

부분 학습구조의 신경회로와 로보트 역 기구학 해의 응용

이 인숙 오 세영
포항 공과대학 전자전기공학과

A Neural Network with Local Weight Learning and Its Application to Inverse Kinematic Robot Solution

Ihn-Sook Yi Se-Young Oh
Dept. of Electronic and Electrical Engineering POSTECH

Abstract

Conventional back propagation learning is generally characterized by slow and rather inaccurate learning which makes it difficult to use in control applications. A new multilayer perceptron architecture and its learning algorithm is proposed that consists of a Kohonen front layer followed by a back propagation network. The Kohonen layer selects a subset of the hidden layer neurons for local tuning. This architecture has been tested on the inverse kinematic solution of robot manipulator while demonstrating its fast and accurate learning capabilities.

1. 서 론

신경회로는 생물체의 신경구조를 모방한 복잡한 계산을 반복적인 간단한 계산으로 대치할 수 있다. 또한 기존의 컴퓨터와는 달리 방정식이나 정확한 알고리즘에 의존하지 않고 학습능력과 보간에 의한 일반화 능력에 의존하므로 비선형 함수를 구하는데 유용하다[1].

본 논문에서는 이러한 신경회로의 특징을 이용하여 로보트의 역 기구학 해를 구하였다. 기존의 방법을 이용할 경우,

- (1) 로보트의 정확한 기구학적 특성을 알아야 하고,
- (2) 로보트 모델 종속의 기구학 해를 가지며,
- (3) 로보트의 물리적인 구조가 바뀐 경우에는 새로운 해를 구해야 한다.

는 단점이 있다[2]. 그러나 신경회로를 이용할 경우 위 문제점의 영향을 거의 받지 않는다.

기존의 신경회로중에서는 역전달 학습방법을 이용하는 다층 퍼셉트론 (multi-layer perceptron) 이 많이

쓰이고 있다. 이 모형은 학습에 의해 임의의 함수관계를 나타낼 수 있지만 [3], 오랜 학습기간을 거쳐야 하고 더우기 수렴여부가 불확실하다는 단점이 있다. 또한 제어 분야의 응용에 있어서는 패턴인식 분야와는 달리 정확한 mapping이 요구되나 다층 퍼셉트론은 어느 정도 오차가 줄어든 이후로는 더 이상 줄어들지 않아 정확도에 문제가 있으며, 한 입력에 대해 모든 중간층 뉴론이 참여 하므로 이전에 학습한 입력을 잊기가 쉽다[4]. 이러한 단점을 보완하기 위해 그동안 많은 연구가 행해졌다[5][6]. 참고문헌 [5]는 다층 퍼셉트론의 학습률을 시간에 따라 변화시켜서 학습속도를 빠르게 하였고, 참고문헌 [6]은 다층 퍼셉트론의 여유 자유도의 문제를 해결하기 위해서 처음에 적은 수의 뉴론으로 시작하여 학습이 진행됨에 따라 뉴론 수를 늘려가는 방법을 택하였다.

본 논문에서는 Kohonen이 제안한 자율 조직 신경회로(Self-Organizing Feature Map, SOFM)와 다층 퍼셉트론을 복합시켜서 다층 퍼셉트론의 느린 학습속도를 개선하였다. SOFM과 퍼셉트론을 복합하여 새로운 알고리즘을 구현한 예는 다음의 두가지가 있다. 먼저, 참고문헌 [7]의 경우는 SOFM으로 입력공간을 나눈 다음 이 SOFM의 출력값이 단층 퍼셉트론의 입력이 되는 신경회로이다. 참고문헌 [4]는 중간층 뉴론을 몇 개의 그룹으로 분할하고 제어 뉴론을 두어서 SOFM을 통하여 중간층 뉴론 그룹중의 하나를 선택한 다음 그룹내의 뉴론들을 다시 역전달 방법으로 학습한다. 여기서 SOFM의 출력은 다층 퍼셉트론에 아무런 영향을 주지 않으며, 그룹 뉴론간의 중첩이 있으므로 경계에 있는 입력 패턴의 학습은 약간 어려울 것으로 생각된다.

