

자기구성 신경회로망을 이용한 매니플레이터의 궤적제어에 관한 연구

김동희*, 신위재**, 주창복**

남해전문대학 전자통신과*, 경남대학교 전기전자공학부**

The Study on the Trajectory Control of Manipulator Using Self-Organizing Neural Network

Dong-Hee Kim*, Wee-Jae Shin**, Chang-Bok Joo**

Division. of Electrical and Electronic Engineering Kyungnam Univ.**

Dept. Communication and Electronic Namhae College*

dhkim@nc.namhae.ac.kr

요약

본 논문에서는 자기구성 신경회로망을 이용하여 3축 매니플레이터의 궤적제어를 설계한다. 궤적제어는 경유점을 정하고 각 경유점에 대한 역기구학을 적용하는 제어기로서 본 논문에서는 역기구학의 해를 자기구성 신경회로망을 통해 해결하는 제어기를 설계하고자 한다. 또한 제어기에서의 은닉층의 활성화 함수는 가우시안 함수를 사용하고, 은닉층의 파라미터는 오차를 기초로 하여 자동적으로 최적의 파라미터 값을 구함으로써 유연한 궤적제어가 되도록 한다.

I. 서론

로봇 매니플레이터는 대표적인 비선형 시스템으로 액추에이터에 의하여 구동되는 조인트를 갖는 연속된 링크들로 구성된다. 로봇의 궤적제어는 최초 위치에서 최종위치까지의 경로를 따라 말단효과장치가 이동하도록 하는 것으로 이러한 궤적 이동을 위해서는 각 조인트의 각도에 대한 궤적

이 계산되어야 하는데 일반적으로 경로점은 각 조인트의 각으로 주어지는 것이 아니라 말단효과장치의 직교좌표점으로 주어지기 때문에 역기구학을 통해 조인트의 각을 구한 뒤 경로제어를 하기 때문에 궤적제어에 있어서 역기구학의 해를 구하는 문제 또한 중요하다. 이러한 경우 인공지능 제어 기법인 신경망, 퍼지, 유전자 알

고리들을 사용하여 매니플레이터 역기구학의 해를 구하고자 하는 연구가 최근에 많이 진행되고 있으며 이러한 인공지능 제어기법은 보다 유연한 궤적제어기 설계를 도와주고 동적 플랜트가 보다 고차원이고 비선형일 때 효과적이다. 그 중에서 신경회로망을 이용한 역기구학 해를 구하는 여러 가지 방법이 제안되고 있으나 이들 대부분의 경우 신경회로망을 구성하는 여러 가지의 파라미터들이 설계자에 의해 고정되기에 따라 많은 시행착오를 경험해야 되고, 최적의 신경망구조를 가지지 못하는 문제를 안고 있다.

본 논문에서 역전파 알고리즘을 기본으로 하여 은닉층 노드의 활성화 함수를 가우시안 위치함수(Gaussian Potential Function)를 사용하며 학습에 따라 자동적으로 가우시안 함수의 위치(Mean)와 모양(Variance)를 조정하며 필요에 따라서는 노드를 생성시키는 자기구성 신경망 알고리즘을 사용하여 자유도가 3인 매니플레이터의 역기구학의 해를 구하여 유연한 궤적제어의 새로운 기법을 제안한다.

II. Gaussian Potential Function Network

본 논문에서 제안하는 신경회로망은 역전파 신경망 알고리즘을 기본으로 하며, 입력, 은닉, 출력 3개 층으로 이루어진다. 여기서 은닉층의 신경망 활성화 함수는 가우시안 위치 함수를 사용하며 식 (1)과 같이 정의되어진다.

$$G(f) = G(x, p_i) = e^{-d(x, p_i)/2} \quad (1)$$

$$d(x, p_i) = d(x, m^i, K^i) \quad (2)$$

$$= (x - m^i) K^i (x - m^i)$$

여기서 x 는 입력이고 m^i 와 K^i 는 i 번째 위치함수의 평균(Mean)벡터와 공분산(Covariance)의 역벡터이다. 식 (2)는 식 (3)으로 다시 정의할 수 있다.

$$d(x, m^i, K^i) = \sum_j \sum_k k_{jk}^i (x_j - m_j^i)(x_k - m_k^i) \quad (3)$$

여기서 x_j 는 x 의 j 번째 원소이고, m_j^i 는 m^i 의 j 번째 원소이고, k_{jk}^i 는 K^i 의 (j,k) 원소다.

