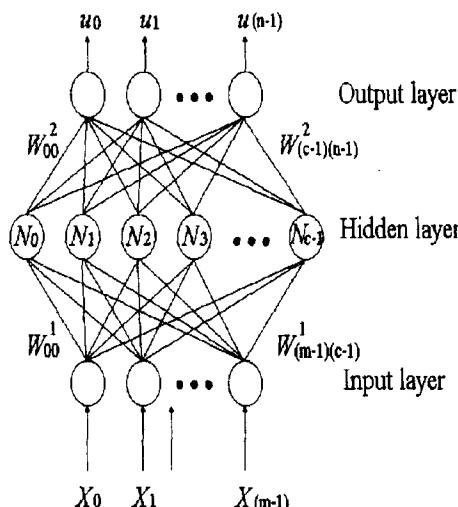


그림 1. 역전파 신경회로망의 구조

Fig. 1. The structure of backpropagation neural network.

2. Self-organizing neural network (SONN)

SONN 모델은 베즈텍(James Bezdek)의 퍼지 c-means 알고리즘의 퍼지 멤버쉽 등식을 신경회로망과 융합한 자율적인 자기조직화 신경회로망 모델이다. 따라서 이 모델은 외부의 교사(teacher)를 필요로 하지 않는다. 이 모델은 주어진 입력에 대한 클러스터의 수나 클러스터의 중심(center)에 대한 사전 지식없이 자율적으로 클러스터에 관한 정보를 제공하여 주므로 패턴분류와 패턴인식 등에 적합하며 좋은 결과를 보여주고 있다.

SONN 모델에 사용되는 SONN 알고리즘은 분류상

으로 자율적인 학습을 하며 연속적인 입력값을 처리할 수 있는 알고리즘으로서, 코호넨의 자기조직화 모델과 유사한 점이 있다. 그러나 코호넨 모델과는 많은 차이점이 있다.

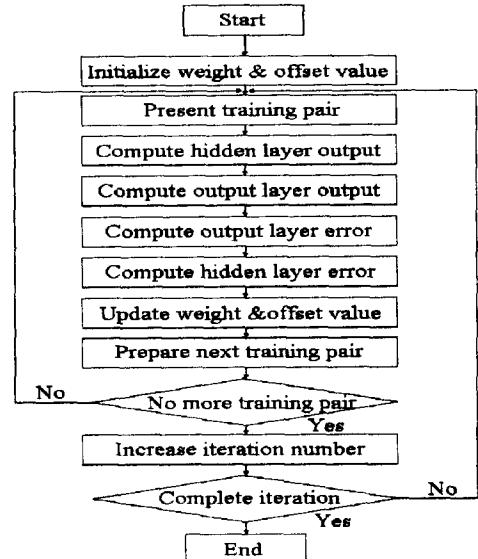


그림 2. 역전파 학습알고리즘의 블럭 다이어그램

Fig. 2. Block diagram of backpropagation learning algorithm.

SONN 모델과 코호넨 모델의 가장 근본적인 차이점은 코호넨 모델이 거리가 가까운 뉴런만을 승자로 선택하는 방법인데 달리 이 모델은 퍼지한 정보를 이용하는 베즈텍의 퍼지 멤버쉽 등식을 이용한다.

이러한 시도는 신경망과 퍼지 개념을 융합시켜 양쪽의 장점을 모두 이용하려는 목적과 잘 부합되었다. 이 모델이 발표된 당시는 퍼지와 신경망의 융합이 쌍틀무렵이었으며, SONN 모델은 퍼지와 신경망이 융합된 초기의 모델중의 하나이다. 이 모델은 Fig. 2.3에서 보는 바와 같이 입력 벡터가 입력층(input layer)으로 들어오고 거리층(distance layer)과 멤버쉽층(membership layer)에서 피드백(feedback)하면서 클러스터들의 정보를 제공하여 준다.

SONN 알고리즘에서는 노드 사이의 연결강도 조정 시 입력벡터와의 퍼지 유사성에 따라 연결강도가 조절된다. 이 점이 코호넨의 방식과는 다르고 퍼지 정보를 이용함으로써 보다 정확한 학습이 이루어질 수 있다.

SONN의 학습 알고리즘을 단계별로 정리하면 아래와 같다.

[단계1] 모든 j 에 대하여 연결강도 $W_j(0)$ 를 임의적으로 0과 1 사이의 값으로 초기화한다. 그리고 원형구조의 이웃 반경(NB)을 $c/2$ 가 되도록 설정한다. 여기서 c 는 출력 노드의 갯수이다. 또한 학습률(LR)을 0과 1 사이의 값으로 설정하고 임계값을 충분히 작게 설정한다.

