

論文95-32B-12-14

신경 회로망을 이용한 최적 가변구조 제어기의 설계에 관한 연구

(A Study on the Design of Optimal Variable Structure Controller using Multilayer Neural Inverse Identifier)

李敏鎬*, 崔炳載**, 李壽永**, 朴哲薰**, 金炳國**

(Minho Lee, Byung-Jae Choi, Soo-Young Lee, Cheol Hoon Park, and Byung Kook Kim)

요 약

이 논문에서는 오차 역전달 학습 알고리즘을 이용하는 다층 구조 신경회로망을 사용한 최적 가변 구조 제어기 설계 방법이 제안된다. 시스템에 대한 외부 잡음이나 시스템 변수 변동 등에 대한 관측기 역할로서 다층 구조 신경회로망이 시스템의 역 특성을 동정 화한다. 제안한 방법은 시스템의 불확실성의 크기에 대한 완벽한 지식 없이도 가변구조 제어기를 설계할 수 있을 뿐만 아니라, 제어 입력의 떨림 크기를 크게 완화시킬 수 있다. 또한, 최적 슬라이딩 라인의 설계 방법과 도달 위상 문제를 해결하기 위해 다층 구조 고차 신경회로망을 이용한 가변 구조 제어기 설계에 적분기도 도입한다. 컴퓨터를 이용한 시뮬레이션 결과에서 보듯이 제안한 방법이 제어 입력의 떨림 크기를 크게 줄이면서 효과적인 제어 결과를 나타냄을 알 수 있다.

Abstract

In this paper, an optimal variable structure controller with a multilayer neural inverse identifier is proposed. A multilayer neural network with error back propagation learning algorithm is used for constructing the neural inverse identifier which is an observer of the external disturbances and the parameter variations of the system. The variable structure controller with the multilayer neural inverse identifier not only needs a small part of a priori knowledge of the bounds of external disturbances and parameter variations but also alleviates the chattering magnitude of the control input. Also, an optimal sliding line is designed by the optimal linear regulator technique and an integrator is introduced for solving the reaching phase problem. Computer simulation results show that the proposed approach gives the effective control results by reducing the chattering magnitude of control input.

I. 서 론

가변구조 제어기는 과도응답 시간 동안에 미리 정한

* 正會員, 韓國海洋大學校 電氣工學科

(Department of Electrical Engineering)

** 正會員, 韓國科學技術院 電氣 및 電子工學科

(Department of Electrical Engineering Korea Advanced Institute of Science and Technology)

接受日字: 1995年1月16日, 수정완료일: 1995年12月4日

알고리즘이나 시스템 구조 변경 규칙에 따라 시스템의 구조를 변화시키는 강력한 비선형 제어기이다^[1,2]. 이 제어 방법은 시스템의 과도응답 특성이 원하는 성능을 만족하도록 제어기를 설계할 수 있을 뿐만 아니라, 시스템의 모델에 대한 정확한 지식 없이도 제어기 설계가 가능하며, 외부 잡음에도 강건한 특성을 갖고 있다^[1,2]. 그러나 가변구조 제어기는 시스템의 불확실성을 보상하기 위하여 미리 결정된 슬라이딩 표면 부근에서 고주파수의 입력값(떨림 현상)을 필요로 하며, 더욱이

시스템의 불확실성 정도에 대한 경계치(bound)를 미리 알고 있어야 한다는 결점이 있다. 특히, 떨림 현상(chattering)은 매우 높은 고주파수 제어 입력을 의미하므로 실제로 바람직하지 않은 현상으로서, 전체 시스템에 예상치 못한 고주파수 동특성을 야기시킬 수 있을 뿐만 아니라^[1], 고주파수 제어 입력 값을 구현하기 위해서는 이론적으로 무한대의 주파수를 갖는 스위칭 소자를 필요로 하는 문제점이 있다^[1,2]. 이와 같은 가변구조 제어기의 떨림 현상을 해결하기 위한 연구가 많은 사람들에 의해 진행되어 왔다. 그 중의 한 방법으로 연속 제어 입력을 사용하는 슬라이딩 라인의 경계층(boundary layer) 접근 방법^[3]은 정상 상태 오차를 유발할 수 있기 때문에 정상 상태 오차와 제어 입력의 떨림 크기 사이에 상호 절충을 필요로 한다^[1,2,3]. 또 다른 방법으로는 적응 떨림 완화(adaptive chattering alleviation) 방법이 있는데 이는 시스템의 동특성이 느리게 변하는 경우에만 적용할 수 있다는 결점이 있다^[4].