2. 개선된 구조 및 학습방법

복합구조는 그림 1과 같다. 먼저 1차원 SOFM을 이용하여 입력의 토폴로지(topology)를 유지하도록 하면서 각 입력에 대한 수용야(receptive field)와 중첩되는 이웃 뉴론들을 다시 역전달 학습방법으로 학습시킨다[8]. 즉, 각 입력에 대해 다층 퍼셉트론처럼 모든 중간층 뉴론이 참여하여 처리를 하지 않고, 그 입력에 가장 가까운 뉴론과 이웃 뉴론들만 참여하여 처리를 하므로 여유 자유도(redundancy)가 감소하여 다층 퍼셉트론보다 학습속도가 빠르다[9].

2.1 SOFM

이 모형은 입력 공간을 나누는 역할을 한다. 각 입력이 들어 오면 유кли디안 거리 계산법(Euclidian distance measure)으로 유사도를 측정하여 가장 가까운 거리에 있는 뉴론을 선택하고 이 뉴론의 가중치(weight)를 입력에 더 가깝도록 학습시킨다. 학습은 식(1)과 같은 방법으로 하며, 수렴을 보장하기 위해 학습률은 지수 함수적으로 감소하도록 한다[10]. 주위 뉴론들과의 상호 억제 작용을 위해 식 (2)와 같은 가우시안(Gaussian)함수를 이용하였다[11]. 다층 퍼셉트론의 중간층 뉴론 선택을 위해서 수용야는 1차원으로 하였다.

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

$\alpha(t)$: 시간에 따라 지수함수적으로 감소하는 학습률

$g(\cdot)$: 상호억제 작용 함수

x_i : 입력층의 i번째 뉴론의 입력값

w_{ij} : 입력층의 i번째 뉴론과 코호넨층의 j번째 뉴론간의 가중치

$$g(s) = \exp\left(-\frac{|x_i - w_{ij}|^2}{\sigma^2}\right) \quad (2)$$

σ : 중심 뉴론으로부터 퍼짐의 정도

2.2 다층 퍼셉트론

2.1에 의해 선택된 중간층 뉴론들은 다시 입력층으로 부터 입력을 받아들여서 역전달 학습방법에 의해 학습한다. 이때, 출력값이 실수일 경우에 출력층의 활성화 함수는 예측할 수 있는 범위의 크기를 갖는 시그모이드(sigmoid)함수를 사용할 수 있다. 또 다른 방법으로 중간층의 활성화 함수는 시그모이드 함수로 하고, 출력층의 활성화 함수는 $y = ax + b$ 형태의 선형 함수를 사용한다. 후자의 경우엔 다음과 같은 영향이 있다. 출력층에서 에너지 함수를 식(3)과 같이 정의하면 출력층과 중간층간의 가중치 변화량 Δw_{kj} 는 식(4)와 같다. 활성화 함수를 시그모이드를

사용한 경우의 식(5)를 살펴보면, 중간층 출력 O_i 가 0 또는 1에 가깝게 되면 에너지 함수에 대한 가중치 변화량이 0에 가깝게 되어 국부 최소치(local minima)에 빠지기 쉽다[12]. 그런데, 활성화 함수가 선형일 경우에는 식(6)과 같이 기울기와 출력층의 오차만의 영향을 받으므로 시그모이드 함수의 경우보다 훨씬 빠르다. 또한 $y = x$ 의 경우보다 $y = ax+b$ (a 는 작은 값) 일 경우가 윗 단으로부터 역전파되는 오차값이 작아서 입력층과 중간층간의 변화량이 작게되어 쉽게 포화되지 않으므로 보다 빠른 학습속도를 얻을 수 있다.

