

# 신경회로망을 이용한 유연한 관절의 선단 위치 제어에 관한 연구

정회원 박 양 수\*, 김 창 화\*\*, 김 순 철\*\*

## The Tip Position Control of Flexible-Link using Neural Network

Yang-Su Park\*, Chang-Hwa Kim\*\*, Sun-Chul Kim\*\* *Regular Members*

### 요 약

본 논문에서는 하나의 유연한 관절을 제어하기 위해 신경회로망을 이용한 적응제어기를 제안한다. 신경회로망은 기존 제어시스템의 응답을 개선하기 위해 기존의 PID, LQG제어기와 같이 이용하고 있다. 이와같은 방법으로 로봇 매니퓰레이터와 같이 시스템이 비선형 요소를 포함하고 있거나 모델링 오차가 존재하는 시스템을 제어하는데 이용되고 있다. 신경회로망의 구조는 궤환-오차 학습(Feedback-error Learning)법 알고리듬을 이용하여 설계하였다. 설계된 신경회로망은 입력변수 8개를 가진 8개의 뉴런과, 은닉층에는 20개의 뉴런을 가지고 있으며 1개의 출력을 가지고 있다. 신경회로망과 함께 사용되어지는 궤환 제어기는 선단 위치 제어를 위하여 passive제어기를 이용하였다. 사용한 플랜트는 유연한 관절(Flexible Link)로서 많은 관심을 가지고 연구를 하고 있다. 또한 동적 신경회로망은 원하는 궤적을 추적하고 유연한 관절을 구동하기 위해 제안되었다. 이와 같이 설계된 신경회로망과 궤환 제어기는 유연한 관절의 선단 응답이 매우 개선되었고, 유연한 모드의 진동이 매우 빠르게 감소되었다. passive 제어기  $\zeta$ 의 영향은 정상상태 편차에 많은 영향을 주었으며, 오버 슈트는 개선되었다.

### ABSTRACT

In this thesis, it will be suggested the adaptive controller using a neural network to control a flexible link. The neural network uses a existing PID or LQG controller to improve the system response. This kind of control method applies to design a system controller with nonlinearity or modelling error such as a robot manipulator. The used neural network architecture in this research is the feedback-error learning algorithm. The network has a input layer with 8 input, a hidden layer with 20 neuron and output layer with 1 output. And also, the passive feedback controllers are included to compare the tip position in the neural network. The position and velocity of the nonlinear flexible link tip can be controlled by the designed neural network. It shows a good tip response and very quick decrement of flexible mode vibration. And the suggested neural network can follows a desired trace and derives the flexible link. Therefore the designed neural network and feedback controller can satisfies a flexible link. The  $\zeta$  element of the passive feedback controller has a serious effect on steady state error and imporves a overshoot response.

### I. 서 론

최근 시스템의 모델이 불확실하거나 비선형이 큰 시스템을 모델링하기 위해 신경회로망을 이용한 새로운

제어방법이 활발하게 연구되고 있다. 비선형 시스템에 대한 적응제어는 시스템의 동적 특성을 일부 또는 전부 알고 있다는 가정하에서 궤환 선형화 기법과 비선형 제어이론에 의해 연구되고 있다. 이러한 가정은 많

\* 경남정보대학 제어시스템정보과 조교수(pysk98@nengjung.kit.ac.kr) 정회원,

\*\* 경남정보대학 제어시스템정보과 전임강사(chkim@nengjung.kit.ac.kr, ks Schul@nengjung.kit.ac.kr) 정회원

논문번호 : 98009-0909, 접수일자 : 1998년 9월 9일

은 제한을 받으며 더구나 미지의 비선형 시스템을 제어하는 경우 많은 문제점이 발생하게 된다. 이러한 문제점의 해결을 위해 동적 신경회로망을 이용하면 제어기의 동작영역을 효과적으로 확대할 수 있을 뿐만 아니라 장인성을 향상시킬수 있다. 신경회로망을 기존의 PID, LQG제어기 등과 같이 사용하는 방법이 있으며, 이 방법은 기존 제어시스템의 응답을 개선하는데 이용되고 있는데 주로 로봇 매니퓰레이터와 같이 시스템이 비선형 요소를 포함하고 있거나 모델링 오차가 존재하는 시스템을 제어하는데 이용되고 있다.<sup>[1]</sup> 이와 같이 신경회로망과 기존의 제어기를 함께 이용한 제어시스템은 신경회로망의 오차신호를 케환 제어기의 출력으로 이용하는 케환-오차 학습(Feedback-error Learning)법<sup>[2,3]</sup>으로써 본 논문에서는 이 알고리듬을 이용하였다. 이 신경회로망은 시스템의 순방향 모델을 학습하여 순방향 보상기로 이용되거나 시스템의 비선형성에 의한 오차를 줄이도록 학습되고, 기존의 제어기를 이용함으로써 기존의 선형 정보를 이용할 수 있고 기존의 제어기가 시스템을 일차적으로 제어하기 때문에 신경회로망만으로 학습하기 어려운 비 최소위상 시스템도 제어가 가능하다. 또한 신경회로망이 시스템의 특성을 학습하기 위해 많은 시스템의 입출력 데이터가 필요하나 이 방법에서는 신경회로망이 부분적인 시스템 특성을 학습하면 되는 장점이 있다.