이 논문에서는 정상 상태 오차의 손실을 줄이면서 제어 입력의 떨림 크기를 완화시킬 수 있는 새로운 가변구조 제어기를 제안한다. 제어 입력의 떨림 크기는 외부 잡음의 크기나 시스템 매개변수의 변동 정도 등과 같은 시스템의 모델링 과정에 포함되지 않은 미지 정보의 크기에 직접적인 관련이 있으므로, 어떤 방법에 의해 시스템의 미지 정보를 더 얻을 수만 있다면 이를 제어기의 추가 입력으로 이용함으로써 가변 구조 제어기의 떨림 입력 크기를 완화시킬 수 있을 것으로 기대할 수 있다^[1,2]. 한편, 인공 신경회로망은 대규모 병렬 처리, 많은 자유도, 적응학습 등의 장점을 가지고 있을 뿐만 아니라, 임의의 함수를 근사화할 수 있으며 일반화할 수 있으므로 시스템의 미지 정보를 찾는 데 적합한 방법을 제공할 수 있다^[5,6]. 이 논문에서는 오차 역전달 학습 알고리즘을 이용하는 다층 구조 고차 신경회로망^[7,8]을 이용하여 시스템의 미지 정보를 찾아 가변 구조 제어기의 추가 입력으로 이용하는 방법을 제시한다. 즉, 외부의 외란이나 시스템의 매개변수 변동등에 관한 관측기로서 다층 구조 신경회로망을 사용한다. 그 결과 가변 구조 제어기 설계에 필요한 각종 외란의 경계치에 대한 완벽한 사전 지식 없이도 제어 입력의 떨림 크기를 크게 줄일 수 있는 효과적인 가변 구조 제어기를 설계할 수 있다. 또한, 가변구조 제어기의 도달 위상(reaching phase) 문제를 해결하기 위

해 적분기를 도입하여 슬라이딩 표면을 설계하고^[9], 슬라이딩 라인을 위한 계수는 주어진 성능 지수(performance index) 함수를 최소화하는 슬라이딩 라인을 가질 수 있도록 최적 선형 조절(optimal linear regulator) 방법에 의해 결정한다^[2].

다음 장에서 신경회로망 역근사화기(inverse identifier)를 갖는 최적 가변구조 제어기에 대해 설명하고, 3장에서는 간단한 예제를 통한 컴퓨터 시뮬레이션 결과를 보여주고, 4장에서 결론을 맺도록 구성한다.

II. 다층 구조 신경 회로망을 갖는 가변 구조 제어기

가변구조 제어를 위한 시스템은 다음 (1)식과 (2)식으로 표현되어 질 수 있다.

$$\dot{x}_i = x_{i+1}, \quad i=1, \dots, n-1 \quad (1)$$

$$\dot{x}_n = -\sum_{i=1}^n a_i x_i + bu - f \quad (2)$$

여기서 x_i 는 시스템의 상태 변수를 나타내고, a_i 와 b 는 i 번째 시스템 매개변수를 나타낸다. 그리고 f 는 모델링 과정에서 고려되지 않은 시스템의 미지 정보나 외부 잡음을 나타내고, u 는 식 (3)과 같은 선형 제어 함수이다.

$$u = \begin{cases} u^+(x, t) & \text{if } \sigma > 0 \\ u^-(x, t) & \text{if } \sigma < 0 \end{cases} \quad (3)$$

여기서 σ 는 식 (4)로 표현되는 스위칭 함수이다.

$$\sigma = \sum_{i=1}^n c_i x_i \quad c_n = 1 \quad (4)$$

먼저, 다음절에서 신경회로망 사용을 고려하지 않았을 때의 가변구조 제어기 설계에 대하여 설명하고, 2.2절에서는 제어 입력의 떨림 크기를 감소시키기 위하여 다층구조 고차 신경회로망을 사용 했을 때의 경우에 대하여 설명하였다. 2.3절에서는 최적 슬라이딩 라인의 설계에 대하여 논의하였고, 2.4절에서는 도달 위상 문제를 해결하기 위해 적분기를 도입한 방법에 대하여 설명하였다.

1. 신경회로망을 사용하지 않은 가변구조 제어기
식(1)과 식(4)로부터 슬라이딩 라인의 미분은 다음 식 (5)와 같다.

$$\dot{\sigma} = \sum_{i=1}^{n-1} c_i x_{i+1} - \sum_{i=1}^n a_i x_i + bu - f \quad (5)$$

여기서 a_i 와 b 를 다음 식 (6)과 같이 가정하면,

$$\begin{aligned} a_i &= a_i^0 + \Delta a_i \\ b &= b^0 + \Delta b \end{aligned} \quad (6)$$

a_i^0 와 b^0 는 각각 시스템의 매개변수 a_i 와 b 에 대하여 정확히 알고 있는 값이며, Δa_i 와 Δb 는 이미 알고 있는 값으로부터의 변동 값을 나타낸다. 그리고, u 는 식 (7)로 표현되는 제어입력이다.

$$u = u_{eq} + \Delta u \quad (7)$$

여기서 u_{eq} 는 등가 제어 입력을 나타내며, $f=0$, $a_i = a_i^0$, 그리고 $b = b^0$ 를 만족하는 경우에 $\dot{\sigma}=0$ 으로부터 구한 제어 입력이다. 즉,

$$\begin{aligned} u_{eq} &= \frac{-\sum_{i=1}^n c_{i-1} x_i + \sum_{i=1}^n a_i^0 x_i}{b^0} \\ &= \frac{-\sum_{i=1}^n (c_{i-1} - a_i^0) x_i}{b^0} \end{aligned} \quad (8)$$

함수 Δu 는 시스템 변수의 불확실성과 외부 잡음의 영향을 제거 하기 위한 제어 입력으로 다음 식 (9)로 표현된다.

$$\Delta u = \sum_{i=1}^n \psi_i x_i + \phi \quad (9)$$

여기서

$$\begin{aligned} \psi_i &= \begin{cases} \alpha_i & x_i \sigma > 0 \\ \beta_i & x_i \sigma < 0 \end{cases} \\ \phi &= \begin{cases} \gamma & \sigma > 0 \\ \delta & \sigma < 0 \end{cases} \end{aligned} \quad (10)$$

