

# 빠르고 정확한 변환을 위한 국부 가중치 학습 신경회로

## (A Local Weight Learning Neural Network Architecture for Fast and Accurate Mapping)

李仁淑\*, 吳世泳\*

(Ihn Sook Yi and Se Young Oh)

### 要約

다층 퍼셉트론의 수렴속도를 개선하여 보다 정확한 mapping을 하도록 구조를 변형시켰다. 먼저 Kohonen의 자율 조직 회로를 또는 leader clustering 회로를 이용하여 입력 공간을 나눈다음 들어온 입력에 대응하는 뉴론들만 역전달법으로 학습하는 구조이다. 제안된 회로의 성능을 보이기위해 5-bit parity 문제와 로봇 팔의 3축에 대한 역 기구학 해를 학습시켰다. 그 결과 기존의 다른 학습 알고리즘에 비해 빠른 수렴속도를 보였다.

### Abstract

This thesis develops a modified multilayer perceptron architecture which speeds up learning as well as the net's mapping accuracy

In Phase I, a cluster partitioning algorithm like the Kohonen's self-organizing feature map or the leader clustering algorithm is used as the front end that determines the cluster to which the input data belongs. In Phase II, this cluster selects a subset of the hidden layer nodes that combines the input and outputs nodes into a subnet of the full scale backpropagation-network.

The proposed net has been applied to two mapping problems, one rather smooth and the other highly nonlinear. Namely, the inverse kinematic problem for a 3-link robot manipulator and the 5-bit parity mapping have been chosen as examples. The results demonstrate the proposed net's superior accuracy and convergence properties over the original backpropagation network or its existing improvement techniques.

### I. 서론

다층 퍼셉트론의 학습에 가장 많이 쓰이는 역전달 학습(back propagation, BP)은 입력층에서 출력층으로 전방향 출력을 내고, 다시 출력층의 오차가 입력

층으로 역전달되면서 모든 학습이 이뤄진다. 입력에 대한 정확한 내부 표현을 만들도록 출력층의 오차가 역전달되기 때문에 중간층은 각 입력에 대한 출력의 맵(map)을 형성한다.<sup>1)</sup> 이 내부 표현을 중간층의 시냅스의 상호 연결내에 있다. 일반적으로 2층의 구조(한 층의 중간층)로 임의의 함수관계를 학습시킬 수 있다고 알려져 있다.<sup>2)</sup> 그러나 역전달 학습에 이용되는 Gradient-Descent 알고리즘은 수렴 보장이 없고, 국부 최소치(local minima)에 빠지기 쉽다. 특히, 복잡한 회로 구조는 가중치에 대한 오차공간에서 복잡

\*正會員, 浦項工科大学 電子電氣工學科  
(Dept. of Elec. Eng., Pohang Inst. of Science & Technology)

接受日字: 1991年 6月 29日

한 오차 함수를 갖기 쉽고, 그만큼 국부 최소치를 갖기 쉽다. 모멘텀(momentum) 항이 이를 어느 정도 보상을 해주지만, 여전히 문제는 남는다.

또 다른 문제는 적절한 중간층 뉴런 수를 결정하기가 어렵다는 것이다. 예를 들어 50개의 중간층 뉴런을 갖는 회로가 200번 반복한 후 수렴하였다면, 같은 결과를 얻기 위해서 100개의 중간층 뉴런을 갖는 회로는 2000번 정도의 반복 학습을 필요로 하는 경우도 있다. 또한 새로운 학습 패턴이 들어올 때마다 모든 가중치가 변하며 학습하므로 이미 학습한 것을 조금씩 잊게된다. 본 논문에서는 다층 퍼셉트론의 문제들을 계산하기 위하여 Kohonen 회로와 다층 퍼셉트론을 결합하여서 각 입력 벡터에 대한 회로의 여유 자유도(redundancy)를 줄임으로써 비교적 빠르고 정확한 mapping을 얻도록 하였다. 자율 조직 신경회로는 Kohonen 회로나<sup>3)</sup> Leader Clustering 회로<sup>4)</sup>등을 사용하여 입력 공간을 나누고, 나눈 결과에 대해 중간층 뉴런의 일부를 선택하여 임출력에 연결하도록 한다. 일반적으로, 연속값을 갖는 정보를 학습할 경우 많은 수의 중간층 뉴런을 사용하므로 이에 따라 여유 자유도가 커져서 회로의 일반화 능력을 향상시키지만 회로가 커지면 수렴속도를 감소시킨다.<sup>4)</sup>