또한 유연한 관절(Flexible Link) 매니퓰레이트는 과거 수년 동안 관심을 가지고 계속 연구되어져 왔다.<sup>[4,5]</sup> 따라서 유연한 관절의 모델링 방법에 따라 여러 가지 형태의 Lagrangian 공식은 시스템을 최적 상태 모드, 정확한 모델화, 시스템의 동적모델과 제어모델 사이의 관계등에 대해 강조되고 있다. 본 논문에서는 유연한 관절에 대한 비선형 시스템의 제어기를 동적 신경회로망을 이용하여 설계하였다. 유연한 관절 제어에 대한 접근을 위해 케환-오차 학습(Feedback-Error Learning)의 신경회로망 구조를 이용하였다. 설계된 신경회로망은 NN1과 NN2로 구성되어 있으며 이 신경회로망에는 입력변수를 8개 가진 8개의 뉴런과 은닉층에는 20개의 뉴런을 가지고, 1개의 출력을 가지고 있다. 또한 케환제어기는 선단 위치 제어를 하기 위하여 passive제어기를 이용하였다. 유연한 관절에 대한 선단 위치 트래킹 제어를 위해 passive제어기에서는  $u = y_c + u_n$ 가 입력 되어진다. 이와 같이 설계된 비선형 제어기를 시뮬레이션을 통해 평가하였으며, 이 결과 선단 위치 응답이 매우 개선되며, 유연한 모드의 진동이 매우 빠르게 감소됨을 입증 하였다.

## II. 제어기 및 신경회로망 설계

### 1. Passive 제어기

일반적으로 Lyapunov함수는 동적 시스템에서 상태량의 정확한 변화를 상세하게 해석함으로써 에너지 관점에 서서히는 쪽이 일반화이다. 즉, 계의 축적에너지 그 자체는 아니지만 이것과 유사한 관계에 있는 함수를 시간의 함수로서 검토한다. 계의 안정을 증명하는데에는 시간을 무한대에 근접시킨는 경우 함수가 0에 가까워지는 것을 증명할 수 있으면 충분하다.

Passivity 이론의 형식은 이러한 것을 공식화한 것이고, 그리고 Lyapunov공식화에서 표현된 블록 또는 부 시스템의 결합을 설명하기 위해 단순한 규칙을 유도한 것이다. 또한 부 케환 제어 목적을 위해 Lyapunov 함수를 구성하여 접근하는데 사용되었다.

우선 선형 또는 비선형으로 된 동적 물리적 시스템을 고려해 보면 다음과 같은 에너지 평형 방정식을 만족시킨다.

$$\frac{d}{dt} [\text{축적에너지}] = [\text{외부전력입력}] + [\text{내부전력발생}] \quad (1)$$

식(1)은 실제로 본드 그라프(bond-graphs)와 같은 모델링 기술의 기초 형태이다. 외부 전력 입력항은 입력  $u$ 와 출력  $y$ 의 스칼라적  $y^T u$ 로서 표현 될 수 있고,  $g_1$ 는 내부전력발생이다. 일반적으로 아래와 같은 형태의 방정식의 시스템을 고려해 보면

$$\dot{V}_1(t) = y_1^T u_1 - g_1(t) \quad (2)$$

여기서  $V_1(t)$ 과  $g_1(t)$ 는 시간의 스칼라 함수이고,  $u_1$ 은 시스템의 입력,  $y_1$ 은 시스템의 출력이다. 예를 들어 입력  $u_1(t)$ 와 출력  $y_1(t)$ 가 임의의 시스템에 주어졌을 때, 내부전력발생은 거의 없으므로  $g_1(t) \approx 0$ 이고,  $V_1(t) = \int_0^t y_1^T(r) u_1(r) dr$ 이다. 그리고  $V_1(t)$ 와  $g_1(t)$ 은 물리적 특징을 가지며, 또한 유사한 시스템의 결합을 통하여 그것들이 전달되어지는 방법에 대해 특히 관심을 가져야 한다. 함수  $V_1 + V_2$ 는 하한(lower) 유한이라고 가정하면 아래와 같이 된다. 만약  $\forall t \geq 0, g_1(t) + g_2(t) \geq 0$ 이면 함수  $V_1 + V_2$ 는 상한(upper) 유한이면