다음 식 (11)의 슬라이딩 모드 존재와 도달 조건으로부터^[11], 식 (12)를 얻을 수 있다.

$$\sigma \dot{\sigma} < 0 \quad (11)$$

$$\sum_{i=1}^n \left(-\Delta a_i + \frac{\Delta b a_i^0}{b^0} - \frac{\Delta b c_{i-1}}{b^0} + b \psi_i \right) x_i \sigma + (b \phi - f) \sigma < 0 \quad (12)$$

식 (12)로부터 식 (10)은 다음의 식 (13)과 (14)로 구해진다.

$$\psi_i = \begin{cases} \alpha_i \left(\Delta a_i - \frac{\Delta b a_i^0}{b^0} + \frac{\Delta b c_{i-1}}{b^0} \right) / b & \text{for } x_i \sigma > 0 \\ \beta_i \left(\Delta a_i - \frac{\Delta b a_i^0}{b^0} + \frac{\Delta b c_{i-1}}{b^0} \right) / b & \text{for } x_i \sigma < 0 \end{cases} \quad (13)$$

$$\phi = \begin{cases} \gamma < f/b & \sigma > 0 \\ \delta > f/b & \sigma < 0 \end{cases} \quad (14)$$

식 (13)으로부터 알 수 있는 바와 같이 가변구조 제어기의 떨림 입력 크기는 시스템의 미지 정보의 크기나 외부 잡음의 크기에 의해 결정됨을 알 수 있다.

2. 다층구조 신경회로망을 갖는 가변 구조 제어기

식 (1)의 시스템을 이미 알고 있는 부분과 모르는 부분으로 나누어 생각하면 다음 식 (15)와 같이 쓸 수 있다.

$$\begin{aligned} \dot{x}_i &= x_{i+1} \\ \dot{x}_n &= -\sum_{i=1}^n a_i^0 x_i + b^0 u - G \end{aligned} \quad (15)$$

$$\text{여기서 } G = \sum_{i=1}^n \Delta a_i x_i - \Delta b u + f$$

식 (13)과 (14)에서 보듯이 떨림 제어 입력의 크기는 시스템의 매개변수 변동이나 외부 잡음과 같은 알지 못하는 동특성과 관련이 있다. 따라서, 식 (15)에서 알지 못하는 정보인 G 를 어떤 방법에 의해서 찾아낼 수만 있다면, 제어 입력의 떨림 크기는 상당히 줄어들 수 있을 것으로 기대된다. 앞에서 설명했듯이 신경 회로망은 충분한 입출력 데이터로부터 임의의 함수를 근사화할 수 있으므로 제어 입력의 떨림 크기를 줄이기 위한 부가적인 제어 입력을 만드는 데에 이용될 수 있다. 즉, 시스템의 불확실한 정보를 얻기 위한 제어 입력을 만들기 위하여 그림 1과 같이 다층 구조 신경 회로망으로 역근사화기를 구성한다. 시스템에 주어진 외부 입력 값이 신경회로망 역근사화기의 출력 u_n 과 이미 알고 있는 동특성으로부터 구한 u_{norm} 에 의한 출력 값의 합과 같도록 Pattern type 오차 역전달 학습 알고리즘에 의해 신경회로망의 연결 강도를 학습시킨다^[7,8]. 이때, 시스템의 역특성을 학습하기 위한 다층 구조 신경회로망의 입력으로는 주어진 입력 값에 대해 얻은 시스템 출력 값과 출력 값의 지연값, 그리고 이 값들의 곱으로 이루어지는 고차 항들을 부가적으로 이용한다. 부가적인 고차 항을 이용함으로써 신경회로망 내의 자유도를 늘려주어 보다 효과적인 학습 결과를 얻을 수 있다^[7,8]. 학습이 완료된 신경회로망 역근사화기는 가변구조 제어기의 제어 입력 설계 과정에서 시스템의 미지 정보를 보상하는 추가 제어입력의 생성을 위하여 이용된다.

다음은 신경회로망의 역근사화 과정이 성공적으로 이루어졌을 때, 시스템 특성에 대한 미지의 정보가 신

경회로망으로 보상될 수 있음을 보여준다. 위에서 주어진 식들로부터 다음 식들이 유도된다.

$$u = \frac{x'_n + \sum_{i=1}^n a_i^0 x_i + G}{b} \quad (16)$$

$$u_{norm} = \frac{x'_n + \sum_{i=1}^n a_i^0 x_i}{b^0} \quad (17)$$

$$u_n = N(W) \quad (18)$$

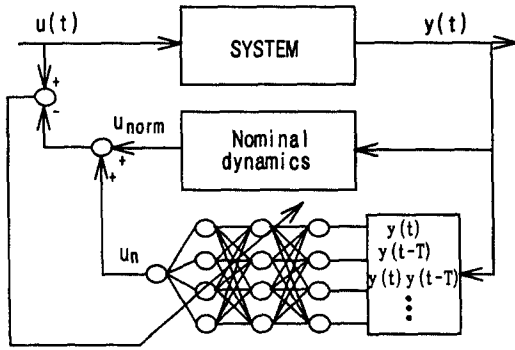


그림 1. 신경회로망을 이용한 시스템의 역 근사화
Fig. 1. Inverse identification of a system using multilayer neural network.