제안된 알고리즘의 성능을 보이기 위해 5-bit parity 문제와 로봇 팔의 역 기구학 해(Inverse Kinematic Solution)를 학습하도록 하였다. 역 기구학은 끝점(end-effector)의 좌표가 주어졌을 때 그 위치에 대한 로봇 팔의 관절각을 결정하는 것을 말한다. 로봇 팔의 역 기구학 해를 구할 때 기존의 방법을 이용할 경우,<sup>5)</sup>

(1) 로봇 팔의 정확한 기구학적 특성을 알아야 하고,

(2) 로봇 모델 종속의 기구학 해를 가지며,

(3) 로봇 팔의 물리적인 구조가 바뀔 경우에는 새로운 해를 구해야 한다는 단점이 있다. 그러나 신경회로를 구할 경우 위 문제점의 영향을 거의 받지 않는다. 즉, 로봇 모델이 필요없고 모델링하기 어려운 복잡한 시스템의 제어도 가능하며 시스템의 파라미터가 변화하여도 계속 학습함으로써 적응할 수 있다. 또한 기구학이 너무 복잡하여서 실제 로봇을 제어하기가 어려운 경우에도 유용하다.<sup>6,7,8)</sup>

기존의 신경회로와 그 알고리즘을 2장에서 간단히 살펴보고 3장에서는 제안된 회로망의 구조와 알고리즘을 살펴본다. 제안된 구조의 모의 실험 결과를 4장에서 보겠다. 5장에서는 본 논문에 대한 결론과 문제점들을 지적하고자 한다.

## II. 기존의 빠른 학습을 위한 연구

Jacobs<sup>9)</sup>는 모든 가변 파라미터가 시간에 따라 변하는 자신의 학습률을 가지며, 성능 지수의 파라미터에 대한 미분치가 같은 부호를 가지면 그 파라미터의 학습률을 증가시키고, 반대의 경우이면 학습률을 줄여주는 방법으로 학습 속도를 빠르게 하였다. 이와 다른 접근 방법으로 [5, 10, 11, 12]등은 회로의 구조를 변형함으로써 수렴 속도를 개선하도록 하였다. 송재명<sup>10)</sup>은 각 입력벡터의 원소마다 Kohonen층을 두고 그 원소값에 가까운 뉴런들을 다층 퍼셉트론의 중간층에서 선택된 뉴런들로 보고 역전달법으로 학습한다. Moody<sup>10,11)</sup>의 국부 동조 회로는 지도 학습 구조와 자율조직 구조를 조합한 회로로써 국부 표현(local representation)과 선형 결합 학습 회로의 조합에 의해 역전달 학습법보다 빠르다. 이 회로는 연속 또는 부분 연속값을 갖는 함수를 근사하는데 잘 맞고, parity와 같은 논리 함수의 근사는 적합하지 않다. 또한 다층 퍼셉트론 보다 더 많은 학습 데이터 소모하는 단점이 있다. Nishikawa<sup>12)</sup>는 다층 퍼셉트론을 여러 그룹으로 나누고 각 입력에 대응하는 그룹을 찾기 위해 제어 회로를 이용하였다. 이 제어 회로는 그룹의 갯수만큼의 뉴런을 갖고 Kohonen 방법으로 학습한다.

## III. 제안된 신경회로의 구조와 학습 방법

### 1. SOFM과 다층 퍼셉트론의 복합구조 : 제안된 구조 I

제안된 신경회로는 Kohonen의 SOFM(self-organizing feature map)을 이용하여 입력공간을 여러 cluster로 나눈 다음,<sup>3)</sup> 들어오는 각 입력과의 유사도를 결정하여서 이에 대응하는 일부의 중간층 뉴런들만 학습에 참여하도록 하였다. 그 구조는 그림1과 같다.

#### 1) SOFM

SOFM은 입력 공간의 토폴로지(topology)를 유지하면서 자율 조직하는 구조의 신경회로이며, 상호 제환(lateral feedback)에 의해 국부 응답(localized responds)을 형성한다.<sup>13)</sup> 이 모형은 입력 데이터의 분포에 맞게 입력 공간을 나누는 역할을 한다. 각 입력이 들어오면 유클리디안 거리(Euclidean distance) 계산법으로 유사도를 결정하여 가장 가까운 거리에 있는 뉴런을 선택하고 이 뉴런의 가중치를 입력에 더 가깝도록 학습시킨다. 학습은 식(1)과 같은 방법으로 하며, 수렴을 보장하기 위해 학습률은 지수 함수적으로 감소하도록 한다.<sup>14)</sup> 주위 뉴런들과의 상호 억제 작용을 위해 식(2)와 같은 가우시안(gaussian)함