또한 k_{jk}^i 는 표준편차 σ_j^i 와 σ_k^i 그리고 상관계수 h_{jk}^i 로 표현하면 식 (4)와 같다.

$$k_{jk}^i = \frac{h_{jk}^i}{\sigma_j^i \sigma_k^i} \quad (4)$$

여기서 σ_j^i 와 σ_k^i 는 양의실수 이고 h_{jk}^i 는 j 와 k 가 같을 때 1이 된다. 따라서 식 (4)는 식 (5)와 같이 정의되어진다.

$$k_{jk}^i = \begin{cases} \frac{1}{\sigma_j^i} & \text{if } j = k \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

신경회로망의 출력 U_k 는 식 (6)과 같다.

$$U_k = \sum_{i=1}^M c_{ki} G_i(f) \quad (6)$$

여기서 c_{ki} 는 가중치(Weight)이다.

III. 자기구성 신경망

신경회로망이 학습을 하는데 있어서 은닉계층의 노드가 충분하지 못하거나 최적의 망 파라미터를 찾지 못한다면 원하는 성능을 발휘하지 못하게되는 경우가 종종 발생하게 된다. 따라서 최적의 노드수와 파라미터를 찾기 위해 수많은 시행착오를 겪어야 하는 문제점을 가지고 있다. 이러한 문제는 자기구성 학습을 통해 최적의 노드수와 파라미터를 발견함으로써 신경회로망 설계시간을 줄일 수 있으며, 제어대상의 상태가 변하거나 제어대상이 변화하더라도 어려움 없이 대처할 수 있다.

본 논문에서 제안 하고자 하는 자기구성 신경회로망은 입력공간에 의해 정의되어진 적응경계(accommodation boundary)에 의해 가우시안 위치함수들의 파라미터를 자동으로 조정하게 된다.

만약 입력된 새로운 표본이 적응경계 내에 존재한다면 새로운 은닉계층의 노드를 생성하지 않고 가우시안 위치함수의 파라미터만 갱신하고, 만약 적응경계 내에 존

재하지 않는다면 새로운 가우시안 위치함수를 생성시킴으로서 최적의 파라미터와 은닉계층의 노드수를 조정할 수 있다. 일반적으로 자기구성 학습은 다음의 2가지로 요약 할 수 있다.

1. 학습은 은닉계층의 노드수는 최소한으로 하고, 적응경계는 크게 하여 시작을 해서 학습을 진행함에 따라 노드수를 증가시키고 적응 경계를 줄이는 방향으로 진행한다.

2. 자기구성 신경회로망의 은닉계층 노드수와 파라미터의 갱신은 역전파 알고리즘과 같이 신경회로망의 출력과 설계되어진 값의 차 즉 오차를 이용하여 수행할 수 있다.

그리고 적응경계는 식 (7) 같이 정의되어진다.

$$H_i(r_i) = \{ x \mid d(x, m^i, K^i) \leq r_i^2 \} \quad (7)$$

자기구성 신경회로망 학습알고리즘은 다음과 같이 구성 하도록 한다.

1단계 : 초기화

- $i = 1, j = 0, p = 0$
(i : 학습수, j : 가우시안 위치함수의 수 p : 패턴수)
- 가우시안 위치함수 초기화
 - $j = j + 1$
 - mean : $m^j = x_p$ (x_p : 입력표본)
 - weight : $c_j = t_p$ (t_p : 설계값)
 - deviation : $K^j = \frac{1}{\sigma^2}$

2단계 : 학습

① $p = p + 1$

① $G(f) = G(x, p_i) = e^{-d(x, p_i)/2}$

② 만약 $|t_{pk} - G_{pk}(f)| > e_m$ 이면 새로운 가우시안 위치함수 생성
(e_m : 오차여유, 가우시안 위치함수 생성은 단계1의 방법과 동일하게 한다.)

