

로봇 매니퓰레이터의 신경제어기 구현과 신경회로망 비교연구

이재원[○], 장철훈^{*}, 정영창^{**}, 홍철호^{***}, 김정도^{****}

호서대학교 전자공학과[○], 전자공학과^{*}, 전자공학과^{**}, 제이케이스터디^{***}, 삼척산업대학교 제이케이스터디^{****}

The Comparison and Implementation of Neural Controllers for Robot Manipulator

Lee Jae-Won[○], Jang Choul-Hun^{*}, Jung Young-Chang^{**}, Hong Chel-Ho^{***}, Kim Jeong-Do^{****}

Electronic Eng., Hoseo univ.[○], Electronic Eng.^{*}, Electronic Eng.^{**}, Control & instruments Eng.^{***}, Control & instruments Eng., Sam Chok national univ.^{****}.

Abstract

In control of complex system, like robot manipulators, BP neural network have several drawbacks. To overcome this problems, the modified BP neural networks have proposed. To find neural network of proper structure for robot manipulator, in this paper, actual experiments using ADSP-21020 for SCARA robot were implemented and have shown the possibility of real-time control and industrial application, without neural chip.

1. 서 론

로봇 매니퓰레이터는 각 관절간의 코리올리(Coriolis)력 및 원심력 등의 강한 비선형 결합으로 인해 정확한 동력학 모델 설성이 어렵기 때문에, 최근에 들어 로봇 매니퓰레이터에 관해 신경회로망을 이용한 제어가 활발히 연구되고 있으며, 신경회로망은 병렬 분산 처리(Parallel Distributed Processing)에 의해 위의의 입력의 데이터 변환(Mapping)을 수행하므로 정확한 계산 알고리즘에 의존하지 않고 학습(Learning)에 의한 보간으로 출력을 발생하므로 비선형 계산에 상당히 적합하다. 신경회로망제어는 각각의 뉴런들이 모든 계산을 독립적으로 병렬 처리하고 간단한 학습 알고리즘을 통해 제어칙(control law)을 알아낸다.

이러한 신경회로망에서 기존의 퍼셉트론과 같이 하나의 조정층으로 구성되는 모델들의 한계점 때문에 입력층, 출력층 및 한 개 이상의 은닉층을 쓰는 세로운 모델들이 제시되었는데 역전파(Backpropagation : 이하 BP)학습 알고리즘이 바로 그것이다. BP 알고리즘은 지도학습(Supervised Learning)방법에 의해 학습하는 신경망 구조이므로, 원하는 상태를 추종해야 하는 로봇이나 전동기같은 동역학 시스템에 사용될 수 있는 구조이다. 반면에 BAM, Hopfield 신경망과 ART등의 구조는 비지도학습(Unsupervised Learning)을 사용하므로 동역학 시스템의 제어에는 적절하지 않을 수 있다.

하지만 하지만 이 BP 신경망은 많은 장점에도 불구하고 실제 적용에 있어서는 몇 가지의 문제점을 가지고 있는데, 그 중 하나가 많은 학습에도 불구하고 최적해에 도달하지 못하는 Local-minima 현상을 가진다는 점이며, 또 많은 학습 횟수가 필요하다는 점이며, 또한 연결강도는 정해진 횟수의 반복을 통해 학습되고 난 후에는 변화하지 않고, 일정하게 다음층에 영향을 미치게 된다는 문제점을 가진다. 이러한 문제점을 해결하기 위한 방식은 크게 두가지로 나누어져 연구되었는데, 뉴런 내부구조를 변화시키는 방법과 BP신경망의 외부 구조를 변화시키는 방법으로 나누어 질수 있다. 이중에서 뉴런 내부구조를 변화시키는 방법은, 활성함수를 조작하는 방법과 학습률에 변화를 주는 방법등으로 대변될 수 있다. 그러나 큰 개선을 가져오지는 못했다. 신경망의 외부 구조를 변화시키는 방식은, 기존의 BP 신경망 구조를 변형시켜 순차처리 연산을 향상시키는 구조가 대표적인데, 주로 순환신경회로망(RNN: recurrent neural network)으로 일컬어 진다. 이러한 방식중 대표적인 것은 Jordan 신경망과 Elman 신경망과 시간지연 신경회로망(Time-delay neural network : 이하 TDNN) 등인데, 로봇과 같은 동역학 시스템의 정보는 정적이기보다 동적이고 현재 상태는 과거에 영향을 받는 시스템이기 때문에 연결 강도가 가지는 내부 정보 축적능력에 일종의 자연요소를 가지게 할 필요가 있다. 그래서 Jordan, Elman 및 Doya는 순환회로망에 대해, 근사적 BP 학습법칙을 적용하여, 여러 가지 패턴을 신경회로망에서 학습시키는 것이 가능하다는 것을 보았다.