$$\int_0^\infty [g_1(t) + g_2(t)] dt < \infty \quad (3)$$

만약 부가적으로 함수  $g_1 + g_2$ 가 연속적이라면,  $t \rightarrow \infty$ 에서  $[g_1(t) + g_2(t)] \rightarrow 0$ 이며,  $g_1(t) + g_2(t)$ 이 부(-)가 아니고 연속적이면 이 값은  $t \rightarrow \infty$ 에서 0으로 된다. 위 결과에서  $V_1 + V_2$ 의 확실한 표현이 필요 없다. 일반적으로  $V_1 + V_2$  또는  $g_1 + g_2$ 의 부호에 대한 어떤 가정이 필요 없다는 것이다. 여기서 다음과 같이 표현을 할 수 있다. 만약  $V_1 + V_2$ 가  $t \rightarrow \infty$ 에서 유한이고, 그리고  $g_1 + g_2$ 가 연속적이라면  $t \rightarrow \infty$ 에서  $[g_1(t) + g_2(t)] \rightarrow 0$ 이다. 하한(lower) 유한과  $g_1 \geq 0$ 로서 식(2)을 증명하는 시스템은 정(+) 또는  $u_1$ 과  $y_1$  사이에서 passive mapping이라고 말한다. 더구나 정(+)의 시스템이  $\int_0^\infty y_1^T(t) u_1(t) dt \neq 0 \Rightarrow \int_0^\infty g_1(t) dt > 0$ 이 되면 소산적(dissipative)이라고 말한다. 제어기 설계방법을 위해 다음의 정의를 고려한다.

정의 :  $L_2$ 는 모든 측정 가능한 함수들의 집합이다.

$f : R_+ \rightarrow R$ 이고

$$\|f(t)\|_2 = \left\| \int_0^t |f(\tau)|^2 d\tau \right\|^{1/2} < \infty \quad (4)$$

이다.

정의 : 만약,  $u \in L_2$ 가  $y \in L_2$ 를 포함하면 시스템  $y = G(u)$ 는  $L_2$ -stable이다.

$$\|y\|_2 \leq \gamma \|u\|_2 \quad (5)$$

이라고 했을 때 시스템 이득(gain)은  $\gamma$ 이다.

passivity 이론: 그림 1과 같은 폐루프 시스템에서, 보상기는 유한한 이득(gain)값을 가지는 strictly passive이고 플랜트는 passive라고 간주해 보자. 그리고 폐루프 시스템은  $L_2$ -stable라고 한다.

미분된 출력에서 입력까지의 전달함수가 passive이기 때문에 유한한 gain값을 가지는 strictly passive 제어기는 시스템을 안정하게 만들 것이다. 이 경우 가장 간단한 예로 gain  $k$ 를 들 수 있다. 출력  $y(t)$ 에서 입력  $T(t)$ 까지의 전달함수는 전달함수  $ks$ 을 가지는

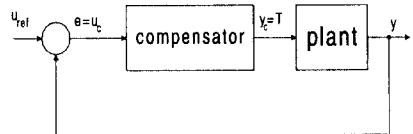


그림 1. 폐루프 시스템  
Fig. 1 Closed-loop system.

제어기에 의해 안정화되어질 수 있다는 의미이다. 이것이 단순한 미분 피드백(derivative feedback)이다. 이런 제어기는 매우 양호한 step응답을 가진다는 것을 시뮬레이션을 통해 쉽게 알 수 있다. 여기서, 최대 입력 토오크의 크기는  $k$ 이다. 앞에서 설명한 바와 같이, 모든 mode가 모델에 포함된다면 이 모델은 passive하지 않을 것이다. 따라서 더 높은 차수의 mode는 제거되어야 된다. 그렇게 하기 위한 가장 간단한 방법은 제어기를 다음과 같이 선택해야 한다.

