

웨이블릿 신경 회로망을 이용한 혼돈 시스템의 일반형 예측 제어기 설계

Design of Generalized Predictive Controller Using Wavelet Neural Networks for Chaotic Systems

박상우*, 최종태*, 최윤호**, 박진배*

* 연세대학교 전기전자공학과

** 경기대학교 전자·기계공학부

요 약

본 논문에서는 혼돈 시스템을 제어하기 위해 웨이블릿 신경 회로망을 예측기로 사용하여 일반형 예측 제어기를 설계하는 방법을 제안한다. 본 논문의 방법에서는 웨이블릿 신경 회로망의 각 파라미터에 대한 학습은 예측 오차를 이용한 경사 하강법에 의해 수행되며, 제어 신호는 웨이블릿 신경 회로망의 출력과 기준 신호 사이의 제어 오차를 최소화 함으로써 생성된다. 한편, 모의 실험을 통해 본 논문에서 제안한 제어기를 각각 연속 시간 혼돈 시스템인 Duffing 시스템과 이산 시간 혼돈 시스템인 Henon 시스템에 적용하여 제어기의 효율성을 확인하고 아울러 신경 회로망을 이용한 예측 제어의 결과와 비교함으로써 제어기의 우수성을 검증한다.

Abstract

In this paper, we propose a novel predictive control method, which uses a wavelet neural network as a predictor, for the control of chaotic systems. In our method, we use the gradient descent method for training the parameter of a wavelet neural network. The control signals are directly obtained by minimizing the difference between a reference signal and the output of a wavelet neural network. To verify the efficiency of our method, we apply it to the Duffing and the Henon system, which are a representative continuous and discrete time chaotic system respectively, and compare with the results of generalized predictive control using multi-layer perceptron.

Key words : Wavelet neural networks, Generalized predictive control, Chaotic systems, Gradient descent method.

1. 서 론

혼돈(chaos) 현상은 결정론적(deterministic) 시스템에서 발생하는 현상으로서 초기 조건에 민감하고 비주기적이며 예측 불가능한 특성을 가진다. 이러한 혼돈 현상이 비선형 동역학 분야에 존재할 경우 예측 불가능성과 불규칙성으로 인해 시스템의 성능을 저하시키거나 시스템을 불안정하게 하므로 혼돈 현상을 억제 혹은 제어하고자 하는 연구들이 진행되고 있다. 그러나 혼돈 시스템에 대한 기존 제어 기법들[1]-[3]은 주기 궤도로 안정화 시키기 위해 오랜 시간이 요구되고, 시스템 파라미터를 알지 못하거나 외부로부터 섭동(perturbation)을 인가할 수 없는 혼돈 시스템에 적용하기 어려울 뿐만 아니라 혼돈 제어를 위해 제어 대상에 대한 정확한 수학적 모델이 필요한 단점을 가진다. 이러한 문제점들을 해결하기 위한 시도로서, 적응 제어 기법 중의 하나인 예측 제어를 혼돈 제어에 적용한 연구 결과가 발표되었으며, 아울

러 신경 회로망과 퍼지 논리 등에 기반한 예측 제어 이론들을 혼돈 제어에 적용한 연구들이 수행되었다[4][5]. 그러나 이와 같은 예측 제어에 기반한 기존의 혼돈 제어 방법들은 일반적으로 제어시 급격히 변하는 혼돈 특성을 정확히 반영할 수 없는 단점을 가진다.

한편, 최근에 시간과 주파수 영역에서 해석 능력이 우수한 웨이블릿 변환(wavelet transform : WT)과 신경 회로망을 결합한 웨이블릿 신경 회로망(wavelet neural network : WNN)이 제안되었고, 이를 이용하여 시스템 식별 및 제어에 적용하고자 하는 연구가 진행되고 있다[6]. 그러나 시간에 따른 급격한 신호의 변화와 넓은 대역폭에서 침투값을 갖는 혼돈 시스템에 대한 식별 및 제어에 적용한 연구는 미비한 실정이다.

