

論文2002-39SC-1-7

연속 시간 혼돈 비선형 시스템을 위한 신경 회로망 제어기의 설계

(Design of Neural Network Controller for Continuous-Time Chaotic Nonlinear Systems)

吳基薰*, 崔允浩**, 朴珍培***, 林桂榮*

(Ki Hoon Oh, Yoon Ho Choi, Jin Bae Park, and Kye Young Lim)

요약

본 논문에서는 혼돈 비선형 시스템의 지능 제어를 위해 간접 적응 제어 방식에 기초한 신경 회로망 제어기 설계 방법을 제안하였다. 제안된 제어 방법은 혼돈 비선형 시스템의 동정을 위해 다층 신경 회로망과 간단한 상태 공간 신경 회로망을 사용한 직-병렬 동정 구조를 이용하여 오프 라인으로 동정 과정을 수행하였으며, 학습된 혼돈 비선형 시스템에 대한 신경 회로망 모델을 사용하여 온 라인으로 제어를 수행하였다. 이때 혼돈 비선형 시스템의 동정 및 제어를 위한 학습 방법은 오차 역전파 방법을 사용하였다. 한편 본 논문에서 제안된 제어 방법을 연속 시간 혼돈 비선형 시스템인 Duffing 방정식과 Lorenz 방정식에 각각 적용하여 신경 회로망을 사용한 기존의 제어 방법과 컴퓨터 모의 실험을 통해 제어 성능을 비교 및 고찰하였다.

Abstract

This paper presents a design method of the neural network-based controller using an indirect adaptive control method to deal with an intelligent control for chaotic nonlinear systems. The proposed control method includes the identification and control process for chaotic nonlinear systems. The identification process for chaotic nonlinear systems is an off-line process which utilizes the serial-parallel structure of multilayer neural networks and simple state space neural networks. The control process is an on-line process which uses the trained neural networks as the system model. An error back-propagation method was used for training of identification and control for chaotic nonlinear systems. The performance of the proposed neural network controller was evaluated by application to the Duffing equation and the Lorenz equation, and the proposed controller was compared with other neural network-based controllers by computer simulations.

I. 서론

혼돈(chaos) 현상은 시스템의 상태 변수들 사이의 비

선형적인 관계로 인해 외부적인 동태가 불규칙하게 관찰되지만, 내부적으로는 결정론적(deterministic) 규칙을 가지는 현상으로 정의될 수 있으며 초기 조건에 매우 민감한 특성을 가진다. 이와 같은 혼돈 현상이 존재하는 비선형 동역학 시스템을 혼돈 비선형 시스템(chaotic nonlinear system)이라고 한다. 시스템에서의 혼돈 현상은 시스템 상태의 예측 불가능 및 비정상적인 동작 등과 같은 유해한 결과를 갖는 경우가 많다. 이러한 유해한 혼돈 현상을 제거 또는 억제하기 위한 혼돈 제어 방법에 관한 연구들이 근래에 활발히 진행되고 있다^[1].

* 正會員, LG산전 中央研究所
(LGIS R&D Center)

** 正會員, 京畿大學校 電子工學科
(Dept. of Electronic Eng., Kyonggi University)

*** 正會員, 延世大學校 電氣電子工學科
(Dept. of Electrical & Computer Eng., Yonsei University)

接受日字:1999年11月26日, 수정완료일:2001年12月10日

Ott, Grebogi와 Yoke에 의해 제안된 OGY 방법^[2]은 시스템의 파라미터에 섭동(perturbation)을 인가함으로써 시스템 동태를 불안정한 주기 운동으로 안정화시키는 방법이며 Jackson과 Hübler에 의해 제안된 비례환 제어 방법^[3]은 시스템내의 위상 공간에 존재하는 수렴 영역을 이용하여 혼돈 시스템을 제어하는 방법이다. 한편 Chen과 Dong은 전통적인 선형 폐환 제어 방법을 이용함으로써 이산 및 연속 시간 혼돈 시스템을 평형 상태로 제어하는 방법을 제안하였다^[4-6]. 이후 많은 제어 공학자들이 기존의 제어 방법을 도입함으로써 혼돈 시스템을 제어할 수 있는 방법을 제안하였다. 이와 같은 제어 공학적 기법을 사용한 혼돈 제어 방법들 중에서, Qammar와 Mossayebi는 시스템 입·출력에 대한 NARMAX(Nonlinear AutoRegressive Moving Average models with eXogenous inputs) 모델^[7]을 사용하여 간접 적응 제어기를 구성하는 제어 방법을 제안하였으며^[8], Nijmeijer와 Berghuis는 최근 비선형 제어 방법으로 각광 받고 있는 Lyapunov 제어 기법을 이용하여 연속 시간 혼돈 비선형 시스템인 Duffing 방정식을 제어하는 방법을 제안하였다^[9].

그러나 이러한 기존의 혼돈 제어 방법들은 혼돈 시스템에 대한 평형 상태 또는 기준 신호로의 수렴이 연구자의 경험적 측면이나 직관에 의해 도출되어 제어 이론의 해석과 합성에 어려움이 있으며, 시스템의 정확한 모델이나 비선형 방정식을 필요로 하므로 실제로 물리적으로 정확한 모델을 알 수 없는 시스템에 대해 적용 불가능하며, 다양한 혼돈 시스템에 대해 적용 가능한 일반적인 제어 방법이 부재하여 혼돈 특성이 바뀔 때마다 제어기를 달리 사용해야 한다는 단점을 가진다^[10-12].

따라서 본 논문에서는 혼돈 비선형 시스템의 지능 제어를 위해 간접 적응 제어 기법에 기초한 신경 회로망 제어기의 설계 방법을 제안하고자 한다. 제안된 신경 회로망 제어기를 다른 신경 회로망 제어기들과 모의 실험을 통해 제어 결과들을 비교함으로써 제어 성능이 우수함을 입증하고자 한다. 한편 제어 대상인 연속 시간 혼돈 시스템으로는 Duffing 방정식과 Lorenz 방정식을 선정하여, 제안된 신경 회로망 제어기가 다양한 혼돈 비선형 시스템에 대해 적용 가능성을 검증하고자 한다.

II. 혼돈 비선형 시스템을 위한 신경 회로망 제어기의 설계

혼돈 비선형 시스템에는 연속 시간 혼돈 비선형 시스템과 이산 시간 혼돈 비선형 시스템이 있으며 본 논문에서는 연속 시간 혼돈 비선형 시스템을 제어 대상으로 한다.

1. 연속 시간 혼돈 비선형 시스템

(1) Duffing 방정식

Duffing 방정식은 다양한 형태가 있으나 본 논문에서는 식 (1)을 사용한다^[4].

$$\ddot{x} + p\dot{x} + p_1x + x^3 = q\cos(ut) \quad (1)$$

여기서 t 는 시변수이며 p, p_1, p_2, q 및 w 는 실계수이다. 이때 선형 계수인 p_1 는 양의 실수값이다. 시계열 방정식인 식 (1)을 상태 변수 방정식으로 표현하기 위해 \dot{x} 을 y 로 정의하여 정리하면 식 (2)와 같다.

$$\begin{aligned} \dot{x} &= y \\ \dot{y} &= -p_1x - x^3 - py + q\cos(ut) \end{aligned} \quad (2)$$

Duffing 방정식은 표 1에서와 같이 q 값의 설정에 따라 주기 해를 가지기도 하고 비주기 해를 갖는 혼돈 현상을 나타내기도 한다.

