

論文91-28B-11-10

퍼지논리와 다층 신경망을 이용한 로봇 매니플레이터의 위치제어

(Position Control of the Robot Manipulator Using Fuzzy Logic and Multi-layer Neural Network)

金 宗 秀*, 李 鴻 奇**, 金 洪 兌*

(Jong Soo Kim, Hong Gi Lee, and Hong Tae Jeon)

要 約

로봇 매니플레이터의 신경 제어기 구성에 널리 사용하는 다층 신경 회로망은 로봇의 불확실한 동적 파라미터 변화에 대한 강건한 학습 적응 능력, 그리고 병렬처리를 통한 실시간 제어등의 장점을 갖고 있다. 그러나 대표적인 학습 방법인 오차 역전파(error back propagation) 알고리즘은 그 학습 속도가 느리다는 문제점을 갖는다.

본 논문에서는 불확실하고 애매한 정보를 언어적인 방법에 의해 효율적으로 처리할 수 있는 퍼지논리(fuzzy logic)를 도입하여 로봇 매니플레이터 신경 제어기의 학습 속도를 개선하기 위한 한 방법을 제안한다. 제안된 제어기의 효용성은 PUMA 560로봇의 모의 실험을 통해 입증된다.

Abstract

The multi-layer neural network that has broadly been utilized in designing the controller of robot manipulator possesses the desirable characteristics of learning capacity, by which the uncertain variation of the dynamic parameters of robot can be handled adaptively, and parallel distributed processing that makes it possible to control on real-time. However the error back propagation algorithm that has been utilized popularly in the learning of the multi-layer neural network has the problem of its slow convergence speed.

In this paper, an approach to improve the convergence speed is proposed using the fuzzy logic that can effectively handle the uncertain and fuzzy informations by linguistic level. The effectiveness of the proposed algorithm is demonstrated by computer simulation of PUMA 560 robot manipulator.

I. 서 론

*正會員, 中央大學校 電子工學科
(Dept. of Elec. Eng., Chungang Univ.)

**正會員, 中央大學校 制御計測工學科
(Dept. of Cont. Inst. Eng., Chungang Univ.)

接受日字: 1991年 7月 15日

(※ 본 연구는 1990년도 한국과학재단 목적기초 연구비 지원으로 수행되었음. 과제번호:90-0100-02)

일반적으로 로봇 매니플레이터의 신경 회로망 제어방식은 역기구학의 모델링에 의한 기구학적 방식과 역동력학을 모델링하는 동력학적 방식으로 구분되고 있다. 역동력학적 방식은 기구학적 방식보다 복잡하고 어려우나 로봇의 비선형과 중첩(coupled)된 동적특성을 고려하기 때문에 많은 연구자들에 의해 선호되고 있다.

로봇 매니플레이터의 신경 위치 제어를 제안하는 본 논문에서 제어 대상의 동적특성과 환경 모델링이 불필요하고, 제어 성능을 자체 학습에 의해 항구적으로 개선할 수 있으며 병렬계산 처리를 할 수 있는 동력학적 신경 제어 기법을 도입한다. 그리고 제안된 로봇 매니플레이터의 신경 제어기는 다음과 같은 특성을 갖는다.⁶⁾¹¹⁾

- 1) 로봇의 동적 특성에 대한 정확한 사전 정보 없이도 제어가 가능한 제어 시스템
- 2) 최소 위치 오차에로의 빠른 수렴성을 보장할 수 있는 신경 제어 시스템

일반적으로 신경 제어기 설계에 있어 응용할 수 있는 신경망 구조들은 Hopfield network을 포함한 여러 형태들이 있으나 최근 불확실한 플랜트 제어에 많이 응용되는 다층 신경 회로망 구조를 본 로봇 매니플레이터의 제어기 설계에 도입한다. 그리고 다층 신경망의 훈련 방법으로 대표적인 오차 역전파 (error back propagation) 학습 알고리즘을 채택하고 있다.^{1)4)7) 그러나 역전파 학습 알고리즘은 느린 학습 수렴속도의 문제점을 갖는다.¹⁾¹⁾²⁾⁵⁾¹⁸⁾}

