

신경회로망을 이용한 유연성 단일 링크 로봇 매니퓰레이터의 진동제어

탁 한 호* · 이 상 배*

Vibration Control of a Flexible Single Link Robot Manipulator Using Neural Networks

Han-Ho Tack · Sang-Bae Lee**

<목 차>	
Abstract	3.1. LQR 제어기
1. 서 론	3.2. 신경회로망 제어기
2. 유연성 단일 링크를 가지는 매니퓰레이터 의 모델링	4. 실험결과
3. 제어시스템의 설계	5. 결 론
	참고문헌

Abstract

In this paper, applications of neural networks to vibration control of flexible single link robot manipulator are considered. The architecture of neural networks is a hidden layer, which is comprised of self-recurrent one. Two neural networks are utilized in a control system ; one as an identifier is called neuro identifier and the other as a controller is called neuro controller. The neural networks can be used to approximate any continuous function to any desired degree of accuracy and the weights are updated by dynamic error-backpropagation algorithm(DEA). To guarantee convergence and to get faster learning, an approach that uses adaptive learning rates is developed by introducing a Lyapunov function.

When a flexible manipulator is rotated by a motor through the fixed end, transverse vibration may occur. The motor torque should be controlled in such a way, that the motor is rotated by a specified angle, while simultaneously stabilizing vibration of the flexible manipulators so that it is arrested as soon as possible at the end of rotation. Accurate vibration control of lightweight manipulator during the large changes in configuration common to robotic tasks requires dynamic models that describe both the rigid body motions, as well as the flexural vibrations.

Therefore, dynamic models for a flexible single link manipulator is derived, and LQR controller and neural networks controller are composed. The effectiveness of the proposed neural networks control system is confirmed by experiments.

* 한국해양대학교 전자통신공학과

1. 서 론

현재 산업현장에서 자동화와 생산성 증대를 위해 많이 이용되고 있는 로봇은 대부분 강체로 아주 두껍고 무거운 매니퓰레이터를 가진 로봇이다. 이러한 강체 로봇은 자체의 무게와 크기로 인하여 많은 공간을 차지하며, 구동장치가 커지고 구동 에너지도 증가하여 동작속도를 증가시키기가 어렵다는 단점을 가지고 있다. 이러한 강체 로봇이 가지는 단점을 보완하기 위해 로봇 매니퓰레이터의 무게를 보다 가볍게 하고 유연성이 큰 로봇 링크에 대한 연구가 많이 진행되고 있다¹⁾⁻⁵⁾. 유연성 로봇 링크는 그 경량성으로 인하여 고속동작이 가능하며 에너지의 효율성과 안정성이 증대된다. 그러나 링크는 그 유연성으로 인해 동작시 진동을 일으키므로 정밀한 위치제어를 위해서는 진동을 효율적으로 제어해야 한다. 이를 위해서는 보다 정밀한 동력학 방정식과 효율적인 제어 알고리즘이 필요하게 된다. Yoshiyuki Sakaw1)과 Zheng-Hua Luo²⁾는 유연성 링크에 최적제어를 적용하였고, K. S. Yeung⁵⁾등은 가변구조 제어법칙을 적용하여 그 유용성을 입증하였다. 그러나 선형 최적제어나 선형 케환제어는 한정된 선형 영역에서만 강건하므로 예측하지 못한 큰 외란이 발생하였을 경우 시스템은 외란에 민감하게 된다. 따라서 시스템 환경이 미지이거나 불확실한 경우에는 이에 대처할 수 있도록 시스템의 매개변수를 조절해 줄 필요가 있다.

최근 제어문제에 어려움을 극복하기 위하여 기존의 수학적 해석기법과는 다르게 신경회로망(neural networks) 이론을 응용한 제어기법이 많은 연구가들에 의해 병렬처리, 학습, 비선형 맵핑, 패턴인식, 정보처리, 산업응용 등에 관한 연구가 진행되고 있다⁶⁾⁻¹¹⁾. 그리고 신경회로망은 그 특징으로써 비선형성, 학습능력, 최적화능력 등을 가지며 이들의 특징을 활용하여 비선형제어, 적응제어 등에 적용되어 성과를 거두고 있다^{8), 9)}.

본 논문에서는 신경회로망¹¹⁾을 이용하여 유연성 단일 링크 로봇 매니퓰레이터의 진동을 능동적으로 제어하는 것을 목적으로 한다. 신경회로망의 구조는 하나의 은닉층을 가지며, 은닉층은 자기순환

구조로 이루어졌다. 그리고 뉴로추정기(Neuro Identifier)라 불리는 추정기와 뉴로제어기(Neuro Controller)라 불리는 제어기로 구성된 두 개의 신경회로망이 제어시스템에 이용된다. 제어되는 플랜트는 뉴로추정기에 의해 추정되어지고, 플랜트의 모든 입력은 뉴로제어기에 의해 제공된다. 또한 일반화된 동적 오차역전파 알고리즘(Dynamic Error-backpropagation Algorithm: DEA)은 뉴로추정기와 뉴로제어기를 학습하기 위해 사용되어지고, 학습의 안정한 수렴을 보장하기 위하여 Lyapunov 함수를 적용했다. 또한 유연성 단일 링크 로봇 매니퓰레이터의 운동방정식은 가정된 모드(assumed mode)법과 Lagrange 방정식을 이용하여 유도하였으며, 본 논문에서 제시된 신경회로망 제어 알고리즘의 효율성을 입증하기 위해 신경회로망 제어기를 설계하여 실험을 통하여 그 결과를 LQR 제어기와 비교 분석한다.

2. 유연성 단일 링크를 가지는 매니퓰레이터의 모델링

그림 1은 유연성 단일 링크를 가지는 매니퓰레이터 시스템을 나타낸 것이다. I_h 는 매니퓰레이터를 구동하는 액추에이터와 링크를 액추에이터에 고정하는 부위를 합한 허브의 질량 관성모멘트이고, M_e 와 J_e 는 앤드 이펙터와 유로하중을 합한 링크의 끝지점(end-point) 질량과 질량 관성모멘트이며, g 는 z 축 아래로 향하는 중력이다.

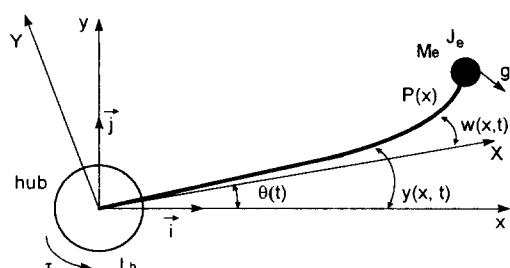


Fig. 1 Flexible single link robot manipulator.