[단계2] 각각의 입력 ξ_i ($i = 1, 2, \dots, n$: n 은 입력의 갯수)에 대하여

- (1) 각 입력 벡터에 대하여 퍼지 피드백 정보 u_{ji} 를 구한다.

$$u_{ji} = \frac{1}{\sum_{k=0}^{c-1} (\frac{d_{jk}}{d_{ki}})^{\frac{2}{(m-1)}}}$$

- (2) ξ_i 와 노드 j 사이의 총 거리의 합계 d_{ji} 가 최소가 되는 출력노드 j^* ($0 \leq j^* \leq c-1$)를 선택한다.
- (3) 연결강도 변화 요소인 dw 를 $dw_{ji} = (X_i - w_{ji})$ 가 되도록 수정한다. 만일 노드 j 가 NB 노드 j^* 의 경계 안에 있다면 $d_{w_{ji}}$ 가 입력 X_i 와 기존의 연결 강도 w_{ji} 사이의 거리가 되도록 한다. 그렇지 않으면 $d_{w_{ji}}$ 를 0으로 한다.
- (4) 연결강도를 수정하기 전에 현재의 연결강도 w_{ji} 를 $w_{old,ji}$ 로 저장한다.
- (5) 다음의 규칙을 사용하여 연결강도 w_{ji} 를 수정한다.

$$W_j(t+1) = W_j(t) + LR \times dw \times u_{ji} \times N$$

- (6) $diff$ 의 값을 리턴한다. 여기서 $diff = (W_j - w_{old,ji})^2$ 이다. 그 $diff_{ji}$ 의 값을 다음의 식에 의하여 $diff_{total}$ 에 더한다.

$$diff_{total} = diff_{total} + diff$$

[단계3] 만일 $diff_{total} > lim$ 이면 단계 4로 가고, 그렇지 않으면 단계 5로 간다.

[단계4] 학습률 LR을 감소시키고, $diff_{total}$ 를 0으로 한 다음 단계 2로 간다.

[단계5] 만일 NB=0이면 단계 6으로 가고, 아니면 NB를 1만큼 감소시킨 후, 단계 2로 간다.

[단계6] 퍼지 멤버쉽 값 u_{ji} 를 결정한다.

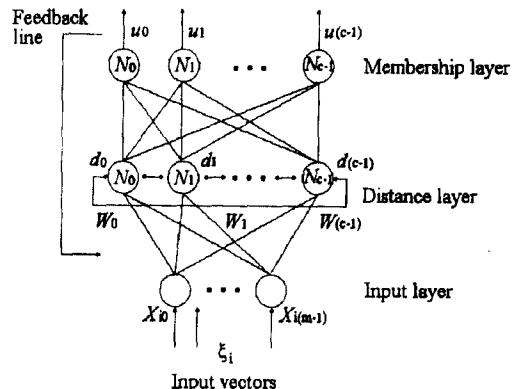


그림 3. SONN의 구조

Fig. 3. The structure of SONN.

3. 새로 구성한 복합형 신경회로망

로보트 매니퓰레이터의 제어와 같이 교사학습의 신경회로망을 사용하는 경우 그 제어 성능은 학습을 종료한 후 목표 출력값과 실제 출력값의 차이인 학습에러의 크기에 따라 크게 좌우된다. 역전파 학습방법의 경우 중간층 노드의 수가 증가할수록 계산량이 증가하므로 학습시간이 매우 길어지는 단점이 있다. 그러므로 신경회로망을 설계함에 있어서 이러한 학습속도를 더 빠르게 하고, 학습에러를 작은 값으로 수렴하도록 하는 것을 염두에 두어야 한다.

위에서 제시된 문제점을 해결할 수 있는 방안으로 교사학습법인 역전파 학습방법과 비교교사학습법인 SONN 모델의 특성을 결합한 복합형 신경회로망(hybrid neural network)을 제안한다.