표 1. q 에 대한 Duffing 방정식의 해
Table 1. Solution of Duffing equation for various q .

q	해	q	해
0.620	1 주기 해	2.100	비 주기
1.498	2 주기 해	2.300	1 주기 해
1.800	비 주기	7.00	1 주기 해

본 논문에서는 제어 대상인 Duffing 방정식이 혼돈 현상을 갖기 위해 다음과 같은 파라미터 집합을 선택하며,

$$\{p, p_1, q, w_1\} = \{0.4, -1.1, 2.1, 1.8\}$$

이와 같이 선택된 파라미터에 대한 Duffing 방정식의 스트레인지 어트랙터(strange attractor)는 그림 1과

같다.




그림 1. Duffing 방정식의 스트레인지 어트랙터
Fig. 1. Strange attractor of Duffing equation.

(2) Lorenz 방정식

Lorenz는 대기중에서 상승 기류의 간략화된 모델로부터 식 (3)과 같은 3차 시스템을 유도하였다^[13].

$$\begin{aligned} \dot{x} &= \sigma(y - x) \\ \dot{y} &= rx - y - xz \\ \dot{z} &= xy - bz \end{aligned} \quad (3)$$

Lorenz는 식 (3)과 같이 결정론적으로 보이는 시스템의 파라미터의 넓은 영역에서 시스템 해가 비주기적으로 진동하며, 시스템 해의 궤적은 위상 공간에서 유사하지만 동일하지 않은 모양을 지니며 한정된 공간에 존재하는 스트레인지 어트랙터의 형태를 가짐을 발견하였다. 안정된 정점이나 제한 사이클(limit cycle)과는 달리 스트레인지 어트랙터는 점이나 곡선이 아니며 프랙탈(fractal)한 형태를 가진다. Lorenz 방정식은 다음과 같은 2 종류의 고정점을 가진다.

- i) $(x^*, y^*, z^*) = (0, 0, 0)$
- ii) $x^* = y^* = \pm\sqrt{b(r-1)}, z^* = r-1$

본 논문에서는 Lorenz 방정식이 혼돈 현상을 갖는 다음과 같은 파라미터 집합을 선택하며,

$$\{\sigma, b, r\} = \{10, 8/3, 28\}$$

선택된 파라미터에 대한 Lorenz 방정식의 스트레인지 어트랙터는 그림 2와 같다.




그림 2. Lorenz 방정식의 스트레인지 어트랙터
Fig. 2. Strange attractor of Lorenz equation.

2. 직접 적응 신경 회로망 제어기

혼돈 비선형 시스템일 위한 신경 회로망을 이용한 단순 직접 적응 제어 방법의 구조는 그림 3과 같다




그림 3. 직접 적응 제어 방법의 구조
Fig. 3. Structure of direct adaptive control method.

신경 회로망 제어기는 혼돈 비선형 시스템의 역(inverse) 동특성을 암시적으로 학습하여 제어 입력 u 를 생성해낸다. 그러나 신경 회로망 제어기의 연결 강도(weight)를 갱신하기 위한 신경 회로망 제어기 출력에서의 오차 신호 e_u 를 직접 구할 수 없으므로, 실제로 구할 수 있는 시스템의 출력 오차 e_y 를 신경 회로망 제어기의 출력단의 오차 e_u 로 변환하여 신경 회로망 제어기를 학습시킨다.

다음과 같은 비용함수를 정의하자

$$E_y = \frac{1}{2} (y_d - y)^2 \quad (4)$$

여기서 $e_y = y_d - y$ 로 정의하면 신경 회로망 제어기의 연결 강도 w 에 대한 오차 경도(gradient)는 식 (5)와 같다.

$$\frac{\partial E_y}{\partial w} = -e_y \frac{\partial y}{\partial w} = -e_y \frac{\partial y}{\partial u} \frac{\partial u}{\partial w} \quad (5)$$

식 (5)에서 $\frac{\partial y}{\partial u}$ 항은 혼돈 비선형 시스템의 순방향 미분 이득 (Jacobian)이며 혼돈 비선형 시스템의 안정도에 중요한 영향을 미친다. $J(u) = \frac{\partial y}{\partial u}$ 로 정의하면 식 (5)은 식 (6)로 쓸 수 있다.

$$\frac{\partial E_y}{\partial w} = -e_y J(u) \frac{\partial u}{\partial w} \quad (6)$$

Psaltis등이 제안한 특별 학습 방법 (specialized learning scheme)^[14] 관점에서 볼 때 혼돈 비선형 시스템을 연결 강도 $J(u)$ 를 갖는 신경 회로망 제어기의 부가적인 층(layer)으로 생각하면 식 (6)은 혼돈 비선형 시스템의 출력 오차 e_y 가 혼돈 비선형 시스템을 통해 역전파되어 신경 회로망 제어기의 출력 오차 e_u 로 변환되는 과정을 나타낸다. $\Delta w_{[p-1, i][p, j]}$ 를 $p-1$ 층의 i 번째 신경 소자와 p 층의 j 번째 신경 소자 사이의 연결 강도 $w_{[p-1, i][p, j]}$ 의 변화량이라 하고, o_j^p 를 p 층에서의 j 번째 신경 소자의 출력이라 하면, 모든 층에 대한 연결 강도는 식 (7)에 의해 갱신될 수 있다.

$$w_{[p-1, i][p, j]}(n+1) = w_{[p-1, i][p, j]}(n) + \Delta w_{[p-1, i][p, j]}(n) + \alpha \Delta w_{[p-1, i][p, j]}(n-1) \quad (7)$$

여기서 $\Delta w_{[p-1, i][p, j]} = \eta \delta_i^p o_j^p$ 이며 η 는 학습률이며, α 는 모멘텀(momentum) 계수^[15]이다. 신경 회로망 각층의 오차값은 다음 식 (8a)와 식 (8b)로 표현된다.

$$\text{출력 층 : } \delta_i^p = J(u) e_y f'_i(\text{net}_i^p) \quad (8a)$$

$$\text{다른 층 : } \delta_i^p = f'_i(\text{net}_i^p) \sum_j \delta_j^p w_{[p-1, i][p, j]} \quad (8b)$$

여기서 net_i^p 는 p 층으로 들어가는 입력이며, f 는 신경 소자의 활성화(activation) 함수이며, f' 는 f 의 미분이다. 이때 미분 이득 $J(u)$ 는 두 개의 정해진 시구간 동안의 혼돈 비선형 시스템 출력 y 와 제어 입력 u 사이의 변화량 $\frac{\Delta y}{\Delta u}$ 에 의해 온 라인으로 계산될 수 있으므로 시스템의 출력 오차를 신경 회로망의 출력 오차로 변환하여 연결 강도를 갱신할 수 있다. 본 논문에서는 신경 회로망 제어기를 이용하여 혼돈 비선형 시

스템의 제어시 추적(tracking) 제어 뿐만이 아니라 조절(regulation) 제어를 하기 위해서 모멘텀을 사용하였다. 추적 제어의 경우에는 기준 신호가 시간에 따라 변하기 때문에 연결 강도의 과거값에 큰 영향을 받지 않는데 비해, 조절 제어의 경우에는 기준 신호가 시불변이기 때문에 연결 강도의 과거값을 사용하는 것이 제어 가능성을 높일 수 있다^[16].