유연성 링크의 길이는 단면적에 비해 아주 커서 전단변형과 회전 관성효과를 무시할 수 있는 가늘

고 긴 균일한 Bernoulli-Euler 링크로 유연성 링크를 모델화하고, 작동시 비틀림이 없어 작동면에서 굽힘 변형만 있는 것으로 가정한다. 또한 결합부위의 마찰과 유연성 링크의 구조적인 감쇠는 시스템 모델링시 무시한다. 그리고 운동의 미분방정식은 자유 휨진동이 존재하는 유연성 링크에 대해서 만족해야 하므로 다음과 같은 방정식으로 주어진다¹⁴⁾

$$\rho A(x) \frac{\partial^2 w(x, t)}{\partial t^2} + \frac{\partial^2}{\partial x^2} [EI(x) \frac{\partial^2 w(x, t)}{\partial x^2}] = 0 \quad \dots \dots \dots (1)$$

여기서 ρ 는 선형 질량농도, $A(x)$ 는 링크의 단면적, $EI(x)$ 는 링크의 굽힘강성이다. 또한 링크의 임의의 점 x 에 대한 탄성변형 $w(x, t)$ 는 가정된 모우드 형상과 일반화 좌표의 선형적인 조합으로 근사화하면 다음과 같이 표현된다¹³⁾.

$$w(x, t) = \sum_{i=1}^n \phi_i(x) q_i(t) = \phi q^T \quad \dots \dots \dots (2)$$

여기서 $\phi_i(x)$ 는 링크의 i 번째 가정된 모우드 형태로써 고정-자유단(clamped-free)의 고유함수이며, $q_i(t)$ 는 $\phi_i(x)$ 에 상응하는 시간의 함수인 i 번째 일반화 좌표이고, n 은 탄성변형을 나타내기 위해 사용된 가정된 모우드의 수로써 모델의 정확도를 향상시킬 때 증가된다. 즉 유연성 링크 시스템의 3차 이상의 고차 모우드의 크기는 1차 모드의 크기에 비하여 대단히 작으므로 모우드 수는 2차 모우드로 하여도 시스템을 정확히 분석할 수 있다. 또한 링크는 관성모멘트 I_b , 길이 l 을 가지고, 링크의 각 변형은 $\theta(t)$ 로써 표시되며, 전체변위 $y(x, t)$ 는 다음과 같다.

$$y(x, t) = x\theta(t) + w(x, t) \quad \dots \dots \dots (3)$$

그리고 시스템의 작동면에서의 탄성변형은 가정된 모우드법에 의해 근사화되게 나타나게 된다. 가정된 모우드법은 탄성변형을 공간좌표의 함수인 가정된 모우드와 시간의 함수인 일반화 좌표의 선형적인 조합에 의해 식 (2)와 같이 나타나고, 이를 이용해서 적당한 크기의 이산화된 모델을 유도한다.

이산화된 모델은 먼저 시스템의 운동에너지와 위치에너지를 구한 다음 가정된 모우드법을 이용하여 Lagrange 방정식에 적용해서 유도한다. 가정된 모우드 형상을 이용해서 유연성 링크의 변형을 나타내는데 적합한 가정된 모우드 형상의 선정은 최종 모델의 정확도에 많은 영향을 미친다. 본 시스템에서 유연성 링크는 액추에이터에 고정되어 탄성운동을 하므로 고정-자유단 링크와 같은 형태의 변형 운동을 한다고 생각할 수 있다. 따라서 고정-자유단 링크의 끝지점에 질량을 가지는 경우의 모든 기하학적 경계조건과 자연적 경계조건을 동시에 만족하는 비교함수를 개발하여 가정된 모우드 형상으로 사용한다. 그리고 고정점($x=0$)에 대해 허브부 위에서 변위와 기울기가 영이라는 조건으로부터 다음과 같은 기하학적 경계조건을 구한다.

- 1) $w(0, t) = w_0 = 0$: 변형은 0이 되어야 한다.
- 2) $\frac{\partial w(0, t)}{\partial x} = 0$: 휨 변형의 경사가 0이 되어야 한다.

자유 끝점($x=l$)에 대해 전단력과 굽힘 모멘트의 균형이 이루어진다는 조건으로부터 다음과 같은 자연적 경계조건을 구한다.

$$1) EI \frac{\partial^2 w(l, t)}{\partial x^2} + J_e [\ddot{\theta} + \frac{\partial \ddot{w}(l, t)}{\partial x}] = 0$$

: 굽힘모멘트는 0이 되어야 한다.

$$2) EI \frac{\partial^3 w(l, t)}{\partial x^3} + M_e [-\ddot{w}(l, t) + \dot{\theta}^2 w(l, t) - \ddot{\theta} l + g \sin \theta] = 0$$

: 전단력이 0이 되어야 한다.

위의 경계조건은 고유주파수 βl 에 대한 초월함수를 발생하고 진동수 방정식은 다음과 같다.

$$\cosh(\beta l) \cos(\beta l) + 1 = 0 \quad \dots \dots \dots (4)$$

식 (2)에서 고유함수 $\phi(x)$ 는 다음과 같다.

$$\phi(x) = c_1 \sin \beta x + c_2 \cos \beta x + c_3 \sin h\beta x + c_4 \cos h\beta x \quad \dots \dots \dots (5)$$

여기서 c_i 는 임의의 상수로 위의 경계조건식을 대입하여 c_1, c_2, c_3, c_4 에 대해 정리하면 다음과 같은 행렬식 형태로 나타낼 수 있다.

$$\begin{bmatrix} 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 0 \\ \alpha_{31} & \alpha_{32} & \alpha_{33} & \alpha_{34} \\ \alpha_{41} & \alpha_{42} & \alpha_{43} & \alpha_{44} \end{bmatrix} \begin{bmatrix} c_1 \\ c_2 \\ c_3 \\ c_4 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad \dots \dots \dots (6)$$