이러한 다층 신경 회로망의 느린 학습 속도는 주로 부적절한 가중치 (weight)들의 설정으로 인해 발생하는 각 뉴런의 조기 포화상태 (premature saturation)에 기인되고 있다. 즉, 신경망을 구성하는 어느 한 뉴런이라도 조기 포화상태에 있을 경우 가중치의 큰 변화에도 불구하고 실제 오차의 변화량은 미미하게 된다. 따라서 빠른 학습 수렴 속도를 얻기 위해서는 뉴런의 조기 포화 상태를 감지하고, 조기 포화상태에서 활성화 함수 (activation function)의 기울기들을 적절히 변화시켜 그 상태를 벗어나게 해야 한다.

본 논문에서는 이러한 포화상태를 미리 감지할 수 있고 동시에 포화상태에서 기울기의 적절한 변화를 통해 다층 신경망의 빠른 수렴성을 얻을 수 있는 한 가지 방법을 제시한다. 제안하는 방식은 논리 및 추론 (inference)의 잇점들을 갖는 퍼지 논리 (fuzzy logic) 기법을 응용하여 뉴런의 활성화 함수의 기울기를 가변시키는 방식이다. 이 방식은 추정하기 어렵고 불확실한 기울기 변화에 대한 수학적 혹은 확률적인 정보를 필요로 하는 방식²⁾⁸⁾ 보다 논리적인 추론에 의한 기울기 변화를 이용, 뉴런의 조기 포화상태를 방지할 수 있는 효율적인 접근 방식이다. 그리고 이 방식을 이용 학습속도가 개선된 로봇 매니플레이터의 위치 제어 시스템을 끝으로 제안한다.

한편 본 논문의 구성은 다음과 같다. 2장에서는 로봇 신경 제어기 구성에 널리 응용되는 다층 신경 회로망 구조와 대표적인 학습방법인 오차 역전파

학습 규칙 (error back propagation learning rule)의 수렴성에 관한 문제점을 파악하고, 수렴속도를 개선하기 위한 기법을 3장에서 제안한다. 그리고 4장에서는 제안한 기법을 이용, 로봇 매니플레이터의 위치 제어를 구성하고 5장에서는 컴퓨터 모의 실험과 그 결과를 보여준다. 끝으로 6장에서는 본 논문의 결론을 서술한다.

II. 다층 신경망의 역전파 학습 알고리즘과 문제점

그림1은 로봇의 신경 제어기에 널리 응용되는 다층 신경 회로망을 보여주고 있다.




그림 1. 다층 신경회로
Fig. 1. Multi-layer neural network.

상기 다층 신경망을 구성하는 각 뉴런의 입·출력 특성 (그림2참조)은 출력단의 k번째 뉴런을 예들들면 다음의 수학적 모델링을 갖는다.⁹⁾

$$f(a, net_k) = \frac{1}{1 + \exp(-a \cdot net_k)} \tag{1a}$$

$$net_k = \sum_j (W_{kj} \cdot OUT_j) \tag{1b}$$

$$OUT_k = f(net_k) \tag{1c}$$

여기에서, OUT_j 는 중간층에서 뉴런j의 출력이며 W_{kj} 는 출력층의 뉴런k와 중간층의 뉴런 j사이의 가중치 (weight)를 나타낸다. 그리고 a는 뉴런 활성화 함수의 기울기를 나타내는 계수이다.

그림1의 다층 신경망 출력단에서 전체 오차는 각 뉴런의 출력과 목표치와의 차이들의 합으로 다음과 같이 구할 수 있다.




그림 2. 인공 뉴런
Fig. 2. Artificial neuron.

$$E = 1/2 * \sum_k (D_k - OUT_k)^2 \quad (2)$$

여기서 D_k 는 출력단 k 번째 뉴런의 목표값이며, OUT_k 는 출력단 k 번째 뉴런의 출력값을 나타낸다.

