

## 신경망과 진화 알고리즘을 이용한 로봇 매니퓰레이터의 궤적 제어에 관한 연구

김해진\*, 임정은\*, 이영석\*\*, 서보혁\*

\*경북대학교 전기공학과, \*\*영진전문대학 디지털의료전기계열

### A Study on Trajectory Control of Robot Manipulator using Neural Network and Evolutionary Algorithm

Hae-jin Kim\*, Jung-eun Lim\*, Young-seok Lee\*\*, Bo-hyeok Seo\*

\* dept. of Electrical Engineering Kyungpook National University

\*\* dept. of Digital Electricity & Medical System Yeungjin Collage

**Abstract** - In this paper, The trajectory control of robot manipulator is proposed. It divides by trajectory planning and tracking control. A trajectory planning and tracking control of robot manipulator is used to the neural network and evolutionary algorithm. The trajectory planning provides not only the optimal trajectory for a given cost function through evolutionary algorithm but also the configurations of the robot manipulator along the trajectory by considering the robot dynamics. The computed torque method (C.T.M) using the model of the robot manipulators is an effective means for trajectory tracking control. However, the tracking performance of this method is severely affected by the uncertainties of robot manipulators. The Radial Basis Function Networks(RBFN) is used not to learn the inverse dynamic model but to compensate the uncertainties of robot manipulator. The computer simulations show the effectiveness of the proposed method.

#### 1. 서 론

로봇 매니퓰레이터의 궤적 계획은 매니퓰레이터의 공구단(end effector)을 현재의 위치에서 목표 위치까지 움직일 때, 시간에 따른 중간 지점을 결정하는 것이다[1]. 로봇의 동역학과 주어진 비용함수를 고려하여 최적 궤적을 구할 수 있는데 동역학 특성이 비선형적이고 비용함수 복잡하기 때문에 계산하기가 어렵다.

로봇 매니퓰레이터에 대한 추적 제어방법으로는 계산된 토크 방식을 보편적으로 사용한다[2]. 이 방식은 로봇의 동역학 모형을 완전히 알면 좋은 결과를 제공해 주지만, 실제로는 정확하지 않는 모형 계수, 비선형적 마찰, 관절의 유연성 등의 불확실성(uncertainty)을 가지므로 좋은 성능을 보이지 못한다. 이러한 어려움을 해결하기 위해 모형에 대한 자세한 사전 지식을 요구하지 않는 적응 제어가 제안되었다.[3] 하지만 적응 제어는 불확실성이나 비선형성은 보상해주지만 큰 계산부하가 걸리는 단점은 가지고 있다. 근래에는 계산량을 줄이면서 제어 성능을 향상시키는 제한 오차 학습을 바탕으로 신경망을 이용한 연구가 활발하게 이루어지고 있다[4].

본 논문에서는 신경망과 진화 알고리즘을 이용하여 로봇 동역학과 비용함수를 이용하여 최적의 궤적을 구한다. 로봇 매니퓰레이터의 궤적 계획은 동역학을 바탕으로 계획되고 진화 알고리즘을 신경망의 학습 방법으로 사용하였다. 그리고 추적 제어방법에서는 계산된 토크법과 불확실성 보상에 대해 방사 기저 함수 회로망을 제안하였다. 그리고 제안된 방법을 2차 자유도를 가진 로봇 매니퓰레이터에 적용하여서 모의 실험 결과를 보였다.

#### 2. 본 론

##### 2.1 로봇 매니퓰레이터의 모형

로봇 매니퓰레이터의 동역학 모형은 동작 모의 실험, 매니퓰레이터의 구조 분석, 제어 알고리즘의 설계 등에 중요한 역할을 한다. 로봇 매니퓰레이터의 동역학식을 기술하기 위한 전형적인 방법은 라그랑지-오일러(Lagrange-Euler)방정식이다. 이 방법을 사용한 n-링크 로봇 매니퓰레이터의 운동 방정식은 다음과 같이 표현된다.

$$\tau = M(\theta)\ddot{\theta} + h(\theta, \dot{\theta}) + F \quad (1)$$

여기서,  $\theta$ ,  $\dot{\theta}$  과  $\ddot{\theta}$ 는 각각 관절의 이동 위치, 속도, 가속도의 n 벡터이다.  $M(\theta)$ 는  $n \times n$  관성행렬이다.  $h(\theta, \dot{\theta})$  는 구심력과 코리오리스(coriolis) 힘을 포함한 n 벡터이다.  $F$ 는 구조화 되지 않는 불확실성 벡터,  $\tau$ 는 조인트 토크 벡터이다.