따라서 본 논문에서는 혼돈 시스템에 대한 기존 지능 제어의 단점을 해결하기 위해 웨이블릿 신경 회로망에 기반한 일반형 예측 제어기 설계 방법을 제안한다. 본 논문의 방법에서는 예측기로 사용한 웨이블릿 신경 회로망의 학습을 위해서 경사 하강법(gradient descent method)을 사용하고 제어 신호는 웨이블릿 신경 회로망의 출력과 기준 신호 사이의 제어 오차를 최소화 함으로써 생성된다. 한편 본 논문에서

접수일자 : 2002년 11월 9일

완료일자 : 2003년 2월 4일

제안한 방법에 의해 설계된 일반형 예측 제어기를 대표적 연속 시간 혼돈 시스템인 Duffing 시스템과 이산 시간 혼돈 시스템인 Hénon 시스템에 각기 적용하여 제어기의 효율성을 확인하고, 아울러 기존의 신경 회로망을 사용한 일반 예측 제어기의 결과와 비교함으로써 웨이블릿 신경 회로망을 이용한 일반형 예측 제어기의 우수성을 검증하고자 한다.

2. 웨이블릿 변환과 웨이블릿 신경 회로망

웨이블릿 이론은 다중 분해 해석(multiresolution analysis) 분야에서 제안되어 주로 영상과 신호처리 등과 같은 분야에 적용되고 발전되었다[7]. 이러한 웨이블릿은 변형 인자(translation)와 확장 인자(dilation)로 구성되며, 식 (1)과 같은 웨이블릿 함수로 표현할 수 있다.

$$\phi_j(z) = \phi\left(\frac{x - m_j}{d_j}\right) \quad (1)$$

여기서, m_j 와 d_j 는 각각 j 번째 웨이블릿 노드의 변형 인자 및 확장 인자로서 실수 값을 가지며, $d_j > 0$ 이다. 또한 웨이블릿 함수의 모체 웨이블릿(mother wavelet)은 Haar 모체 웨이블릿의 변형인 가우시안(Gaussian) 함수의 1차 미분형으로서 식 (2)와 같다.

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

2.1 웨이블릿 신경 회로망

웨이블릿 신경 회로망에서 웨이블릿 함수를 결정하는 방법에는 크게 세 가지가 있다. 첫번째 방법은 직교 웨이블릿 분해(orthogonal wavelet decomposition) 이론으로부터 적절한 모체 웨이블릿을 선택하고 이때 결정되는 m 과 d 를 m 과 d 를 고정시키고 단지 웨이블릿 노드와 출력 노드 사이의 가중치만을 학습하여 갱신하는 방법이다[8]. 두번째 방법으로는 데이터의 공간 주파수 해석 방식에 의해 결정된 m 과 d 를 가지고 웨이블릿 노드와 출력 노드간의 가중치를 학습 및 갱신하는 방법으로서, 이것은 첫번째 방식과 달리 반드시 직교성을 가질 필요가 없다[9]. 마지막 방법은 m 과 d 를 임의의 실수로 두고 웨이블릿 노드와 출력 노드간의 가중치 학습과 동시에 m 과 d 를 학습 및 갱신하는 방법이다.

본 논문에서는 미지의 시스템에 적용 가능성을 보이기 위해 마지막 방법을 이용하여 혼돈 시스템에 대한 예측과 제어를 수행한다.

2.1.1 웨이블릿 신경 회로망의 구조

그림 1은 N_i 개의 입력과 1개의 출력을 갖는 웨이블릿 신경 회로망의 구조를 나타내며, 그림에서 웨이블릿 노드의 각 웨이블릿은 각 입력에 대한 모체 웨이블릿의 곱으로서 식 (3)과 같다.

$$\Phi_j(\mathbf{x}) = \prod_{k=1}^{N_i} \phi(z_{jk}), \text{ with } z_{jk} = \frac{x_{jk} - m_{jk}}{d_{jk}} \quad (3)$$

여기서, $j=1, \dots, N_w; k=1, \dots, N_i$ 이다.