본 연구에서는 비선형이 내포되어지는 로봇 매니퓰레이터에 기존 BP 신경망과 순환신경회로망인 Jordan과 Elman망을 적용하여 학습후의 RMS오차 및 학습속도에 관해 고찰하여 로봇과 같은 동역학 시스템에 가장 적절한 구조가 어떤 것인가를 비교하고자 하며, 이 비교를 위해 실제 제작 판매되고 있는 로봇 매니퓰레이터를 제작하게 되며, 실험을 위해 회로 설계는 자체 제작하여 사용하였다.

2. 순차처리 신경회로망

2.1 Jordan 망

Jordan망은 Jordan의 연속순차이론을 구현시킨 본질적으로 전형적인 다층 전향 신경회로망(multilayer feedforward neural network)으로 망의 중간에 완전결합형태를 이루고 있다. 출력을 귀환하여 상태층에 시계열적 정보를 지니도록 하기 위하여

출력노드와 출력의 값을 그대로 복사하는 상태노드(state units) 사이에는 한 조의 귀환연결(feedback connection)이 있으며 각 상태노드는 1보다 작은 고정된 강도의 자기귀환루프를 가지고 있다. 회로망의 교육에는 통상의 EBP 학습 알고리즘이 사용되고 망의 전향연결(feedforward connections)은 역전파에 의해서 학습을 받으나 시간을 통한 귀환연결은 학습을 받지 않는다. Jordan의 회귀망 구조는 그림 1과 같다.

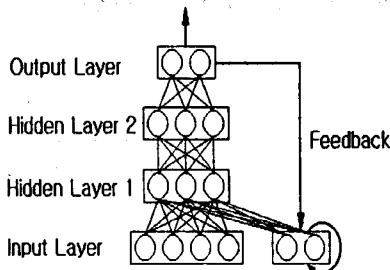


그림 1. Jordan 신경회로망
Fig 1. Jordan Neural Network

Jordan망의 출력값은 다음과 같다.

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

$$\text{여기서 } NET_i^k = \sum_j out_j^{k-1} \cdot w_{ij}^{k-1} \quad (1)$$

여기서 k 는 출력층을 의미하고 w_{ij}^{k-1} 는 $(k-1)$ 번째 층의 i 번재 뉴런과 k 번째 층의 j 번재 뉴런간의 연결강도의 값이며 $f(\cdot)$ 는 활성함수임을 의미한다.

단, 중간층-입력층과 상태층사이의 NET는

$$NET_i = \sum_i In_i \cdot w_{ij} + \sum_n dstate_n \cdot dw_{ij} \quad (2)$$

여기서 In_i 는 i 번째 입력을 의미하고 $dstate$ 는 출력층에서 복사된 뉴런을 의미하고 dw 는 상태층과 중간층사이의 연결강도를 의미하며 n 은 상태층 뉴런수를 의미하므로 출력층의 뉴런수와 같다.

학습은 상태층의 연결강도를 제외하고는 다음과 같이 이루어진다.