3. 간접 적응 신경 회로망 제어기의 설계 방법

직접 적응 제어 방법에 의해 혼돈 비선형 시스템을 제어하는 경우, 시스템 미분 이득이 필요하며 학습시 연결 강도의 급격한 변화를 줄이기 위해 학습률을 작게 주어 혼돈 비선형 시스템을 제어한다. 반면에 근사화 방법을 혼돈 비선형 시스템의 제어 규칙을 설정하려 하는 것은 효율적인 미분 이득을 정의할 수 없기 때문에 근본적으로 한계성을 가진다.

따라서 본 논문에서는 직접 적응 제어 방식의 이러한 문제점 해결을 위해, 제어 대상의 동정(identification)을 통해 제어 대상에 대한 정보를 가지고 정확한 제어 규칙을 생성해 내는 간접 적응 제어 방법에 기초한 혼돈 비선형 시스템의 제어기 설계 방법을 제안한다.

(1) 혼돈 비선형 시스템의 동정

제어 공학 관점에서 제어를 위한 모델을 미리 설정하는 것은 매우 효과적인 방법이나 모델을 잘 알지 못하는 실제 시스템에 적용할 경우 잡음이 첨가된 데이터에서 시스템의 동특성을 추출하는 것은 무척 중요하며 어려운 일이다^[17]. 이러한 중요한 시스템 모델링의 한 방법으로 시스템 동정을 생각할 수 있으며, 그림 4와 같은 동정 방법이 사용된다. 그림에서 $u(\cdot)$ 와




그림 4. 시스템 동정 블록 선도

Fig. 4. System identification block diagram.

$y_p(\cdot)$ 는 각기 플랜트의 입력 및 출력이며 $y_m(\cdot)$ 는 모델의 출력이다. 또한 $u(\cdot)$ 는 시간에 대해 제한된 값을 갖는 입력이다.

이러한 구성되어진 혼돈 비선형 시스템에 적용된 기존의 대부분 모델들은 부분적으로 선형이거나 매우 복잡한 구조를 가지므로, 실제 모델의 구성이 가능하더라도 혼돈 비선형 시스템의 해석 및 제어에 유용하게 사용될 수 없다. 이러한 문제점을 해결하고자 Billings 등은 NARMAX 모델을 사용하여 혼돈 비선형 시스템을 모델링하였으나^[7], 양호한 성능을 유지하기 위해서는 정확한 차수를 필요로 하며 또한 사전에 플랜트에 대한 어느 정도의 정보가 필요하게 된다. 이러한 정보를 가지지 않은 상태에서의 NARMAX 모델은 매우 복잡한 형태를 가지며 궤환 제어 등의 방법에서 실제 제어 법칙을 유도하기가 어렵다^[18]. 이러한 문제점을 해결하기 위해 본 논문에서는 신경 회로망을 사용한 혼돈 비선형 시스템의 동정 방법을 사용한다. 신경 회로망을 이용한 모델링은 플랜트에 대한 정보가 전혀 알려지지 않은 경우에도 플랜트의 동정에 비교적 강인하게 대처할 수 있으므로 일반적인 동정 방법으로 사용할 수 있다.

(2) 혼돈 비선형 시스템 동정을 위한 신경 회로망의 구조

시스템 동정을 위한 신경 회로망의 구조는 크게 회귀 신경 회로망(recurrent neural network)과 비회귀 신경 회로망(nonrecurrent neural network)으로 나눌 수 있다. 대표적인 비회귀 신경망인 다층 신경 회로망(multilayer neural network : MLNN)은 패턴 인식 문제 등의 분야에서 성공적인 성능을 나타내며, 회귀 신경 회로망은 최적해 문제등에 널리 사용되고 있다. 시스템 이론적 측면에서 본다면 다층 신경 회로망은 주어진 데이터를 정적 사상을 하는데 비해 회귀 신경망은 구조 자체가 동력학을 고려하기 때문에 다층 신경 회로망에 비해 빠른 수렴 속도와 양호한 성능을 나타낼 수 있다. 시스템 동정의 구조는 병렬 동정 구조와 직-병렬 동정 구조가 있다. 병렬 구조는 동정 모델의 출력의 과거값을 모델 입력으로 사용하며, 직-병렬 구조는 플랜트의 출력의 과거값을 모델의 입력으로 사용한다. 이 두 개의 동정 구조 중에서 직-병렬 구조가 양호한 성능과 수렴성을 내포하는 모델이다^[17]. 따라서 본 논문에서는 비회귀 신경 회로망을 이용한 혼돈 비선형 시

스템의 동정에 그림 5의 피드 포워드 신경 회로망을 사용한 직-병렬 구조를 사용한다.

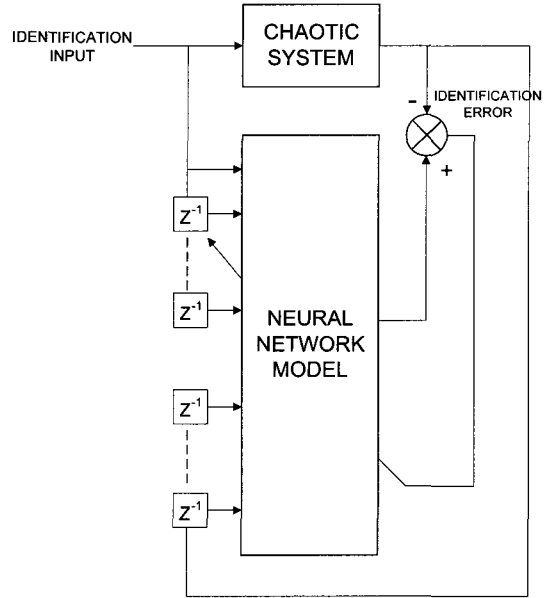


그림 5. 직-병렬 동정 구조
Fig. 5. Series-parallel identification structure.

Almeida는 모든 퍼셉트론(perceptron)에 피드백 요소를 추가한다고 하여 항상 성능 향상이 된다고는 할 수 없음을 지적하였다^[19]. 모델링 방법의 대부분의 경우에 오직 모델링 유니트(unit)의 작은 부분만이 피드백 요소를 첨가하였을 경우 유용할 뿐이다. 마찬가지로 Ljung도 시스템 동정시 동정기(identifier)는 작은 수의 파라미터를 선택하여야 한다는 점을 지적하였는데^[20], 신경 회로망의 경우에는 작은 부분의 연결 강도에 해

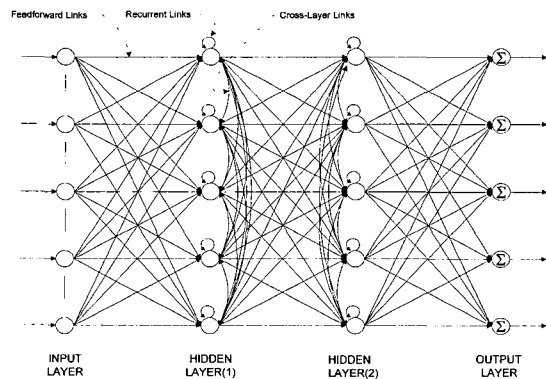


그림 6. 간단한 상태 공간 신경 회로망의 구조
Fig. 6. Structure of SSSNN.