1) 제안된 복합형 신경회로망의 구조

제안된 복합형 신경회로망의 구조를 Fig. 4에 나타내었다. 그림에서 보는 바와 같이 제안된 신경회로망은 중간층이 입력벡터의 차원과 동일한 수의 그룹으로 나뉘어져 있고, 각 노드의 연결은 역전파 학습방법과 동일하게 되어있다. 중간층의 각 그룹내에 있는 각각의 노드에는 SONN에서의 연결강도와 같은 역할을 하는 반응범위(responding region)가 입력벡터의 범위에 따라 주어진다. 입력벡터가 입력층에 인가되면 입력벡터와 가장 가까운 반응범위를 가지는 노드가 승자노드(winner node)가 되고 이 승자노드와 승자노드의 이웃노드(neighborhood node)의 반응범위가 퍼지 피드백값을 이용하여 수정되고, 또한 각 노드간의 연결강도도 이 승자노드와 그 이웃노드에 대해서만 수정의 과

정이 행해진다.

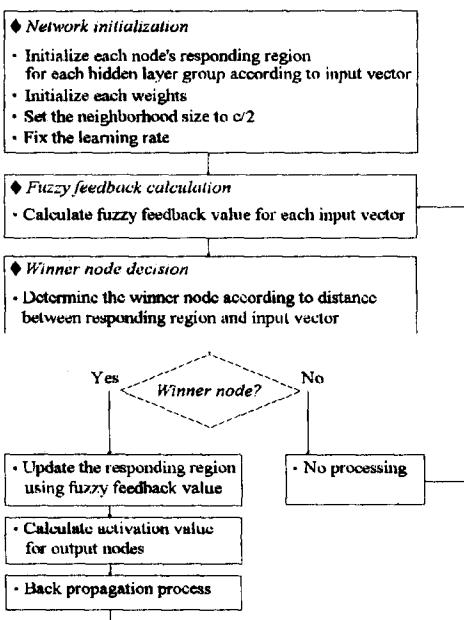
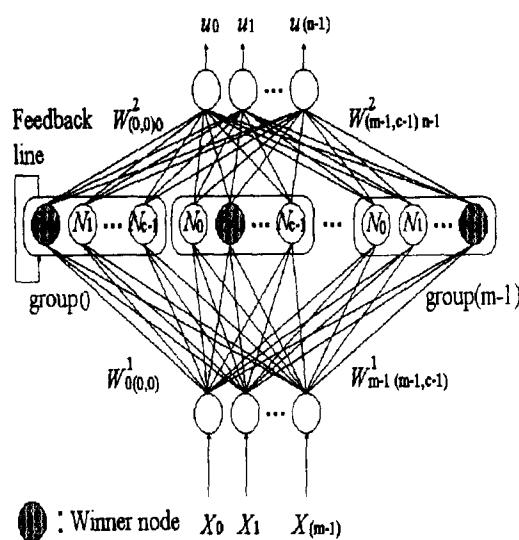


그림 5. 새로 구성한 신경회로망의 학습 알고리즘
Fig. 5. Learning algorithm of the proposed neural network scheme.

2) 제안된 복합형 신경회로망의 학습 알고리즘
제안된 복합형 신경회로망의 학습은 크게 중간층 노드의 반응범위를 수정하는 과정과 노드간의 연결강도

를 조정하는 과정으로 분리할 수 있다.

아래에 제안된 신경회로망의 학습알고리즘을 단계별로 정리하였다.

[단계1] 회로망을 초기화 시킨다.

- (1) 중간층의 각 그룹에 속해있는 각각의 노드의 반응범위를 입력벡터의 범위에 따라 초기화한다.
- (2) 각각의 노드간의 연결강도를 초기화한다.
- (3) 이웃반경(neighborhood radius)을 각 그룹에 속하는 노드 갯수의 반($c/2$)으로 설정한다.
- (4) 학습율을 지정한다.

[단계2] 입력벡터에 대하여 퍼지 피드백값을 구한다.

- [단계3] 반응범위와 입력벡터의 거리에 따라 각 그룹 내의 승자노드를 결정한다.

[단계4] 승자노드이거나 이웃노드로 결정된 노드에 대해서 퍼지 피드백값을 이용하여 SONN의 연결강도를 수정하는 방법으로 반응범위(RR)를 수정한다.

- [단계5] 승자노드도 이웃노드도 아닌 노드에 대해서는 아무런 처리도 하지 않는다.

[단계6] 승자노드와 그 이웃노드에 관련된 모든 연결강도를 역전파 학습방법에 의하여 수정한다.

- [단계7] 승자노드도 이웃노드도 아닌 노드와 관련된 연결강도에 대해서는 조정과정을 거치지 않는다.

[단계8] 지정된 반복횟수가 시행되지 않은 경우는 단계 2로 되돌아 간다.

- [단계9] 지정된 반복횟수가 시행된 경우는 학습을 종료한다.