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

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

$$\delta_i^k = (target_i - out_i^{k+1}) \cdot f'(NET_i) \quad (4)$$

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

$$\delta_i^{k-1} = f(NET_i^{k-1}) \cdot \sum_j \delta_j^k \cdot w_{ij}^{k-1} \quad (5)$$

상태층의 학습은

$$dw_m(n+1) = dw_m + \eta \cdot \delta_j \cdot dstate_m + \alpha \cdot \Delta dw_m(n) \quad (6)$$

여기서 n 은 상태층의 n 번째 뉴런을 의미하고 j 는 중간층의 j 번째 뉴런을 의미한다. 또한 δ_j 는 중간층에서의 δ 를 의미한다.

또한 상태층의 뉴런은 자기회귀능력을 가지는데, m 번째 $dstate$ 뉴런은

$$dstate_m = out_m + dstate_m \cdot \mu \quad (7)$$

여기서 μ 는 자기회귀계수로 0과 1사이의 값이다.

2.2 Elman 망

Elman 망은 한층의 은닉층을 가지는 이층구조의 퍼셉트론을 변형한 간단한 회귀망이다. 매 시간스텝에서 은닉노드상의 활성패턴이 문맥층(context layer)으로 복사되어 다음 시간스텝에서 회로망의 입력상태의 일부로 작용한다. 이것은 은닉노드가 자신을 포함한 모든 다른 은닉노드에 회귀링크를 결합한 순환구조의 오류역전파 신경회로망과 동일한 구조를 가진다. 은닉층의 활성은 순환(recycle)하게 된다. 회로망의 중간결합은 완전결합 형태이고 Jordan 망과 같이 통상의 EBP 학습 알고리즘으로 교육되며 망의 전향연결은 역전파 과정에 의해서 학습을 받으나 시간을 통한 귀환연결은 학습을 받지 않는다.

Elman 망의 구조는 그림 2와 같다.

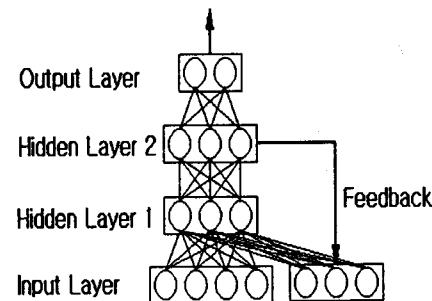


그림 2. Elman 신경망
Fig 2. Elman Neural network

Elman 망의 출력값도 Jordan망이나 일반적인 BP처럼 다음과 같다.

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

$$\text{여기서 } NET_i^k = \sum_j out_j^{k-1} \cdot w_{ij}^{k-1} \quad (8)$$

단, 중간층-입력층과 문맥층사이의 NET는

$$NET_i = \sum_i In_i \cdot w_{ii} + \sum_n cstate_n \cdot cw_{in} \quad (9)$$

여기서 In_i 는 i번째 입력을 의미하고 $cstate$ 는 중간층에서 복사된 뉴런을 의미하고 cw 는 문맥층과 중간층사이의 연결 강도를 의미하며 n은 문맥층 뉴런수를 의미하므로 복사된 중간층의 뉴런수와 같다.

학습은 상태층의 연결강도를 제외하고는 다음과 같이 이루어진다.

$$w_{ii}^{(n+1)} = w_{ii}^k + \eta \cdot \delta_i^k \cdot out_i + \alpha \cdot \Delta w_{ii}^k(n) \quad (10)$$

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

$$\delta_i^k = (target_i - out_i^{k+1}) \cdot f'(NET_i) \quad (11)$$

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

$$\delta_i^{k-1} = f(NET_i^{k-1}) \cdot \sum_j \delta_j^k \cdot w_{ij}^{k-1} \quad (12)$$

문맥층의 학습은

$$cw_{mj}(n+1) = cw_{mj} + \eta \cdot \delta_j \cdot cstate_m + \alpha \cdot \Delta cw_{mj}(n) \quad (13)$$

여기서 n은 문맥층의 n번째 뉴런을 의미하고 j는 중간층의 j번째 뉴런을 의미한다. 또한 δ_j 는 중간층에서의 δ 를 의미한다.