여기서

$$\alpha_{31} = -\beta^2 EI \sin(\beta l) - \beta \omega^2 J_e \cos(\beta l)$$

$$\alpha_{32} = -\beta^2 EI \cos(\beta l) + \beta \omega^2 J_e \sin(\beta l)$$

$$\alpha_{33} = \beta^2 EI \sinh(\beta l) - \beta \omega^2 J_e \cosh(\beta l)$$

$$\alpha_{34} = \beta^2 EI \cosh(\beta l) - \beta \omega^2 J_e \sinh(\beta l)$$

$$\alpha_{41} = -\beta^3 EI \sin(\beta l) + \omega^2 M_e \cos(\beta l)$$

$$\alpha_{42} = \beta^3 EI \cos(\beta l) + \omega^2 M_e \sin(\beta l)$$

$$\alpha_{43} = \beta^3 EI \sinh(\beta l) + \omega^2 M_e \cosh(\beta l)$$

$$\alpha_{44} = \beta^3 EI \cosh(\beta l) + \omega^2 M_e \sinh(\beta l)$$

이며, $\omega^2 = \frac{EI}{\rho A} \beta^4$ 이다. 위의 식 (6)이 유용해 를 갖기 위해서는 행렬 (α_{ij})의 행렬식이 영이어야 한다는 조건으로부터 비선형 대수방정식이 유도된다. 이 비선형 대수방정식을 풀면 식 (5)의 β 값을 구할 수 있고, 각각의 β 값들에 상응하는 상수 c_1, c_2, c_3, c_4 의 값들은 위의 식 (6)을 이용하여 구할 수 있다.

다음은 운동방정식의 유도로, 입력은 모터 토오크 τ 로 표현되고, 출력은 전체변위로 식 (3)과 같이 표현되며, 시스템의 운동에너지는 허브부위의 회전운동 및 유연성 링크의 선형과 회전운동 그리고 끝지점 질량의 선형과 회전운동에 의해 발생되며 전체 운동에너지는 이를 합한 것으로 다음과 같다.

$$\begin{aligned} K &= \frac{1}{2} I_h \dot{\theta}^2 + \frac{1}{2} \rho A \int_0^l [\dot{\theta}^2 x^2 + \dot{w}^2 \\ &\quad + 2 \dot{\theta} \dot{w} x + \dot{\theta}^2 w^2] dx + \frac{1}{2} J_e [\dot{\theta}^2 \\ &\quad + 2 \dot{\theta} \dot{w}_l + \dot{w}_l^2] + \frac{1}{2} M_e [\dot{w}_l^2 \\ &\quad + \dot{\theta}^2 w_l^2 + 2 \dot{\theta} \dot{w}_l l + \dot{\theta}^2 l^2] \end{aligned} \quad \dots \dots \dots (7)$$

여기서 웃 첨자 “'”와 “.”는 각각 공간좌표에 대한 편미분과 시간에 대한 편미분을 나타낸다. 그리고 시스템의 위치에너지는 유연성 링크의 탄성변형 및 끝지점 질량과 유연성 링크에 중력이 작용함에 의해 발생되며 시스템의 총 위치에너지는 이들을 합한 것으로 다음과 같다.

$$\begin{aligned} V &= \frac{1}{2} EI \int_0^l \left(\frac{\partial^2 w}{\partial x^2} \right)^2 dx \\ &\quad + \int_0^l \rho Ag [wsin\theta - xcos\theta] dx \\ &\quad + M_e g [wsin\theta - xcos\theta] \end{aligned} \quad \dots \dots \dots (8)$$

운동방정식은 다음의 Euler-Lagrange 방정식을 적용할 수 있다.

$$\frac{d}{dt} \frac{\partial L}{\partial \dot{q}_i} - \frac{\partial L}{\partial q_i} = 0, \quad i = 1, 2, \dots, n \quad \dots \dots \dots (9)$$

$$\frac{d}{dt} \frac{\partial L}{\partial \dot{\theta}} - \frac{\partial L}{\partial \theta} = \tau \quad \dots \dots \dots (10)$$

여기서 τ 는 액추에이터를 통해 유연성 링크를 구동하기 위해 가해지는 입력 토오크이며, $L = K - V$ 이다. 위 식 (7)과 (8)을 식 (9)와 (10)에 대입하고, 유연성 링크의 끝지점의 질량과 질량 관성모멘트 및 중력은 고려하지 않은 상태에서 편미분을 일반화 좌표에 대해서 시행하면 다음과 같은 이산화된 미분방정식 형태의 운동방정식을 구하게 된다.

$$\ddot{\theta} = \frac{\tau + \sum_{j=1}^n q_j \omega_j^2 \int_0^x \phi_j x dm}{I_h} \quad \dots \dots \dots (11)$$

$$\begin{aligned} \ddot{q}_i &= -\frac{T}{I_h} \int_0^x \phi_i x dm \\ &\quad - q_i \omega_i^2 \left[1 + \frac{\left(\int_0^x \phi_i x a \right)}{I_h} \right. \\ &\quad \left. - \sum_{j \neq i} q_j \omega_j^2 \int_0^x \phi_j x dm \right] / I_h \end{aligned} \quad \dots \dots \dots (12)$$

식 (12)의 맨 우측항은 계수가 커지면 영이고, 관성모멘트에 대해 Bessel의 등식으로 표현이 가능하다. 즉

$$I_b = \int_0^x x^2 dm = \sum_{i=1}^{\infty} \left(\int_0^x \phi_i x dm \right)^2 \quad \dots \dots \dots (13)$$

이므로 다음과 같이 표현된다.

$$I_b - \sum_{i=1}^n \left(\int_0^x \phi_i x dm \right)^2 = 0 \quad \dots \dots \dots (14)$$

3. 제어시스템의 설계

3.1. LQR 제어기

LQR 제어기는 시불변 케이스로써 플랜트를 기준상태로부터 원하는 편차이내로 유지시키기 위하여 사용된다. LQR 제어기는 데이터 입력으로부터 유효한 모든 정보를 사용하는 모든 상태케이스를 이용한다. 또한 그것은 정적인 특성 때문에 실행하기가 쉽고, 좋은 이득과 위상여유를 보장하여 상대적으로 플랜트의 불확실성에 대해서 강인하지만 시스템의 성능 및 안정도에 관한 설계사양을 설계과정에서 직접 고려할 수 없고, 단지 설계 후 성능을 검토할 수밖에 없는 시행착오 방법이라는 문제를 가지고 있다. 선형 제어이론을 이용해서 유연성 링크의 위치 및 진동제어를 위한 알고리즘을 개발하려면 앞에서 유도된 운동방정식 (11)과 (12)의 선형화가 필요하다. 그래서 선형 상태공간 방정식으로 유도하면 다음과 같다.