$$E = \frac{1}{2} \sum_k (T_k - O_k)^2 \quad (3)$$

T_k : 출력층의 k번째 뉴론의 원하는 값

O_k : k번째 뉴론의 실제 출력값

$$\Delta w_{kj} = \alpha \cdot \delta_k \cdot O_j \quad (4)$$

α : 다층 퍼셉트론의 학습률

w_{kj} : 출력층과 중간층간의 가중치

δ_k : 에너지 함수에 대한 출력층 가중치 합의 변화량

O_j : 중간층의 출력값

$$\delta_k = (T_k - O_k) \cdot O_k \cdot (1 - O_k) \quad (5)$$

$$\delta_k = (T_k - O_k) \cdot a \quad (6)$$

a : 선형 함수의 기울기

3. 모의 실험 결과

2절의 학습방법과 구조를 역 기구학 해를 구하는 데 이용하였다. 모의 실험 대상은 PUMA 560의 3축이다. 신경회로를 이용하여 역기구학 해를 구하는 경우 로보트에 관한 사전 지식이 없다고 가정하였으므로, 모의 실험 도중 얻을 수 있는 정보는 신경회로 출력으로 부터의 직교 좌표상의 현재 위치와 원하는 위치 뿐이므로 오프 라인(off-line) 학습을 위해 임의의 관절각(joint angle)에 대한 (x, y, z) 값의 데 이터를 얻는 것이 필요하다. 그림 2는 PUMA 560의 각 관절을 각각 $-90^\circ \leq \theta_1 \leq 90^\circ$, $-30^\circ \leq \theta_2 \leq 60^\circ$, $-45^\circ \leq \theta_3 \leq 45^\circ$ 범위에서 변하도록 하여 162개의 데이터를 만들었을 때 이들의 기구학 해를 구하여 xy평면에 나타낸 것이고, 그림 3은 각각 다층 퍼셉트론과 제안된 알고리즘으로 학습 시켰을 때의 학습속도를 비교한 것이다. 두 신경회로 모두 출력단의 활성화 함수는 선형 함수를 택하였고 a 는 0.3, b 는 0.0으로 하

였다. 중간층 뉴론은 둘다 30개로 하였고, 중간층을 거치지 않고 입력층과 출력층을 바로 연결하는 가중치도 포함하였다. 그럼에 나타낸 오차는 직교 좌표상의 절대 평균 오차이다(위 3개의 그래프 : 다층 퍼셉트론에 의한 학습속도, 아래 3개의 그래프 : 제안된 알고리즘에 의한 학습속도). 제안된 알고리즘의 Kohonen층의 학습은 $\alpha=3$, 근접이웃의 갯수=4로 하였고 α 의 초기치는 0.3으로 하고 반복학습에 따라 지수함수적으로 감소하도록 하였다. 전체 학습은 먼저 Kohonen 층을 학습한 후 다층 퍼셉트론을 학습하는 방법을 사용했다. 그림 2에서 알 수 있듯이 입출력 공간의 범위가 넓어서 5000번 반복 학습한 후에도 두 신경회로의 출력은 오차가 큰 것으로 나타났다. 그러나 제안된 알고리즘의 경우는 먼저 입력공간을 나눈 후 몇개의 선택된 뉴론만을 학습하므로 다층 퍼셉트론보다는 훨씬 빠른 학습속도를 보이고 있다. 그림 4는 $-15\text{cm} < x < 15\text{cm}$, $40\text{cm} < y < 70\text{cm}$, $5\text{cm} < z < 35\text{cm}$ 의 정육면체 내부의 경사면을 입력공간으로 잡아서 학습속도를 비교한 것이다. 중간층 뉴론은 둘다 50개로 하였고 제안된 알고리즘의 경우 선택되는 뉴론 수는 11개이다. 그림 5는 500번 반복학습 후의 Kohonen 층의 가중치 분포를 나타낸 것인데 입력공간을 잘 나눈 것으로 보인다. 그림 6과 7은 각각 다층 퍼셉트론과 제안된 알고리즘을 이용하여 학습한 내용을 기억한 것을 보인 것이다. 실선이 각 기억 점들을 연결하여 보인 것이고 작은 사각형 점들이 원하는 값들이다. 그림 8은 제안된 알고리즘의 일반화 특성을 보인 것으로 충분히 학습을 마친 다층 퍼셉트론의 일반화 특성보다는 좋지 못할 것으로 생각된다. 이유는 여유 자유도의 감소로 인한 것으로 생각된다. 일반화 특성을 높이기 위해서는 좀 더 조밀하게 입력 패턴을 만들어야 할 것이다[7].