당된다. 이러한 것은 더 많은 파라미터를 사용할수록 더 많은 랜덤 요소가 모델에 영향을 주기 때문이다.

따라서 본 논문에서 사용한 회귀 신경망을 이용한 동정은 그림 6과 같은 간단한 상태 공간 신경 회로망 (simple state space neural network : SSSNN)을 사용한 직-병렬 구조를 사용한다.

그림 6에서 나타난 바와 같이 간단한 상태 공간 신경 회로망의 구조는 다층 신경 회로망의 은닉층에 피드백 성분과 크로스(cross) 성분이 추가된 형태이다. l 층의 i 번째 신경 소자의 상태 $x_{[l,i]}$ 는 식 (9)와 같이 표현될 수 있다.

$$\begin{aligned} z_{[l,i]}(m) &= \sum_{j=1}^{N(l)} w_{[l,i][j]} x_{[l,j]}(m-1) \\ &+ \sum_{j=1}^{N(l-1)} w_{[l-1][l][i,j]} x_{[l-1,j]}(m) + b_{[l,i]} \quad (9) \\ x_{[l,i]}(m) &= F_{[l]}(z_{[l,i]}(m)) \end{aligned}$$

여기서 m 은 신경층의 출력에서 계산되는 이산치 시간이며, $N(l)$ 은 l 층에서의 신경 소자 수이며, $b_{[l,i]}$ 는 바이어스(bias) 항이다.

(3) 혼돈 비선형 시스템 동정을 위한 학습 방법

혼돈 비선형 시스템을 위한 동정 모델의 학습에는 오차 역전파 방법을 사용한다. 회귀 신경망의 경우에는 여러 가지 학습 방법이 있으나 일반적인 오차 역전파 학습 방법으로도 적절한 제어가 가능하다. 회귀 신경 회로망에 대한 동정 오차의 비용 함수를 식 (10)와 같이 표현하자.

$$E(k) \equiv \frac{1}{2} \sum_{i=1}^{N(\gamma)} (x_{[i,\gamma]}(k) - y_i(k))^2 \quad (10)$$

여기서 γ 는 출력층을 나타내며 $N(\gamma)$ 는 출력층의 신경 소자 수를 나타낸다. 이때 회귀 신경 회로망을 이용한 연결 강도의 갱신은 식 (11)과 식 (12)로 표현할 수 있다.

$$\begin{aligned} \Delta w_{[l-1][l][i,j]}(m+1) &= -\eta \sum_{k=k(m-1)+1}^{k\gamma} \frac{\partial E(k)}{\partial w_{[l-1][l][i,j]}} \\ &+ \alpha \Delta w_{[l-1][l][i,j]}(m) \\ &= -\eta \sum_{k=k(m-1)+1}^{k\gamma} \left(\frac{\partial E(k)}{\partial x_{[l,i]}} \right) \left(-\frac{\partial x_{[l,i]}}{\partial w_{[l-1][l][i,j]}} \right) \\ &+ \alpha \Delta w_{[l-1][l][i,j]}(m) \quad (11) \end{aligned}$$

$$\begin{aligned} \Delta w_{[l][l][i,i]}(m+1) &= -\eta \sum_{k=k(m-1)+1}^{k\gamma} \frac{\partial E(k)}{\partial w_{[l][l][i,i]}} \\ &+ \alpha \Delta w_{[l][l][i,i]}(m) \end{aligned}$$

$$\begin{aligned} &= -\eta \sum_{k=k(m-1)+1}^{k\gamma} \left(\frac{\partial E(k)}{\partial x_{[l,i]}} \right) \left(-\frac{\partial x_{[l,i]}}{\partial w_{[l][l][i,i]}} \right) \\ &+ \alpha \Delta w_{[l][l][i,i]}(m) \quad (12) \end{aligned}$$

식 (11)은 순방향 연결 강도의 갱신에 관한 식이고, 식 (12)은 피드백 및 상호층(cross layer) 연결 강도 갱신에 관한 식이며, 각각의 식에서 α 는 모멘텀 계수이다. 이때,

$$\begin{aligned} \frac{\partial x_{[l,i]}(k)}{\partial w_{[l-1][l][i,j]}} &= \dot{F}_{[l]}(z_{[l,i]}(k)) x_{[l-1,j]}(k) \\ &= \dot{F}_{[l]}(z_{[l,i]}(k)) F_{[l-1]}(z_{[l-1,j]}(k)) \\ \frac{\partial x_{[l,i]}(k)}{\partial w_{[l][l][i,i]}} &= \dot{F}_{[l]}(z_{[l,i]}(k)) x_{[l,i]}(k-1) \\ &= \dot{F}_{[l]}(z_{[l,i]}(k)) F_{[l]}(z_{[l,i]}(k-1)) \end{aligned}$$

이고, F 는 활성화 함수를 나타내며 \dot{F} 는 활성화 함수의 미분치 이다.

3. 혼돈 비선형 시스템을 위한 신경 회로망 간접 적응 제어기의 설계

간접 적응 제어 방식에 기초한 신경 회로망 제어 방법은 일단 동정 모델을 적절히 오프 라인(off-line)으로 생성한 후, 생성된 동정 모델을 이용하여 제어 대상 플랜트를 온 라인으로 제어하는 방법이다. 본 논문에서 제안한 간접 적응 제어 방식에 기초한 혼돈 비선형 시스템의 신경 회로망 제어기의 구조는 그림 7과 같다.




그림 7. 신경 회로망을 이용한 간접 적응 제어기의 구조
Fig. 7. Structure of the indirect adaptive controller using NN.

그림 7에서 동정을 위해 사용하는 신경 회로망은 2 가지로서 다층 신경 회로망과 간단한 상태 공간 신경 회로망을 사용하여 혼돈 비선형 시스템을 동정한다. 또한 동정 구조는 직-병렬 동정 구조를 사용하며, 사용된 신경 회로망의 학습 방법은 앞서 서술한 오차 역전파 방법을 사용한다. 제어를 위해 사용된 신경회로망은 가

장 많이 쓰이며 일반적인 다층 신경 회로망을 사용하며 오차 역전파 방법을 사용하여 신경 회로망을 학습한다^[17]. 혼돈 비선형 시스템의 동정을 제한된 오차 범위에 도달할 때 까지 오프 라인으로 적절히 수행한 다음, 학습된 동정 모델을 사용하여 제어 법칙을 설정한다. 신경회로망 제어기의 오차 역전파 방법은 제어기와 동정 모델을 직렬로 연결된 하나의 신경회로망 형태로 생각하여 제어기의 출력단과 모델의 입력단을 하나의 신경회로망의 은닉층으로 고려하여 제어 오차 e_c 를 동정 모델을 통해 제어기의 출력단의 오차로 변형된다. 이러한 방법은 시스템의 상태가 급격히 변동하는 혼돈 비선형 시스템에서 직접 적응 제어같은 근화된 미분 이득을 사용함으로써 발생하는 오차의 부정확성을 제거할 수 있어 더 정확한 오차의 전달이 가능하다. 신경 회로망 제어기는 직접 적응 제어의 경우와 마찬가지로 플랜트의 역 동특성을 학습하게 되어 원하는 제어 입력을 생성해낸다. 그리고 모델이 얼마나 정확하게 혼돈 비선형 시스템의 동특성을 동정하였느냐에 따라 그 모델을 이용한 오차의 변형에 정확성이 변하므로 실제 제어 성능의 결과는 모델링의 결과와 밀접한 관계가 있다. 그러므로 플랜트의 출력이 변경되기 때문에 실제 적절히 변형된 제어기의 출력단의 오차를 구하기 위해서는 동정 모델의 정확성이 매우 중요하므로 제어가 수행되는 순간에도 온 라인 동정은 동시에 수행되어야 한다^[21].