여기서 W 는 신경회로망의 연결 값들을 나타내고, $N(\cdot)$ 는 다층 구조 신경회로망을 나타내는 함수이다. 이때,

$$\begin{aligned} \|u - (u_{norm} + u_n)\|_{\infty} &= \left\| \frac{x'_n + \sum_{i=1}^n a_i^0 x_i + G}{b} - \frac{x'_n + \sum_{i=1}^n a_i^0 x_i}{b^0} - N(W) \right\|_{\infty} \\ &= \left\| \left(\frac{x'_n + \sum_{i=1}^n a_i^0 x_i}{b^0} \right) \left(\frac{b^0}{b^0 + \Delta b} - 1 \right) + \frac{G - \Delta b u}{b^0 + \Delta b} - N(W) \right\|_{\infty} \quad (19) \\ &= \left\| \left(\frac{x'_n + \sum_{i=1}^n a_i^0 x_i}{b^0} \right) \left(\frac{-\Delta b}{b^0 + \Delta b} \right) + \frac{G - \Delta b u}{b^0 + \Delta b} - N(W) \right\|_{\infty} \end{aligned}$$

특히, $\|u - (u_{norm} + u_n)\|_{\infty} < \epsilon_m$ 이고 $\Delta b = 0$ 이면, 식 (19)로부터 식 (20)을 얻을 수 있다.

$$\|G/b^0 - N(W)\|_{\infty} < \epsilon_m \quad (20)$$

즉, 학습이 끝난 다층 구조 신경회로망이 $\|u - (u_{norm} + u_n)\|_{\infty} < \epsilon_m$ 를 만족하고, 신경회로망의 학습을 위한 데이터 u 가 원하는 출력을 위한 입력 값의 범위를 포함한다고 가정할 때, $\Delta b = 0$ 일 경우 시스템의 불확실한 정보양인 G 는 위의 식 (20)에서처럼 신경회로

망에 의해 표현될 수 있다.

이제 위의 결과들을 이용하여 다층 구조 신경회로망을 사용하는 가변구조 제어기의 제어 입력을 Δb 가 영이 아닌 일반적인 경우에 대하여 구해보자. 신경회로망 역 근사화기를 사용하는 가변구조 제어기의 제어 입력은 다음 식 (21)과 같이 표현할 수 있다. 이때 Δu 는 학습 오차 ϵ' 를 보상하기 위한 떨림 제어 입력이다.

$$u = u_{eq} + u_n + \Delta u \quad (21)$$

그리고 u_n 는 다음 식으로 표현할 수 있다.

$$\begin{aligned} u_n &= u - u_{norm} + \epsilon' \\ &= \frac{x'_n + \sum_{i=1}^n a_i x_i + f}{b} - \frac{x'_n + \sum_{i=1}^n a_i^0 x_i}{b^0} - \epsilon' \end{aligned} \quad (22)$$

여기서, $\|\epsilon'\| < \epsilon_m$ 이다.

슬라이딩 모드의 존재와 도달 조건으로부터 다음 식 (23)을 얻을 수 있다.

$$\begin{aligned} \sigma \dot{\sigma} < 0 \\ \rightarrow \sigma \left[-\frac{\Delta b}{b^0} \left(\sum_{i=1}^n c_{i-1} x_i + x'_n \right) - b\epsilon' + b\Delta u \right] < 0 \quad (23) \\ \rightarrow \sigma \left[-\frac{\Delta b}{b^0} \sum_{i=1}^n c_i x_i - b\epsilon' + b\Delta u \right] < 0. \end{aligned}$$

여기서, $C_i = [0, c_1, c_2, \dots, c_{n-1}, 1]$ 이고 $i=1, 2, \dots, n+1$ 이다. 신경회로망 역근사화기의 오차를 보상하기 위한 떨림 제어 입력, $\Delta u = \sum_{i=1}^n \psi_i x_i + \phi$ 이라고 하면,

$$\sigma \dot{\sigma} \rightarrow \sigma \left[\sum_{i=1}^n \left(-\frac{\Delta b}{b^0} c_i + b\psi_i \right) x_i - b(\epsilon' - \phi) \right] < 0 \quad (24)$$

이다. 여기서 ψ_i 와 ϕ 이 식 (10)과 같이 주어질 때, 다음의 식 (25)와 (26)이 얻어진다.

$$\psi_i = \begin{cases} \alpha_i < \frac{\Delta b C_i}{b b^0}, & x_i \sigma > 0 \\ \beta_i > \frac{\Delta b C_i}{b b^0}, & x_i \sigma < 0 \end{cases} \quad (25)$$

$$\phi = \begin{cases} \gamma < \epsilon', & b\sigma > 0 \\ \delta > \epsilon', & b\sigma < 0 \end{cases} \quad (26)$$

특히, $\Delta b = 0$ 일 때 $\Delta u = \phi$ 라고 하면, 위의 식 (20)에 의해 다음과 같은 간단한 제어 입력을 얻을 수 있다.

$$\Delta u = \begin{cases} \gamma < \epsilon', & \sigma b^0 > 0 \\ \delta > \epsilon', & \sigma b^0 < 0 \end{cases} \quad (27)$$

따라서, 가변 구조 제어기를 설계할 때 필요한, 시스

템의 불확실한 정보들 중 Δb 의 최대 크기와 부호만 알면 가변 구조 제어기의 제어 입력을 설계할 수 있을 뿐만 아니라, 떨림 제어 입력 값의 크기도 신경회로망 학습에 의해 많이 줄어들므로, 제어 입력의 떨림 크기를 크게 완화시킬 수 있다.