III. 제안된 신경회로망의 성능실험

본 장에서는 역전파 학습방법과 SONN의 특성을 결합하여 구성한 복합형 신경회로망의 성능을 테스트하기 위하여 컴퓨터 시뮬레이션을 통하여 대표적인 비선형 함수인 XOR 함수와 3Bit parity 함수, 또 2 축로보트의 역기구학 해에 대하여 역전파 학습방법과 그 학습성능을 비교하였다.

1. XOR 함수

XOR 함수는 Minsky가 단층 퍼셉트론의 한계를 지적하는데 사용한 아래로 여러 사람들의 실험대상이 되어왔다. 이 함수는 패턴인식의 문제중 선형으로는 구분이 불가능한 대표적인 예이다. 이 함수의 진리표는

Table 1에 나타내었고, 역전파 학습방법과 제안된 신경회로망의 학습성능을 판단할 수 있는 normalized error는 Table 2와 Table 3에 나타내었다.

표 1. XOR 함수의 진리표

Table 1. XOR function.

X1	X2	Y
0	0	0
0	1	1
1	0	1
1	1	0

표 2. 학습률 0.5, 관성을 0.7, 학습횟수 500

Table 2. learning rate 0.5, moment 0.7, iteration number 500.

역전파 학습방법	중간층 노드수	잔류 에러	제안된 신경회로망	중간층 노드수	잔류 에러
	2	0.00633		16	0.00016
	4	0.01520		20	0.00000
	6	0.00530		24	0.00000
	8	0.00731		32	0.00001

표 3. XOR 패턴에 대한 normalized error
중간층의 노드수 : 역전파 학습방법 6,
제안된 신경회로망 20, 학습율 : 0.5
관성을 : 0.7

Table 3. Normalized error for XOR pattern.

of nodes in hidden layer : BP 6, proposed neural network 20
learning rate 0.5, moment 0.7

Iteration number	역전파 학습방법	제안된 신경회로망
50	0.1353	0.1212
100	0.1336	0.1159
150	0.1310	0.0921
200	0.1212	0.0743
250	0.0985	0.0007
300	0.0780	0.0000
350	0.0475	0.0000
400	0.0206	0.0000
450	0.0096	0.0000
500	0.0055	0.0000

2. 3Bit parity 함수

3Bit parity 함수는 XOR 함수와 유사한 특징을 가지는 3차원 함수로서 그 진리표를 Table 4에 나타내

었고, 그 학습결과를 Table 5와 Table 6에 나타내었다.

표 4. 3Bit parity 함수의 진리표

Table 4. 3bit parity function.

X1	X2	X3	Y
0	0	0	0
0	0	1	1
0	1	0	1
0	1	1	0
1	0	0	1
1	0	1	0
1	1	0	0
1	1	1	1

표 5. 학습률 0.5, 관성을 0.7, 학습횟수 2500

Table 5. learning rate 0.5, moment 0.7, iteration number 2500.

역전파 학습방법	중간층 노드수	잔류 에러	제안된 신경회로망	중간층 노드수	잔류 에러
	2	0.00009		12	0.00000
	4	0.00008		18	0.00000
	6	0.00008		24	0.00000
	8	0.00013		42	0.04219

표 6. 3Bit parity 패턴에 대한 normalized error

중간층의 노드수 : 역전파 학습방법 4,
제안된 신경회로망 18, 학습율 : 0.5,
관성을 : 0.7

Table 6. Normalized error for 3Bit parity pattern.

of nodes in hidden layer : BP 4, proposed neural network 18
learning rate : 0.5, moment : 0.7

Iteration number	역전파 학습방법	제안된 신경회로망
250	0.0072	0.1270
500	0.0008	0.1271
750	0.0004	0.0994
1000	0.0002	0.0000
1250	0.0002	0.0000
1500	0.0001	0.0000
1750	0.0001	0.0000
2000	0.0001	0.0000
2250	0.0001	0.0000
2500	0.0001	0.0000

3. 2축 로보트의 역기구학 해

본 절에서는 비선형관계를 가지는 로보트의 역기구학 해를 학습시켜 역전파 학습방법에 대한 제안된 신경회로망의 일반화 성능을 알아보았다.

Table 7에 학습에 사용된 역기구학 데이터를 나타내고, Table 8에는 학습결과를 나타내었다.

표 7. 2축 로보트의 역기구학 해의 학습 데이터

Table 7. Learning data of inverse kinematics solutions of two-linked robot.