$$\dot{x} = Ax + Bu \quad \dots \dots \dots (15)$$

$$y = Cx \quad \dots \dots \dots (16)$$

행렬 A , B , C , x 를 $n=3$ 의 경우에 대해서 적용하면

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & w_1^2 \frac{\gamma_1}{I_h} & 0 & w_2^2 \frac{\gamma_2}{I_h} & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & -w_1^2 \left(1 + \frac{\gamma_1^2}{I_h}\right) & 0 & -w_2^2 \left(1 + \frac{\gamma_2^2}{I_h}\right) & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & -w_1^2 \frac{\gamma_1 \gamma_3}{I_h} & 0 & -w_2^2 \frac{\gamma_2 \gamma_3}{I_h} & 0 \end{bmatrix}$$

$$B = \begin{bmatrix} 0 & \frac{1}{I_h} & 0 & -\frac{\gamma_1}{I_h} & 0 & -\frac{\gamma_2}{I_h} & 0 & -\frac{\gamma_3}{I_h} \end{bmatrix}^T,$$

$$C = [x \ 0 \ \phi_1(x) \ 0 \ \phi_2(x) \ 0 \ \phi_3(x) \ 0],$$

$$x = [\theta \ \dot{\theta} \ q_1 \ \dot{q}_1 \ q_2 \ \dot{q}_2 \ q_3 \ \dot{q}_3]^T$$

이며, 여기서

$$\gamma_i = \int_0^x \phi_i x dm \quad \dots \dots \dots (17)$$

이다. 그리고 2차 가격함수를 갖는 선형시스템의 최적제어 문제를 다루기 위하여 위 식 (15)와 (16)과 같은 선형 상태공간 방정식으로 표현되는 선형 시변 시스템에 대해 생각하면, 표준 LQR 문제는 다음의 2차 가격함수를 최소화하는 것을 요구한다.

$$J = \frac{1}{2} \int_0^\infty [x^T(t) Q x(t) + u^T(t) R u(t)] dt \quad \dots \dots \dots (18)$$

여기서 $x(t)$ 는 상태벡터, $u(t)$ 는 제어 입력벡터, Q 는 양의 반한정 대칭행렬인 상태 가중치행렬, R 은 양의 한정 대칭행렬인 제어 가중치행렬이다. 그리고 상태 가중행렬 Q 는

$$Q = \begin{bmatrix} [q_1 \ 0] & & 0 \\ 0 & I & \\ 0 & & [q_2 \ 0] \\ & & 0 & I \end{bmatrix}$$

이고, 여기서 q_1 과 q_2 는 각각 θ 와 $\dot{\theta}$ 의 가중치이며, 모든 유연성 상태의 가중치는 1의 형태로 간단히 표현된다. 그리고 토오크 τ 는 다음과 같다.

$$\tau = -K(x - x_{ref}) \quad \dots \dots \dots (19)$$

여기서 K 는 모든 상태케이스로 이득행렬이며, 적당한 레귤레이터 이득행렬 K 는 바라는 응답이 될 때 까지 q_1 , q_2 와 R 의 값을 변화시켜 찾는다. 본 논문에서의 제어기 이득 K 는 $q_1 = 4000$, $q_2 = 2500$ 및 $R = 10$ 의 값을 가질 때 [14.5095 14.5788 1.6608 3.0870]로 주어졌다. 그리고 LQR 제어기는 그림 2와 같이 설계했고, 그림에서 CC (Command Converter)블럭은 상태공간형으로 기준입력을 간단히 변환시키는 역할을 한다.

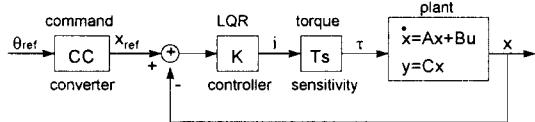


Fig.2 LQR control system.

3.2. 신경회로망 제어기

임의의 비선형 함수는 신경회로망을 이용하여 원하는 정확한 정도까지 근사화시킬 수 있으므로 신경회로망 모델에 대한 짧은 학습시간의 목적으로 은닉층에 자기순환 뉴런을 가진 신경회로망을 그림 3에 나타낸다. 그림 3에서 각 이산시간 k 에 대해 $I_i(k)$ 는 i 번째 입력, $S_j(k)$ 는 j 번째 자기 순환 뉴런에 대한 입력의 합, $X_j(k)$ 는 j 번째 은 닉층인 자기 순환뉴런의 출력 및 $O(k)$ 는 출력층의 출력이며, Z^{-1} 은 지연시간이고, ●는 자기순환 뉴런이다. 그리고 회로망에서 W^H , W^O , W^D 는 각각 은닉층, 출력층 및 자기 순환층의 가중치 벡터이다.

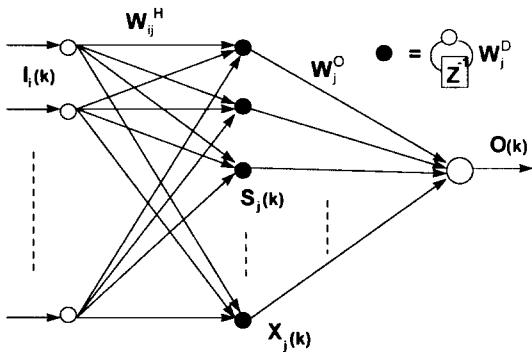


Fig.3 Neural networks architecture.

여기서 입출력 동적매핑을 $M: I^m \rightarrow O^n$ 으로 정의하고, $O(k)$ 는 신경회로망의 출력으로 한다. 만약 $m=3$, $n=1$, $I^3 = [r(k), y(k), u(k)]$ 라 가정하면

$$O(k) = Q_M^D(r(l), y(l), u(l); l \leq k) \quad \dots \dots \dots (20)$$

이고, 여기서 $Q_M^D(\cdot)$ 는 비선형함수이다. 이것은 이전의 모든 입력을 포함하기 때문에 비선형 동적 매핑 신경회로망으로 표현되며, l 과 k 는 양의 정수이다. 그리고 신경회로망에 기초로한 전체 제어시스템의 구성은 그림 4로써 설계했다. 여기서 뉴로제어기는 미지의 동적시스템을 구동하기 위해 사용되어지고, 플랜트와 요구되는 출력사이의 오차를 최소화하기 위함이며, $y_r(k) = r(k)$ 로 한다.