3. 최적 슬라이딩 라인의 설계

가변 구조 제어기의 스위칭 평면을 위해서 본 논문에서는 최적 슬라이딩 라인 설계 기법을 도입한다. 슬라이딩 라인 $\alpha(x)$ 다음 식 (28)과 같이 주어진다.

$$\alpha(x) = CX \tag{28}$$

그러면, 슬라이딩 모드에서 어떤 시스템이 원하는 특성을 갖도록 설계하는 문제는 선형 상태 변수 제환 (linear state feedback) 문제로 간주 될 수 있다. 최적 선형 조절 기법에 의해 최적 이득 C 를 결정하기 위해서는 다음 식 (29)와 같은 성능 지수 함수가 최소화되어야 한다.

$$I = \frac{1}{2} \int_{t_0}^{\infty} (X^T Q X + R u^2) dt \tag{29}$$

여기서 $Q = Q^T > 0$ 는 웨이팅(weighting) 행렬이고, $R > 0$ 는 웨이팅을 나타내는 스칼라 양이다. 그리고 t_0 는 슬라이딩 모드를 시작하는 시간이다. 웨이팅 (weighting) 행렬 Q 는 $D^T D$ 로 정의되고, D 는 하나의 출력 O 를 갖는 시스템이라 할 때 출력 $O = DX$ 로 표현되는 $1 \times n$ 벡터로서, 시스템은 관측 가능한 것으로 가정하자. 이때, 최적 이득 C 는 다음의 식 (30)으로부터 얻어진다.

$$C = -R^{-1} B^T P \tag{30}$$

여기서 P 는 다음의 식 (31)를 만족하는 Riccati 방정식의 해이다.

$$PA' + A'^T P - PB'R^{-1}B'^T P + Q = 0 \tag{31}$$

4. 도달 위상(reaching phase) 문제에 대한 고려
가변 구조 제어기의 도달 위상 동안에는 슬라이딩 모드가 일어나지 않는다. 따라서 가변구조 제어의 장점 들인 외부 잡음에 대한 강건성과 과도응답의 성능에 대해 도달 위상 동안에는 보장할 수가 없다. 이 문제를 해결하기 위하여 슬라이딩 라인을 설계할 때, 적절한 초기 조건을 갖는 적분기를 이용할 수가 있다^[11]. 다음의 식 (32)는 적분기에 의해 추가적인 상태변수를

갖는 시스템을 나타낸다.

$$\begin{aligned} \dot{x}_i &= x_{i+1}, \quad i=1, \dots, n-1 \\ \dot{x}_n &= -\sum_{i=1}^n a_i x_i + bu - f \\ \dot{z} &= r - x_1 \end{aligned} \tag{32}$$

$\Delta b = 0$ 이라 할 때, 적분기에 의해 첨가된 상태변수를 가지는 슬라이딩 라인은 식 (33)과 같다.

$$\sigma = c_1(x_1 - k_1 z) + \sum_{i=2}^n c_i x_i, \quad c_n = 1 \tag{33}$$

그리고 $z(0) = (x_1(0) + \frac{c_2}{c_1} x_2(0) + \dots + \frac{c_n}{c_1} x_n(0)) / k_1$

이때, 등가 제어 입력은 식 (34)와 같고,

$$u_{eq} = (c_1 k_1 (r - x_1) - \sum_{i=2}^n c_{i-1} x_i) / c_n b^0 + \sum_{i=1}^n a_i^0 x_i / b^0 \tag{34}$$

2.2 절에서와 같이 다층 구조 신경회로망이 시스템의 미지 정보와 외란에 의한 불확실성을 최대 오차 ϵ_m 안에 근사화할 수 있다면, 다음 식 (35)와 같은 제어 입력을 사용할 때,

$$u = u_{eq} + u_n + \Delta u \tag{35}$$

슬라이딩 모드의 존재와 도달 조건으로부터 다음 식 (36), (37)을 얻을 수 있다.

$$\psi_i = \begin{cases} \alpha_i < \frac{\Delta b}{bb^0} C_i', & x_i \sigma > 0 \\ \beta_i > \frac{\Delta b}{bb^0} C_i', & x_i \sigma < 0 \end{cases} \tag{36}$$

$$\phi = \begin{cases} \gamma < -\frac{1}{b} \left[\frac{\Delta b}{b^0} c_1 k_1 r - b \epsilon' \right], & \sigma > 0 \\ \delta > -\frac{1}{b} \left[\frac{\Delta b}{b^0} c_1 k_1 r - b \epsilon' \right], & \sigma < 0 \end{cases} \tag{37}$$

여기서 $C_i' = [c_1 k_1, c_1, \dots, c_{n-1}, 1]$ 이다.

III. 시뮬레이션

제한된 방법의 타당성을 입증하기 위하여 다음과 같은 간단한 시스템을 생각한다.

$$\dot{X} = AX + BU - f \tag{38}$$

여기서

$$\begin{aligned} A &= \begin{bmatrix} 0 & 1 \\ -2 & -3 \end{bmatrix}, \quad B = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \\ \Delta a_i &= \pm 0.5, \quad \Delta b = 0, \quad f = \sin(x_1) \end{aligned} \tag{39}$$

최적 슬라이딩을 위한 성능 지수 함수는 다음 식 (40)과 같다.