##### 2.2 진화 알고리즘과 궤적 계획기

###### 2.2.1 진화 알고리즘

진화 알고리즘은 자연 진화 과정을 모방한 것이다. 진화는 새로운

유전 정보의 창조와 평가 선택 사이의 상호 작용의 결과이다. 모집단의 한 개체는 환경뿐만 아니라 그 모집단의 다른 개체에 의하여 영향을 받는다. 이 상황에서 한 개체가 우수할수록 그 개체가 생존하고 동시에 자손을 생산할 가능성이 커지게 되며, 차례로 부모의 유전 정보가 상속된다. 진화 과정을 거치면서, 이것은 평균 이상의 적합도(fitness)를 가진 개체들의 유전 정보를 모집단에 확장하게 된다. 대생산의 확률적 특성은 새로운 유전 정보의 생산과 다양한 자손의 창조를 이끌어 낸다. 이러한 생물학적 모델은 그림(1)은 일반적인 진화 알고리즘 구조에 의해 반영된다.

```

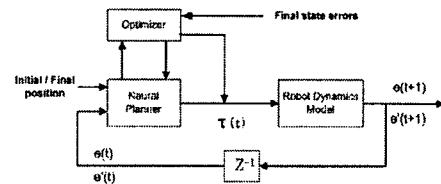
Algorithm 1:
t=0;
initial P(t);
evaluate P(t);
while not terminate do
    P(t) = variation[P(t)];
    evaluate [P(t)];
    P(t+1) = select[P(t) U Q];
end

```

〈그림1〉 진화 알고리즘 구조

###### 2.2.2 궤적 계획기

매니퓰레이터의 궤적 계획은 로봇 매니퓰레이터의 동역학을 바탕으로 입력 토크의 최적 순열을 만들도록 신경망을 학습하는 것으로 전환될 수 있다. 주어진 비용 함수에 대하여 신경망의 최적의 가중치를 찾는 것은 복잡한 비선형 최적화 문제이며 이것은 진화 알고리즘을 사용하여 구하여 진다[5].



〈그림 2〉 궤적 계획기

그림(2)은 제안된 궤적 계획을 위한 전체 구조이다. 신경망 궤적 계획기는 로봇 매니퓰레이터 모델을 바탕으로 주어진 목적 함수인 최종 상태 오차를 최소화하기 위해 진화 알고리즘을 사용하여 학습된다. 신경망의 입력은 로봇 매니퓰레이터의 현재 상태 즉, 관절 위치  $\theta(t)$ 와 속도  $\dot{\theta}(t)$ , 그리고 궤적 계획을 위한 초기 위치와 최종 위치에 관한 정보가 사용된다. 이를 위하여 순환 신경망이 사용된다. 신경망은 로봇 매니퓰레이터에 적용되고 역 기구학을 통하지 않고 관절 구조를 결정한다. 생성된 궤적은 주어진 비용 함수에 따라 평가된 후 성능을 향상시키기 위하여 진화 된다.

##### 2.3 로봇 매니퓰레이터의 추적 제어

###### 2.3.1 방사 기저 함수 회로망

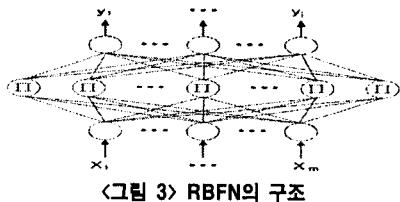
###### (Radial Basis Function Networks, RBFN)

RBFN[6]은 오류 역전파 학습 규칙(error-propagation algorithm)을 사용하는 다층 퍼셉트론(multi-layer perceptron)에 비해 수렴 속도가 빠르고 간단한 구조를 가지고 있다. 그리고 RBFN은 신경망 모델의 주요한 종류 중 하나로 입력 벡터와 원형(prototype) 벡터 사이의 거리가 은닉 소자의 활성화를 결정한다. 이 회로망은 입력 공간  $\mathbb{R}^n$ 로부터 출력 공간  $\mathbb{R}^l$ 로의 비선형 사상을 수행한다. 그 관계는 다음과 같다.