3. 제어 시스템

본 논문에서는 DSP Chip을 신경망 계산을 위한 주제이기로 사용하여 Robot Manipulator의 신경망 제어기의 구현과, 여러 신경 회로망중에서 실제 로봇 매니퓰레이터에 가장 적절하게 사용될 수 있는 신경망 구조를 찾아 내는 것을 목표로 하고 있다.

로봇 매니퓰레이터의 위치제어가 실시간으로 처리 가능하고 좋은 성능을 가지기 위해서 샘플링 주기를 2~5ms 정도로 설정하는 것이 좋다. 샘플링 주기를 2~5ms로 설정하기 위해서는 신경망의 계산시간을 되도록 짧게 만들어 주어야 하는데, 신경망의 계산시간을 짧게 만들기 위하여 계산량을 적게 할 수는 없으므로 빠른 프로세서를 사용하여 계산시간을 단축시키는 것이다. 본 실험에서는 DSP Chip을 사용하여 계산시간을 단축시키고자 하였고 사용한 DSP Chip은 ADSP-21020이다. ADSP-21020은 32 Bit 프로세서인데 프로그램 메모리는 48 Bit로 되어있으며 모든 명령이 한 워드로 구성되어 모든 명령은 한 사이클에 실행되어 고속의 연산을 할 수 있다.

신경망의 계산시간에 따라서 Robot Manipulator에 신경망 제어기를 적용하여 실시간으로 제어할 수 있는 가를 평가할 수 있으므로 ADSP-21020을 사용하여 뉴런수에 따른 계산시간을 측정하여 표에 기록하였다.

본 실험에서는 신경제어기를 SCARA형 Robot Manipulator의 2축 위치 제어에 적용하였지만 12, 16, 16, 6인 신경망의 계산시간이 2.71msec인 것으로 보아 6축 수직다관절 로봇에 신경망 제어기를 적용하여도 한 샘플링 주기안에 모든 것을 계산

할 수 있다. 따라서 고속의 DSP Chip을 사용하면 신경칩을 사용하지 않고도 신경망 제어기를 구현할 수 있을 것으로 보인다.

실험에 사용한 Robot Manipulator는 삼성전자의 FARA SCARA ROBOT으로 Brushless DC Servo Motor가 사용되었고 Motor의 제어를 위하여 AC Servo Driver를 이용하였다. 로봇 팔의 위치 센서로 Resolver가 사용되었으며, Resolver의 아날로그 신호를 AC Servo Driver가 디지털 위치 신호인 엔코더 신호로 바꾸어 주는 역할도 한다.

신경망의 구조	계산시간 [단위 : msec]
4 3 3 2	0.1720
4 10 10 2	0.69173
8 16 16 4	2.28370
12 16 16 6	2.71200
12 20 20 6	3.76752

표 1. 뉴런에 따른 계산시간

Table 1. The computing time per the number of neuron

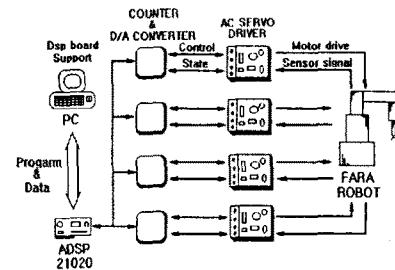


그림 3. 인터페이스 회로

Fig 3. Interface Circuit

그림 3은 제작된 인터페이스 회로의 구조이며, 그림 4는 전체 신경제어기의 구조이다.