X	Y	θ_1	θ_2
1.000000	0.000000	0.000000	1.000000
1.000000	0.066667	0.018230	0.966072
1.000000	0.133333	0.036588	0.931907
:	:	:	:
:	:	:	:
0.000000	0.800000	0.908097	0.151317
0.000000	0.866667	0.916684	0.106843
0.000000	0.933333	0.928934	0.057009
0.000000	1.000000	0.945785	0.000000

표 8. 역기구학 해에 대한 학습결과

Hidden layer의 노드수 : 48, 학습율 : 0.3, 관성율 : 0.3

Table 8. Learning error for solutions of inverse kinematics.

of nodes in hidden layer : 48, learning rate : 0.3, moment : 0.3

Iteration number	역전파 학습방법	제안된 신경회로망
1000	9.089	0.002
2000	6.358	0.001
3000	3.928	0.000
4000	3.346	0.000
5000	3.193	0.000
6000	3.111	0.000
7000	3.043	0.000
8000	2.978	0.000
9000	2.902	0.000
10000	2.785	0.000

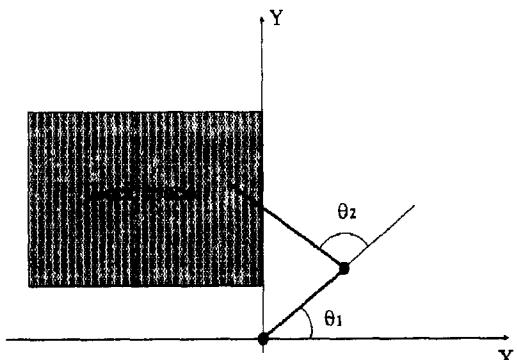


그림 6. 실험에 사용된 2축 평면 로보트

Fig. 6. A two-link planar robot used in the experiment.

IV. 제안된 신경회로망을 이용한 시각추적제어

신경회로망을 이용한 로보트 매니퓰레이터의 대상물 시각추적제어는 비전(vision) 정보와 로보트 매니퓰레이터의 각축에 투입되는 제어입력의 비선형 관계를 mapping하여 학습된 결과에 의하여 수행된다. 그러므로, 일단 한번의 학습이 이루어진 후에는 매번 복잡한 수식에 의하여 제어입력을 계산하지 않아도 되므로 실시간 제어에 있어서 유리한 점을 가진다.

본 장에서는 PUMA560 로보트의 매니퓰레이터를 이용하여 대상물의 시각추적제어를 위한 데이터의 학습에 제안된 신경회로망을 사용한 결과를 실었다^{[6][7]}।

학습에 필요한 데이터의 추출방법과 시뮬레이션 결과를 아래에 나타내었다.

1. 학습 데이터의 추출 및 학습

본 논문의 시뮬레이션에서는 로보트 매니퓰레이터의 end effector에 장착된 카메라가 항상 대상물이 움직이는 이차원 평면과 수직을 이루고 또한 그 평면과 일정한 거리를 유지하도록 하는 제한 조건하에서 데이터를 추출하였다. 또한, 로보트의 end effector에 장착된 카메라로부터 측득한 영상의 정 중앙과 대상물의 중심이 일치하였을 때를 추적이 완료된 것으로 가정한다. 대상물의 중심 좌표는 다음 식과 같이 무게 중심법을 이용하여 구해진다.

$$X_c = \sum_{i,j}^N \frac{i X_{ij}}{X_{ij}}, \quad Y_c = \sum_{i,j}^N \frac{i Y_{ij}}{Y_{ij}}$$

여기서, X_c , Y_c 는 대상물의 중심이고, N 은 영상의 size를, X_u , Y_u 는 영상의 gray level값을 의미한다. 학습 데이터를 추출하는 방법은 다음과 같은 과정에 의해서 진행된다.

우선, 카메라로 취득한 영상으로부터 무게 중심법을 이용하여 대상물의 현재의 중심점의 좌표 (x_{cl}, y_{cl}) 을 구한다. 다음으로 로보트 매니퓰레이터가 수평하게 움직이도록 $\Delta\theta_1, \Delta\theta_2, \dots, \Delta\theta_n$ (여기서 n 은 매니퓰레이터의 자유도) 값을 로보트 매니퓰레이터의 각 축에 인가한 후, 카메라로 대상물의 영상을 재 취득한다. 이후 다시 무게 중심법을 이용하여 대상물의 현재의 중심점의 좌표 (x_{c2}, y_{c2}) 을 구한다.