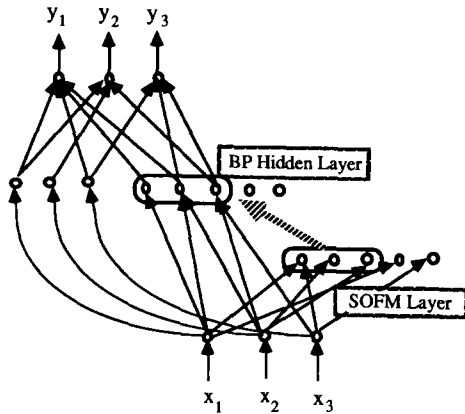


그림 1. 제안된 회로 I의 구조  
Fig. 1. The proposed architecture I.

수를 이용하였다.<sup>13)</sup> SOFM이 2차원일 경우도 마찬가지이다.

$$\Delta w_{ij}(t) = \alpha(t) g(s) (x_i - w_{ij}(t)) \quad \Delta w_{ij}(t) \quad (1)$$

$\alpha(t)$  : 시간에 따라 지수함수적으로 감소하는 학습률

$x_i$  : 입력층의  $i$ 번째 뉴런의 입력값

$w_{ij}$  : 입력층의  $i$ 번째 뉴런과 SOFM층의  $j$ 번째 뉴런간의 가중치

$$g(s) = \exp\left[-\frac{\|r-s\|^2}{\sigma^2}\right] \quad : \text{상호 작용 함수} \quad (2)$$

$\sigma$  : 분산

$r-s$  : 중심뉴런  $r$ 과 이웃뉴런  $s$ 의 뉴런간의 거리

2) 다층 퍼셉트론

SOFM에 의해 선택된 중간층 뉴런들은 다시 입력층으로부터 입력을 받아들이어서 역전달 학습방법에 의해 학습한다. 즉, Nishikawa처럼 미리 중간층을 몇 개의 그룹을 정해놓는 것이 아니라, SOFM 출력에 따라 중간층 뉴런의 그룹화가 자동적으로 이루어진다. 다층 퍼셉트론은 연속값을 갖는 함수의 mapping에 적절한 신경회로이다. 중간층의 활성화 함수는 Huberman등<sup>14)</sup>이 지적한 대칭성을 갖도록  $\tanh(x)$ 를 사용한다. 출력층의 활성화 함수는  $y=ax$ 와 같은 선형함수로 한다. 선형함수일 경우에는 출력층에서는 중간층의 비선형을 선형결합하므로 비선형 활성화 함수를 사용하는 것보다 빠른 수렴을 할 수 있다.<sup>11)</sup> 중간층에서는 입력과 일대일 대응이 되는 슬랩(slab)을 갖도록 하여 입력이 직접 출력에 참여하도록 하

였다.

3) 신경회로의 Jacobian을 이용한 오차 보상 방법  
Jordan,<sup>15)</sup> Hornik<sup>16)</sup>은 신경회로가 임의의 시스템에 대해 학습을 마치면 그 시스템의 Jacobian항도 동시에 학습이 된다고 하였다. 신경회로의 응용분야중에서 비전이나 음성, 문자인식, 혹은 최적화와 같이 전방향 계산만이 존재하는 문제와는 달리, 로봇의 역기구학 문제처럼 mapping의 역함수가 존재하는 경우, 그림2와 같이 신경회로를 통해 역방향 계산을 한 후 이 결과를 전방향 계산하면 신경회로의 입력의 오차를 알 수 있고 이 오차를 신경회로의 Jacobian 항과 계산하면 신경회로 출력의 오차를 알게되므로 이를 보상할 수 있다.




그림 2. 신경회로의 Jacobian을 이용한 오차 보상 방법  
Fig. 2. Error Reduction scheme using the network jacobian.

여기서,  $f$ 는 신경회로가 근사하는 목표 함수,  $f'$ 은  $f$ 의 Jacobian이고  $f^{-1}$ 는 전방향 계산이다.

2. Leader Clustering 회로와 단층 퍼셉트론의 결합 구조 : 제안된 구조 II

이 구조는 Leder Clustering 회로와 단층 퍼셉트론을 직렬로 연결하는 형태로 그림3과 같다.

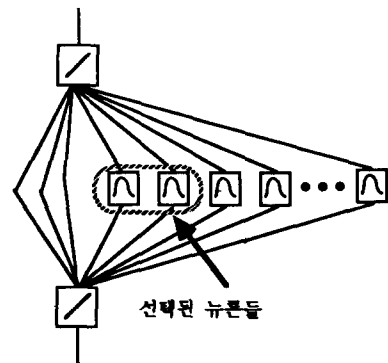


그림 3. 제안된 회로 II의 구조  
Fig. 3. The proposed architecture II.