4. 결 론

일반적으로 비선형 mapping에 많이 쓰이는 다층 퍼셉트론의 느린 속도를 개선하여 빠르고, 정확도가 향상되도록 하였으며 이를 역 기구학 해를 구하는데 이용하였다. 역 기구학 해의 응용에 있어서, 임의의 관절각에 대한 직교 좌표상의 값을 미리 얻어서 이것을 학습시키는 방법보다는 온라인 학습을 위해 참고문헌 [11]과 같이 Jacobian을 직접 학습시키는 방법도 연구할 과제라고 생각된다. 또한 여유 자유도의 감소에 따른 일반화 특성의 감소에 대해서도 연구해야 할 것으로 생각된다.

5. 참고문헌

1. R.P. Lippman, " An Introduction to Computing with Neural Nets", IEEE ASSP Magazine, April 1987.
2. G. Josin, " Nueral-Space Generalization of a Topological Transformation", Biological Cybernetics, Vol. 59, 1988.
3. K.I. Funahashi, " On the Approximate Realization of Continuous Mappings by Neural Networks", Nueral Networks, Vol. 2, 1989.
4. Y. Nishikawa, H. Kita and A. Kawamura, " NN/I: Nueral Network With Divides and Learns Environments", Proc. of IJCNN, Feb. 1990.
5. R. A. Jacobs, " Increased Rates of Convergence through Learning Rate Adaption", Neural Networks, Vol.1, 1988.
6. T. Ash, " Dynamic Node Creation in Back Propagation Networks", ICS Reports 8901, Univ. of California, San Diego, Feb. 1989.
7. J. Moody, C. Darken, " Learning with Localized Receptive Field", Proc. of connectionist models, Morgan Kaufmann, 1988.
8. J.M. Song and S.Y. Oh, " A composite Neural Network Architecture for Inverse Kinematic Robot Control Based on a Kohonen-BP Algorithm", Proc. of the Korean Automatic Control Conference, 1989.
9. 김 성석, " 순차구조 처리를 위한 부분 결합 회귀 신경회로망", 박사학위 논문, 울산 대학교, 1990.
10. T. Kohonen, Self-Organization and Associative Memory, 2nd Ed., Springer-Verlag, 1988.
11. H.J. Ritter, T.M. Martinez, and K. J. Schulten, " Three-Dimensional Neural Net for Learning Visuomotor Coordination of a Robot Arm", IEEE Trans. On Neural Networks, Vol. 1, No. 1, 1990.
12. A. Krzyzak, W. Dai and C.Y. Suen, " Unconstraints Handwritten Character Classification Using Modified Backpropagation Model", Frontier of Handwriting Recognition, Concordia Univ., 1990.