그림 1. 웨이블릿 신경 회로망의 구조

또한 그림 1의 웨이블릿 신경 회로망의 최종 출력은 식 (4)와 같이 표현할 수 있다.

$$y = \psi(\mathbf{x}, \theta) = \sum_{j=1}^{N_w} c_j \Phi_j(\mathbf{x}) + a_0 + \sum_{k=1}^{N_i} a_k x_k \quad (4)$$

여기서, θ 는 학습을 통하여 갱신되는 웨이블릿 신경 회로망의 파라미터 집합으로서 다음과 같다.

$$\theta = \{m_{jk}, d_{jk}, c_j, a_k, a_0\} \quad (5)$$

2.2.2 웨이블릿 신경 회로망의 학습 방법

웨이블릿 신경 회로망의 학습은 식 (6)으로 정의된 비용 함수를 최소화하는 파라미터 집합 θ 를 구하는 것이다.

$$J = \frac{1}{2}(y(n) - \hat{y}(n))^2 = \frac{1}{2}e^2(n) \quad (6)$$

여기서, $y(n)$ 과 $\hat{y}(n)$ 은 각각 플랜트 출력과 웨이블릿 신경 회로망 출력이다.

식 (5)의 파라미터 집합은 경사 하강법에 의해 구해지며, 식 (7)과 같다.

$$\theta(n+1) = \theta(n) - \Delta\theta(n) = \theta(n) - \eta \frac{\partial J}{\partial \theta(n)} \quad (7)$$

여기서, η 는 학습률(learning rate)을 나타내고, $\frac{\partial J}{\partial \theta(n)}$ 는 $\theta(n)$ 에 대한 비용 함수의 기울기로서, 식 (8)과 같이 나타낼 수 있다.

$$\frac{\partial J}{\partial \theta(n)} = -e(n) \frac{\partial \hat{y}(n)}{\partial \theta(n)} \quad (8)$$

식 (7)과 식 (8)에 의해 식 (5)의 각 파라미터는 식 (9)에서 식 (13)까지로 재정의 될 수 있다.

- 파라미터 a_0 :

$$\frac{\partial \hat{y}(n)}{\partial a_0(n)} = 1 \quad (9)$$

- 직접 연결 파라미터 a_k :

$$\frac{\partial \hat{y}(n)}{\partial a_k(n)} = x_k, \quad k=1, \Lambda, N_i \quad (10)$$

- 연결 하중 c_j :

$$\frac{\partial \hat{y}(n)}{\partial c_j(n)} = \Phi_j(\mathbf{x}), \quad j=1, \Lambda, N_w \quad (11)$$

- 변형 인자 m_{jk} :

$$\frac{\partial \hat{y}(n)}{\partial m_{jk}(n)} = -\frac{c_j}{d_{jk}} \frac{\partial \Phi_j}{\partial z_{jk}}, \quad k=1, \Lambda, N_i; j=1, \Lambda, N_w \quad (12)$$

여기서, $\frac{\partial \Phi_j}{\partial z_{jk}} = \phi(z_{j1})\phi(z_{j2})\cdots\phi'(z_{jk})\cdots\phi(z_{jN_i})$ 이고, $\phi'(z_{jk}) = (z_{jk}^2 - 1) \exp\left(-\frac{1}{2}z_{jk}^2\right)$ 이다.

- 확장 인자 d_{jk} :

$$\frac{\partial \hat{y}(n)}{\partial d_{jk}(n)} = -\frac{c_j}{d_{jk}} z_{jk} \frac{\partial \Phi_j}{\partial z_{jk}}, \quad k=1, \Lambda, N_i; j=1, \Lambda, N_w \quad (13)$$

식 (9)에서 식 (13)의 각 파라미터 벡터는 식 (7)에 의해 반복 수행함으로써 학습 및 갱신된다.

3. WNN을 이용한 예측 제어기 설계

웨이블릿 신경 회로망 구조를 이용한 혼돈 비선형 시스템에 대한 예측은 시스템의 출력 $y(n)$ 과 웨이블릿 신경 회로망의 출력 $\hat{y}(n)$ 사이의 오차를 이용하여 각 파라미터들을 학습시킴으로써 주어진 시스템에 대한 예측이 수행되며, 제어의 경우는 기준 신호 $y_r(n)$ 과 플랜트 출력 $y(n)$ 의 차로 정의되는 제어 오차 $e_c(n)$ 을 이용하여 제어 신호를 생성한다. 그림 2는 웨이블릿 신경 회로망을 사용한 예측 제어기의 구조를 나타낸다.

