

## RBF 신경회로망을 이용한 Mobile Inverted Pendulum의 위치제어

노 진석, 이근형, 정술  
충남대학교 메카트로닉스 공학과 지능시스템 및 감성공학 실험실

### Position control of a Mobile Inverted Pendulum using RBF network

Jin Seok Noh, Geun Hyeong Lee, and Seul Jung  
Intelligent Systems and Emotional Engineering(ISEE) Lab, Chungnam National University

**Abstract** - This paper presents the desired position control of the mobile inverted pendulum system(MIP). The MIP is required to track the circular trajectory in the xy plane through the kinematic Jacobian relationship between the xy plane and the joint space. The reference compensation technique of the radial basis function(RBF) network is used as a neural network control method. The back-propagation learning algorithm of the RBF network is derived and embedded on a DSP board. Experimental studies of tracking the circular trajectory are conducted.

#### 1. 서 론

최근 로봇 산업의 발전에 의해 인간과 같은 휴머노이드 로봇의 등장으로 지능적인 제어에 대한 관심이 점차 높아지고 있다. 지능형 로봇산업은 첨단 신기술로써 인공지능, 부품신소재등 분야에 대규모 국가적 R&D 사업이 진행되고 있고 인간과 친화적으로 삶의 질 향상에 기여하고 있다. 일반적으로 역진자 시스템은 비선형 시스템의 대표적으로 교육적으로나 연구에 있어서 많이 사용되고 있다. 또한 그 특성이 비선형이고 SIMO(Single Input Multi Output) 시스템의 대표적인 예이다. 이처럼 역진자 시스템에 대한 관심도가 높은 이유는 간단하면서도 흥미가 있고 또한 비선형적인 특성을 가진 시스템이기 때문이다. 일반 산업 현장에서 많이 사용되고 있는 고전적 제어인 PID 제어기로는 전자 제어가 가능하지만 수레의 위치까지 제어하기에는 매우 어렵다. 동 특성 변화에 따른 PID 제어기의 계수를 조정하는 과정이 필요하며, 그 이득값 또한 공정에 맞게 고정되어 있으므로, 불확실성에 대한 보장이 없는 단점이 있다. 따라서 이러한 비선형 시스템의 동특성에 대한 변화를 보상할 수 있는 비선형 제어기가 필요한데 비선형 제어기 중에서 신경회로망 제어기는 시스템의 동특성 변화 및 외란과 같은 불확실성을 보상함으로써 비선형 시스템에 대한 좋은 제어 성능을 가진다. 여기에서 사용되는 신경회로망의 방식으로는 최근, 제어분야에서 그 사용이 두드러지고 있는 RBF(Radial Basis Function) network를 사용한다. 제어분야에서 RBF network를 사용하면 feed forward network를 사용했을 때 보다 안정성의 이론적 증명이 어려웠던 것이 가능해지고, 입력층과 출력층 사이에 가중치도 존재하지 않는 단단한 구조로 인해 학습이 빠르다는 장점이 있다. 신경회로망의 보상 방식으로는 입력보상 방식인 RCT(Reference Compensation Technique)로 기존의 PD 제어와 PID 제어기와 함께 기준입력에 신경회로망의 출력을 더하여 시스템의 불확실성을 보상하게 된다. 입력보상방식은 비선형 시스템에 적용되어 그 성능이 실증적으로 평가되어왔다.

본 논문에서는 기존의 RBF network를 사용하여 토크에 보상하는 방식과 달리 입력보상방식인 RCT 방식으로 PID 제어기를 기본 제어기로 사용하여 신경회로망의 보상 입력을 기준 입력에 더하게 된다. 신경망의 학습 방법은 역전파 알고리즘을 사용하였으며, 학습이 가능하도록 학습 알고리즘을 유도하였다. 시스템의 구성은 두 바퀴를 갖은 모바일형식의 cart로 구성되어 있으며, 최근에는 하드웨어 기술이 발달하여 신경회로망의 하드웨어 구현을 가능하게 해 주었다. 이전의 선행 연구에서는 Multi-layered perceptron network (MLP)과 역전파 학습알고리즘을 상용 DSP보드에 구현하여 2축 역진자를 제어하였다. 본 논문의 실험에도 TI사의 DSP를 사용하여 PWM을 발생시켜 각 모터의 제어 신호를 인가해주며 신경회로망의 Back-propagation 알고리즘을 수행하도록 하였고 각도를 제어하며 cart의 원 경로를 추종하며 원하는 위치까지 제어를 실증적으로 성능을 평가하였다.