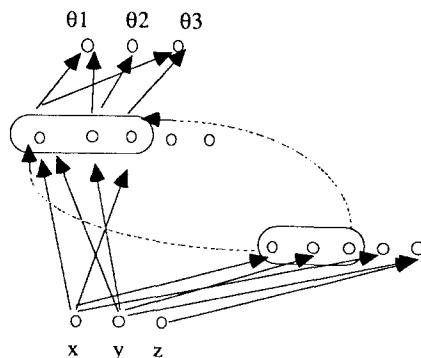


그림 1. 부분 학습 신경회로의 구조

Fig. 1. A Neural Network Architecture with Partial weight Learning

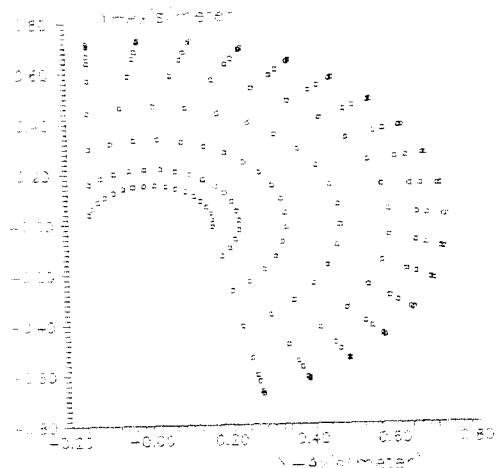


그림 2. 관절각을 변화시켜서 얻은 학습 데이터의 직교 좌표
상의 표현

Fig. 2. Training Data Distribution whose Cartesian Positions
are Obtained by Joint Space Tessellation

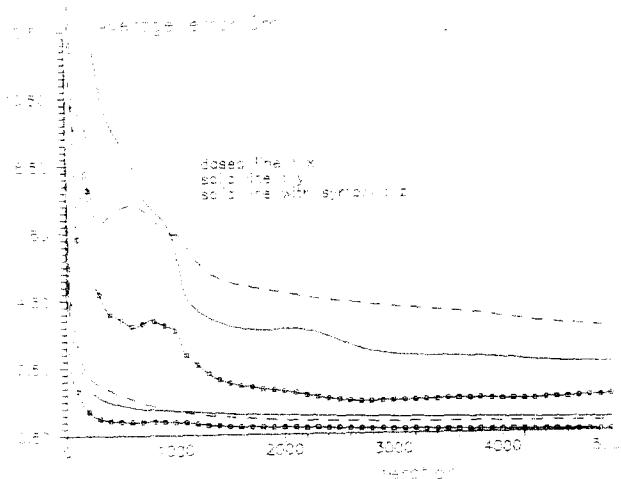


그림 3. 그림 2의 학습 데이터에 대한 다중 퍼셉트론과
제안된 부분 학습 신경회로의 학습 속도 비교

Fig. 3. Composition of Rates of Learning for Partial Weight
Learning versus Conventional BP Net Using Data in Fig. 2

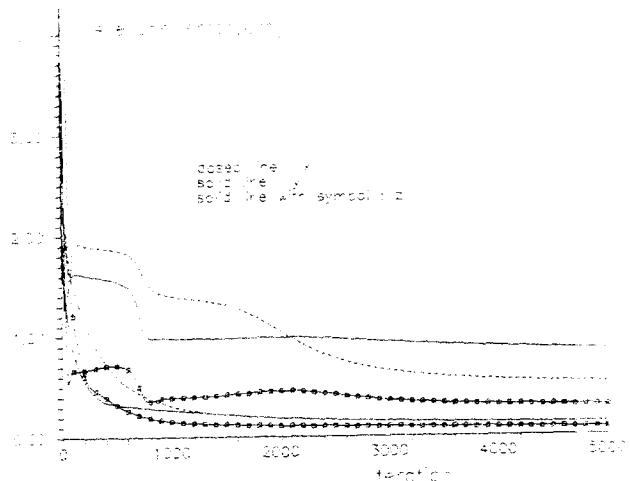


그림 4. 정육면체의 경사면에 대한 학습 속도 비교
Fig. 4. Comparision of Rates of Learning Using Training Data
in a Rectangular Slope