$$C(s) = \frac{ks}{\frac{s}{\omega_f} + 1} \quad (6)$$

여기서,  $\omega_f$ 는 모델에서 가장 마지막의 공진 주파수보다는 높게 되어야 한다. 그러나, 첫 번째로 무시되는 모드보다는 낮아야 한다. 순수한 미분기가 구현될 수 없기 때문에 식(6)의 형태의 보상기는 어디에서나 사용이 된다. 이 제어기의 step입력에 대한 정상상태 오차는 쉽게 zero로 된다는 것을 알 수 있다. 따라서, 가장 간단한 아날로그 제어기가 elastic deformation을 제어하는데 사용이 되어질 수가 있다. 지금, 이런 제어기는 passive로써 알려진 hub velocity feedback이 아니라는 것을 알아야 한다. 변수  $y(t)$ 는 elastic deformation  $\omega(t)$ 를 포함한다. 만약, hub velocity feedback을 얻기 위해  $y(t)$ 로부터  $\omega(t)$ 를 제거한다면 상당한 진동이 초래된다. net tip deflection과 토오크 사이의 전달함수에 식(6)의 제어기를 부착하면 불안정성이 초래된다는 것을 쉽게 알 수 있다. 이런 점에서 디지털 제어기를 사용해서 이런 제어 방법을 쉽게 구현할 수 있다는 것을 설명하는 것은 관심거리가 될 것이다. 또한 외란에 더욱더 강인한 제어기를 만들려는 변화들이 조금씩 일어날 것이다. 디지털 보상기의 입력은  $u_c$ 로, 출력은  $y_c$ 로 설계되어질 것이다. 본 논문에서는 샘플링시간  $T_s = 5$  [msec]를 이용한다. 이것은 다음과 같은 형태의 제어기를 가진다.

$$y_c(z) = k\omega_f \frac{(z-1)u_c(z)}{z-1 + \omega_f T_s} \quad (7)$$

만약, 이런 제어기가 사용된다면 약간의 문제가 있다. 그림 3의 출력  $y$ 는 때때로 외란의 결과로써 발생하는 변화를 막을 수도 있다. 어느 점에서 출력  $y$ 가 샘플링 주기동안 충분한 변화를 가지지 않는다면  $u_{ref}$ 가 상수이기 때문에  $u_c$ 에 들어가는 입력은 샘플링 주기동안에 변화하지 않은 상태로 될 것이다. 식(7)은  $y_c$ 는 변화하지 않는다는 것으로 하였다. 이것은 전체 시스템이 큰 정상상태 오차에서 이동(moving)과 결과를 멈추게 하는 요인이 될 수도 있다. 그런 외란들에 더욱더 강인한 제어기를 만들 수 있는 두 가지 개선방안이 있다. 첫째로, 작은 값으로 비례 피드백 인자  $\zeta$ 를 다음과 같이 추가하는 것이다.

$$y_c(z) = \left[ k\omega_f \frac{(z-1)u(z)}{z-1 + \omega_f T_s} + \zeta \right] u_c(z) \quad (8)$$

이것은 전달함수의 정상상태 오차에 대해 큰 효과를 가진다. 두 번째 변형방법은  $u_{ref}$ 를 다음과 같은 형태로 바꾸는 것이다.

$$u_{ref}(z) = \frac{z}{z-1} - \frac{z}{z-a} \quad (9)$$

이렇게 변형을 함으로써  $y$ 가 샘플링 주기동안 비록 상수가 될지라도 제어기는 변형된  $u_{ref}$ 에 의해 여전히 구동이 되어지는 효과를 얻을 수 있다. 또 다른 효과는 step 응답이 부드러워진다는 것과 최대 입력 토오크가 감소되어진다는 것이다. 이와 같은 방법에 의하여 궤환 제어기를 이용하였다.

## 2. 신경회로망 설계

본 논문에서는 궤환 제어기의 출력을 신경회로망의 교사신호로 이용하였다. 신경회로망의 궤환-오차 학습 방법의 하나인 역동적 모델 학습(IDML : Inverse Dynamic Model Learning)이라 불리는 제어시스템 구조를 그림 2에서 나타내었다.

이 구조에서 전통적 궤환 제어기(CFC : Conventional Feedback Controller)는 학습 기간 동안 점근적 안정성을 보장하기 위한 보통의 궤환 제어기로서 사용되어지기도 하고, 제어된 시스템 응답에 대한 기준 모델로 사용되어진다.

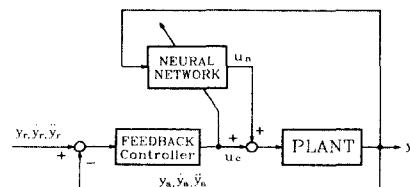


그림 2. 역동적 모델 학습 구조

Fig. 2 Structure of Inverse Dynamic Model Learning(IDML).