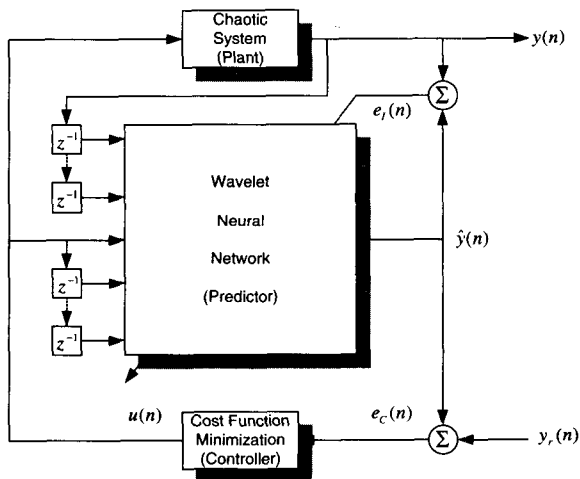


그림 2. WNN을 이용한 예측 제어기 구조

웨이블릿 신경 회로망을 이용한 예측기의 입력은 플랜트 출력의 과거 값 $y(n)$ 과 제어 입력 신호 $u(n)$ 로 구성되며, 식 (14)와 같다.

$$\hat{y}(n) = f(y(n-1), y(n-2), \Lambda, y(n-N_s), u(n-2), u(n-1), \Lambda, u(n-N_e)) \quad (14)$$

예측 제어기의 설계를 위한 비용 함수는 식 (15)과 같이 정의된다.

$$J = \frac{1}{2}(e_c^2(n+1) + \lambda \Delta u^2(n)) \quad (15)$$

여기서, λ 는 제어 신호의 가중치 이며, $e_c(n+1)$ 은 제어 오차 신호로서 식 (16)과 같이 정의된다.

$$e_c(n+1) = \hat{y}(n+1) - y_r(n+1) \quad (16)$$

여기서, $y_r(n+1)$ 은 기준 신호이다.

그림 1의 웨이블릿 신경 회로망을 이용하여 식 (4)를 다시 나타내면, 예측된 출력은 식 (17)과 같이 된다.

$$\hat{y}(n+1) = \sum_{j=1}^{N_w} c_j \Phi_j(\mathbf{x}) + a_0 + \sum_{k=1}^{N_i} a_k x_k \quad (17)$$

식 (15)의 비용 함수 J 를 최소화하기 위해 제어 신호 $u(n)$ 은 경사 하강법에 의해 반복적으로 계산되며, 식 (18)에 의해 갱신된다.

$$u(n+1) = u(n) - \eta \frac{\partial J}{\partial u(n)} \quad (18)$$

여기서, $\eta > 0$ 은 학습률로서 웨이블릿 신경 회로망의 출력 $\hat{y}(n)$ 을 기준 신호 $y_r(n)$ 으로 점근적으로 근사화하는데 사용된다.

식 (18)의 $\frac{\partial J}{\partial u(n)}$ 은 제어 신호 $u(n)$ 에 대한 비용 함수의 편미분 값으로서, 식 (19)에 의해 구해진다.

$$\frac{\partial J}{\partial u(n)} = e_c(n+1) \frac{\partial \hat{y}(n+1)}{\partial u(n)} + \lambda \Delta u(n) \quad (19)$$

여기서, $\frac{\partial \hat{y}(n+1)}{\partial u(n)}$ 은 제어 신호 $u(n)$ 에 대한 웨이블릿 신경 회로망의 기울기(gradient)로서 식 (20)으로 주어진다.

$$\begin{aligned} \frac{\partial \hat{y}(n+1)}{\partial u(n)} &= \sum_{j=1}^{N_w} c_j \frac{\partial \Phi_j(\mathbf{x})}{\partial u(n)} + a_k \Big|_{k=N_s+1} \\ &= \sum_{j=1}^{N_w} \left[\frac{c_j}{d_{jk}} \frac{\partial \Phi_j(\mathbf{x})}{\partial z_{jk}} \frac{\partial \mathbf{x}}{\partial u(n)} \right] + a_k \Big|_{k=N_s+1} \end{aligned} \quad (20)$$

여기서, $\frac{\partial J}{\partial u(n)} = [0, 0, \dots, 1, 0, \dots, 0]^T$ 이다.