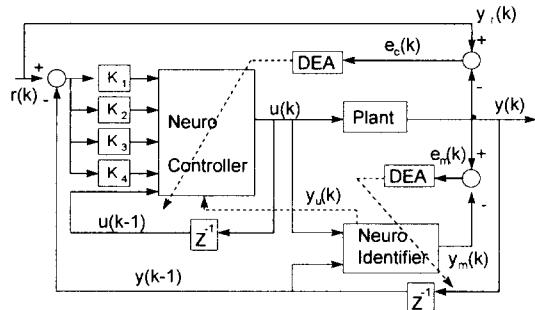


Fig.4 Total system using neural networks.

그리고 DEA라 불리는 동적 오차역전파 알고리즘은 뉴로추정기와 뉴로제어기 둘 다를 학습하기 위해 적용된다. 뉴로제어기의 입력은 기준입력과 이전의 플랜트 출력과의 오차에 이득을 곱한 것과 이전의 제어신호이고, 출력은 플랜트의 제어신호이다. 뉴로제어기의 가중치는 약간의 학습주기 후에 작은 값으로 접근하여 플랜트의 출력과 기준모델로부터 요구되는 출력사이의 오차를 조절한다. 그리고 뉴로제어기가 학습을 할 때는 플랜트의 정보가 필요하다. 플랜트가 미지이기 때문에 시스템 추정기인 뉴로추정기는 뉴로제어기에 대한 플랜트 감도 $y_u(k)$ 를 추정하기 위해 사용된다. 또한 뉴로 추정기의 입력은 이전의 플랜트 출력과 뉴로제어기의 출력이 사용되며, 뉴로추정기의 출력과 플랜트 사이의 오차는 각 반복에 의해 계산되어지고 뉴로추정기의 가중치를 조절하기 위해 사용된다. 그리고 신경회로망의 출력값과 가중치 갱신은 그림 3에 대한 수학적 모델로 다음과 같다.

$$O(k) = \sum_{j=1}^n W_j^O X_j(k) \quad \dots \dots \dots (21)$$

$$X_j(k) = f(S_j(k)) \quad \dots \quad (22)$$

$$S_j(k) = W_j^D X_j(k-1) + \sum_{i=1}^n W_{ij} I_i(k) \quad \dots \dots \dots (23)$$

여기서 $f(\cdot)$ 은 일반적으로 시그모이드 함수이다.
그리고 동적 오차역전파 알고리즘 DEA를 유도하기 위해 신경회로망에 대한 오차함수를 다음과 같이 정의한다.

$$E_c(k) = \frac{1}{2} \sum_{k=1}^n (y_r(k) - y(k))^2 \quad \dots \dots \dots \quad (24)$$

여기서 $y_r(k)$ 는 플랜트에 요구되는 응답이고, $y(k)$ 는 플랜트의 실제 응답이다. 일반적으로 플랜트 응답은 입력 $u(k)$ 의 비선형 맵핑 $G(\cdot)$, 즉 $y(k) = G(u(i), i \leq k)$ 이다. 여기서 플랜트 입력 $u(k)$ 는 뉴로제어기의 출력, 즉 식 (21)에서 $u(k) = O(k)$ 로써 뉴로추정기의 입력이다. 오차함수에 대한 식 (24)에서 $y_r(k)$ 를 $y(k)$ 로, $y(k)$ 를 $y_m(k)$ 로 정의하여 뉴로추정기에 대해 수정하면 다음과 같다.

$$E_m(k) = \frac{1}{2} \sum_{k=1}^n (y(k) - y_m(k))^2 \quad \dots \dots \dots (25)$$

여기서 $y_m(k)$ 는 뉴로추정기의 출력으로 식 (21)에서 $O(k)$ 이다. 뉴로제어기의 경우에 대한 오차의 그래디언트는 임의의 가중치 벡터에 관하여 식 (24)에서 다음으로 표현된다.

$$\begin{aligned} \frac{\partial E_c(k)}{\partial W} &= -e_c(k)y_u(k) \frac{\partial u(k)}{\partial W} \\ &= -e_c(k)y_u(k) \frac{\partial O(k)}{\partial W} \end{aligned} \quad \dots \quad (26)$$

여기서 $e_c(k)$ 는 플랜트의 요구되는 응답과 실제응답 사이의 오차이고, $y_u(k) = \frac{\partial y(k)}{\partial u(k)}$ 는 플랜트 입력에 대한 플랜트의 감도를 나타내며, 일반적으로 플랜트가 미지이기 때문에 플랜트 감도도 미지이다. 이 미지의 값은 뉴로추정기를 사용함으로써 추정

되어진다. 뉴로추정기가 학습할 때 뉴로추정기의 동적동작은 미지의 플랜트에 접근해 있다. 즉 $y(k) = y_m(k)$ 이고, $y_m(k)$ 는 뉴로추정기의 출력이다. 그리고 뉴로추정기의 경우 식 (25)에 있어서 그래디언트 오차는 다음과 같이 표현된다.

$$\frac{\partial E_m(k)}{\partial W} = -e_m(k) \frac{\partial y_m(k)}{\partial W} = -e_m(k) \frac{\partial O(k)}{\partial W}$$

..... (27)

여기서 $e_m(k)$ 는 플랜트와 뉴로추정기 출력사이의 오차이다. 식 (26)과 (27)의 출력 그레디언트 $\frac{\partial O(k)}{\partial W}$ 는 같으며, 뉴로제어기와 뉴로추정기를 계산하기 위해 필요하다. 그리고 출력과 자기순환 및 입력 가중치에 관계되는 출력 그레디언트는 각각 다음과 같다.

$$\frac{\partial O(k)}{\partial W_i^0} = X_j(k) \quad \dots \quad (28)$$

$$\frac{\partial O(k)}{\partial W_i^D} = W_i^o P_j(k) \quad \dots \dots \dots \quad (29)$$

$$\frac{\partial O(k)}{\partial W_i^T} = W_i^T Q_{ij}(k) \quad \dots \quad (30)$$

여기서

$$P_j(k) = \frac{\partial X_j(k)}{\partial W_i^D} \quad Q_{ij}(k) = \frac{\partial X_j(k)}{\partial W_{ii}^I} \quad \dots \quad (31)$$

이고, 다음을 만족시킨다.

$$P_i(k) = f'(S_i)(X_i(k-1)) + W_i {}^D P_i(k-1), \quad P_i(0) = 0 \quad \dots \quad (32)$$

$$Q_{ij}(k) = f(S_j)(I_i(k)) + W_i^D Q_{ij}(k-1), \quad Q_{ij}(0) = 0 \quad (33)$$