#### 2. 본 론

##### 2.1 Radial Basis Function network

RBF 네트워크는 비선형 함수로 가오시안 함수를 사용하고 출력부분이 간단히 선형적으로 합하게 되므로 가중치의 수도 MLP 네트워크와 비교하여 매우 적다. 그림 1은 RBF network의 구조를 나타내고 있다.

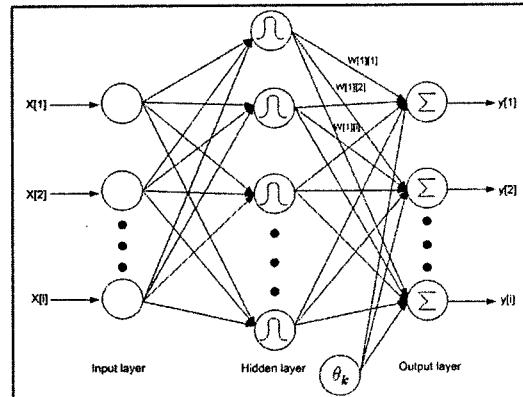


그림 1) Radial Basis Function network 구조

RBF network는 구조상 다층 퍼셉트론 network와 같이 입력층, 은닉층, 그리고 출력층으로 구성되어 있다. 하지만 각 층의 역할이 MLP(Multi Layer Perceptron)에서와 달리 단지 센서 정보를 모으는 역할을 하는 층으로 입력과 은닉층 사이에 가중치도 존재하지 않는다는 점에서도 다르다는 것을 알 수 있다. 은닉층의 노드수는 사용자에 의해서 결정이 되며, 그림 1에서와 같이 은닉층과 출력층 사이에는 서로를 연결해 주는 가중치가 존재한다. 은닉층은 비선형 함수로 구성되어 입력으로의 데이터를 비선형적으로 변환시켜 출력층으로 내보낸다. 입력데이터는 은닉층의 가오시안 함수를 거쳐 가중치와 곱해진 후 출력되어 진다. 이는 Radial Basis Function network가 함수의 근사치를 구하는 방법으로부터 유추되었다는 것을 나타낸다. Radial Basis Function으로는 가오시안(Gaussian) 함수가 가장 널리 사용되고 있으며, 본 논문에서도 가오시안 함수를 사용하여 실험하였다. 가오시안 함수의 수식은 다음과 같다.

$$\Phi_j(x) = \exp\left(-\frac{(x - \mu_j)^2}{\sigma_j^2}\right) \quad (1)$$

여기서  $\Phi_j$ 는 비선형 radial basis 함수이고,  $\mu_j$ 는 center 벡터, 그리고  $x$ 는 입력벡터들이다.  $\sigma_j$ 는  $j$  번째 공분산이다. 가오시안 함수를 사용하면 거리가 0 일 때 최대값 1을 출력하게 되고 거리가 멀어지면 0에 가깝게 된다. 은닉층에서는 유클리디안 거리를 계산하며 출력층에서는  $w_{jk}$ 를 곱해 합한다.  $w_{jk}$ 는 은닉층과 출력층 사이의 가중치로 사용되며, RBF 신경회로망에서 출력층의 출력은 다음과식과 같다.

$$y_k = \sum_{j=1}^M w_{jk} \Phi_j + \theta_k, \quad k = 1, 2, \dots, N \quad (2)$$

##### 2.2 학습방법

다층 퍼셉트론 네트워크는 비선형 함수로 시그모이드 함수를 사용하고 있으나 Radial Basis Function net은 패턴간의 유클리디언 거리를 사용한다. Radial Basis Function을 학습하는 방법으로 gradient decent algorithm의 역전파 알고리즘을 사용한다. 여기서 엘타 법칙을 이용하여 각각의 gradient를 구해 보면 다음과 같다.

$$\Delta w_{jk} = -\eta_c \frac{\partial E}{\partial w_{jk}} = \eta_c e_k \Phi_j \quad (3)$$

$$\Delta b_k = -\eta_b \frac{\partial E}{\partial b_k} = \eta_b e_k$$

$$\Delta \mu_j = -n_{\mu} \frac{\partial E}{\partial \mu_j} = n_{\mu} \Phi_j \sum_{i=1}^{N'} \frac{(x_i - \mu_j)}{\sigma_j^2} \sum_{k=1}^{N''} e_k w_{jk}$$

$$\Delta \sigma_j = -n_{\sigma} \frac{\partial E}{\partial \sigma_j} = n_{\sigma} \Phi_j \sum_{i=1}^{N'} \frac{(x_i - \mu_j)^2}{\sigma_j^3} \sum_{k=1}^{N''} e_k w_{jk}$$

### 2.3 신경회로망 제어방식

아래의 그림 2는 신경회로망의 제어 방식 중 입력보상 방식을 나타낸다.