1) Leader Clustering 회로

Leader Clustering 회로의 출력값은 입력과 cluster 중심값과의 거리에 상관되는 값을 얻기 위해 가우시안을 택하였다. 입력과 가장 가까운 가중치를 갖는 출력 뉴런값을 1로 하고, 그 이웃 뉴런들의 값은 식(3)과 같이 입력으로부터 멀어질 수록 값이 작아지도록 하였다.

$$o_j = \exp \left[ -a \frac{||x - w_j||^2}{||w_\alpha - w_j||^2} \right] \quad (3)$$

- x : 입력 벡터
- w<sub>j</sub> : j번째 출력 뉴런의 가중치 벡터
- a : 상수
- α : 입력과 최소 거리에 있는 출력 뉴런의 위치
- o<sub>j</sub> : 출력

활성화 되는 이웃 뉴런은 각 출력 뉴런과 위의 α 번째 뉴런과의 Euclidean distance가 임계값보다 작은 값일 경우로하고 임계값보다 크면 비활성화 된다.

2) 단층 퍼셉트론

출력은 식(4)와 같다. 입력과 출력간의 가중치 연결이 있도록 하였다.

$$o_k = \frac{\sum_j w_{kj} o_j}{\sum_j o_j} + \sum_i w_{ki} I_i \quad (4)$$

- o<sub>k</sub> : k번째 뉴런의 출력
- o<sub>j</sub> : 활성화된 중간층의 뉴런의 출력
- I<sub>i</sub> : i번째 입력
- w<sub>kj</sub> : k번째 출력 뉴런과 j번째 중간층 뉴런간의 가중치
- w<sub>ki</sub> : k번째 출력 뉴런과 i번째 입력 뉴런간의 가중치

3) 관절각 오차 보상 학습

본 절에서는 관절각의 오차를 학습하는 보조회로를 두어서 이를 학습에 이용하는 방법을 살펴 본다. 학습이 완료되기 전의 신경회로의 출력은 부정확한 출력이 되지만 이 출력과 로봇 팔의 운동간에는 정확한 기구학이 성립하므로 출력 오차에 의한 입력 오차를 알 수 있다. 이 입출력 오차를 학습하는 보조회로를 구성하면 보다 정확한 역기구학을 학습할 수 있다. 그 구조는 그림2에서 보인 바와 같고 단지 f' 항이 신경회로의 Jacobian 항이 아닌 보조 회로라는 점이 다르다. 전자의 경우에는 신경 회로의 Jacobian 항이므로 따로 학습할 필요가 없고, 후자의 경우에는 끝점의 오차와 관절각의 오차를 입출력으로 학습하게 된다.

IV. 모의 실험 결과

제안된 구조의 성능을 보이기 위해 5-bit parity 문제와 로봇 팔의 역기구학 해를 학습하도록 하였다. 프로그램은 C언어로 짰고, HNC사의 ANZA-plus accelerator board를 이용하여 모의 실험하였다. 학습율과 관성율은 실험적으로 결정하였다.

1. 5-bit parity 문제

5-bit parity 문제는 입력에 1이 홀수개이면 출력이 1이고, 짝수개면 출력은 0이 되는 이진 mapping이다. 그림4는 중간층 뉴런이 10개일 때 다층 퍼셉트론과 Nishikawa의 회로, 그리고 제안된 구조 I의 학습속도이다. 모두 출력단의 활성화 함수는 선형함수로 하였다. 기울기는 0.5이다. 학습률은 다층 퍼셉트론의 경우는 학습률은 0.9, 관성율은 0.7로 하였고, Nishikawa의 회로와 제안된 구조는 둘 다 학습률은 0.6, 관성율은 0.5로 하였다. Nishikawa 회로의 경우는 2개의 뉴런씩 5그룹으로 나누었다. 제안된 회로 I의 경우는 이웃 뉴런을 1개로 하였다.

1) 로봇 팔의 역 기구학 해 문제

모의실험 대상으로 삼은 로봇 모델은 PUMA 560의 3축이다. 입력공간은 -15cm ≤ X ≤ 15cm, 40cm ≤ Y ≤ 70cm, 5cm ≤ Z ≤ 35cm 범위에 있는 정육면체 내부 경사면의 256점이다.