CFC의 출력은 신경회로망에 오차 신호를 공급하고, 신경회로망은 또한 보통의 입력인  $\dot{\theta}, \delta, \ddot{\delta}, \ddot{y}_a$ 를 받는다. 신경회로망의 출력은  $u_n = \Phi(\dot{\theta}, \delta, \ddot{\delta}, \ddot{y}_a, w)$ 이고  $w$ 는 신경회로망의 가중치 행렬이다. 궤환 오차 학습 구조의 학습 규칙은  $\dot{w} = \eta \frac{\partial \Phi}{\partial w} u_c$ 이고  $\eta$ 는 학습률이다. 학습 후에 신경회로망은 임의적으로 제어된 시스템에 근접한 역동적 모델을 얻는다.

본 논문에서는 그림 2와 같은 구조를 이용한 2차 학습 구조의 배치로서 비선형 레귤레이터 학습(NRL : Nonlinear Regulator Learing)방법으로 설계하였다. 설계된 구조를 그림 3에서 나타내었다.

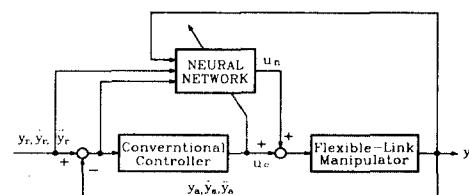


그림 3. 비선형 레귤레이터 학습 구조

Fig. 3 Structure of the Nonlinear Regulator Learing(NRL).

제안한 구조에서 신경회로망의 내부구조는 NN1과 NN2의 구조로 되어있다. 신경회로망의 내부 구조를 그림 4에 나타내었다.

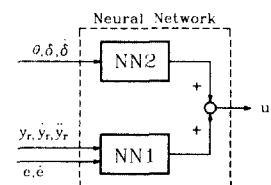


그림 4. 신경회로망 구조

Fig. 4 Structure of Neural Network.

설계된 신경회로망에서 NN1은 feedforward 제어기로서 원하는 응답을 얻기 위해 기준궤도(위치, 속도, 가속도)와 오차  $e, \dot{e}$ 가 입력되어 진다. 또한 NN2에는  $\theta, \dot{\theta}, \ddot{\theta}$ 가 입력되어진다.

### 3. 제어시스템 및 플랜트 설계

본 논문에서는 DD Motor(Direct Drive Motor)의 회전자의 중심축에 연결된 가는 비임(beam)의 선단에 관성을 가지고 있는 유연한 관절을 그림 5에 나타내었다.

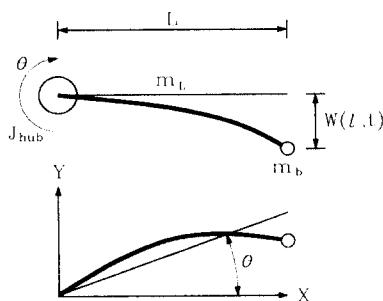


그림 5. 단일 유연한 관절  
Fig. 5 Single Flexible Link.

여기서 관절의 파라미터는 다음과 같다.

$x$ : 관절의 길이에 따른 거리[m]

$L$ : 관절의 길이[m]

$w$ : 관절의 휨

$J_{hub}$ : 중심관성[kg · m<sup>2</sup>]

관절은 초기에 직선적이고 Euler-Bernoulli 관절이론을 반복한다고 가정한다. 관절의 변형된 측면도에 따른 이동점은 x, y 좌표의 원주와 반지름에 의하여 설명되어 진다.

그림 5에서  $y$ 는 중심회전각  $\theta$ , 관절의 이동 굴절성  $w$ 와 매우 밀접한 관계가 있으며 다음식과 같이 표현된다.

$$y(x, t) = w(x, t) + (x + r) \theta(t) \quad (10)$$

유연한 관절 제어기에 관한 동적 방정식을 다음과 같이 표현된다.

$$M(\delta) \begin{bmatrix} \ddot{\theta} \\ \ddot{\delta} \end{bmatrix} + \begin{bmatrix} h_1(\dot{\theta}, \delta, \dot{\delta}) + f_c \\ h_2(\dot{\theta}, \delta) + K\delta \end{bmatrix} = \begin{bmatrix} u \\ 0 \end{bmatrix} \quad (11)$$