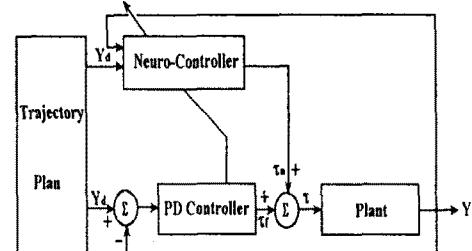


그림 4. 전체 신경제어기의 구조

Fig 4. The Structure of Neural Controller

그림 4와 같은 구조에서는 학습을 위한 에너지 함수는 다음과 같아야 한다.

$$E = \frac{1}{2} \sum (r_d - r_n)^2 \quad (14)$$

여기서 r_d 는 바람직한 토크이다.

그리나 r_d 는 알 수 없는 값이므로 (4)는 다음과 같이 수정되어야 한다.

$$E = \frac{1}{2} \sum r_j^2, \quad (15)$$

여 $r_j = k_p \cdot (Y_d - Y) + k_d \cdot (Y_d - \dot{Y})$ 기서 이고, k_p 와 k_d 는 PD계수이다.

연결강도의 변화는 다음 관계에 의해 학습되어 진다.

$$\Delta w_{ij}^k \propto \frac{\partial E}{\partial w_{ij}^k} \quad (16)$$

4. 실험 결과

본 실험에서 사용한 수직 다관절 로봇은 SCARA Robot로써 4 자유도를 갖고, 비교적 비선형성이 작은 로봇이며, 1, 2축과 3, 4축은 서로 거의 독립적으로 작용한다. 하지만 비선형성이 대부분 1축과 2축에서 나타나므로 본 실험에서는 1축과 2축만을 제어하였다.

4.1 실험 결과

로봇의 채팅입력으로 지름이 12cm인 원을 2초 동안 회전하도록 주었으며, 샘플링 시간은 4[msec], 샘플링 개수를 500개로 하였다. 빠른 시간동안의 로봇회전에서 비선형성이 크게 나타나므로 짧은 시간의 채팅을 입력으로 하였다.

본 연구에서 사용한 각각의 신경망의 구조는 2개의 중간층을 갖고 각 층의 뉴런수가 4,3,3,2인 신경구조로 되어 있으며, 4개의 입력층 뉴런에 로봇의 각 조인트의 위치와 각속도의 값을 입력시켰다. 또한 활성함수의 기울기, 학습률, 모멘텀 계수를 각각 1.0, 0.005, 0.001로 정의하였다.

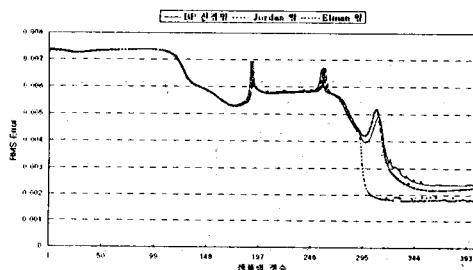


그림 5. 신경망에 따른 조인트 1, 2의 합성 RMS 오차
Fig 5. The Comparison with RMS Error for Joint 1 and 2

그림 5는 400번 학습후의 각각의 신경망구조에 따른 RMS오차를 나타낸 것이다. Robot Manipulator를 제어 할 때는 각 조인트마다의 오차를 비교하여 제어하였지만, 학습의 정도를 나타낼 때는 Robot Manipulator의 End-Effector가 가리키는 위치를 사용하였다. 따라서 그림 4는 조인트 1, 2의 합성 RMS오차를 나타낸다. 그림에서 볼수 있듯이 학습후 일반 BP 신경망의 RMS오차는 2.5mm 정도이지만, 회귀 신경망인 Jordan망과 Elman망의 경우 1.8mm 정도로 수렴정도에서 차이를 나타내고

있다.

그림 6은 조인트 1과 2의 오차를 비교한 그림이다. Jordan 신경망이 가장 좋은 결과를 보임을 알 수 있다.