중간층 뉴런은 모두 50개이다. 출력단의 선형함수 y=ax에서 a=0.3으로 하였고 학습률과 관성율은 각각 0.3, 0.3으로 하였다. 각각의 신경회로에 대해 같은 파라미터 값을 준 이유는 각 회로의 최적 파라미터를 구하기 어렵고 또한 수차례의 모의실험 결과 초기 학습시 영향을 끼치지만 최종 학습시에는 회로

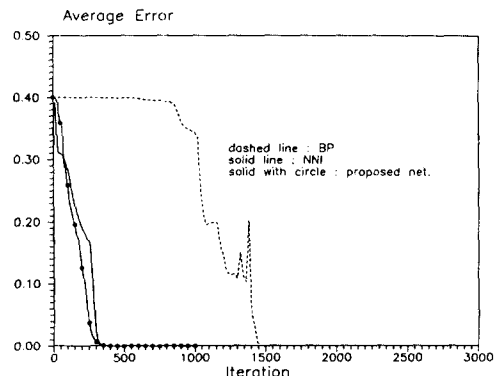


그림 4. 5-bit parity 문제에 대한 학습 속도  
Fig. 4. 5-bit parity learning speed comparison.

의 구조가 영향을 많이 끼치는 것으로 판단 되었기 때문이다. 국부 동조 뉴런의 회로의 출력의 활성화 함수는  $y=x$ 이고, 학습률과 모멘텀은 각각 0.09, 0.09이다.

그림5에 각 신경회로에 대한 역 기구학 해의 학습 속도를 나타냈다. 점선은 2단의 중간층 뉴런인 경우의 학습속도로 뉴런 갯수가 각각 30, 20개이다. 실선은 송재명이 제안한 회로로 이웃 뉴런이 3개인 경우의 학습 속도이다. 원 모양이 있는 점선은 Moody가 제안한 회로의 학습 속도이다. 초기에는 빠른 학습을 하지만 점점 그 속도가 느려짐을 볼 수 있다. 원 모양이 있는 실선은 Nishikawa가 제안한 회로의 학습 속도로 뉴런간의 중첩이 없으므로 SOFM에 의해 그룹 선택이 중요하다고 생각된다. 세모 모양이 있는 점선은 제안된 회로 I의 학습 속도다. 이웃 뉴런이 2개일 경우이다. 세모 모양이 있는 실선은 제안된 회로 II의 학습 속도이다. clustering을 위한 임계값은 0.03이고 중간층 뉴런의 활성화를 위한 임계값은 0.07로 하였다. clustering 결과 64개의 뉴런이 형성되었으므로 중간층 뉴런수는 이 경우에 64개다. 출력의 활성화 함수는  $y=x$ 이고, 학습률과 모멘텀은 각각 0.09, 0.09이다.

2단의 중간층의 경우에는 첫번째 층의 뉴런수와 두번째 층의 조합이 각각 (30, 20) (35, 15) (25, 25) 개의 뉴런을 사용한 결과 큰 차이는 없으나 (30, 20)의 조합이 가장 좋은 결과를 보였다. 1단의 중간층을 갖는 다층 퍼셉트론으로는 임의의 mapping이 가능하지만 많은 뉴런이 필요하고 그 속도도 늦다. 일반적으로 1단의 중간층으로 구현하는 것보다 2단의 중간층으로 구현하는 것이 속도가 빠르다.<sup>24)</sup> 송재명의 회로는 이웃 뉴런을 2~5개로 변화시키면서 그

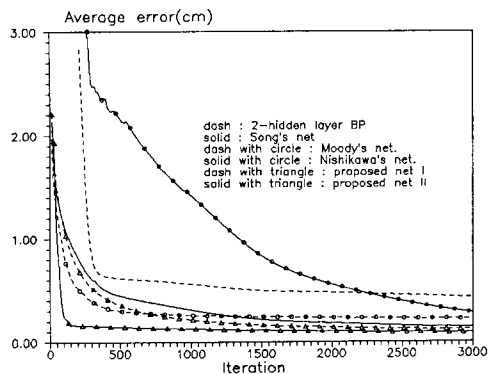



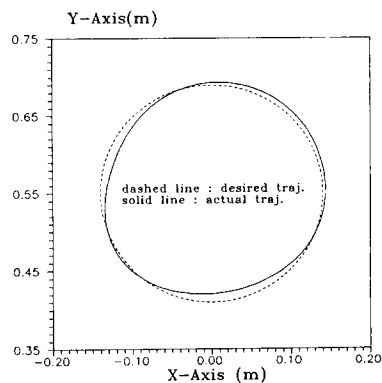
그림 5. 각 신경회로의 역 기구학 학습속도  
Fig. 5. Inverse kinematic learning speeds for different nets.