③ 만약 $|t_{pk} - G_{pk}(f)| \leq e_m$ 이면 파라미터 갱신

④ 만약 모든 패턴에 대한 학습을 수행 했 으면 2단계의 ① 실행

단계3 : $i = i + 1$

단계4 : 학습결과가 만족이면 정지 그렇지 않으면 2단계 실행

- 파라미터 갱신규칙

$$n_j^{new} = n_j^{old} + \eta \Delta n_j \quad (7)$$

$$n_j \equiv [w_j^t, m_j^t, \sigma_j^t] \quad (8)$$

$$\Delta n_j \equiv [\Delta w_j^t, \Delta m_j^t, \Delta \sigma_j^t] \quad (9)$$

· j번째 출력과 I번째 가우시안 위치함수 사이의 가중치 갱신

$$\Delta w_{ji} = -\frac{\partial E_p}{\partial w_{ji}} = (t_j - U_k) G_i(f) \quad (10)$$

· j번째 원소의 평균벡터의 갱신

$$\Delta m_{ji} = -\frac{\partial E_p}{\partial m_j^t} \quad (11)$$

$$= \sum_{t=1}^N k_{jt}^i (x_t - m_j^t) G_i(f) \sum_{k=1}^M (t_k - U_k) w_{ki}$$

· j번째 원소의 평균벡터의 갱신

$$\Delta \sigma_{ji} = -\frac{\partial E_p}{\partial \sigma_j^t} \quad (12)$$

$$= \sum_{t=1}^N k_{jt}^i \frac{(x_t - m_j^t)(x_t - m_j^t)}{\sigma_j^t}$$

$$G_i(f) \sum_{k=1}^M (t_k - U_k) w_{ki}$$

IV. 매니플레이터의 기구학




그림 1. 3 자유도를 가진 매니플레이터

매니플레이터의 궤적제어를 위해서는 각 조인트의 각도를 구하여야 함으로 먼저 역기구학 문제를 풀어야 한다. 이를 위해서는 먼저 기구학 문제를 해결하여야 한다.

따라서 본 논문에서는 먼저 자유도가 3인 매니플레이터의 기구학에 대한 해를 구하고, 이를 바탕으로 역기

구학의 해를 자기구성 신경회로망을 활용하여 풀어 궤적제어를 위한 각 조인트의 각도를 구하고자 한다.. 본 논문에서의 매니플레이터는 그림 1.과 같다.

그림1의 링크변수는 표 1과 같다.

표 1. 3자유도를 가진 매니플레이터의 링크변수

축	θ	α	l	d
1	θ_1	90	0	d_1
2	θ_2	0	l_2	0
3	θ_3	-90	l_3	0

표 1.에서 α 는 n-1축에서 n축으로의 뒤틀림 각도이고, l은 x축과 평행한 링크길이이고, d는 z축과 평행한 링크 길이 이다.

IV. 시뮬레이션 결과

시뮬레이션은 그림 2와 같이 시스템을 구성하여 수행하였다.




그림 2.시뮬레이션 블록선도

시뮬레이션 방법은 그림 2.와 같이 자기구성 신경회로망에 설계되어진 직교좌표상의 X, Y, Z값을 입력하면 매니플레이터의 각 관절각을 출력하게 되고 이를 기구학 알고리즘으로 다시 직교좌표상의 X', Y', Z'값을 계산하여 설계되어진 값과 비교하여 오차가 발생하면 이를 자기구성 신경회로망에 인가하여 적절히 가우시안 위치 함수의 파라미터나 은닉계층의 노드수를 증가시킴으로써 설정 직교좌표계에 대한 각 조인트의 각 $\theta_1, \theta_2, \theta_3$ 를 구하여 궤적제어에 활용한다.