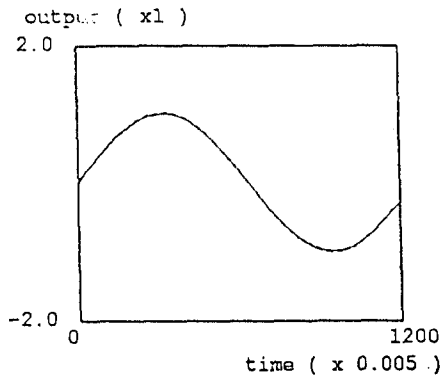
$$J = \int_0^{\infty} (5x_1^2 + x_2^2 + 4u^2) dt \quad (40)$$

여기서

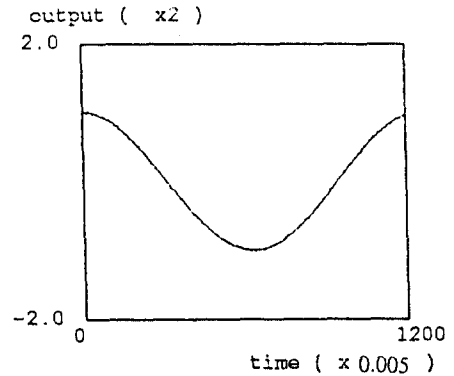
$$Q = \begin{bmatrix} 5 & 0 \\ 0 & 1 \end{bmatrix}, \quad R = 4.$$

식 (31)의 Riccati 방정식으로부터 슬라이딩 라인을 위한 이득값 C 는 다음과 같다.


$x_2 = \cos(t)$ 라고 하고, 신경회로망을 사용했을 때와 사용하지 않았을 때의 가변 구조 제어의 추적(Tracking) 결과를 비교해 보았다. 시뮬레이션을 위해 4차 Runge-Kutta 알고리즘을 이용하였으며, 주기 T 는 5msec를 이용하였다. 시스템 역 특성에 대한 불확실성을 배우기 위해 사용되어진 다층 구조 고차 신경회로망은 2개의 은닉층(Hidden layer)을 가지며, 입력층 뉴런으로는 현재 시스템에서 얻은 상태, 즉 $x_1(t)$, $x_2(t)$ 와 이들의 1차 지연값 $x_1(t-T)$, $x_2(t-T)$ 와 2차



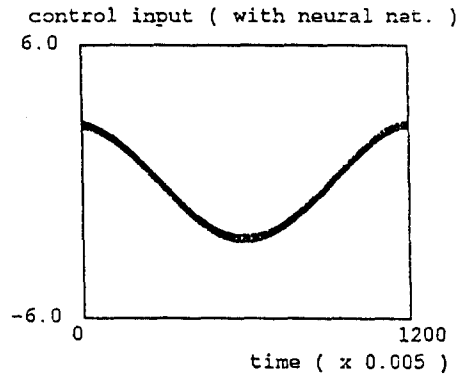
(a)



(b)



(c)



(d)

그림 2. 시스템의 초기 조건이 제어기의 초기 조건과 같을 때 가변 구조 제어기의 제어 결과

(a) 신경회로망 모델을 이용하지 않을 때의 제어 결과 (b) 신경회로망 모델을 이용할 때의 제어 결과
(c) 신경회로망 모델을 이용하지 않을 때의 제어 입력 (d) 신경회로망 모델을 이용할 때의 제어 입력

Fig. 2. Control result of variable structure controller when the initial conditions of system are same with those of controller.

(a) Control result in case that the neural network is not used (b) Control result in case that the neural network is used (c) Control input when the neural network is not used (d) Control input when the neural network is used

$$C = [-0.29125 \quad -0.13575]$$

우선, 시스템 변수들의 원하는 궤적을 $x_1 = \sin(t)$ 와

지연값 $x_1(t-2T)$, $x_2(t-2T)$, 그리고 이들의 상호 곱으로 이루어진 상관 항으로 15개를 이용하였으며, 출

력으로는 각 시점 t 에서의 예측되는 입력 값 u 를 위한 하나의 출력뉴런을 가지며, 은닉층 뉴런으로는 활성화 함수(Sigmoid function)를 전달특성으로 가지며 1번째 은닉층의 뉴런 수로는 21개 두 번째 은닉층의 뉴런 수는 15개를 가지고 오차 역전달 학습 알고리즘을 이용한 Pattern type 학습 법을 이용하였다^[12].

있는 정도의 랜덤 입력 값을 이용하였다. 그림 2는 시스템의 상태변수인 x_1 과 x_2 의 초기 조건이 각각 0과 1일 때, 그리고 그림 3은 초기조건이 각각 0.2와 0.85 일 때의 제어 결과를 나타낸다.