위의 식 (32)와 (33)은 상태 그래디언트 $\frac{\partial X_i(k)}{\partial W}$ 에 대한 비선형 동적 순환방정식이고, 주어진 초기 조건을 가지고 순환적으로 풀 수 있다. 그리고 뉴로추정기에 대한 DEA는 식 (27)에서 가중치 벡터

에 관계되는 오차의 부 그래디언트는 다음과 같다.

$$-\frac{\partial E_m}{\partial W} = e_m(k) \frac{\partial O(k)}{\partial W} \quad \dots \dots \dots (34)$$

뉴로추정기에 대한 각 층의 가중치들은 그래디언트 방법에 의해서 조절되어지므로 가중치의 개선법칙은 다음과 같다.

$$W(n+1) = W(n) + \eta \left(-\frac{\partial E_m(k)}{\partial W} \right) \quad \dots \dots \dots (35)$$

여기서 η 는 학습율로써 다음의 Lyapunov 함수를 이용하여 학습의 안정한 수렴특성을 정의한다. 또한 뉴로제어기에 대한 DEA는 식 (24)에서 가중치 벡터에 관계되는 오차의 부 그래디언트는 다음과 같다.

$$-\frac{\partial E_c(k)}{\partial W} = e_c(k) y_u(k) \frac{\partial O(k)}{\partial W} \quad \dots \dots \dots (36)$$

그리고 학습이 행하여 질 때 뉴로추정기의 출력감도는 다음과 같이 접근된다.

$$y_u(k) \doteq \frac{\partial y(k)}{\partial u(k)} \doteq \frac{\partial y_m(k)}{\partial u(k)} \quad \dots \dots \dots (37)$$

식 (37)에 연속법칙을 적용할 수 있고, 뉴로추정기에 대한 입력이 $u(k)$ 와 $y(k-1)$ 이기 때문에 식 (23)에서 다음을 얻을 수 있다.

$$\begin{aligned} S_j(k) &= W_j^D X_j(k-1) + W_{1j}^T u(k) \\ &+ W_{2j}^T y(k-1) + W_{3j}^T b_I \end{aligned} \quad \dots \dots \dots (38)$$

여기서 b_I 는 뉴로추정기에 대한 바이어스 가중치이다. 그리고 $O(k) = y_m(k)$ 라 하면 뉴로제어기에 대한 감도는 다음과 같다.

$$y_u(k) = \frac{\partial y_m(k)}{\partial u(k)} = \sum_{i=1}^n W_i^T f(S_i(k)) W_{1j} \quad \dots \dots \dots (39)$$

그리고 뉴로제어기에 대한 각 층의 가중치들은 그래디언트 방법에 의해서 조절되어지므로 가중치의 개선법칙은 다음과 같다.

$$W(n+1) = W(n) + \eta \left(-\frac{\partial E_c(k)}{\partial W} \right) \quad \dots \dots \dots (40)$$

다음은 학습의 안정한 수렴특성의 정의에 관한 것으로 식 (35)와 (40)의 가중치 개선법칙은 학습율 η 를 적당히 선택되도록 해야한다. η 의 값이 작으면 수렴은 보장되지만 속도는 매우 느리고, η 가 클 경우 수렴속도는 빠르나 발진을 할 수 있다. 그래서 Lyapunov 함수를 이용하여 학습의 안정한 수렴특성을 위해 적당한 학습율을 선택하기 위한 방법을 정의한다. 이산형 Lyapunov 함수는 다음과 같이 가정한다.

$$V(k) = \frac{1}{2} e^2(k) \quad \dots \dots \dots (41)$$

여기서 $e(k)$ 는 학습과정에서의 오차이다. 그리고 학습과정에 기인한 Lyapunov 함수의 변화값은 다음과 의해 얻어진다.

$$\begin{aligned} \Delta V(k) &= V(k+1) - V(k) \\ &= \frac{1}{2} [e^2(k+1) - e^2(k)] \end{aligned} \quad \dots \dots \dots (42)$$

학습에 기인한 오차의 차이는 다음과 같이 표현할 수 있다.

$$\begin{aligned} e(k+1) &= e(k) + \Delta e(k) \\ &= e(k) + \Delta W \left[\frac{\partial e(k)}{\partial W} \right]^T \end{aligned} \quad \dots \dots \dots (43)$$

여기서 ΔW 는 임의의 가중치 벡터량으로 표현되며, 뉴로추정기의 수렴특성은 식 (27)과 (35)의 개선법칙으로부터 다음과 같다.

$$\begin{aligned} \Delta W_I &= -\eta_I e_m(k) \frac{\partial e_m(k)}{\partial W_I} \\ &= \eta_I e_m(k) \frac{\partial O(k)}{\partial W_I} \end{aligned} \quad \dots \dots \dots (44)$$

여기서 W_I 와 η_I 는 각각 뉴로추정기에서의 임의의 가중치와 학습율을 나타내며, $O(k)$ 는 뉴로추정기의 출력이다. 그리고 뉴로제어기의 수렴특성은

식 (26)과 (40)의 갱신법칙으로부터 다음과 같다.

$$\begin{aligned}\triangle W_c &= -\eta_c e_c(k) \frac{\partial e_c(k)}{\partial W_c} \\ &= \eta_c e_c(k) y_u(k) \frac{\partial O(k)}{\partial W_c}\end{aligned}\quad \dots\dots\dots(45)$$

만약 η , 가 뉴로추정기의 가중치에 대한 학습율이라 하고, $g_{l, \max} = \max_k \|g_l(k)\|$ 로써 정의하면 $g_l(k)$ 는 다음과 같다.

$$g_I(k) = \frac{\partial O(k)}{\partial W_I} \quad \dots \quad (46)$$

$\|\cdot\|$ 는 일반적으로 Euclid 놈이며, 식 (42), (43) 및 (44)로부터 $\triangle V(k)$ 는 다음과 같이 표현된다.

$$\begin{aligned}\triangle V(k) &= \triangle e_m(k) \left[e_m(k) + \frac{1}{2} \triangle e_m(k) \right] \\ &= -\eta_I e_m^2(k) \left\| \frac{\partial O(k)}{\partial W_I} \right\|^2 \\ &\quad + \frac{1}{2} \eta_I^2 e_m^2(k) \left\| \frac{\partial O(k)}{\partial W_I} \right\|^4 \quad \dots \dots (47) \\ &\doteq -\frac{1}{2} \|g_I(k)\|^2 \eta_I \left(2 - \frac{\eta_I \|g_I(k)\|^2}{g_I^2} \right)_{\max}\end{aligned}$$

그러므로 수렴은 π_1 가 다음과 같을 때 보장된다.