식(11)에서  $\theta$ 는 중심각,  $\delta$ 는 휨 변수들의  $n \times 1$  벡터,  $h_1$ 과  $h_2$ 는 Coriolis와 원심력으로 인한 항이고,  $M$ 는 양으로 정의된 질량 행렬이고,  $K$ 는 양으로 정의된 강건성 행렬이고,  $u$ 는 입력 토오크이다.  $f_c$ 는 다음과 같이 표현된다.

$$f_c = c_1 \left( \frac{2}{1 + e^{-a\theta}} - 1 \right), \quad C_1 > 0, \quad a > 0. \quad (12)$$

본 논문에서 사용된  $f_c$ 는 비임의 고유주파수이다. 여기서  $f_c = 1.386[\text{Hz}]$ 인 비임을 사용하였으며, 이득  $G$ 는 2이다. 사용된 모터 토오크  $K_t$ 는  $0.17[\text{Nm/Amp}]$ 이며, 모터 위에 설치된 카메라 무게 등을 포함한 관성 모우멘트  $J_L$ 과 선단 관성 모우멘트  $J_b$ 는 다음과 같이 주어진다.

$$J_L = \frac{1}{3} m_L \rho L^2 \quad (13)$$

$$J_b = m_b L^2 \quad (14)$$

여기서  $\rho$ 는 재질밀도로서  $\rho = 23 * 10^{-3}[\text{N/m}^2]$

$L$ 은 관절의 길이[m]

$m_L$ 은 모터에 설치되어 있는 질량[kg]

$m_b$ 은 선단위치의 질량[kg]

따라서 전체 관성 모우멘트는

$$J_{Load} = J_L + J_b \quad (15)$$

모터의 hub에 대한 관성 모우멘트는

$$J_{hub} = J_m + J_b \quad (16)$$

관절의 강성 값 KSTIFF는

$$K_{STIFF} = (2\pi f_c)^2 (J_m + J_b) \quad (17)$$

따라서 상태방정식과 출력방정식은 (11)에서 (17)으로부터 다음과 같이 주어진다.

$$\dot{x} = Ax + BV \quad (18)$$

$$y = Cx \quad (19)$$

여기서

$$A = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & \frac{K_{STIFF}}{J_{hub}} & 0 & 0 \\ 0 & \frac{K_{STIFF}(J_{Load} + J_{hub})}{J_{hub}J_{Load}} & 0 & 0 \end{bmatrix},$$

$$B = \begin{bmatrix} 0 & 0 & -\frac{1}{J_{hub}} & -\frac{1}{J_{hub}} \end{bmatrix}^T$$

$$C = [1 \ 0 \ 1 \ 0], \quad x = \begin{bmatrix} \theta & 0 & \frac{W(l,t)}{l} & 0 \end{bmatrix}^T$$

이다.

여기서  $V$ 는 서보 전력증폭기에 인가되는 전압이다.

유연한 관절의 선단 위치는  $y_a = \theta + \frac{W(l,t)}{l}$  이고  $W(l,t)$ 은 선단에서의 탄력적 힘이고,  $l$ 는 관절의 길이이다.

### III. 시뮬레이션

본 논문에서는 설계된 궤환-오차 학습방법의 신경회로망을 이용하여 passive제어기를 궤환 제어기로 시뮬레이션을 하였다. 그림 6은 시뮬레이션 결과이다.



(a) 학습 진행 중 상태

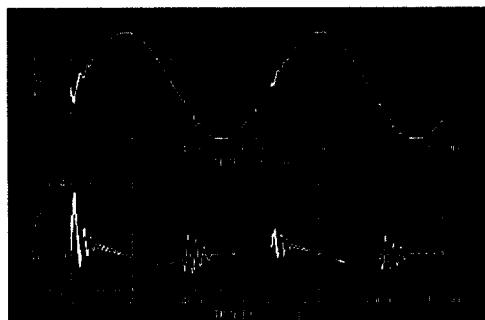
(b) 오 차

그림 6. 임의적인 초기조건에 의한 학습, 오차  
Fig. 6 Learning and error for random initial condition.  
( $y_r = \sin(t)$ )

그림 6은 궤환 제어기를 passive제어기로 하였을 때

$\sin$ 함수를 입력으로 하여 설계한 신경회로망을 학습을 하였다. 학습률  $\eta = 0.5$ 로 하였으며, 샘플링시간을 5 [msec]로 하였다. 그림 6의(a)는 입력 함수를  $y_r = \sin(t)$ 의 값을 입력으로 하여 처음 1회 학습을 한 상태를 나타내었다. 그림 6에서와 같이 처음 부분에서는 아주 큰 값을 나타내고 있으나 가중치의 학습으로 인하여 마지막부분에서 학습된 특성이 좋은 것을 알 수 있다. 그림 6(b)의 학습오차를 보여주고 있다. 초기상태의 가중치를 바꾸어 주기 위하여 학습을 계속하였다. 그림 7(a)와 같은 결과를 얻을 수가 있었다.