결과를 보았고 3개인 경우가 더 좋은 결과를 보였다. 이웃 뉴런이 3개인 경우 전체 활성화되는 뉴런 수는 21개이다. Moody의 회로는 분산값을 정할 때 이웃 뉴런을 1개 택하였을 경우가 다른 경우보다 좋은 결과를 얻었다.

K-means clustering 알고리즘에 의한 뉴런 선택에 따라 결과가 조금씩 다르지만 학습률이 0.8, 반복학습에 따른 시간 감소율이 0.01일 때와 이웃 뉴런을 1개로 했을 때 가장 좋은 결과를 내었다. Nishikawa 회로의 경우는 제안된 구조와 비슷한 구조로 뉴런간의 중첩이 없다. 이 경우엔 중간층 뉴런이 50개라할 때 각 그룹에 10개의 뉴런씩 5그룹 보다는 5개의 뉴



(a)



(b)

그림 6. (a) 2단의 중간층을 갖는 다층 퍼셉트론의 학습 결과

(b) 2단의 중간층을 갖는 다층 퍼셉트론의 일반화 결과

Fig. 6. (a) Learned mapping for a 2-hidden layer MLP,

(b) Generalization result for a 2-hidden layer MLP.

런씩 10개의 그룹으로 묶는 것이 더 좋은 결과를 냈다. 그러나 2개의 뉴런씩 25개 그룹으로 묶는 경우는 더 좋지 않았다. 어느 경우에도 뉴런 그룹간의 중첩이 없으므로 그룹간의 경계에서는 오차가 많은 것으로 생각된다. 제안된 회로 I의 경우는 먼저 SOFM을 학습시켜서 입력공간을 나누게 한 다음 다층 퍼셉트론을 학습한 결과이다. SOFM의 학습률은 0.8, 시간 감소율은 0.01이고, 500번 반복 학습 하였다. 이웃 뉴런의 갯수에 따른 결과는 그다지 차이가 없었고 2개인 경우가 다른 경우보다 조금 더 좋았다. 이때 전체 활성화 되는 뉴런 수는 5개이다. 제안된 회로 II의 경우는 식(3)의 a를 2.0으로 하였고, 임계값은 0.07로 하였다.

그림6은 2단의 중간층을 갖는 다층 퍼셉트론의 학습 결과와 일반화 결과이다. 그림7은 제안된 회로 I

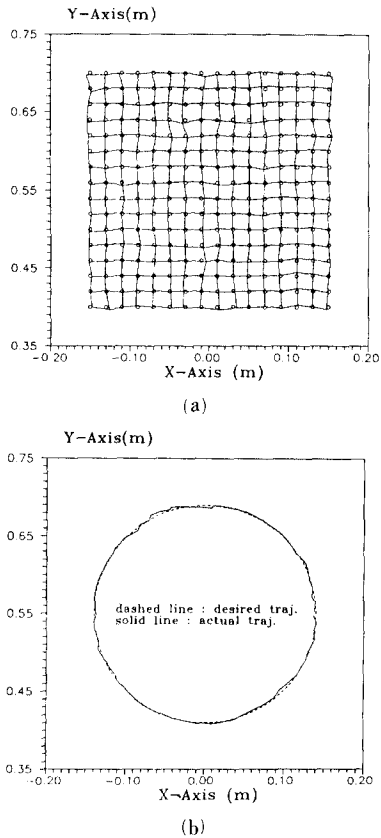


그림 7. (a) 제안된 회로 I의 학습결과  
 (b) 제안된 회로 I의 일반화 결과  
 Fig. 7. (a) Learned mapping for the proposed architecture I,  
 (b) Generalization result for the proposed architecture II.

의 학습 결과와 일반화 학습 결과이고, 그림8은 신경 회로의 Jacobian항을 이용하여 보상한 결과이다. 그림9는 제안된 회로 II에 대한 학습결과와 일반화 결과이고, 그림10은 관절각 보상을 위해 보조회로를 두어 학습한 결과이다. 두 경우 모두 보상한 결과가 훨씬 좋은 결과를 보이고 있다.