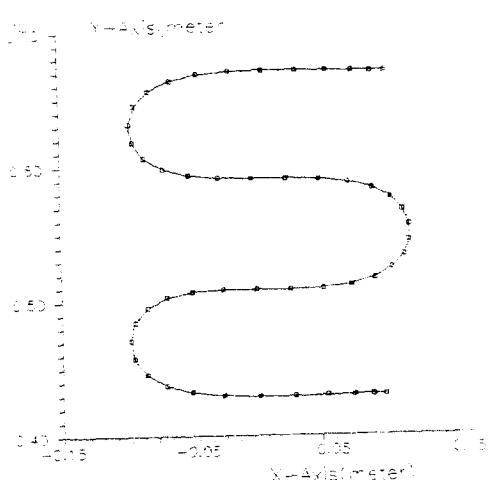


그림 5. Kohonen 층의 가중치 분포

Fig. 5. Kohonen Weight Vector Distribution

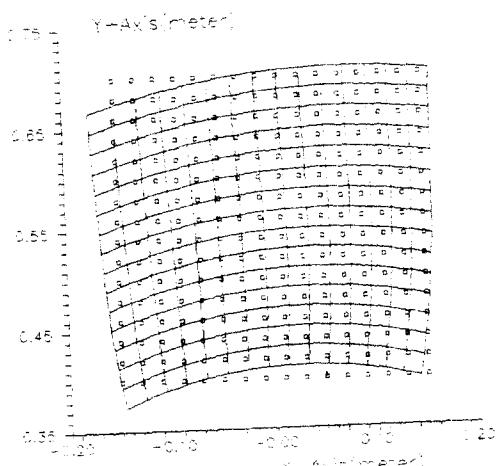


그림 6 5000번 반복 학습후 다중 퍼셉트론의 기억 결과
Fig. 6. Inverse Kinematic Solution Approximation Using a BP Net

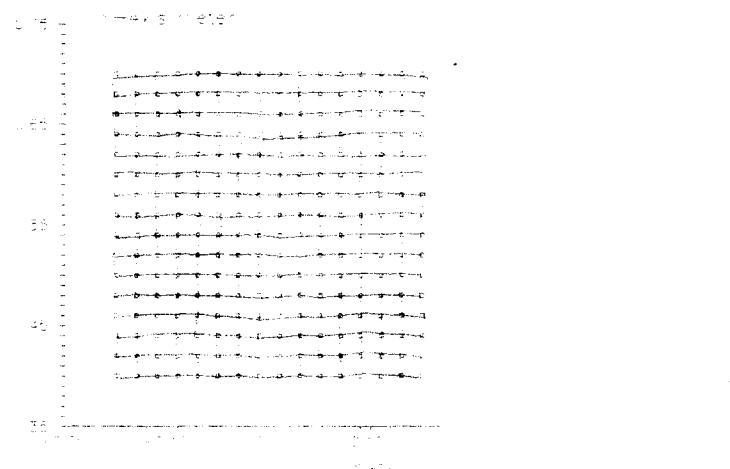


그림 7. 5000번 반복 학습후 부분 학습 신경회로의 기억 결과
Fig. 7. Inverse Kinematic Solution Approximation Using Partial Weight Learning

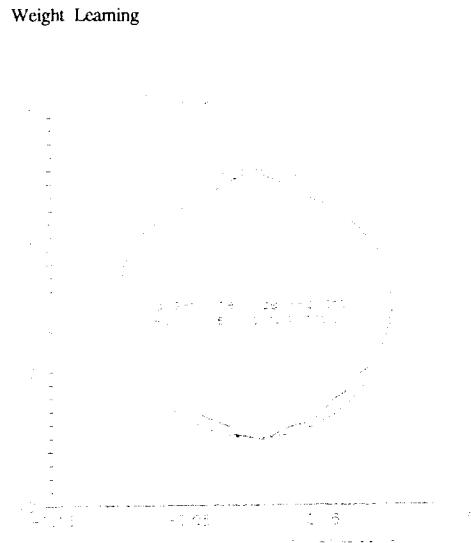


그림 8. 부분 학습 신경회로의 일반화 특성
Fig. 8. Generalization Characteristics for Partial Weight Learning