III. 모의 실험 및 결과 고찰

본 논문의 모의 실험은 연속 시간 혼돈 비선형 시스템인 Duffing 방정식과 Lorenz 방정식을 제어 대상으로 선정하였으며, Duffing 방정식의 경우는 추적 제어를 위해 기준 경로를 1 주기 해로, Lorenz 방정식의 경우는 조절 제어를 위해 기준 경로를 수렴점으로 설정하였다. 선정된 Duffing 방정식과 Lorenz 방정식이 혼돈 특성을 갖도록 하기 위해 표 2에서와 같이 파라미터를 설정하였다.

한편 본 논문에서 제안한 혼돈 시스템의 신경 회로망 제어기를 연속 시간 혼돈 시스템인 Duffing 방정식과 Lorenz 방정식에 각각 적용하여 얻어진 제어 성능을 다른 신경 회로망 제어기의 제어 성능과 비교함으로써 제안된 제어기 성능의 우수성을 입증한다. 이때 실험에서 사용된 상태 초기값은 Duffing 방정식의 경우 $(x, \dot{x}) = (0.0, 0.0)$ 이며, Lorenz 방정식의 경우 $(x, y, z) = (0.1673, 0.5651, 0.9854)$ 를 선정하였으며, 모든 실험에서 상태 초기값은 동일하다.

1. Duffing 방정식에 대한 제어 결과

Duffing 방정식은 추적 제어를 실행하기 위해 1주기 해를 기준 경로로 삼았다.

- (1) 시스템 동정
- 오프 라인 동정

표 2. 모의 실험에 사용된 플랜트 및 실험 조건
Table 2. Plants and parameters for simulations.

system	system dynamics	parameter	desired value
Duffing	$\dot{x} = y$ $y = -p_1x - x^3 - py + q\cos(ut) + u$	$\{p, p_1, q, w_1\} =$ $\{0.4, -1.1, 2.1, 1.8\}$	1 periodic solution
Lorenz	$\dot{x} = \sigma(y - x)$ $\dot{y} = rx - y - xz$ $\dot{z} = xy - bz + u$	$\{\sigma, b, r\} = \{10, 8/3, 28\}$	$(x^*, y^*, z^*) =$ $(-8.4853, -8.4853, 27)$

표 3. Duffing 방정식의 오프 라인 동정시 파라미터 설정

Table 3. Parameter values for off-line identification of Duffing equation.

NN.	neurons in model	learning rate of model	momentum of model	number of past plant	number of past input	learning iteration
MLNN	5, 5	1.0e-4	1.0e-6	2	1	180,000
SSNN	5, 5	1.0e-2	1.0e-3	2	1	90,000

동정 입력은 $1.0e^{-3}\cos(t)$ 로서 혼돈 현상이 유지되도록 충분한 값을 실험을 통해 설정하였다. 동정을 위한 신경 회로망은 2개의 은닉층을 갖는 피드 포워드 신경 회로망과 간단한 상태 공간 신경 회로망을 사용하였으며 학습 방법은 오차 역전파 방법을 사용하였다. 혼돈 비선형 시스템의 동정에 사용된 신경 회로망의 파라미터는 표 3과 같다.

사용한 간접 적응 제어의 파라미터 설정에 관한 것이다. 제어기로는 모두 다층 신경 회로망을 사용하였으며 학습 방법은 오차 역전파 방법을 사용하였다.

표 4. Duffing 방정식의 간접 적응 제어 방법시 파라미터 설정

Table 4. Parameter values for indirect adaptive control of Duffing equation.

N.N.	neurons in controller	learning rate of controller	momentum of controller	number of past plant	number of past input
MLNN	5, 5	$1.0e-2$	$1.0e-12$	2	1
SSSNN	5, 5	$1.0e-2$	$1.0e-3$	2	1

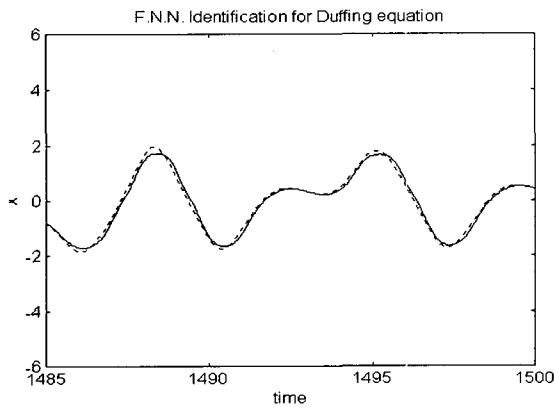


그림 8. MLNN을 사용한 오프라인 동정 결과
Fig. 8. Result of off-line identification using MLNN.




그림 9. SSSNN을 사용한 오프 라인 동정 결과
Fig. 9. Result of off-line identification using SSSNN.

그림 8과 그림 9의 비교에서 보듯이 다층 신경 회로망의 사용에 비해 간단한 상태 공간 신경 회로망의 사용이 학습 횟수가 반밖에 걸리지 않으면서도 동정 결과가 더 양호함을 알 수 있다. 동정 입력뿐만 아니라 출력의 과거 값의 선택에 따라 동정의 정확성이 결정되는데 이러한 설정은 실험을 통하여 결정되었다.

온 라인 동정 및 제어 결과

표 4는 표 3에 의해 수행된 오프 라인 동정 모델을

그림 10과 그림 11은 간접 제어시의 동정 모델의 온 라인 동정 결과를 나타낸다. 다층 신경망에 의한 결과보다 간단한 상태 공간 신경 회로망에 의한 결과가 더 우수한 것을 확인할 수 있다.

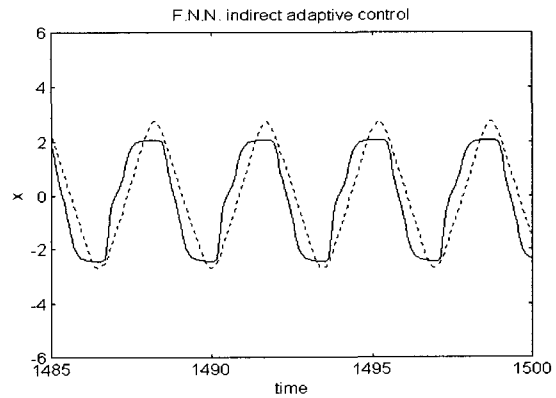


그림 10. MLNN을 사용한 온 라인 동정 결과
Fig. 10. Result of on-line identification using MLNN.

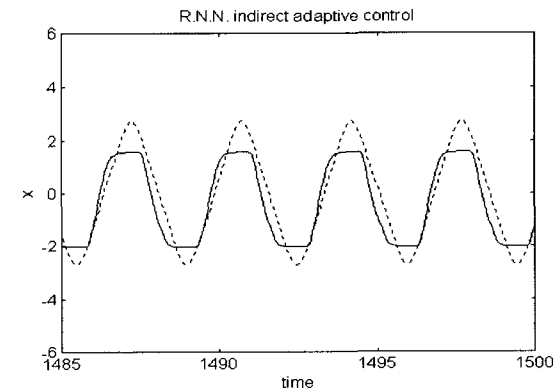


그림 11. SSSNN을 사용한 온 라인 동정 결과
Fig. 11. Result of on-line identification using SSSNN.