Fig. 7과 같이 영상내에서 대상물의 중심점 좌표의 변화량 $x_{c2} - x_{c1}$, $y_{c2} - y_{c1}$ 을 구한다. 결정된 $x_{c2} - x_{c1}$, $y_{c2} - y_{c1}$ 과 $\Delta\theta_1, \Delta\theta_2, \dots, \Delta\theta_n$ 을 각각 신경회로망의 입력과 출력의 쌍으로 정한다.

이러한 과정을 학습할 데이터의 수 만큼 반복한다.

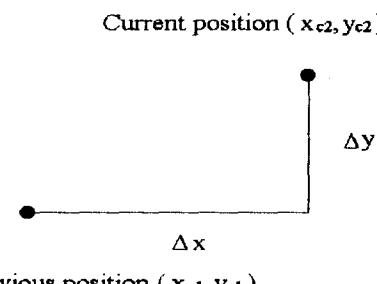


그림 7. 대상물의 중심을 이용한 학습 데이터 추출 방법

Fig. 7. Extraction of learning data using object center.

이와같이 추출된 화면상의 편차와 각 축에 인가된 임의의 제어입력 값을 각각 제안된 신경회로망의 입력과 출력으로 학습시켜 비선형 관계를 mapping하는 노드간의 연결강도를 구한다.

이때 데이터의 수는 로보트의 작업공간에 알맞게 적당량을 취한다.

(20cm × 40cm 정도의 작업공간에 대하여 120에서 140개 정도)

학습할 데이터를 추출하기 위해 임의의 제어입력을 각 축에 인가한 후 화면상에 발생한 대상물의 중심 편차와 함께 학습 데이터 쌍으로 삽았기 때문에 학습된 연결강도를 이용하여 화면상에 발생된 편차를 보상하

기 위해서는 신경회로망에 의해 계산된 각 축에 인가한 제어입력에 음의 부호를 붙여서 로보트에 인가해 주어야 한다.

2. 시뮬레이션 결과

Puma 560 robot의 사양을 이용하여, 기준위치와 현재위치의 화면상의 편차와 이 편차의 보상을 위해서 각 관절에 투입되는 제어입력을 제안된 신경회로망의 입력과 출력으로하여 학습 시킨후 시각적제어 결과를 컴퓨터 시뮬레이션을 통하여 살펴보았다.

사용된 Puma 560 robot의 사양은 아래의 Table 9과 같다.

표 9. PUMA 560 Robot의 사양

Table 9. Specification of PUMA 560 Robot.

Joint i	θ_i	a_i	a_i	d_i	Joint range
1	90	90	0	0	-160 to 160
2	0	0	431.8mm	149.09mm	-225 to 45
3	90	90	-20.32mm	0	-45 to 225
4	0	-90	0	433.07mm	-110 to 170
5	0	90	0	0	-100 to 100
6	0	0	0	56.25mm	-266 to 266

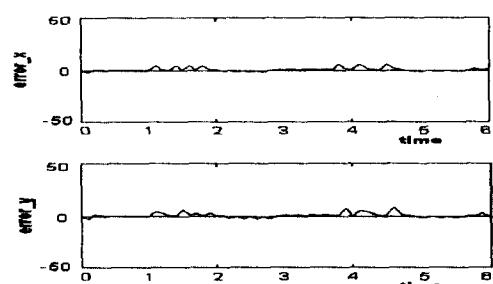


그림 8. 임의로 움직이는 대상물의 추적에러

Fig. 8. Tracking error of randomly moving object.

Fig. 8의 결과는 추적의 대상인 대상물이 임의의 방향으로 움직이는 상황에서 로보트 매니퓰레이터가 대상물을 추적하는 양상을 보여준다. 임의의 방향으로 발생한 화면상의 편차를 로보트 매니퓰레이터가 잘 보상해 나가는것을 알 수 있다. Fig. 9에서 Fig. 12까지의 결과는 로보트 매니퓰레이터가 있는 위치를 대상물이 놓여있는 평면의 원점으로 하였을때 그 원점을 수직으로 교차하는 두 직선 x축과 y축으로 이루어지는 4분면

을 설정하여 대상물이 각각 1사분면에서부터 4사분면에 존재할 경우 로보트 매니퓰레이터가 대상물이 존재하는 위치로 이동하여 편차를 보상하는 양상을 보인 것이다.