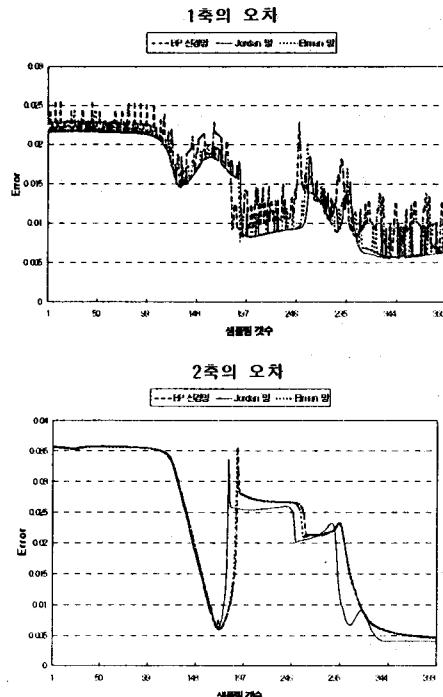


그림 6. 조인트 1, 2의 오차 비교
Fig 5. The Comparison with Errors for Joint 1 and 2

5. 결론

본 연구에서는 기존의 BP 신경망을 변형시킨 신경 회로망인 Jordan망과 Elman망을 이용하여 Robot Manipulator에 적용하여 그 수렴정도에 관해 연구하였다.

일반 BP 신경망에서는 그림 6에서 볼수 있듯이 말단부의 에리가 2.5mm 정도로 뒤에 수렴하지 않지만, Jordan 신경망의 경우 학습후의 에리가 1.8mm 정도로 일반 BP 신경망에서 보다도 작게 나왔다. 이것으로부터 Robot Manipulator와 같은 동역학 시스템에는 Jordan 신경망이 가장 우수함을 알 수 있으며, Elman 신경망의 경우도 보통 입력 패턴이 복잡한 음성처리에 적용이 용이한 알고리즘이지만 로봇에 적용시 일반적 BP 신경망 보다는 우수함을 알 수 있었다.

참고문헌

1. M.I.Jordan, "Serial Order : A parallel Distributed Processing Approach", Technical Report ICS-8604, Institute for Cognitive Science, Univ.of California, SanDoego, LaJolla, California, May, 1986

2. J.L.Elmel, "Finding Structure in Time", Technical Report CRL-8801,center for Research in Language, Univ.of California, San diego, La Jolla, California, April 1988.
3. A.Waibel, T.Hanazawa, G.Hinton, K.Shikano and K.J.Lang,"Phoneme Recognition using Time-Delay Neural Networks", IEEE trans.on Acoustics, Speech and signal Processing, Vol.37,No.3, pp328-339, 1991
4. J.D.Kim, J.S.Chi, D.K.Chung and T.C.Lee, " DC Servo Motor Position control using Neuro Controller",Journal of KITE,Vol 29-B, No 5, pp83-94, May 1992
5. D.E.Rumelhart, J.McCelland, " Parallelized Distributed Processing",MIT Press, 1988
6. J.Chen, P.Mars,"Stepsize Variation Methods for Accelerating the Back-Propagation Algorithm",Vol.1, pp.1-601~634,1989
7. H.Ritter, T.MarhNetz and K.Schulten, "Neural Computation and Self-organizing Maps", Addison wesley Publishing Company,1991
8. T.Fukuda and T.Shibara,"Theory and Application of Neural Network for Industrial Control Systems", IEEE Trans. on Industrial Electronics, Vol.39, No 6, pp472~489,DEc,1992
9. D.Ottoson, "Phisiology of the Nervous Systems", The MacMillan Press, Ltd, 1983
10. Miller, Sutton and Werbers, "Neural Networks for Control", The MIT Press, 1980
11. D.Nguyen and B.Widrow, "Improving the Learning Speed of 2-layer Neural Networks by Choosing Initial Values of the Adaptive Weight", IJCNN, San Diego, California, Vol.3, pp.21~26, June, 1990
12. F.Nadi, "Topological Design of Modular Neural Network.", Artificial Neural networks, Vol1, pp.213~218, 1991