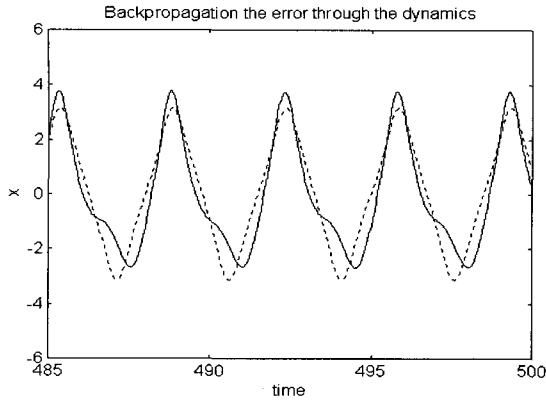


그림 12. 직접 적응 제어방법의 제어 결과
Fig. 12. Result of direct adaptive control.




그림 13. MLNN을 사용한 간접 적응 제어방법의 제어 결과
Fig. 13. Result of indirect adaptive control using MLNN.




그림 14. SSSNN을 사용한 간접 적응 제어 방법의 제어 결과
Fig. 14. Result of indirect adaptive control using SSSNN.

그림 12은 직접 적응 제어 방법의 제어 결과이며 그림 13과 그림 14는 각각 다층 신경망과 간단한 상태 공간 신경 회로망을 사용한 간접 적응 제어 방법의 제어 결과를 나타낸다.




그림 15. 직접 적응 제어 방법의 제어 입력
Fig. 15. Control input of direct adaptive control method.




그림 16. MLNN을 사용한 간접 적응 제어 방법의 제어 입력
Fig. 16. Control input of indirect adaptive control using MLNN.

직접 적응 제어 방법에 의한 제어 결과와 간접 적응 제어에 의한 제어 결과를 비교해 볼 때 간접 적응 제어가 우수한 제어 성능을 보임을 확인할 수 있다. 이러한 결과의 원인은 오차 역전파시에 모델을 사용하여 오차를 역전파시킨 간접 적응 제어 방법이 미분 이득을 이용한 오차 역전파 방법을 쓴 직접 적응 제어 방법에 비해 정확한 오차 전달이 가능하기 때문이다. 특히 시간에 따라 급격히 변하는 혼돈 현상에 대해서는 이러한 정확한 오차 전달이 매우 중요함을 증명한다.

그림 15는 직접 적응 제어시의 제어 입력을 그림 16과 그림 17은 각각 다층 신경망과 간단한 상태 공간 신경 회로망을 사용한 간접 적응 제어시의 제어 입력을 나타낸다.

제어 입력의 크기를 비교해 볼 때 직접 적응 제어 방법은 매우 큰 제어 입력을 필요로 하나 간접 적응 제어 방법은 상대적으로 매우 작은 제어 입력으로도 더 우수한 제어 성능을 보임을 알 수 있다. 특히 오차 전달이 매우 정확한 간단한 상태 공간 신경 회로망을 사용한 경우 제어 입력이 매우 작아짐을 알 수 있다.

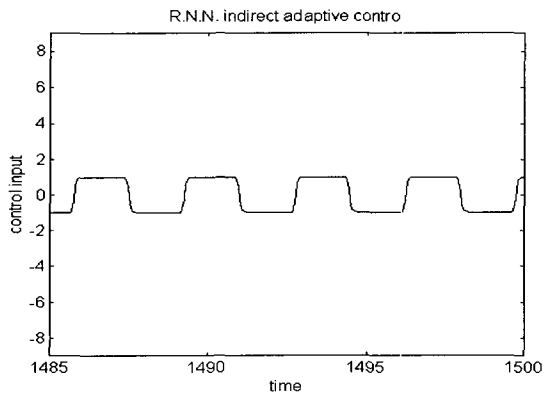


그림 17. SSSNN을 사용한 간접 적응 제어 방법의 제어 결과

Fig. 17. Result of indirect adaptive control using SSSNN.

2. Lorenz 방정식에 대한 제어 결과

Lorenz 방정식은 조절 제어를 하기 위해 평형점을 기준 경로로 하였다.

(1) 시스템 동정

오프라인 동정

Duffing 방정식과 마찬가지로 동정 입력은 $1.0e^{-3} \cos(t)$ 로서 혼돈 현상이 유지되도록 충분한 값을 실험을 통해 설정하였으며 동정을 위한 신경 회로망은 2개

의 은닉층을 갖는 피드 포워드 다층 신경 회로망과 간단한 상태 공간 신경 회로망을 사용하였으며 학습 방법은 오차 역전파 방법을 사용하였다. 혼돈 비선형 시스템의 동정에 사용된 신경 회로망의 파라미터는 표 5와 같다.

그림 18과 그림 19는 다층 신경 회로망과 간단한 상태 공간 신경 회로망을 사용한 오프 라인 동정의 결과이다.




그림 18. MLNN을 사용한 오프 라인 동정 결과

Fig. 18. Result of off-line identification using MLNN.

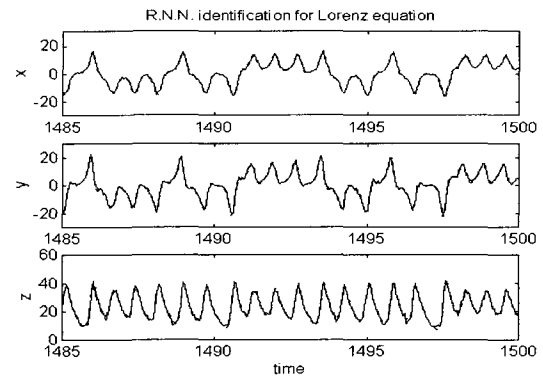


그림 19. SSSNN을 사용한 오프 라인 동정 결과

Fig. 19. Result of off-line identification using SSSNN.

표 5. Lorenz 방정식의 오프 라인 동정시 파라미터 설정

Table 5. Parameter values for off-line identification of Lorenz equation.

Method	neurons in model	learning rate of model	momentum of model	number of past plant	number of past input	learning iteration
MLNN	20, 10	1.0e-4	1.0e-9	2,2,2	1	600,000
SSSNN	20, 10	1.0e-4	1.0e-9	2,2,0	1	600,000

표 6. Lorenz 방정식의 간접 적응 제어 방법시 파라미터 설정
Table 6. Parameter values for indirect adaptive control of Lorenz equation.

Method	neurons in controller	controller learning rate	controller momentum	number of past plant	number of past input
MLNN	40, 20	1.0e-6	1.0e-6	0, 0, 0	1, 1, 1
SSSNN	40, 20	1.0e-6	1.0e-6	0, 0, 0	1, 1, 1

신호의 크기가 매우 큰 것을 고려할 때 Lorenz 방정식의 오프 라인 동정은 Duffing 방정식과 마찬가지로 우수한 결과가 나왔음을 알 수 있다.

온라인 동정 및 제어 결과

표 6은 표 5에 의해 수행된 오프 라인 동정 모델을 사용한 간접 적응 제어의 파라미터 설정에 관한 것이다. 제어기로는 모두 다층 신경 회로망을 사용하였으며 학습방법은 오차 역전파 방법을 사용하였다.