식(2)의 오차 E 를 감소시키기 위한 출력단 가중치들의 변화량은 gradient descent 방법의 의해 다음과 같이 구할 수 있다.

$$\begin{aligned} \Delta W_{kj} &= -\eta \cdot \frac{\partial E}{\partial W_{kj}} = -\eta \cdot \frac{\partial E}{\partial net_k} \cdot OUT_j \\ &= \eta \cdot \delta_k \cdot OUT_j \end{aligned} \quad (3a)$$

$$\delta_k = (D_k - OUT_k) \cdot f'(a, net_k) \quad (3b)$$

여기에서, $f'(a, net_k) = \partial net_k / \partial f(a, net_k)$ 그리고 $net_k = \sum_j W_{kj} \cdot OUT_j$ 이다. 또한 η 는 학습율을 나타내고 δ_k 는 역 방향으로부터 전달되어오는 오차이다. 식(3)에 의한 출력단에서 가중치 변화와는 달리 중간층에서의 가중치 변화량 ΔW_{ji} 는 다음식에 의해 구할 수 있다.

$$\Delta W_{ji} = -\eta \cdot \frac{\partial E}{\partial W_{ji}} = \eta \cdot \delta_j \cdot OUT_i \quad (4a)$$

$$\delta_j = f'(net_j) \cdot \sum_k (\delta_k \cdot W_{kj}) \quad (4b)$$

식(3)과 (4)를 이용 각 층에서의 새로운 가중치들은 최종적으로 다음식에 의해 조정된다.

$$W_{kj}(t+1) = W_{kj}(t) + \Delta W_{kj} + \alpha [W_{kj}(t) - W_{kj}(t-1)] \quad (5a)$$

$$W_{ji}(t+1) = W_{ji}(t) + \Delta W_{ji} + \alpha [W_{ji}(t) - W_{ji}(t-1)] \quad (5b)$$

여기서, α 는 운동량 항(momentum term)이다.

식(5)를 출력단에서 입력단까지 계속적으로 반복하면 각 뉴런의 출력오차가 감소하도록 가중치가 변하게 되며, 마지막에는 오차가 없게되는 오차 역전파(error back propagation) 학습이 이루어 진다.

그러나 식(3)과 (4)에서 δ_j 와 δ_k 값을 결정할때 오차의 크기에 상관없이 가중치들의 합이 부적절하게 위치하면 학습이 이루어지지 않은 상태에서도 활성화

함수의 미분 출력값이 0에 가깝게 되며 이때는 식(3)과 식(4)에서 오차값에 관계없이 가중치 변화량이 작아지게 되는 이른바 조기 포화상태(early saturation)에 빠지게 된다. 조기 포화 상태에서 가중치들의 변화량은 매우 작게되며 전체적인 학습속도에 큰 영향을 미치게 된다.

따라서 이러한 조기 포화상태를 미리 감지할 수 있고 그 포화상태에서 활성화 함수의 기울기를 조절해 주면 용이하게 문제의 조기 포화상태를 벗어나게 할 수 있다. 그림3은 활성화 함수 $f(a, x)$ 에서 기울기 계수 a 의 변화에 따른 활성화 함수들과 그 일차 미분값, 즉 기울기 변화를 보여주고 있다.




그림 3. 뉴런의 활성화 함수와 그 기울기
Fig. 3. Activation function of neuron and its slope.

III. 퍼지 논리에 의한 기울기 수정방법

조기 포화상태를 감지하여 활성화 함수의 기울기를 변화 시켜주는 방법으로 언어적인 표현이 가능한 퍼지 논리(fuzzy logic)를 이용한다.¹⁰⁾ 그림4는 본 논문에서 제안하는 뉴런 활성화 함수의 기울기를 조절하기 위해 퍼지 논리를 이용한 기울기 수정기(slope modifier)를 보여주고 있다.