학습 데이터에 대한 정확도 성능을 보기위해 중간층 뉴런수를 입력 패턴 갯수까지 늘어보았다. 1단의 중간층을 갖는 다층 퍼셉트론의 중간층 뉴런수가 50개일 경우보다 오히려 늘어났다. 반면에 제안된 회로 I (Leader Clustering 회로+다층 퍼셉트론)의 경

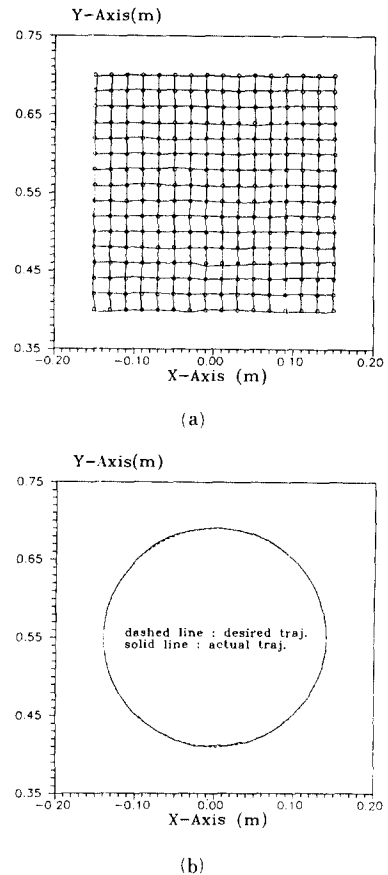
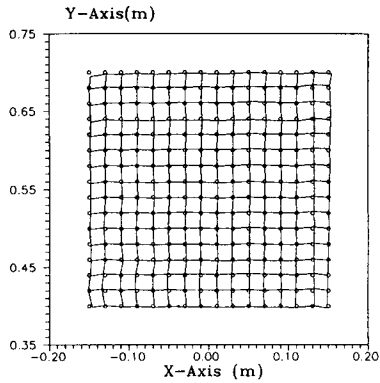
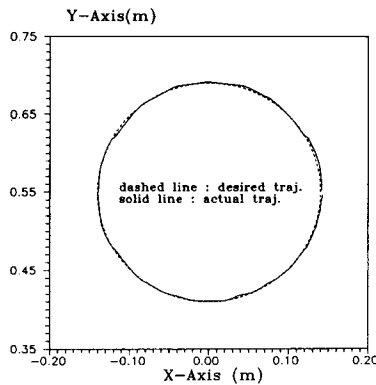


그림 8. (a) Jacobian항에 의한 출력 오차의 보상 결과(학습 데이터)  
 (b) Jacobian 항에 의한 출력 오차의 보상 결과(일반화)  
 Fig. 8. (a) Jacobian error reduction performance for the trained data,  
 (b) Jacobian error reduction performance for the trained data.



(a)



(b)


그림 9. (a) 제안된 회로 II의 학습 결과  
(b) 제안된 회로 II의 일반화 결과

Fig. 9. (a) Learned mapping for the proposed architecture II,  
(b) Generalization result for the proposed architecture II.

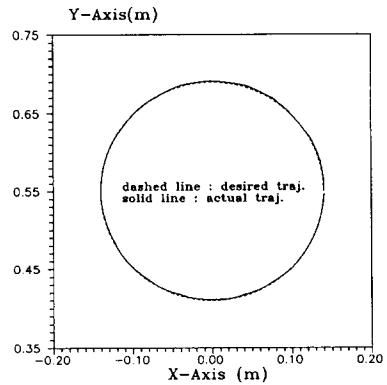
우 최종 학습 오차는 중간층 뉴런수가 50개일 때 오차의 30% 정도로 줄었고, 제안된 회로 II의 경우는 약 1200번 반복학습 후 오차가 0이 되었다.

## V. 결 론

본 논문에서 가장 널리 쓰이는 다층 퍼셉트론의 느린 수렴속도를 개선하기 위하여 SOFM과 다층 퍼셉트론을 조합하여서 부분 학습을 함으로써 다층 퍼셉트론보다 빠르고 정확함을 보였고, 제안된 구조와 비슷한 구조를 갖는 신경회로를 모의 실험으로 비교하였고 제안된 구조의 경우가 더 좋은 결과를 내는 것을 보였다. 또 다른 방법으로 Leader Clustering 회로와 다층 퍼셉트론을 결합하여 이를 역기구학 해를 구하는 문제에 적용하였고, 중간층 뉴런을 입력



(a)



(b)

그림 10. (a) 관절각 보상 학습에 의한 보상 결과 (학습 데이터)  
(b) 관절각 보상 학습에 의한 보상 결과 (일반화)

Fig. 10. (a) Joint error reduction performance for the trained data,  
(b) Joint error reduction performance for the generalization data.

갯수만큼 갖는 경우 정확하게 풀어냄을 보였다. 제안된 회로는 서론에서 언급한 메모리의 강건성에 문제를 해결하기 위한 방법으로 부분 학습에 의해 새로운 입력 패턴을 학습시킬 때 이미 학습하였던 결과를 다층 퍼셉트론의 경우보다 덜 교란시키며 수행한다는 장점이 있다.