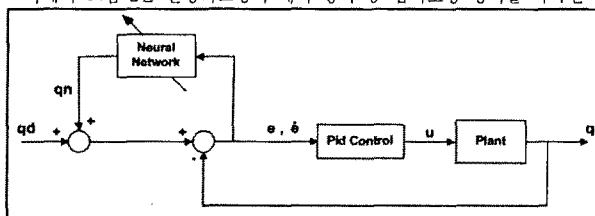


그림 2) 입력보상방식의 RBF 신경회로망

그림2의 Block diagram을 보면 알 수 있듯이, PID제어기를 기본제어기로 사용하고 비선형 제어기인 신경회로망 중 RBF 함수를 이용한 제어입력을 보상해 주는 시스템이다. 입력보상방식의 장점으로써는 풍정의 변수나 변화에 대한 불확실성을 보상해 줌으로써 출력오차를 보상할 수 있다. 또한 FEL(Feedback Error Learning)기반의 방식과 구조적으로 비교해서 RCT(Reference Compensation Technique)기반의 방식은 시스템의 내부를 건드리지 않고 외부에서 보상하는 장점이 있다. 입력보상방식은 기준 입력에 신경회로망이 위치하여 마치 선필터(prefilter) 역할을 하는 구조이다. 여기서 신경망의 역할은 기준 입력을 조절하여 시스템의 불확실성을 줄이는 것이다.

### 2.4 이동로봇의 기구학

이동로봇은 바퀴의 형태에 따라 무한궤도와 wheeled 이동로봇이 있다. 가장 일반적인 이동 로봇으로 wheeled mobile robot(WMR)이 있는데 이 WMR은 두 바퀴가 각각 독립적으로 구동되므로 두 바퀴의 회전 속도에 의해 방향이 결정된다. 무게 중심이 바퀴의 중심축의 연장선상에 있을 때, 즉  $d = 0$ 일 때 각 바퀴의 각속도에 의해서 결정되어지는 직교좌표는 다음과 같이 간단히 구할 수 있다.

$$\begin{bmatrix} x_g \\ y_g \\ \phi \end{bmatrix} = \begin{bmatrix} \frac{r}{2} \cos \phi & \frac{r}{2} \cos \phi \\ \frac{r}{2} \sin \phi & \frac{r}{2} \sin \phi \\ \frac{r}{L} & -\frac{r}{L} \end{bmatrix} \begin{bmatrix} w_R \\ w_L \end{bmatrix} \quad (4)$$

### 2.5 Mobile Inverted Pendulum System

두 바퀴를 갖은 mobile 형태의 pendulum system은 그림 3과 같다. 각도에 대한 제어신호는 사이로 센서로부터 A/D 처리 후 나오는 각도값을 받아 제어에 사용하였으며, 위치에 대한 제어신호는 엔코더로부터 나오는 Pulse 값으로 사용하였다. 각각의 제어신호를 통하여 DSP제어기로부터 PWM을 발생시켜 모터드라이브를 통하여 DC모터에 직접 제어신호를 인가하여 시스템을 제어하게 된다. 각도에 대한 초기값은 사이로센서의 0도를 기준으로 제어를 하게 되며 초기의 0도에 대한 각도 값 또한 제어에 상당한 영향을 미치게 되는 중요한 요소 중 하나다.