그림4의 각 뉴런에서 δ_k 와 δ_j 는 위에서 정의한 값이고 각 뉴런의 출력에서는 다음과 같은 오차값 NE(network error)를 정의한다(이후 δ_k 혹은 δ_j 는 δ 로 대체한다).

$$NE = 1/2 * (D_k - OUT_k)^2 \quad (6)$$

기본 구성도는 그림4의 퍼지화(fuzzification) 과정은 각 뉴런에서 구한 crisp한 수치 δ 값과 NE값들을 singleton 방법을 이용 퍼지 변수로 변환하는 과정이다(그림5참조). 이 퍼지화 과정에서 입력값은 식(7)에 의해 정규화(normalize)되어 퍼지집합 소속함수

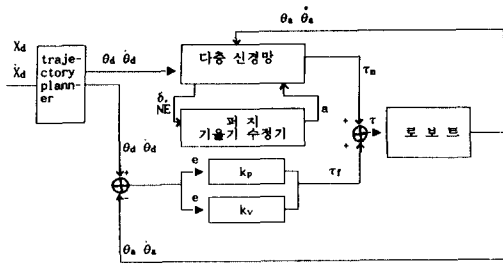


그림 6. 퍼지논리의 기율기 수정기를 갖는 로봇 신경 제어기

Fig. 6. Neuro controller of the robot with slope modifier based on fuzzy logic.

실제 측정된 조인트 위치와 속도들이다. 이들 값들로부터 조인트의 위치 및 속도 오차들을 다음과 같이 정의한다.

$$e \in R^n = \theta_a - \theta_a \tag{11a}$$

$$\dot{e} \in R^n = \dot{\theta}_a - \dot{\theta}_a \tag{11b}$$

여기에서 n은 매니퓰레이터의 조인트 갯수를 나타낸다.

로봇의 위치 제어기는 상기 오차들을 감소시키기 위한 즉, 로봇이 명령된 궤적을 정확하게 수행하는데 그 목표가 있다. 일차적으로 그림6의 PD 제어기는 오차를 감소하기 위한 새로운 보정입력 τ_f 를 다음과 같이 결정한다.

$$\tau_f \in R^n = k_p(\theta_a - \theta_a) + k_v(\dot{\theta}_a - \dot{\theta}_a) \tag{12}$$

여기에서 k_p 와 k_v 는 각각 위치 및 속도의 제환 이득들이다.

그러나 상기 PD 기법만을 이용, 비선형적이고 중첩된 그리고 가변성의 동적 특성을 갖는 로봇 매니퓰레이터의 강건한 제어를 구성하는 일이 매우 어렵다. 이에 로봇의 동적 특성을 하나의 'black-box'로 보고 제어를 가능케하는 신경 제어기의 필요성이 대두된다. 이를 위해 그림6의 상단에 다층 신경회로망 구조를 갖는 신경 제어기를 기존의 PD 제어기와 병렬로 연결 구성한다.

상기 제어기에서 초기에는 신경 제어기의 출력 τ_n 과 PD제어기 출력 τ_f 의 합성된 토크로 동작하게 된다. 이후 신경제어기가 점진적으로 오차를 감소시키는 방향으로 학습되면서 오차에 의한 PD 제어기의 출력 토크 τ_f 는 감소하게 된다. 이때 신경 제어기의 학습은 역전파 알고리즘에 의해 얻어진다. 완전한 학습이 이루어지면 PD 제어기의 오차 보정입력 τ_f 는 0이 되며 이때부터 로봇은 오직 신경회로망의

출력 τ_n 에 의해 동작된다.

그러나 앞서 설명한 것처럼 다층 신경회로망 제어기의 문제점은 역전파 학습시 그 수렴속도이다. 이에 역전파 학습속도를 향상시키기 위해 앞절의 퍼지논리 기법을 이용한 기율기 수정기를 상기 로봇 매니퓰레이터의 위치 제어 시스템에 도입한다(그림6 참조). 이 경우 식(3), (4)의 δ 값과 NE값은 다음과 같이 변하게 된다.

$$\delta_k = \tau_f \cdot f'(a, net_k) \tag{13a}$$

$$\delta_j = f'(a, net_j) \cdot \sum (\delta_k \cdot W_{kj}) \tag{13b}$$

$$NE = 1/2 * (\tau_f)^2 \tag{13c}$$

기율기 수정기는 오차 보정 입력 τ_f 에 의해 변환된 δ 값과 NE값을 이용하여 초기 포화상태에 있는 뉴런에서 그 상태를 벗어나기 위한 활성화 함수의 새로운 기율기 값을 추론하게 된다.