학습된 상태에서도 처음 상태에서는 오차가 개선됨을 확인할 수 있다. 그림 7의 마지막 부분에서는 거의 정상상태에 도달하고 있으므로 이때의 가중치를 초기값으로 설정하였다. 또한 그림 8은  $y_r = 1$ 의 스텝 입력을 주었을 때 결과를 나타내었다.



(a) 학습 된 상태 (b) 오 차

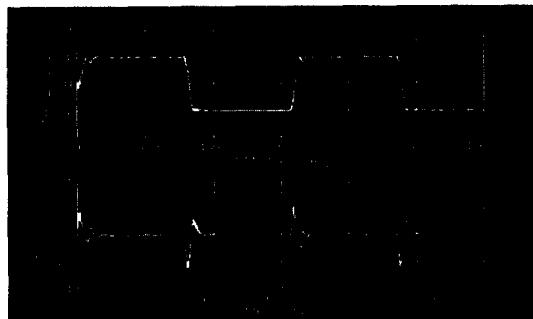
그림 7. 임의적인 초기조건에 의한 학습된 상태  
Fig. 7 Learning and error for random initial condition.  
( $y_r = \sin(t)$ )



(a) 학습 진행 중 상태 (b) 오 차

그림 8. 임의적인 초기조건에 의한 학습, 오차  
Fig. 8 Learning and error for random initial condition. ( $y_r = 1$ )

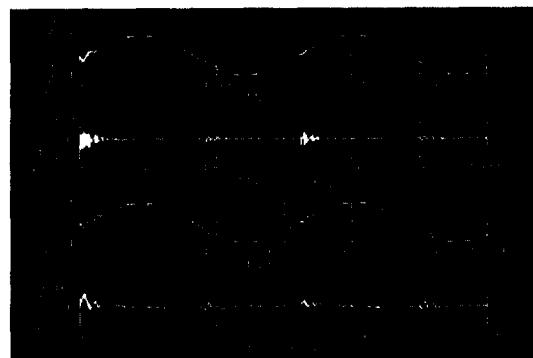
그림 8은  $y_r = 1$ 을 스텝 입력으로 하여 설계한 신경회로망을 학습시켰다. 학습률  $\eta = 0.5$ 로 하였다. 그림 8은  $y_r = 1$ 의 값을 입력으로 하여 처음으로 한번 학습을 한 상태를 나타내었다. 그림 8(a)에서와 같이 처음부분에서는 아주 큰 값을 나타내고 있으나 가중치의 학습으로 인하여 마지막부분에서는 좋은 특성을 볼 수 있다. 그림 8(b)의 학습오차를 보여주고 있다. 반복 학습을 함으로서 그림 9과 같은 결과를 얻을 수가 있었다.



(a) 학습 된 상태 (b) 오 차

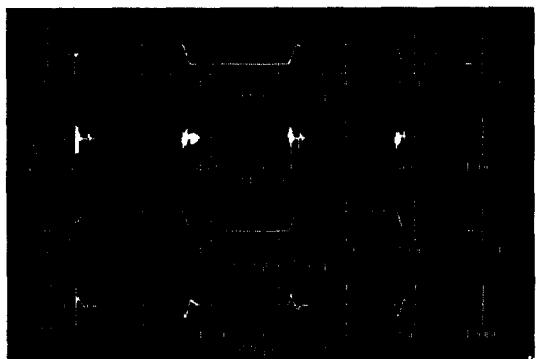
그림 9. 임의적인 초기조건에 의한 학습된 상태  
Fig. 9 Learning and error for random initial condition.  
( $y_r = 1$ )

그림 9(a)에서 보듯이 처음 상태에서는 오차가 있는 것을 확인할 수 있다. 그러나 학습을 계속함으로서 좋은 응답을 얻을 수 있음을 알 수 있다. 이와 같은



(a) Total-Angle (b) Tip-Angle (c) Position (d) Error

그림 10. 제어시스템의 응답 ( $y_r = \sin(t)$ )  
Fig. 10 Response of control system ( $y_r = \sin(t)$ )



(a) Total-Angle (b) Tip-Angle (c) Position (d) Error

그림 11. 제어시스템의 응답 ( $y_r = 1$ )  
Fig. 11 Response of control system ( $y_r = 1$ )

방법으로 가중치를 학습한 후 가중치를 초기값으로 하여 궤환 제어기의 출력을 교사신호로만 사용하여 유연한 관절을 제어하여 보았다. 그림 10와 그림 11과 같은 원하는 입력신호에 대한 각 시스템 응답을 나타내었다.