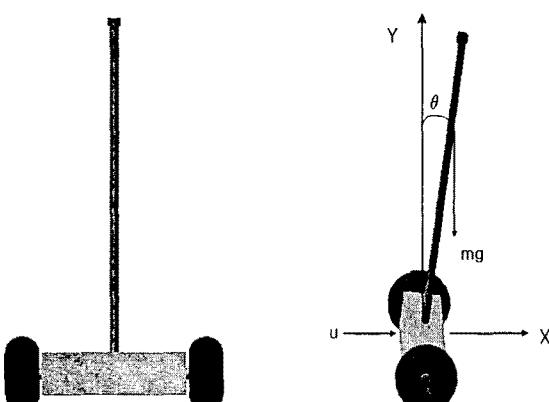


그림 3) Mobile Inverted Pendulum의 구조

### 2.6 실험결과

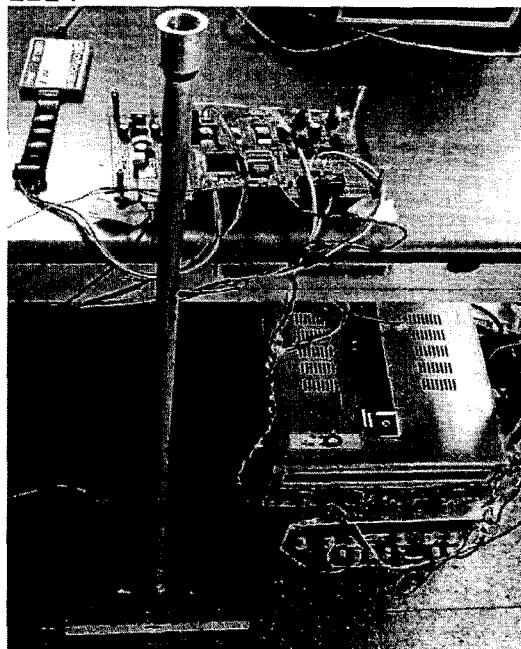


그림 4) Mobile Inverted Pendulum

전체시스템의 구성은 그림 4와 같다. 기울어진 각을 세우며 동시에 원하는 위치제어까지 실험적으로 검증하였고, 원 경로를 추종하는 실험 또한 검증하였다.

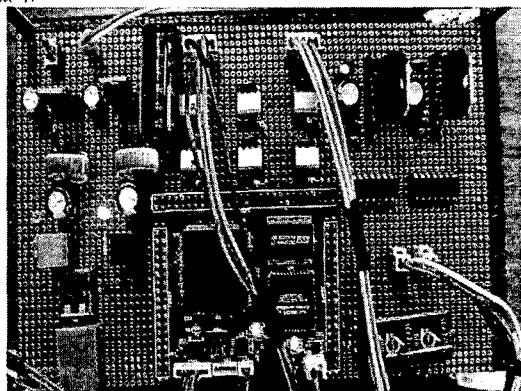


그림 5) DSP 신경회로망 제어기

그림 5는 TI사의 DSP로써 간단한 PID 제어 알고리즘과 RBF신경회로망의 Back-propagation 연산을 수행하기 위한 하드웨어이다. 또한 각각의 모터를 제어하기 위한 모터드라이버와 사이로센서의 전원공급을 위한 USB 포트로 구성되어 있다. 실제로 구현한 지능제어기를 Mobile inverted pendulum 시스템에 적용하여 실험적으로 성능을 평가하였다.

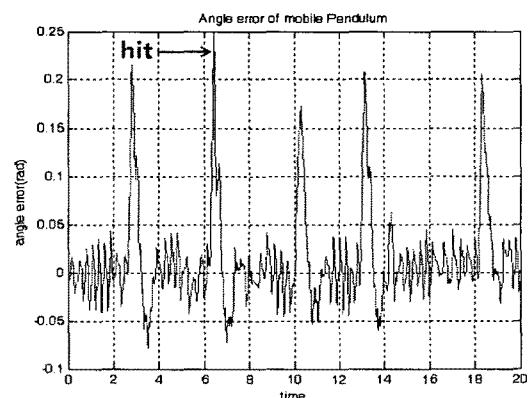
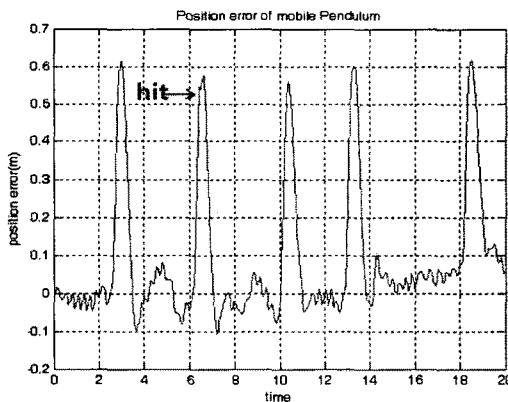
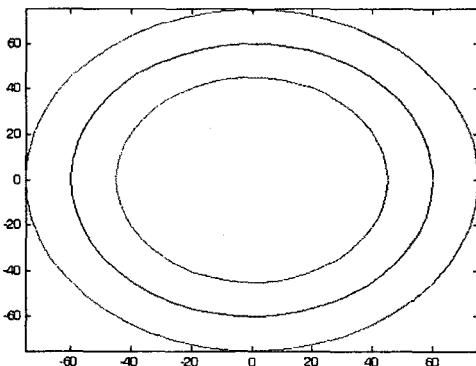