V. 컴퓨터 시뮬레이션

PUMA 560로봇의 3축만을 제어 대상으로 하였으며, 시뮬레이션에 사용된 다층 신경망은 입력층에 12개의 뉴런, 2개의 중간층(각20개, 10개) 및 출력층에 3개의 뉴런을 갖는 12-20-10-3의 구조를 갖는다. 그리고 신경 제어기와 본 논문의 제어기와 비교하기 위해 동일한 초기 가중치와 학습율, 운동량 값을 선정하였다. 그 파라미터 값들에서 초기 가중치는 -1에서 1사이의 임의값으로 정하였고, 학습율은 0.3 그리고 운동량 항의 값은 0.2로 하였다. 또한 K_p 와 K_v , G1 그리고 G2값들은 다음과 같이 선정하였다.

$$K_p = \begin{bmatrix} 500 & 0 & 0 \\ 0 & 1000 & 0 \\ 0 & 0 & 1000 \end{bmatrix} \quad K_v = \begin{bmatrix} 10 & 0 & 0 \\ 0 & 20 & 0 \\ 0 & 0 & 20 \end{bmatrix} \tag{14}$$

$$G1 = 0.1 \quad G2 = 100$$

그리고 명령 궤적으로 다음의 카르테시안 궤적을 선정하였다.

$$X_a(t) = \begin{bmatrix} P_x(t) \\ P_y(t) \\ P_z(t) \end{bmatrix} = \begin{bmatrix} 0.2 + 0.1 \cos(t) \\ 0.2 + 0.05 \sin(t) \\ 0 \end{bmatrix} \tag{15a}$$

$$\dot{X}_a(t) = \frac{dX_a(t)}{dt} \tag{15b}$$

그림7에서 그림9는 신경 제어기만을 이용하여 첫 번째, 20번째 그리고 100번째 학습에서 로봇의 수행 궤적을 보여주고 있으며, 그림10에서 그림11은 본

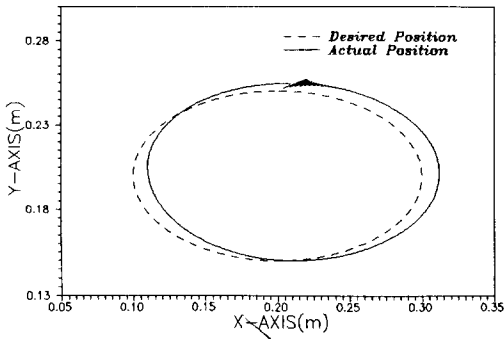


그림 7. 카르테시안 공간에서 신경제어기의 첫번째 학습

Fig. 7. The first learning trial of the neuro controller in the cartesian space.




그림 10. 기울기 수정기를 갖는 신경제어기의 첫번째 학습

Fig. 10. The first learning trial of the neuro controller with slope modifier.




그림 8. 신경제어기의 20번째 학습

Fig. 8. The 20th learning trial of the neuro controller.




그림 11. 기울기 수정기를 갖는 신경제어기의 20번째 학습

Fig. 11. The 20th learning trial of the neuro controller with slope modifier.




그림 9. 신경제어기의 100번째 학습

Fig. 9. The 100th learning trial of the neuro controller.

논문에서 제안한 퍼지 추론에 의한 기울기 수정기를 갖는 신경 제어기의 첫번째와 20번째의 로봇 수행 궤적들이다. 이 결과를 비교해볼 때 신경 제어기만을 사용하였을 경우는 100번째에 수렴성을 보이지만 기울기 수정기를 갖는 신경 제어기는 20번째에서 수렴됨을 알 수 있다.