$$y_j = \sum_{i=1}^m C_{ij} \phi_i, \quad j = 1, 2, \dots, l \quad (2)$$

$$\phi_i(x) = \exp\left(-\frac{|x - \mu_i|}{\sigma_i^2}\right) \quad (3)$$

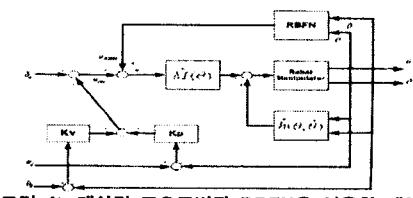
여기서,  $m$ 은 노드 수,  $l$ 은 출력 수,  $y_j$ 는 출력층  $j$  번째 노드에서의 출력이며  $C_l$ 는 방사 기저 함수 회로망의 가중치, 그리고  $\phi_i(x)$ 는 은닉층  $i$  번째 노드에서의 출력이며,  $u_i \in \mathbb{R}^n$ 는 중심 벡터,  $\sigma_i \in \mathbb{R}^l$ 은 표준 편차이다. 일반적으로 기본 함수는 가우시안 함수가 은닉 뉴런으로 사용된다.



〈그림 3〉 RBFN의 구조

### 2.3.2 추적 제어기의 구현

본 논문에서 제안된 로봇 매니퓰레이터의 추적 제어기는 그림(4)와 같이 나타내었다.



〈그림 4〉 계산된 토크방식과 RBFN을 이용한 제어기

계산된 토크 방식(C.T.M)의 제어 법칙에 대해서 식(5)과 같이 나타난다.

$$\begin{aligned} \hat{M}(\theta)u + \hat{h}(\theta, \dot{\theta}) &= \tau \\ \ddot{\theta}_d + K_p(\theta_d - \theta) + K_v(\dot{\theta}_d - \dot{\theta}) &= u \end{aligned} \quad (5)$$

여기서,  $\hat{M}$ 과  $\hat{h}$ 는  $M$ 과  $h$ 의 추적치를 나타낸다. 제안된 추적 제어기에는 RBFN의 불확실성 보상기 부분이 추가되므로 입력  $u$ 는 다음과 같다

$$u = u_{ctm} + u_{RBFN} \quad (6)$$

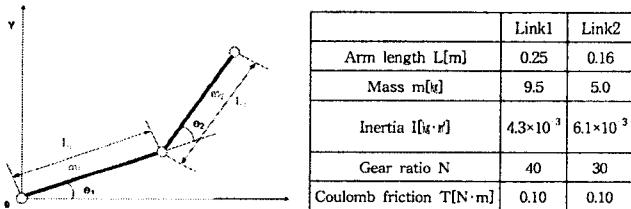
식(5)을 식(6)에 대입하고 오차에 대하여 풀면 식(7)과 같이 된다.

$$\ddot{e} + K_p e + K_v \dot{e} = \hat{M}(\Delta M \ddot{\theta} + \Delta h + F) - u_{RBFN} \quad (7)$$

이때, 좌변의 불확실성의 부분은 RBFN의 불확실성 보상기 부분에서 조절하므로 보다 정확한 추적제어가 이루어지게 된다.

### 2.4 모의 실험

본 논문에서는 2차 자유도를 가지는 로봇 매니퓰레이터에 적용을 하였다.



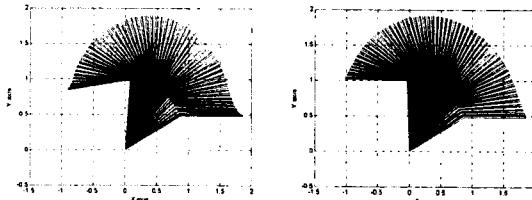
〈그림 5〉 2차 자유도를 가지는 로봇 매니퓰레이터와 파라미터

궤적 계획에 대한 실험 조건은 다음과 같다. 목표의 초기점과 최종점은 직교 좌표로 이루어지며 순환 신경망의 구조는 입력층 6개, 은닉층 8개, 출력층 2개인 구조(6-8-2)를 가지고 있다. 입력으로는 초기 위치, 목표 위치, 관절의 위치와 속도를 받게 된다. 진화 알고리즘에서는  $(\mu + \lambda) - q$ 의 토너먼트 방식으로 부모 개체 200개, 자손 개체 200개, 토너먼트 개체 20개를 가진다. 궤적의 초기 위치는  $(1.85, 0.50) \rightarrow$  목표 위치  $(-1, 1)$ 로 궤적이 형성되도록 실험을 하였다. 로봇 매니퓰레이터의 추적제어의 실험에는 구조화되지 않은 불확실성에 대해 쿠лон 마찰력(coulomb friction)을 사용하였다.