따라서 식 (18)은 식 (21)로 나타낼 수 있다.

$$\begin{aligned}
 u(n+1) &= u(n) - \eta \frac{\partial J}{\partial u(n)} \\
 &= u(n) - \eta \left(e_c(n+1) \sum_{j=1}^N \left[\frac{c_j}{d_{jk}} \frac{\partial \Phi_j(\mathbf{x})}{\partial \mathbf{x}} \frac{\partial \mathbf{x}}{\partial u(k)} \right] \right. \\
 &\quad \left. + a_k \Big|_{k=N, +1} + \lambda \Delta u(n) \right) \quad (21)
 \end{aligned}$$

여기서, $\frac{\partial \Phi_j(x)}{\partial z_{jk}}$ 는 $\phi(z_{j1})\phi(z_{j2})\cdots\phi'(z_{jk})\cdots\phi(z_{jNi})$ 로 정의되고 $\phi'(z_{jk})$ 는 지점 z_{jk} 에서 모체 웨이블릿의 미분값으로 식 (22)와 같이 정의된다.

$$\phi'(z_{jk}) = \frac{d\phi(z_{jk})}{dz_{jk}} = (z_{jk}^2 - 1) \exp\left(-\frac{1}{2}z_{jk}^2\right) \quad (22)$$

이상은 단단계 예측의 경우이며, 다단계 예측의 경우 기준 신호와 시스템 출력, 제어 오차는 각각 식 (23), 식 (24) 및 식 (25)와 같이 벡터로 정의할 수 있다.

$$\mathbf{R}_{N|n} = [r_{n+1}, r_{n+2}, \Lambda, r_{n+N}]^T \quad (23)$$

$$\hat{\mathbf{Y}}_{N|n} = [\hat{y}_{n+1}, \hat{y}_{n+2}, \Lambda, \hat{y}_{n+N}]^T \quad (24)$$

$$\mathbf{E}_{N|n} = [e_{n+1}, e_{n+2}, \Lambda, e_{n+N}]^T \quad (25)$$

또한, 제어 신호는 식(26)와 같이 정의된다.

$$\mathbf{U}_{N|n} = [u_n, u_{n+1}, \Lambda, u_{n+N-1}]^T \quad (26)$$

식 (18)은 식 (27)과 같다.

$$\mathbf{U}_{N|n+1} = \mathbf{U}_{N|n} - \eta \mathbf{D}_{N|n} \quad (27)$$

여기서, $\mathbf{D}_{N|n}$ 은 식 (28)과 같다.

$$\mathbf{D}_{N|n} = \frac{\partial J}{\partial \mathbf{U}_{N|n}} = \frac{\partial \hat{\mathbf{Y}}_{N|n}}{\partial \mathbf{U}_{N|n}} \mathbf{E}_{N|n} + \lambda \mathbf{M} \Delta \mathbf{U}_{N|n} \quad (28)$$

또한, 제 \mathbf{M} 은 다음과 같이 정의될 수 있다. 어 신호의 차를 생성하기 위해

$$\mathbf{M} = \begin{bmatrix} 1 & -1 & 0 & \Lambda & 0 \\ 0 & 1 & -1 & 0 & \mathbf{M} \\ \mathbf{M} & 0 & 0 & -1 & 0 \\ \mathbf{M} & \mathbf{M} & 0 & 1 & -1 \\ 0 & 0 & \Lambda & 0 & 1 \end{bmatrix}$$

따라서, 식 (28)의 $\frac{\partial \hat{\mathbf{Y}}_{N|n}}{\partial \mathbf{U}_{N|n}}$ 는 식 (29)로 다시 나타낼 수 있다.

$$\frac{\partial \hat{\mathbf{Y}}_{N|n}}{\partial \mathbf{U}_{N|n}} = \begin{bmatrix} \frac{\partial \hat{y}_{n+1}}{\partial u_n} & \frac{\partial \hat{y}_{n+2}}{\partial u_n} & \Lambda & \frac{\partial \hat{y}_{n+N}}{\partial u_n} \\ 0 & \frac{\partial \hat{y}_{n+2}}{\partial u_{n+1}} & \Lambda & \frac{\partial \hat{y}_{n+N}}{\partial u_{n+1}} \\ \mathbf{M} & \mathbf{M} & \mathbf{O} & \mathbf{M} \\ 0 & 0 & \Lambda & \frac{\partial \hat{y}_{n+N}}{\partial u_{n+N-1}} \end{bmatrix} \quad (29)$$

식 (29)의 N 차 예측에 사용되는 제어 신호의 유도 과정은 부록에 기술한다.