그림 6) 각도에 대한 Error



〈그림 7〉 위치에 대한 Error

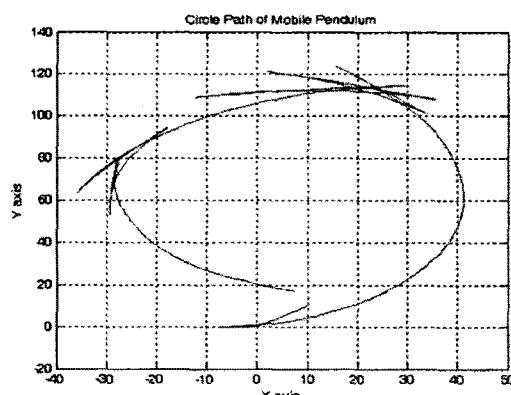
그림 6과 7은 실제 실험을 통한 각도와 위치에 대한 오차 값을 나타낸다. 초기의 제어시 각도와 cart의 위치가 0점을 유지하다가 특정 외란에 대하여 각도와 위치가 원하는 값인 0을 다시 유지하는 것을 확인 할 수 있다.



〈그림 8〉 원 경로 추종 Simulation

그림 8은 원 경로를 실험적으로 수행하기 전에 먼저 이동로봇의 기구학식을 바탕으로 원 경로를 추종하는지 Simulation 해 보았다. Simulation을 하기 위해서 먼저, 원의 방정식을 기반으로 하여 원하는 원 경로에 대해서 원의 반지름을 결정하고 카테시안 공간에서의 좌표, 즉  $x, y, \phi$ 의 좌표 값을 조인트 공간에서의 원 경로에 대한 방정식을 세운다. 그래서  $x, y, \phi$  값을 미분하게 되면 각각의 속도팀이 되는데 여기에서 각 바퀴의 각속도인

$w_L, w_R$  구해야 한다. 자코비안의 pseudo-inverse를 취하게 되면 결국 원하는 각속도를 구할 수 있게 된다. 지름 120cm의 원을 추종하도록 명령하여 각각의 각속도와 위치를 다음과 같이 얻을 수 있었다. 여기에서 위치에 대한 결과는 각 바퀴의 각속도 값을 적분하게 되면 위치를 얻을 수 있다. 안쪽과 바깥쪽 선의 원 경로는 안쪽 바퀴와 바깥쪽 바퀴의 경로를 나타내며 중앙의 원 경로는 Mobile Inverted Pendulum의 중심점을 나타낸다.



〈그림 9〉 원 경로에 대한 위치 Error(1)

위의 Simulation을 기반으로 실제 실험을 통하여 얻은 결과 그래프이다. 각 모터의 Torque 값에 서로 다른 이득 값을 곱해주어 추의 각도를 세우며 원 경로를 추종하도록 실험하였다. 초기에는 신경망 없이 PID 제어기로만

실험했을 경우 추도 세우지 못하고 원 경로 역시 그리지 못하고 쓰러지게 되었다. PID 제어기로 RBF 신경회로망을 참가하여 실험했을 경우 추의 각도제어까지 하며 그림 9와 같이 원 경로를 그리는 것을 실험적으로 확인하였다. Mobile Inverted Pendulum의 각도제어와 위치제어를 위해서 왼쪽과 오른쪽의 모터 Torque에 입력되는 수식은 다음과 같다.