본 논문에서는 입력 공간을 나누기 위해 SOFM, Leader Clustering과 같은 알고리즘을 사용하였는데 SOFM의 경우 적절한 파라미터를 정하기 어렵고 많은 반복 학습을 해야 한다. Leader Clustering 알고리즘을 사용하는 경우 반복 학습이 없으므로 빠르지

만 cluster 반경이 일정하므로 입력 패턴의 분포를 충분히 반영하도록 각 입력에 따라 cluster 반경을 조정할 수 있도록 연구해야 할 것이다.

본 논문에서는 다층 퍼셉트론의 느린 수렴속도를 개선하는데 중점을 두어서 기존의 신경회로 구조를 조금 변형하였다. 그러나 서론에서 지적한 다른 문제점들 (가변 파라미터의 선정, 수렴성의 보장, 중간층 뉴런의 갯수와 같은 구조에 관한 문제 등)에 대해서는 앞으로 많은 연구가 행해져야 할 것이다.

參 考 文 獻

[1] M. Caudill and C. Butler, *Naturally Intelligent Systems*, MIT Press, 1990.  
 [2] J. Sietsma and R.J. F. Dow, "Creating Artificial Neural Networks that Generalize," *Neural Networks*, vol. 4, 1991.  
 [3] T. Kohonen, *Self-Organizing and Associative Memory*, 2nd Ed., Springer-Verlag, 1988.  
 [4] Y.H. Pao, *Adaptive Pattern Recognition and Neural Networks*, Addison Wesley, 1988.  
 [5] 송재명, "동적 변화 구조의 역전달 신경회로와 로봇의 역기구학 제어에의 응용," 석사 학위 논문, 포항 공과대학, 1990.  
 [6] 류연식, "다층 신경회로를 이용한 로봇 팔의 다이내믹 제어에 관한 연구," 석사 학위 논문, 포항 공과대학, 1990.  
 [7] 조문중, "신경 회로를 이용한 6축 로봇의 역동력학적 제어," 석사 학위 논문, 포항 공과대학, 1991.  
 [8] S. Kieffer, V. Morellas, and M. Donath, "Neural Network Learning of the Inverse

Kinematic Relationships for a Robot Arm," *Proc. of the IEEE International Conference on Robotics and Automation*, 1991.  
 [9] R.A. Jacobs, "Increased Rates of Convergence through Learning Rate Adaptation," *Neural Networks*, vol. 1, 1988.  
 [10] J. Moody and C. Darken, "Learning with Localized Receptive Field," *Proc. of Connectionist models, Morgan Kaufmann*, 1998.  
 [11] J. Moody, "Fast Learning in Networks of Locally-Tuned Processing Units," *Neural Computation*, vol. 1, 1989.  
 [12] Y. Nishikawa, H. Kita and A. Kawamura, "NNI/I: Neural Network with Divides and Learns Environments," *Proc. of IJCNN*, Feb. 1989.  
 [13] H.J. Ritter, T.M. Martinez, and K.J. Schulten, "Three Dimensional Neural Nets for Learning Visuomotor Coordination of a Robot Arm," *IEEE Trans. on Neural Networks*, vol. 1, no. 1, 1990  
 [14] B.A. Huberman and W. Scott Stomett, "An Improved Three-layer, Backpropagation Algorithm," *Proc. of ICNN*, San Diego, 1987.  
 [15] M.I. Jordan, "Generic Constraints on Underspecified Target Trajectories," *Proc. of IJCNN*, vol. 1, 1989.  
 [16] Homik, M. Stinchcombe, and H. White, "Universal Approximation of an Unknown Mapping and Its Derivatives Using Multilayer Feedforward Networks," *Neural Networks*, vol. 3, 1990.

著 者 紹 介



吳世泳(正會員)

1952年 9月 18日生. 1974年 2月 서울대학교 공대 전자공학과(공학사). 1974年 1月~1976年 2月 한국원자력연구소연구원 1978年 8月 Case Western Reserve University 전기공학 석사. 1981年 5月 同大學 박사. 1981年 9月~1984年 12月 일리노이대 조교수. 1985年 1月~1988年 4月 플로리다대 조교수. 1988年 5月~현재 포항공과대학 전자전기학과 부교수. 주관심분야는 Neural Network의 로봇 및 자동화 응용, 로봇공학, 패턴인식 등임.



李仁淑(正會員)

1988年 2月 건국대학교 공과대학 전자공학과 졸업. 1991年 8月 포항공과대학 대학원 전자전기공학 학과 졸업. 주관심분야는 연속변환을 위한 신경회로구현 신경회로를 이용한 로봇 팔의 제어등임.