식 (48)은 어떠한 η_1 이 $0 < \eta_1 < 2$ 일 때 수렴은 보장됨을 의미한다. 그러나 최대학습율은 최적 수렴이 $\eta_1 = 1$ 로 일치할 때 보장되므로 다음과 같다.

$$\eta_I^* = \frac{1}{\delta_{I_{\max}}^2} \quad \dots \quad (49)$$

식 (49)는 어떤 다른 학습율이 η ; 보다 더 크면 빠른 수렴을 보장하지 못함을 의미하며, 뉴로제어기에 대해서도 같이 적용된다. 일반적인 Lyapunov 안정도는 식 (35)와 (40)처럼 각각의 신경회로망에 대한 각 층의 가중치를 개선하는데 적당한 학습율을 선택할 수 있다. 그러므로 구성된 페루프 시스

템의 출력은 원하는 출력을 따라 가며, 각 층의 가중치는 최적의 값으로 수렴한다.

4. 실험결과

앞에서 기술한 두가지 제어시스템의 구조를 실험을 통하여 성능을 비교하기 위한 제어기의 실험장치 구성도는 그림 5와 같다. 그림 5에서 카메라는 선형으로 배열된 2048 아날로그 광검출기를 가지며, 각 광검출기의 폭은 $13[\mu\text{m}]$ 이고, 배열 전체의 길이는 $26.624[\text{mm}]$ 이다. 렌즈를 사용하여 LED의 광이 광검출기의 배열에 투시되며, 투시된 광은 전압분포로 바뀌어 엔코드를 통하여 컴퓨터에서 계산되어진다. 그리고 모터는 $3000[\text{RPM}]$ 의 PMI DD모터와 서보 증폭기를 사용했다.

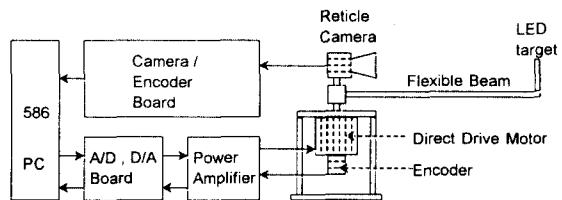


Fig.5 Configuration of experimental setup.

본 논문에서 사용된 시스템의 매개변수는 다음의 **〈표 1〉**과 같으며, 실제 실험장치를 그림 6에 나타내었고 링크의 끝지점 유로하운은 고려하지 않았다.

⟨Table 1⟩ System parameters.

링크의 길이	$l = 1.2[m]$
링크의 폭	$W = 0.0254[m]$
링크의 뚜께	$D = 0.0032[m]$
선형 질량밀도	$\rho = 0.2332[Kg/m]$
탄성계수	$EI = 6.715[N \cdot m^2]$
허브관성	$I_h = 0.005[Kg/m^2]$
링크의 재질	알루미늄
카메라 화소감도	$pix - sens = 26[\mu m]$

신경회로망 제어기에 대한 가중치의 초기값은 [-0.05, 0.05] 사이의 난수로 하였고, 뉴로추정기에 대한 초기 학습율 η_I^H , η_I^D 와 η_I^O 는 각각 0.11, 0.19와 0.87 및 뉴로제어기에 대한 초기 학습율 η_c^H , η_c^D 와 η_c^O 는 각각 0.41, 0.38과 0.23으로 하였다. 그리고 이득 상수 K_1 , K_2 , K_3 및 K_4 는 각각 0.78, 0.18, -0.51 및 0.04로 하였고, 바이어스 가중치는 1.0으로 했으며, 뉴로추정기 및 뉴로제어기에 대한 입력층의 뉴런 수는 5개, 은닉층은 시그모이드 뉴런을 이용하고 뉴런 수는 여러 가지 실험 결과를 토대로 빠른 학습을 위해 10개, 출력층은 선형 뉴런을 이용하고 뉴런 수는 1개을 사용하였다.

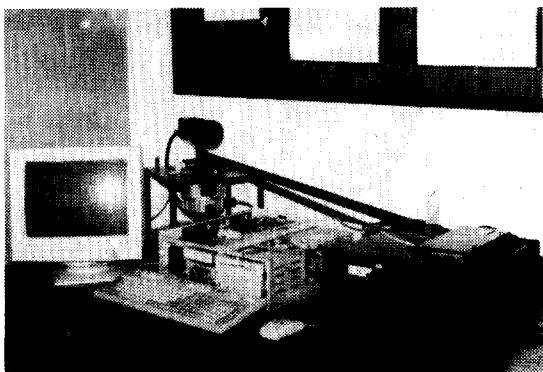
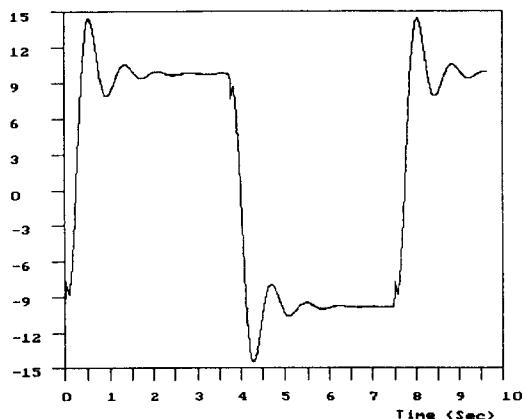


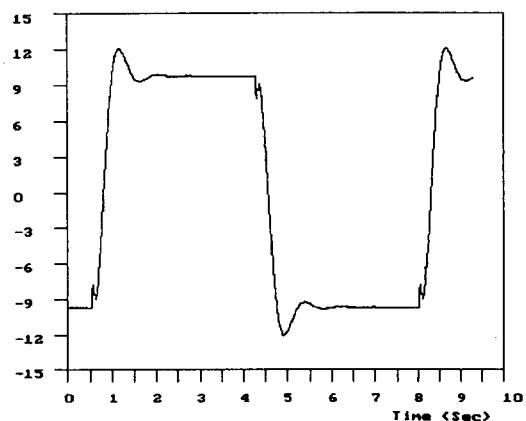
Fig.6 Experimental setup.