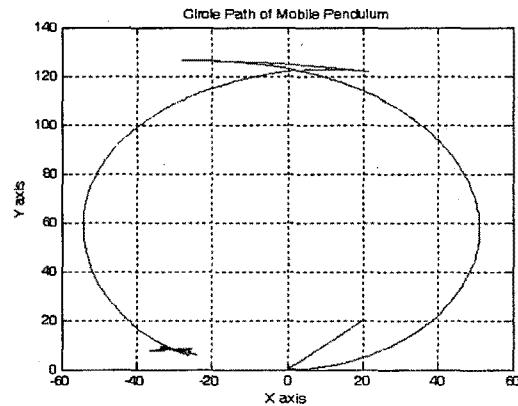
$$\text{Torque} = \text{Angle PID control} + \text{Position PID control}$$

그림 9의 원 경로 추종의 실험결과에 대한 각 모터의 Torque 값으로 입력해 준 Gain값은 다음과 같다.

$$\text{Left Torque} = \text{Angle PID control} + \text{Position PID control} \times 0.8$$

$$\text{Right Torque} = \text{Angle PID control} + \text{Position PID control} \times 1.5$$

왼쪽모터의 Torque 수식은 0.8이라는 이득 값과 오른쪽 모터의 Torque 수식에 1.5라는 이득 값이 있는데 이 부분이 바로 원 경로를 추종하기 위한 이득 값으로서 각각의 모터에 이득 값을 달리 주어 원 경로를 추종하였고 위에 해당하는 이득 값에 대한 결과는 그림 9와 같다. 위의 결과를 보면 초기에는 어느 정도 타원을 그리며 추종하지만 점차 시간이 흐를수록 원 경로를 추종하는 동안 각도에 대한 오차가 발생하기 때문에 앞뒤로 움직이며 다시 각도제어를 하고 있다는 것을 결과를 통해 알 수 있다. 또한 원의 모양 역시 원래의 위치에서 벗어난 영역에서 또다시 원 경로를 따라가기 때문에 위와 같이 올바르지 못한 계란형의 원 경로를 확인 할 수 있었다.



〈그림 10〉 원 경로에 대한 위치 Error(2)

그림 10은 이득 값의 조절을 통하여 최적의 원 경로 추종에 대한 결과이다. 제어시간은 Simulation에서와 마찬가지로 10초 동안 실험을 하였고 좀 더 천천히 경로 추종을 하도록 이득 값을 작게 주어 실험 해 보았지만 초기 세우기에는 역부족이었다. 그림 9와 같이 초기에는 원 경로의 오차가 커지만 최적의 원 경로를 추종하도록 점차 이득 값을 조절하여 많은 실험의 시행착오를 통하여 위와 같은 결과를 얻을 수 있었다. 위의 결과에 대한 이득 값은 다음과 같다.

$$\text{Left Torque} = \text{Angle PID control} + \text{Position PID control} \times 0.35$$

$$\text{Right Torque} = \text{Angle PID control} + \text{Position PID control} \times 1.2$$

Left Torque 와 Right Torque의 수식이 실제 실험에 사용되는 Torque 수식이다. 결과 그래프를 보면 알 수 있듯이 중간쯤에 한번 약간 벗어나서 각도제어를 하며 다시 원 경로를 추종하는 Data를 볼 수 있다. 처음의 실험에 비하여 점차 원 경로에 대한 추종 성능이 좋아졌고 위의 그림 9와의 차이는 각 모터의 이득 값을 1/2 정도로 입력하였는데 각각의 모터 이득 값을 고정하고 한쪽 바퀴의 이득값을 수정하며 실험한 결과 왼쪽 모터의 이득값이 오른쪽에 비해 훨씬 작아야 원 경로에 대한 성능이 좋았다. 더 작게 해보았지만 각도를 세우며 동시에 제어가 어려웠다.

### 3. 결 론

본 논문에서는 RBF의 가오시안 합성을 사용하여 입력보상방식을 이용한 지능제어기를 설계하여 Mobile Inverted Pendulum System의 성능 또한 실험을 통하여 입증하였다. 신경회로망을 이용하여 추의 각도와 cart의 위치 제어까지 동시에 제어를 실험을 통하여 확인할 수 있었으며, DSP에 신경회로망의 학습을 통하여 Mobile Inverted Pendulum의 원 경로의 추종도 실험적으로 입증하였다. 추후의 과제로는 다른 시스템에 적용하여 그 성능을 입증하는 것이 필요하며 보다 나은 지능제어기를 통한 시스템의 성능 향상 및 결과를 확인 해 볼 필요가 있다.

### [참 고 문 헌]

- [1] S. Jung and T. C. Hsia, "Neural network inverse control techniques for PD controlled robot manipulator", Vol. 19, No. 3, pp. 305-314, ROBOTICA, 2002
- [2] H.T. Cho and Seul Jung, "Neural network position tracking control of an inverted pendulum by an x-y table robot", IEEE IROS, pp. 1210-1215, 2003