한편 그림 12는 제안한 방식에 의한 학습과정중 두 개의 뉴런만을 대상으로 관찰한 기울기 값들의 변화를 보여주고 있다. 이 그림에서 기울기 값이 감소하는 부분이 뉴런의 초기 포화상태에서 벗어나기 위한 기울기의 조정 부분에 해당된다. 이러한 조정에 의해 해당 뉴런이 초기 포화 상태를 효과적으로 벗어날 수 있음을 알 수 있다.




그림 12. 활성화 함수의 기울기 변화
Fig. 12. Variation of the slope of activation function.

VI. 결 론

본 논문은 로봇트 매니퓰레이터의 신경제어기에 널리 응용되는 다층 신경회로망의 대표적인 학습 방법인 오차 역전파 학습 알고리즘의 학습 속도를 개선하는 방법을 제안하고 있다. 이 방식은 추정하기 어렵고 불확실한 뉴런의 기울기 변화를 퍼지 논리에 의해 효과적으로 수정하는 방식으로 오차 역전파 알고리즘이 갖는 뉴런의 초기 포화상태의 문제점을 효율적으로 해결하고 있다.


제안하는 방식의 효용성은 컴퓨터 시뮬레이터에 의해 입증이 되고 있으며 로봇트 매니퓰레이터의 신경 제어기의 학습속도 향상에 이바지할 것으로 판단된다. 끝으로 본 방식은 휴 필드 신경 회로망을 이용한 로봇트 제어기에도 용이하게 적용할 수 있을 것으로 판단된다.

參 考 文 獻

[1] N. Baba, "A Hybyid Algorithm for Finding Global Minimum of Error Function of Neural Networks," *Proc. Int. Joint Conf. Neural Networks*, pp. 1585-1588, 1990.

[2] J.R. Chen and P. Mars, "Stepsize Variation for Accelerating the Back Propagation Algorithm," *Proc. Int. Joint Conf. Neural Networks*, pp. 1601-1604, Jan 1990.
 [3] R.K. Elsley, "A learning architecture for control based on Back-Propagation neural network," *Proc. of the IEEE Conf. on Neural Networks*, vol. 2, pp. 587-594, 1988.
 [4] A. Guez, J.L. Eilbert, and M. Kam, "Neural Network Architecture for Control," *IEEE Control Systems Magazine*, pp. 22-24, April, 1988
 [5] R.A. Jacobs, "Increased Rates of Convergence Through Learning Rate Adaptation," *Neural networks*, vol. 1, pp. 295-308, 1988.
 [6] G. Josin, D. Charney, and D. White, "Robot Control Using Neural Networks," *Proc. of the IEEE International Conference on Neural Networks*, pp. 625-631, July 1988.
 [7] H. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki, "Feedback error-learning neural network for trajectory control of a robotic manipulator," *Neural Networks*, vol. 1, no. 3, 1988.
 [8] A. Rezgui, et al., "The Effect of the Slope of the Activation Function on the Back Propagation Algorithm," *Proc. Int. Joint Conf. Neural Networks*, pp. 1707-1710 Jan 1990.
 [9] David E. Rumelhart and James L. McClelland, "Parallel Distributed Processing," MIT Press, 1987
 [10] H.J. Zimmermann, *Fuzzy Set Theory and Its Application*, Kluwer-Nijhoff Publishing a member of the Kluwer Academic Publishers Group, 1986.
 [11] 오세영, 유연식, "다층 신경회로 및 역전달 학습 방법에 의한 로봇트 팔의 다이내믹 제어" 대한 전기학회지, Vol. 39, No. 12, pp. 1306-1316, 1990.

著 者 紹 介



金 宗 秀 (準會員)
1964年 5月 5日生. 1990年 2月 중 앙대학교 전자공학과 졸업. 1990年 6月~현재 중앙대학교 전자공 학과 대학원 석사과정 재학중. 주 관심분야는 퍼지 및 신경망, 로보 틱스 및 F. A 등이다.

全 洪 兌 (正會員) 第26卷 第10號 參照
현재 중앙대학교 전자공학과 부교수
李 鴻 奇 (正會員) 第28卷 A編 第11號 參照
현재 중앙대학교 제어계측공 학과 부교수