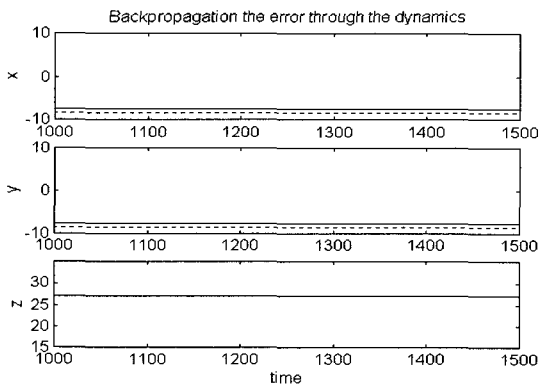


그림 20. 직접 적응 제어 방법을 사용한 제어 결과
Fig. 20. Result of direct adaptive control method.




그림 21. MLNN을 사용한 간접 적응 제어 방법의 제어 결과
Fig. 21. Result of indirect adaptive control using MLNN.

그림 20은 직접 적응 제어 방법의 제어 결과이며, 그림 21과 그림 22은 각각 다층 신경망과 간단한 상태 공간 신경 회로망을 사용한 간접 적응 제어 방법의 제어 결과를 나타낸다.




그림 22. SSSNN을 사용한 간접 적응 제어 방법의 제어 결과
Fig. 22. Result of indirect adaptive control using SSSNN.

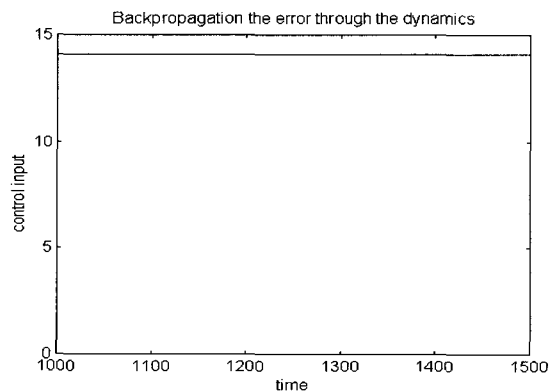


그림 23. 직접 적응 제어 방법의 제어 입력
Fig. 23. Control input of direct adaptive control method.

직접 적응 제어 방법에 의한 제어 결과와 간접 적응 제어에 의한 제어 결과를 비교해 볼 때 간접 적응 제

어의 오프 셋이 직접 적응 제어의 오프 셋에 비해 더 작은 결과를 가져왔으며 더 우수한 제어 성능을 보임을 확인할 수 있다. 그림 23는 직접 적응 제어시의 제어 입력을 그림 24과 그림 25는 각각 다층 신경망과 간단한 상태 공간 신경 회로망을 사용한 간접 적응 제어시의 제어 입력을 나타낸다.




그림 24. MLNN을 사용한 간접 적응 제어 방법의 제어 입력

Fig. 24. Control input of indirect adaptive control using MLNN.

제어 입력의 크기를 비교해 볼 때 직접 적응 제어 방법은 매우 큰 제어 입력을 필요로 하나 간접 적응 제어 방법은 상대적으로 매우 작은 제어 입력으로도 더 우수한 제어 성능을 보임을 알 수 있다. 특히 오차 전달이 매우 정확한 간단한 상태 공간 신경 회로망을 사용한 경우 제어 입력이 매우 작아짐을 알 수 있다.

표 8과 표 9는 모의 실험을 통해 획득된 혼돈 비선형 시스템에 대한 신경 회로망 제어 방법의 제어 결과를 각 혼돈 비선형 시스템별로 정리한 것이다.

표 7의 Duffing 방정식의 제어 결과에서 학습률면에

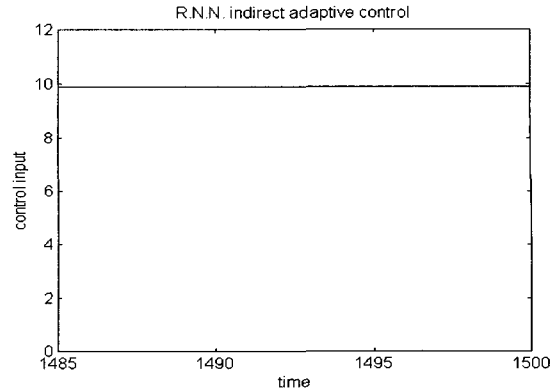


그림 25. SSSNN을 사용한 간접 적응 제어 방법의 제어 입력

Fig. 25. Control input of indirect adaptive control using SSSNN.

서 간접 적응 제어 방법이 직접 적응 제어 방법에 비해 큰 학습률을 사용할 수 있음을 알 수 있다. 또한 최소 자승 오차도 간접 적응 제어 방법이 직접 적응 제어 방법에 비해 작은 오차를 가짐을 알 수 있으며 특히 제안된 간단한 상태 공간 신경 회로망을 사용한 간접 적응 제어의 경우 매우 작은 오차를 가짐을 알 수 있으며 제어 성능을 가지기 위해 사용되는 제어 입력은 간단한 상태 공간 신경 회로망을 1로서 기준을 세울 경우 간접 적응 제어 방법이 상대적으로 작은 제어 입력임에도 불구하고 좋은 제어 성능을 가짐을 알 수 있다.

표 8의 Lorenz 방정식의 제어 결과에서도 Duffing 방정식의 결과와 마찬가지로 학습률면에서 간접 적응 제어 방법이 직접 적응 제어 방법에 비해 큰 학습률을 사용할 수 있음을 알 수 있다. 또한 오프셋(offset) 오차를 비교해 보면 제안된 간단한 상태 공간 신경 회로망을 사용한 간접 적응 제어 방법의 경우가 비교적 작

표 7. 신경 회로망을 이용한 Duffing 방정식의 제어 결과
Table 7. Results of control of Duffing equation using NN.

system	Controller learning rate	off-line Identification error (on-line error)	Control error (MSE)	Control input ratio
DAC	1.0e-7	.	0.6622	6.7559
IAC (MLNN)	1.0e-2	0.01300 (0.4155)	0.0568	1.0003
IAC (SSSNN)	1.0e-2	0.0110 (0.4124)	0.0110	1.0000

표 8. 신경 회로망을 이용한 Lorenz 방정식의 제어 결과
Table 8. Results of control of Lorenz equation using NN.

system	Controller learning rate	off-line Identification error (on-line error)	Control error	Control input ratio
DAC	1.0e-10	.	0.8782, 0.8792, 9.7870e-8	1.4294
IAC (MLNN)	1.0e-4	0.7936, 1.9308, 2.6655 (-1.8718, 2.9487, 4.1499)*e-6	-0.6223, -0.6223 2.8335e-7	1.0285
IAC (SSSNN)	1.0e-4	0.5618, 1.3980, 2.0360 (-1.3066, -1.2803, 0.1495)*e-6	-0.6044 -0.6044 -3.9827e-7	1.0000

은 값의 오프셋 오차를 나타냄을 알 수 있으며 이때 사용되는 제어 입력은 간단한 상태 공간 신경 회로망을 1로서 기준을 세울 경우 간접 적응 제어 방법이 상대적으로 작은 제어 입력에도 불구하고 좋은 제어 성능을 가짐을 알 수 있다.