그림 2와 3의 (a), (b)에서 실선은 원하는 궤적을 나타내고, 굵은 점선과 가는 점선은 각각 신경회로망을

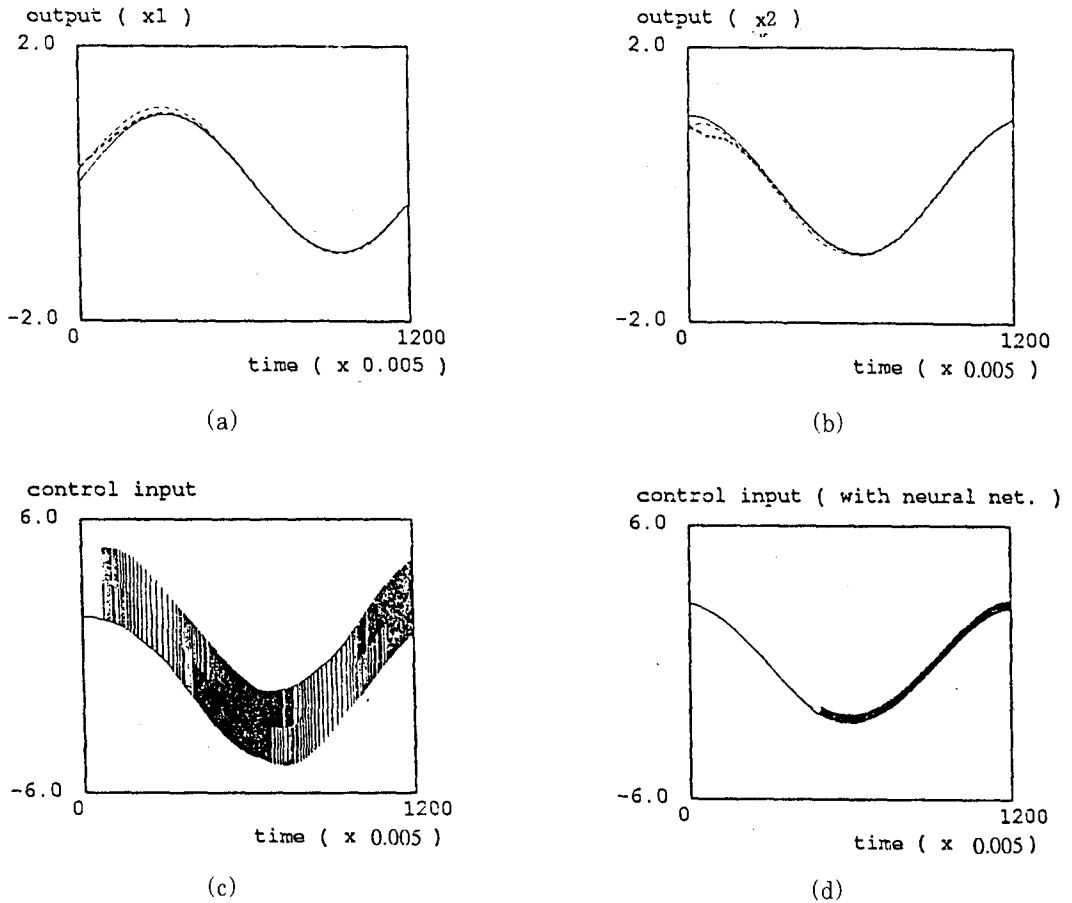


그림 3. 시스템의 초기 조건이 제어기의 초기 조건과 같을 때 가변 구조 제어기의 제어 결과
 (a) 신경회로망 모델을 이용하지 않을 때의 제어 결과 (b) 신경회로망 모델을 이용할 때의 제어 결과
 (c) 신경회로망 모델을 이용하지 않을 때의 제어 입력 (d) 신경회로망 모델을 이용할 때의 제어 입력
 Fig. 3. Control result of variable structure controller when the initial conditions of system are same with those of controller.


(a) Control result in case that the neural network is not used (b) Control result in case that the neural network is used (c) Control input when the neural network is not used (d) Control input when the neural network is used

학습에 이용한 데이터의 수는 신경회로망의 일반화 성능을고려하여 전체 연결 강도(Interconnection weight)의 수의 10배 정도가 되는 1000개의 데이터를 이용하였으며^[6], 학습을 위한 입력 데이터의 범위는 시스템의 출력이 원하는 궤적을 충분히 포함할 수


사용하지 않았을 때와 신경회로망을 사용했을 때의 제어 결과를 나타낸다. 그리고 그림 2와 3의 (c)와 (d)는 각각 신경회로망을 사용하지 않았을 때의 제어 입력과 신경회로망을 사용했을 때의 제어 입력을 나타낸다. 신경회로망을 사용함으로써 제어 입력의 펄스 크기

가 대폭 감소되었음을 알 수 있었다. 그림 3에서는 초기조건이 다른 경우에 도달위상 문제가 발생함을 보여주고 있다.

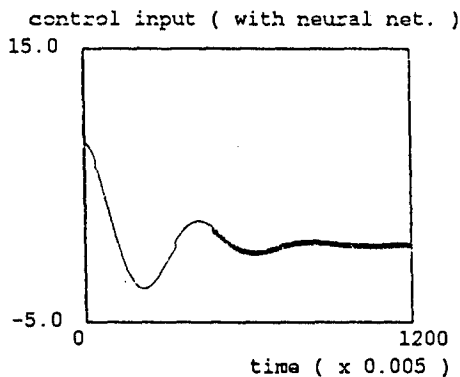
근사화기를 이용함으로써 펄스 제어 입력의 크기를 많이 줄여 줄 수 있음을 알 수가 있다.



(a)



(b)



(c)

그림 4. 적분기를 이용할 때의 가변 구조 제어기의 제어 결과

(a) 신경회로망을 이용할 때와 이용하지 않을 때의 가변 구조 제어기의 제어 결과 비교 (b) 신경회로망 모델을 이용하지 않을 때 제어 입력 (c) 신경회로망 모델 이용할 때의 제어 입력

Fig. 4. Control result of variable structure controller with integrator.