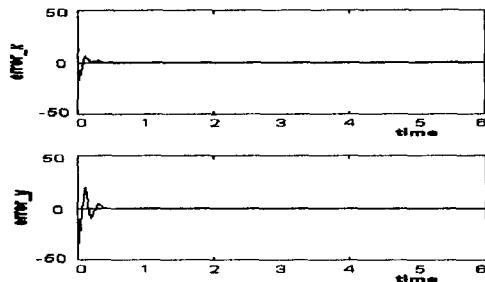


그림 9. 1사분면 영역에 정지해 있는 대상물의 추적 에러

Fig. 9. Tracking error of stationary object
Case 1 : Object is in first quadrant.

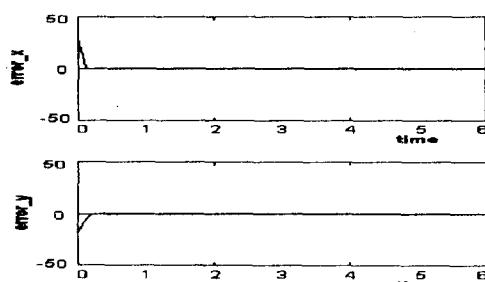


그림 10. 2사분면 영역에 정지해 있는 대상물의 추적 에러

Fig. 10. Tracking error of stationary object
Case 2 : Object is in second quadrant.

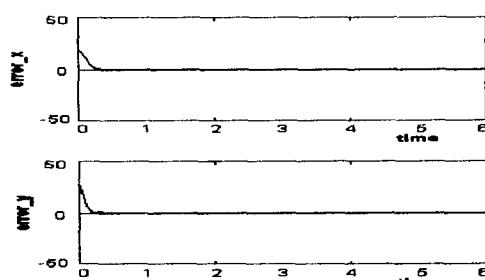


그림 11. 3사분면 영역에 정지해 있는 대상물의 추적 에러

Fig. 11. Tracking error of stationary object
Case 3 : Object is in third quadrant.

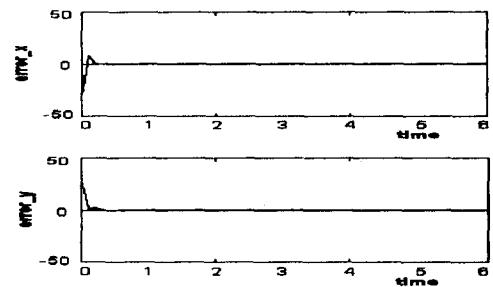


그림 12. 4사분면 영역에 정지해 있는 대상물의 추적 에러

Fig. 12. Tracking error of stationary object
Case 4 : Object is in fourth quadrant.

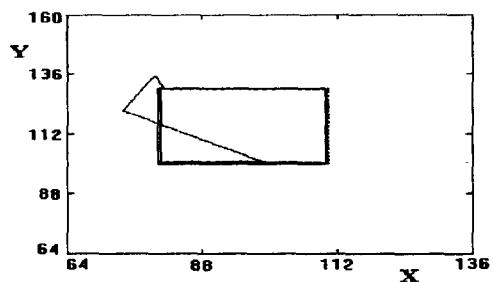


그림 13. 직사각형 운동을 하는 대상물의 추적 궤적

Fig. 13. The trajectory of robot end-effector for object with rectangular motion.

Fig. 13은 대상물이 작업 공간내에서 직사각형의 형태로 움직이고 있을 때 로보트 매니퓰레이터가 추적하는 모습을 보인다. 위의 시뮬레이션 결과에서 대상물과 로보트 매니퓰레이터 사이에 수평방향으로 발생한 편차는 신경회로망에 의해 계산된 제어입력에 의하여 빠른 시간내에 보상될 수 있음을 알 수 있다.

V. 결 론

본 논문에서는 교사학습 방법의 일종인 역전파 학습 방법을 사용하는 다층 퍼셉트론과 비교사 학습방법의 일종인 SONN의 특성을 결합하여 복합형 신경회로망을 구성하였다.

제안된 신경회로망은 역전파 학습방법이 중간층 노드의 수가 증가할수록 그 계산시간이 길어짐을 개선하고자 SONN 모델의 neighborhood node(이웃노드)

의 개념을 이용하여 구성되었다. 이는 중간층 노드의 수가 학습이 진행되는 과정에서 선택된 노드(winner node)와 그 이웃노드만이 연결강도의 수정이 이루어지도록 되어, 학습이 진행됨에 따라 이웃노드의 수를 감소시켜 결과적으로 계산량이 적어지는 효과를 기대하였다.