그리고 표1에서의 d_1, l_2, l_3 값은 다음과 같다.

$$d_1 = 255[\text{mm}], l_2 = 200[\text{mm}], l_3 = 250[\text{mm}]$$

시뮬레이션 방법은그림 3, 4, 5와 같이 X축의 위치는 287[mm]로 고정시키고 Y축과 Z축을 삼각과 형태로 궤적을 설정하여 시뮬레이션을 수행하였다.

그림 3은 X축에 대한 궤적시뮬레이션 결과로 약 100회 학습후에 설정치에 근접함을 알 수 있고, 그림 4는 Y축 그림5는 Z축에 대한 궤적 시뮬레이션 결과로 약 100회

학습 후에 설정치에 근접하는 양호한 시뮬레이션 결과를 보여주고 있다.

자기구성 신경회로망의 은닉계층의 노드수도 5개로 매우 빠른 계산속도를 얻을 수 있었다.

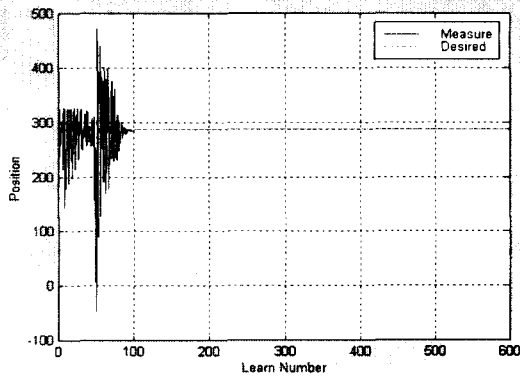


그림 3. X축 궤적 시뮬레이션결과




그림 4. Y축 궤적 시뮬레이션결과




그림 5. Z축 궤적 시뮬레이션결과

III. 결론.

그림3, 그림4,에서 보여주는 결과와 같이 정상상태에 도달하는데 걸리는 학습의 횟수가 100회로 비교적 작은 결과를 보여주고 있다. 또한 본 논문에서 제안한 자기구성 신경회로망은 모든 파라미터를 자동으로 조정함에 따라 제어기 설계에서 가장 많은 시간을 투자하여야 하는 초기조건 설정이 쉽게 이루어짐으로서 제어기의 설계의 편리함을 보여주고 있고, 은닉계층의 노드수를 최적화 시킴으로서 계산시간을 최소화 할 수 있음을 보여주고 있다.

IV. 참고문헌

- [1] Joseph A. Driscoll, "Comparison of Neural Network Architectures for the Modeling of Robot Inverse Kinematics ", Proceedings of the 2000 IEEE Southeastion , pp.44-51 , 2000.
- [2] Sujhan Lee, Rhee M. Kil, " A Gaussian Potential Function Network With Hierarchically Self-Organizing Learning", Neural Networks Vol4, pp 207-224, 1991.
- [3] Howard DW, Zilouchian A, "Application of fuzzy logic for the solution of inverse kinematics and hierarchical controls of robotic manipulators", Journal of Intelligent & Robotic Systems , V.23 N.2-4 , pp.217-247 , 1998.
- [4] Ki-Cheol Park, Pyung-Hun Chang, Seung- Ho Kim, "Characteristics of Optimal Solutions in Resolving Manipulator Redundancy under Inequality Constraints", Proceedings of the 1999 International Conference on Intelligent Robots and Systems - Volume 1 , pp.442-447 , 1999.
- [5] Johnj. Craig, "Introduction to Robotics: Mechanics and Control", Addison-Wesley, pp.113-151, 1989.
- [6] P. J. McKerrow, "Robot Engineering", Addison-Wesley, pp.173-223, 1994.
- [7] F. ABDESSEMED, " A Two-Layer Robot Controller Design Using Evolutionary Algorithms", journal of Intelligent and Robotic Systems 30, pp.73-94. 2001
- [8] A.s>Morris, S.Khemaissia, "Stable and fast neurocontroller for robot arm movement", IEE proc.-control Theory Appl, Vol.142, pp.378-384, 1995