#### IV. 결 론

본 논문에서는 신경회로망과 passive제어기를 사용한 유연한 관절의 선단 위치 제어에 대하여 연구하였다. 시뮬레이션에서 궤환 제어기를 passive제어기로 이용하여 검토하였으며, 선단위치 제어를 위하여 유연한 관절의 선단 위치는  $y_a = \theta + \frac{W(l, t)}{l}$ 이고  $W(l, t)$

는 선단에서의 탄력적 휨이고,  $l$ 는 관절의 길이로 하였다. 시뮬레이션 결과는 신경회로망을 궤환-오차 학습을 사용하므로써 passive 궤환 제어기에서 높은 이득을 사용함으로써 마찰 효과가 극복되는 것이 관찰되었고, 과도응답에 대한 좋은 특성으로 선단위치의 떨림이 개선됨을 알 수 있었으며,  $y$ 가 샘플링 주기동안 비록 상수가 될지라도 제어기는 변형된  $u_{ref}$ 에 의해 여전히 구동이 되어지는 효과를 얻을 수 있다. 또 다른 효과는 step 응답이 부드러워진다는 것과 최대 입력토오크가 감소되어진다는 것이다.

#### 참 고 문 헌

- N. V. Bhat, P. A. Mindelman, T. McAvoy, and N.

- S. Wang, "Modeling chemical process system via neural computation", *IEEE Contr. Syst., Mag.*, Vol. 10, pp. 24-31, 1990.
2. Mayamoto, H., Kawato, M., Setoyama, T. and Suzuki, R., "Feedback-Error-Learning Neural Network for Trajectory Control of a Robotic Manipulator", *Neural Network*, vol. 1, pp. 251-265, 1988.
3. F. C. Chen, "Back-propagation neural networks for nonlinear self-tuning adaptive control," *IEEE Contr. syst. Mag.*, Vol. 10, pp. 44-48, Apr. 1990.
4. Donne, J. D. and Ozguner, U., "Neural Control of A Flexible-Link Manipulator", *Proceeding of IEEE Int. Conf. on Neural Networks*, pp. 2327-2332, 1993.
5. Wang,D. and Vidyasagar, M., "Transfer Function for Single Flexible Link", *Proceeding of IEEE Int. Conf. on Robotics and Automation*, pp. 1042-1047, 1989.
6. M. Kawato, "A hierarchical model for voluntary movement and its application to robotics", *IEEE Contr. Syst. Mag.*, Vol. 10, pp. 18-23, 1990.
7. Cheng, W. and Wen, J. T., "Controller for the Tracking Control of Flexible Arms", *Proceeding of IEEE Int. Conf. on Neural Networks*, pp. 749-754, 1993.
8. 박양수, 박윤명, 박영식, 이형기, 최부귀, "신경회로망을 이용한 선단위치 트래킹제어", '97 Proceedings of the 12 th, Korea Automatic Control Conference, 제2권 pp.1225-1228, 1997.



박 양 수(Yang Su Park) 정회원  
1959년 2월 17일생  
1987년 : 부산공업대학 전자공학과  
졸업  
1989년 : 동아대학교 전자공학과 공  
학석사  
1998년 : 동아대학교 전자공학과 공  
학박사

현재 : 경남정보대학 제어시스템정보과 조교수



김 창 화(Chang Hwa Kim) 정회원  
1965년 12월 17일생  
1991년 : 부산수산대학교 기관공학  
과 졸업  
1993년 : 부산수산대학교 대학원 기  
관공학과 공학석사(제어  
공학)  
1997년 : 부경대학교 대학원 제어기  
계공학과 공학박사(제어  
공학)

현재 : 경남정보대학 제어시스템정보과 전임강사



김 순 칠(Sun Chul Kim) 정회원  
1962년 2월 20일생  
1984년 : 영남대학교 기계공학과 졸  
업  
1987년 : 영남대학교 대학원 기계공  
학과 공학석사  
1987년 : 삼성중공업(주)입사  
1989년 ~ 1992년 : 삼성중공업(주)  
연구소 주임연구원

1993년 ~ 1997년 : 삼성중공업(주) 연구소 선임연구원

현재 : 경남정보대학 제어시스템정보과 전임강사