(a) Comparison of control result in two cases that the variable structure control with and without the neural network (b) Control input when the neural network is not used (c) control input when the neural network is used

그림 4는 도달위상 문제의 해결을 위하여 적분기를 도입했을 때의 레귤레이션(Regulation)결과를 보여주고 있다. 그림 4(a)에서 실선은 원하는 값을 나타내고, 굵은 점선과 가는 점선은 각각 신경회로망을 사용하지 않았을 때와 신경회로망을 사용했을 때의 제어 결과를 나타낸다. 그림 4의 (b)와 (c)는 각각 신경회로망을 사용하지 않았을 때의 제어 입력과 신경회로망을 사용했을 때의 제어 입력을 나타낸다. 역시 신경회로망 역

IV. 결론 및 추후 연구 방향

다층 구조 신경회로망을 시스템의 역 근사화기로 이용함으로써 가변구조 제어기의 제어 입력의 펄스 크기를 많이 줄일 수 있음을 간단한 예제를 통한 컴퓨터 시뮬레이션으로 입증하였다. 또한 제안된 방법은 시스템 변수의 변화나 외부 잡음의 크기등 제어 대상 플랜트의 불확실한 정도를 정확히 모르더라도 신경회로망

의 학습 오차의 크기에 의해 가변구조 제어기를 설계할 수 있는 장점이 있다. 하지만, 신경회로망 역근사화기를 학습시키는 데에 필요한 입출력 데이터를 충분히 얻어야 하며, 이를 위한 연구가 현재 진행 중에 있다. 또한 보다 복잡한 비선형 시스템에 대한 시뮬레이션과 실험이 연구 중에 있으며, 시스템의 불확실성을 온라인으로 보상하는 방법에 대한 연구도 진행 중에 있다.

참 고 문 헌

- [1] U. Itkis, Control systems of variable structure, 1976.
- [2] J.Y. Hung, W. Gao, and J.C. Hung, "Variable structure control : a survey," *IEEE Trans. on Industrial Electronics*, 40(1), 1993.
- [3] J.J. Slotine, "Sliding controller design for nonlinear systems," *International Journal of Control*, 40(2), 421-434, 1984.
- [4] F.J. Chang and S.H. Twu, "Adaptive chattering alleviation of variable structure systems control," *IEE Proceedings Part D*, 137(1), 1990.
- [5] K. Hornik, "Approximation capabilities of multilayer feedforward networks," *Neural Networks*, 4(2), 251-257, 1991.
- [6] E.B. Baum and D. Hausser, "What size net gives valid generation ?," *Neural Information Processing Systems 1*, 81-90, 1989.
- [7] M. Lee, S.Y. Lee, and C.H. Park, "Neural controller of nonlinear dynamic systems using higher order neural networks," *Electronics Letters*, 28(3), 276-277, 1992.
- [8] M. Lee, S.Y. Lee, and C.H. Park, "Higher-order neural controller of dynamic systems," *KITE Journal of Electronics Engineering*, 5(1), 90-94, 1994.
- [9] T.L. Chern and Y.C. Wu, "An optimal variable structure control with integrated compensation for electrohydraulic position servo control system," *IEEE Trans. on Industrial Electronics*, 39(5), 460-464, 1992.
- [10] C.H. Park, "Neuro-fuzzy information processing," *Proc. of 91' Korean Scientist and Engineer Summer Symposium*, 90-94, 1990.
- [11] D. Rumelhart, G.E. Hinton, and R.J. Williams, "Learning internal representation by error propagation," *Parallel Distributed Processing*, D. Rumelhart and J. McClelland(Eds.), 1, MIT Press, 1986.
- [12] S.Z. Qin, H.T. Su, and T.J. McAvoy, "Comparison of four neural net learning methods for dynamic system identification," *IEEE Trans. on Neural Networks*, 3(1), 122-130, 1992.

저 자 소 개



李 敏 鎬(正會員)

1995년 9월 ~ 현재 한국해양대학교 이공 대학 전기 공학과 전임강사. 1988년 경북대학교 공과대학 전자공학과(학사). 1992년 한국과학기술원 전기 및 전자공학과(석사). 1995년 8월

한국과학기술원 전기 및 전자공학과(박사). 주요관심분야는 신경회로망과 퍼지 논리 및 유전 알고리즘을 이용한 지능 제어 시스템 개발 및 비선형 시스템의 동정화와 제어, 시계열 예측 문제등

李 壽 永(正會員) KITE journal of Electronics Engineering, vol. 3, no. 1, pp 77-78, 1992. 참고

金 炳 國(正會員) 第 29卷 第 8號 B編 參照

현재 한국과학기술원 전기및전자공학과 부교수

朴 哲 薰(正會員) KITE journal of Electronics Engineering, vol. 3, no. 1, pp 77-78, 1992. 참고

崔 炳 載(正會員)

1965년 8월 20일생. 1987년 경북대학교 전자공학과(공학사). 1989년 한국과학기술원 원자력공학과(공학석사). 1993년 ~ 현재 한국과학기술원 전기및전자공학과 박사과정. 1989년 2월 ~1995년 3월 한전 전력연구원 인공지능연구팀. 주관심 분야는 지능 제어 이론