이상의 결과로부터 제안된 비선형 시스템의 간접 제어 방법은 모델을 이용하지 않는 직접 적응 제어 방법에 대해 효과적인 오차 전달 방법을 통하여 제어 성능을 향상시킬 수 있었음을 확인할 수 있었다. 또한 간접 적응 제어 방법 중에서 다층 신경 회로망을 사용한 제어보다는 간단한 상태 공간 신경 회로망을 사용한 제어의 결과가 더 우수한 것으로부터 동정 모델이 혼돈 비선형 시스템의 동특성을 더 잘 반영할 수록 제어 성능이 개선된다는 점을 확인할 수 있었다.

IV. 결론

본 논문에서는 혼돈 비선형 시스템의 지능 제어를 위해 간접 적응 제어 방식에 기초한 신경 회로망 제어 기 설계 방법을 제안하였다. 본 논문에서 제안된 간접 적응 제어 방식의 신경 회로망 제어 방법은 제어 대상 혼돈 비선형 시스템의 동정에 대해 다층 신경 회로망과 간단한 상태 공간 신경 회로망을 사용한 직-병렬 동정 구조를 이용하여 오프 라인으로 동정 과정을 수행하였으며, 학습된 혼돈 비선형 시스템에 대한 신경 회로망 모델을 사용하여 온 라인으로 제어를 수행하였다. 이때 혼돈 비선형 시스템의 동정 및 제어를 위한 학습 방법은 오차 역전파 방법을 사용하였다. 한편 본

논문에서 제안된 제어 방법을 연속 시간 혼돈 비선형 시스템인 Duffing 방정식과 Lorenz 방정식에 각각 적용하여 신경 회로망을 사용한 기존의 제어 방법과 컴퓨터 모의 실험을 통해 제어 성능을 비교 및 고찰하였다.

참고 문헌

- [1] G. Chen and X. Dong, "From Chaos to Order-Perspectives and Methodologies in Controlling Chaos Nonlinear Dynamical Systems," *Int. J. Bifurcation and Chaos*, Vol. 3, No. 6, pp. 1363-1409, 1993.
- [2] E. Ott, C. Grebogi, and J. A. Yorke, "Controlling Chaos," *Phys. Rev. Lett.*, Vol. 64, No. 11, pp. 1196-1199, 1990.
- [3] E. A. Jackson and A. W. Hübler, "Periodic Entrainment of Chaotic Logistic Map Dynamics," *Physica D*, Vol. 44, pp. 407-420, 1990.
- [4] G. Chen and X. Dong, "On Feedback Control of Chaotic Continuous-Time Systems," *IEEE Trans. Circuits and Systems*, Vol. 40, No. 9, pp. 591-601, 1993.
- [5] G. Chen, "Controlling Chua's Global Unfolding Circuit Family," *IEEE Trans. Circuits and Systems*, Vol. 40, No. 7, pp. 829-832, 1993.
- [6] G. Chen and X. Dong, "On Feedback Control of


- Chaotic Nonlinear Dynamic Systems," *Int. J. Bifurcation and Chaos*, Vol. 2, No. 2, pp. 407-411, 1992.
- [7] I. J. Leontaritis and S. A. Billings, "Input-Output Parametric Models for Nonlinear Systems : Part I & II," *Int. J. Contr.*, Vol. 41, No. 2, pp. 303-353, 1985.
- [8] H. K. Qammer and F. Mossayebi, "Systems Identification and Model-Based Control of a Chaotic System," *Int. J. Bifurcation and Chaos*, Vol. 4, No. 4, pp. 843-851, 1994.
- [9] H. Nijmeijer and H. Berghuis, "On Lyapunov Control of the Duffing Equation," *IEEE Trans. Circuits and Systems*, Vol. 42, No. 8, pp. 473-477, 1995.
- [10] G. Chen and X. Dong, "Identification and Control of Chaotic Systems : An Artificial Neural Network Approach," *Proc. IEEE Int. Symposium on Circuits and Systems, Seattle, WA*, pp. 1177-1182, 1995.
- [11] H. Wang, K. Tanaka, and T. Ikeda, "Fuzzy Modelling and Control of Chaotic Systems," *IEEE Symposium on Circuit and System*, pp. 209-212, 1996.
- [12] Ted W. Frison, "Controlling Chaos with a Neural Network," *Proc. Int. Conf. on Neural Network, Baltimore, MD*, pp. 75-80, 1992.
- [13] S. H. Strogatz, *Nonlinear Dynamics and Chaos*, Addison-Wesley, 1994.
- [14] D. Psaltis, A. Sideris, and A. A. Yamamura, "A Multilayered Neural Network Controller", *IEEE Control Systems Magazine*, Vol. 4, pp. 17-21, April, 1988.
- [15] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning Internal Representations by Error Propagation", *Parallel Distributed Processing*, Vol. 1, pp. 318-362, 1986.
- [16] 오기훈, 주진만, 박광성, 박진배, 최윤호, "신경 회로망을 이용한 혼돈 비선형 시스템의 지능 제어에 관한 연구", *96한국자동제어학술회의 논문집* pp. 453-456, 1996
- [17] K. S. Narendra and K. Parthasarathy, "Identification and Control of Dynamical Systems using Neural Networks," *IEEE Trans. Neural Networks*, Vol. 1, No. 1, 1990.
- [18] L. A. Aguirre, "The Use of Identified Models in the Control of a Chaotic Circuit," *IEEE Symposium on Circuits and Systems, Seattle*, 1995.
- [19] L. B. Almeida, "Backpropagation in Non-feedforward Networks," *I. Aleksander(Ed), Neural Computing Architectures, Cambridge, MA*, MIT Press, pp. 75-91, 1989.
- [20] L. Ljung, "Issue in System Identification," *IEEE Contr. Syst. Mag.*, Vol. 11, pp. 25-29, 1991.
- [21] P. M. Mills and A. Y. Zomaya, "A Neural Network Approach to Online Identification of Nonlinear Systems," *Cybernetics and Systems*, vol. 24, pp. 171-195, 1993.

저 자 소 개



吳基薰(正會員)

1972년 2월 22일생. 1995년 연세대학교 전기공학과 학사. 1997년 동대학원 석사. 1997년~현재 LG산전 중앙연구소 Embedded System 연구팀 주임연구원. 관심분야는 내장형 시스템, Real Time OS, 지능 제어 등



朴珍培(正會員)

1977년 연세대학교 전기공학과 학사. 1985년 ~ 1990년 Kansas State University 전기 및 컴퓨터 공학과 박사. 1990년~1991년 Kansas State University 전기 및 컴퓨터 공학과 조교수. 현재 연세대학교 전기 및

컴퓨터 공학과 정교수



崔允浩(正會員)

1980년 연세대학교 전기공학과 학사. 1982년 연세대학교 대학원 전기공학과 석사. 1991년 동 대학원 박사. 현재 경기대학교 전자·기계공학부 부교수.



林桂榮(正會員)

1975년 서울대 전기공학과 학사. 1983년 뉴욕주립대 전기공학과 석사. 1985년 동대학원 박사. 1978 ~ 1981년 국방과학연구소 연구원. 1986 ~ 현재 LG산전 중앙연구소장. 상무 이사. 제어·자동화·시스템 공학회 이사. 관심분야는 Real-time control, 적응제어 등