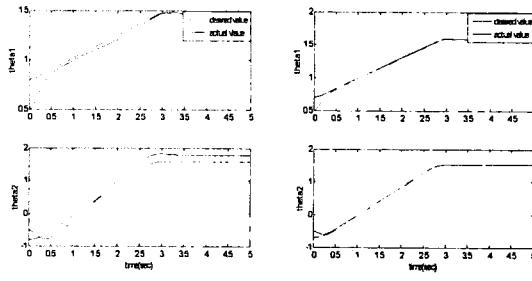
$$F_1 = T_1 \cdot \text{sgn}(\dot{\theta}_1) \text{ and } F_2 = T_2 \cdot \text{sgn}(\dot{\theta}_2) \quad (8)$$

궤적 계획기에서 나온 궤적에 따라 정확하게 추적하는지를 판단하는 학습 구조의 제어 성능은 추적 오차로 평가된다. 추적 오차는 각 시행동안 표본 시간에서의 위치에 대한 추적 오차로 계산된다.

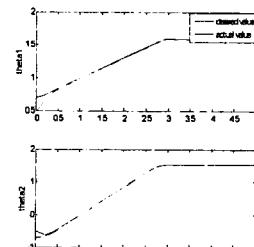
그림(6)은 초기 위치  $(1.85, 0.50)$ 와 목표 위치  $(-1, 1)$ 에 대한 궤적을 진화 알고리즘으로 학습하기 전의 궤적과 학습 후의 궤적으로 나타내었다. 진화 알고리즘으로 학습하고 난 후에 목표 위치에 정확하게 도달하는 것을 알 수 있다. 다음으로 주어진 최적의 궤적을 이용해서 제안한 추적 제어를 실행한다. 그림(7)은 불확실성(25%)이 존재하는 경우에 계산된 토크방식으로 제어기 설계한 경우에 각각의 관절의 위치를 추적을 하는 것을 보여준다. 그림(8)은 계산된 토크 방식과 RBFN으로 제어기 설계한 경우이다. 마지막으로 그림(9)은 위치에 대한 추적 오차를 나타냈다.



〈그림 6〉 초기 위치  $(1.85, 0.50)$ 와 목표 위치  $(-1, 1)$ 에 대한 궤적



〈그림 7〉 계산된 토크 방식만 사용



〈그림 8〉 RBFN로 보상해 준 경우



〈그림 9〉 위치에 대한 추적 오차

### 3. 결 론

본 논문에서는 궤적 계획기를 신경망과 유전자 알고리즘으로 이용하여 구성하였다. 로봇 매니퓰레이터의 궤적이 진화 알고리즘으로 학습하므로 정확하게 목표 위치에 도달하였다. 그리고 계산된 토크 방식과 방사 기저 함수 회로망(RBFN)을 이용해서 로봇 매니퓰레이터의 추적제어기를 구성하였다. 전체를 신경망을 이용해서 제어하는 것이 아니라 로봇 매니퓰레이터의 불확실성한 부분만을 제어하므로 구조적으로 간단함을 볼 수가 있었으며 실험을 통해 성능이 향상된 것을 알 수가 있었다.

### [참 고 문 헌]

- [1] M. Brady, Trajectory planning, Robot Motion : Planning and Control, The MIT Press, pp. 222-243, 1982.
- [2] J. Y. S. Luh, M. W. Walker, and R. P. C. Paul, "On-line computational scheme for mechanical manipulator," J. Dyn. Syst., Meas. contr., vol. 102, pp.69-76, June 1980.
- [3] J. Craig, P. Hsu, and S.S. Sastry, "Adaptive control of mechanical manipulator," in Proc. IEEE Int. Conf. On Robotics and Automation, San Francisco, CA, pp. 190-195, 1986
- [4] M. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki, "Feedback-error learning neural network for trajectory control of a robotic manipulation," Neural networks, Vol.1, pp.251-265, 1988.
- [5] T. Fukuda, T. Kohno, and T. Shibada, "Learning scheme for recurrent neural network by genetic algorithm," in proc. IEEE Int. Conf. On Intelligent Robots and Systems, pp.1756-1761, 1993.
- [6] C. T. Lin, C. S. George Lee, "Neural Fuzzy Systems : A Neuro-Fuzzy Synergism to Intelligent Systems," Prentice-Hall, 1996.