또한 중간층 노드에 대해서는 SONN 모델에서의 연결강도와 같은 역할을 하는 반응범위(responding region)을 설정하였는데, 이 반응범위의 수정도 역시 선택된 승자노드와 그 이웃노드에 대하여 이루어 진다. 이 반응범위의 수정과정에서는 퍼지 피드백값이 사용되는데 이는 이웃노드에 비하여 승자노드의 수정시 가치를 주어 학습이 더욱 원활하게 이루어지는 효과를 기대하였다.

제안된 신경회로망의 학습 개선효과의 확인을 위하여 이진 힘수중 XOR 힘수와 3Bit parity 힘수, 2축 로봇의 역기구학 해의 일반화 특성을 역전파 학습방법과 비교해 보았다.

컴퓨터를 이용한 시뮬레이션 결과에서 제안된 신경회로망은 역전파 학습알고리즘을 사용하는 다층 퍼셉트론에 비하여 수렴속도와 잔류 학습에러가 개선되었음을 알 수 있다.

이러한 결과는 로보ット 매니퓰레이터 등의 제어에 있어서, 기존의 역전파 학습 방법과 같이 모든 중간층 노드를 사용한 제어입력의 계산 시간보다 승자노드에 의한 계산 시간이 훨씬 단축이 되므로 더 효율적인 제어가 가능할 것이다.

마지막으로 제안된 신경회로망을 이용하여 시작추적 제어를 시행하였다.

컴퓨터 시뮬레이션의 결과를 통하여 제안된 신경회로망을 이용한 매니퓰레이터의 제어가 가능함을 확인하였다.

차후 연구과제로는 이웃노드의 효과적인 감소 알고리즘의 개발로 학습과정에서 이웃노드의 감소시 발생

하는 약간의 오실레이션을 제거하여 더욱 우수한 학습 성능을 가지는 신경회로망이 구현되어야 하겠다.

참 고 문 헌

- [1] 김 대수, 신경망이론과 응용(I), 하이테크정보, August 1992
- [2] R. P. Lippmann, "An Introduction to Computing with Neural Nets", IEEE ASSP Magazine, April 1987.
- [3] A. Guez, J. L. Eilbert, and M. Kam, "Neural Network Architecture for Control", IEEE Control Systems Magazine, April 1988.
- [4] D. Psaltis, A. Sideris, and A. A. Yamamura, "A Multilayered Neural Network Controller", IEEE Control System Magazine, April 1988.
- [5] Stephen I. Gallant, *Neural network learning and expert systems*, The MIT Press, 1993.
- [6] Koichi Hashimoto, *Visual servoing*, Word Sientific Publishing, 1993.
- [7] K. S. Fu, R. C. Gonzalez, C. S. G. Lee, *Robotics : Control, Sensing, Vision, Intelligence*, McGraw-Hill Book Company, 1987.
- [8] Arun D. Kulkarni, *Artificial Neural Networks for Image Understanding*, Van Nostrand Reinhold, 1994.
- [9] Teuvo Kohonen, "The Self-Organizing Map", IEEE, vol. 78, no. 9, September, 1990.

저자 소개

**金 景 敏(正會員)**

1966년 6월 12일생. 1988년 2월 고려대학교 전기공학과 공학사. 1991년 2월 고려대학교 대학원 전기공학과 공학석사. 1992년 2월 ~ 고려대학교 대학원 전기공학과 박사과정 수료.

주관심 분야는 퍼지 및 신경 회로망, 영상 처리, 패턴 인식, 로봇 비전 등임

**朴 重 租(正會員)**

1957년 3월 21일생. 1981년 2월 고려대학교 전기공학과 공학사. 1983년 2월 고려대학교 대학원 전기공학과 공학석사. 1995년 8월 고려대학교 대학원 전기공학과 공학. 주관심분야는 영상 처리, 신경

회로망, 퍼지 이론 등임

**朴 貴 泰(正會員)**

1947년 10월 25일생. 1975년 고려대학교 전기공학과 공학사. 1977년 고려대학교 대학원 전기공학과 공학석사. 1975년 1월 ~ 1978년 2월 한국 원자력 연구소 연구원. 1978년 3월 ~

1981년 8월 광운대학 전기공학과 조교수. 1981년 고려대학교 대학원 전기공학과 공학박사. 1984년 ~ 1985년 미국 일리노이 대학 객원 연구원. 1981년 ~ 현재 고려대학교 전기공학과 교수. 서울대 ERC-ACI 연구위원. 주관심 분야는 디지털 서보 제어기 설계, 현대 제어 이론, 퍼지 및 신경망 제어, 컴퓨터 비전 및 시스템 설계 등임