본 논문의 실험은 유연성 단일 링크 로봇 매니퓰레이터의 초기위치를 0° 에서 시스템 출력의 링크 위치를 원하는 각도로 변화시키는 것으로, $\pm 10^\circ$ 이동시킬 때 LQR 제어기와 신경회로망 제어기에 대한 링크의 전체 변위각도 및 끝지점 진동을 비교 조사하였다. 그림 7은 LQR 제어기와 신경회로망 제어기의 전체 변위각도에 대한 비교로 가로축은 시간[sec]을 세로축은 전체 변위각도[rad]를 표시 한다. 그림 7(a)는 LQR 제어기의 응답으로 약 2.5초 후 큰 진동을 가지면서 정상위치에 도달하는 반면, (b)는 신경회로망 제어기의 응답으로 약 1.5초 후 정상위치로 진동이 적으면서 빠른 안정화가 이

루어짐을 알 수 있다. 또한 그림 8은 LQR 제어기와 신경회로망 제어기에 대한 링크의 끝지점 진동을 나타낸 것으로 가로축은 시간[sec]을 세로축은 끝지점 진동[cm]을 표시한다. 그림 8(a)는 LQR 제어기에 대한 것이고, (b)는 신경회로망 제어기에 대한 것으로 신경회로망 제어기에 대한 끝지점 진동이 LQR 제어기 출력에 비해 진폭이 적으면서 더 빠른 시간내에 안정화가 이루어진다는 것을 볼 수 있다.



(a) Response of LQR controller.

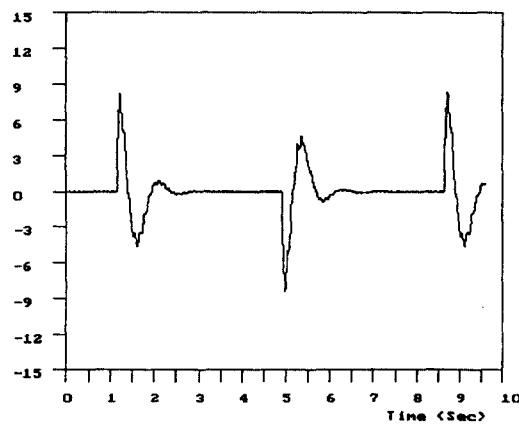


(b) Response of neural networks controller.

Fig.7 Total displacement angle control.



(a) Response of LQR controller.



(b) Response of neural networks controller.

Fig 8 End-point vibration control.

5. 결 론

본 논문은 전통적인 제어 기법에서 다루어지는 제어문제의 어려움을 극복하기 위해 기존의 수학적 해석기법과는 다르게 신경회로망 이론을 적용하여 실제의 시스템 구성을 통하여 실험적으로 유연성 단일 링크 로봇 매니퓰레이터의 진동제어를 행하였다. 유연성 단일 링크 로봇 매니퓰레이터의 운동방정식은 기하학적 경계조건과 자연적 경계조건

을 동시에 만족시키도록 가정된 모드법과 Lagrange 방정식을 이용하여 유도하였다. 제어시스템은 LQR 제어기와 신경회로망 제어기를 구성하였고, 신경회로망의 가중치를 개선하기 위해 동적 오차역전파 알고리즘을 사용하였으며, 학습의 안정한 수렴특성을 위해 Lyapunov 함수를 적용했다.

실험결과 선형제어기인 LQR 제어기보다 비선형 제어기인 신경회로망 제어기가 원하는 각도를 끝지점의 진동이 적으면서 더 빠른 시간내에 안정화가 이루어짐을 알 수 있었으며, 신경회로망 제어기가 유연성 단일 링크 로봇 매니퓰레이터의 진동제어에는 더 효율적으로 이용될 수 있음을 보여 주었다.

향후 연구 과제로는 링크의 끝지점에 여러 가지 유로하중을 포함시키는 것과 다중 링크에 대한 실험에서 신경회로망 제어기와 다른 고전적인 제어기의 제어특성을 비교, 검토하는 것이다.

참 고 문 헌

- [1] Yoshiyuki Sakawa, Fumitoshi Matsuno, and Shigenobu Fukushima, "Modeling and Feedback Control of A Flexible Arm", Journal of Robotic System, Vol. 2, No. 4, pp. 453-472, (1985).
- [2] Zheng-Hua Luo, "Direct Strain Feedback Control of Flexible Robot Arms: New Theoretical and Experimental results", IEEE Tran. on Automatic Control. Vol. 38, No. 11, pp. 1610-1622, (1993).
- [3] S. Nicosia, P. Tomei, and A. Tornambe, "Non-Linear Control and Observation Algorithms for A Single-Link Flexible Robot Arm", Int. J. Control, Vol. 49, No. 3, pp. 827-840, (1989).
- [4] Omer Morgul, "Orientation and Stabilization of A Flexible Beam Attached to a Rigid Body : Planar Motion", IEEE Tran. on Automatic Control. Vol. 38, No. 11, pp. 953-962, (1991).
- [5] K. S. Yeung and Y. P. Chen, "Sliding-mode controller design of a single-link flexible manipulator under gravity", Int. J. Control,

- Vol. 52, No. 1, pp. 101–117, (1990).
- [6] K. G. Shin and X. Cui, "Design of a Knowledge- Based Controller for Intelligent Control System," IEEE Trans. Syst., Man, Cybe., Vol. 21, No. 2, pp. 368–375, (1991).
 - [7] X. Cui and K. G. Shin, "Intelligent Coordination of Multiple Systems with Neural Networks", IEEE Trans. Syst., Man, Cybern., Vol. 21, No 6, pp. 1488–1497, (1991).
 - [8] M. Sekiguchi, T. Sugasaka and S. Nagata, "Control of Multivariable System by a Neural Network", IEEE International Conf. on Robotics and Automation, pp. 2644–2649, (1991).
 - [9] K. S. Narendra and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks", IEEE Trans. Neural Networks, Vol. 1, No. 1, pp. 4–27, (1990).
 - [10] A. U. Levin and K. S. Narendra, "Control of Nonlinear Dynamical Systems Using Neural Networks–Part II: Observability, Identification, and Control", IEEE Trans. Neural Networks, Vol. 7, No. 1, pp. 30–42, (1996).
 - [11] C. C. Ku and K. Y. Lee, "System Identification and Control Using Diagonal Recurrent Neural Networks", in Proc. American Control Conf., pp. 545–549, (1992).
 - [12] 탁한호, 이상배, "신경회로망을 이용한 유연한 로보트 빔의 위치제어에 관한 연구", 한국항해 학회지, 제21권, 제1호, pp. 109–118, (1997).
 - [13] Leonard Meirovitch, "Analytical Methods in Vibrations", Macmillan Publishing Co, pp. 126–166, 1996.
 - [14] Daniel J. Inman, "Engineering Vibration", Prentice Hall, pp. 126–166, 1994.