본 논문에서 사용된 웨이블릿 신경 회로망을 이용한 혼돈 시스템의 예측 제어기 수행 과정을 단계별로 서술하면 다음과 같다.

- 단계 1 : 웨이블릿 신경 회로망과 제어기의 파라미터를 초기화한다.

$$\begin{aligned}
 \{a_0, a_k, c_j, m_{jk}, d_{jk}\} &= \{1, a_k, c_j, m_{jk}, d_{jk}\} \\
 &= \{random\}
 \end{aligned}$$

$$u(n) = 0$$

- 단계 2 : 혼돈 비선형 시스템의 출력 $y(n)$ 과 웨이블릿 신경 회로망의 출력 $\hat{y}(n)$ 의 차로 정의된 예측 오차 $e_f(n)$ 을 계산한다.

$$e_f(n) = y(n) - \hat{y}(n)$$

- 단계 3 : 예측 오차 $e_f(n)$ 을 이용하여 웨이블릿 신경 회로망의 각 파라미터를 경사 하강법을 통해 학습, 갱신한다.

$$\theta(n+1) = \theta(n) - \eta \frac{\partial J}{\partial \theta(n)}$$

- 단계 4 : 웨이블릿 신경 회로망의 출력 $\hat{y}(n)$ 과 원하는 기준 신호 $y_r(n)$ 사이의 오차인 제어 오차 $e_c(n)$ 를 계산한다.

$$e_c(n) = \hat{y}(n) - y_r(n)$$

- 단계 5 : 제어 오차를 이용하여 일반형 예측 제어기의 출력인 혼돈 시스템의 제어 입력을 경사 하강법으로 갱신한다.

$$u(n+1) = u(n) - \eta \frac{\partial J}{\partial u(n)}$$

- 단계 6 : 제어 오차가 허용된 오차 범위 이내의 값을 가질 때 까지 단계 2에서 단계 6까지 반복 수행한다.

식 (29)으로부터 얻어진 제어 신호 벡터 $\mathbf{U}_{N|n}$ 에서 단지 첫 번째 항만이 실제 혼돈 시스템의 제어 신호로 사용된다.

4. 모의 실험

본 논문에서는 제안된 예측 제어기의 성능을 평가하기 위

해 대표적 연속시간 혼돈 시스템인 Duffing 시스템과 이산시간 혼돈 시스템인 Hénon 시스템에 대해 각기 모의 실험을 수행하였다.

각각의 혼돈 시스템에 대한 상태 방정식과 선택된 파라미터는 식 (30), 식(31), 식(32) 및 식 (33)과 같다.

• Duffing 시스템

$$\begin{bmatrix} \dot{x}(t) \\ \dot{y}(t) \end{bmatrix} = \begin{bmatrix} y \\ -p_1x(t) - x^3(t) - py(t) + q\cos(wt) \end{bmatrix} \quad (30)$$

$$\{p, p_1, q, w\} = \{0.4, -1.1, 2.1, 1.8\} \quad (31)$$

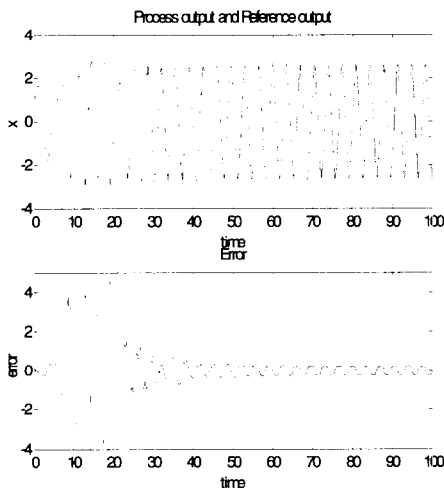
• Hénon 시스템

$$\begin{bmatrix} x_{n+1} \\ y_{n+1} \end{bmatrix} = \begin{bmatrix} y_n + 1 - ax_n^2 \\ bx_n \end{bmatrix} \quad (32)$$

$$\{a, b\} = \{1.4, 0.3\}, \{x_0, y_0\} = \{0, 0\} \quad (33)$$

본 논문 모의 실험에서는 은닉층의 웨이블릿 노드 수는 5개, 샘플링 주기 및 학습률은 0.05초와 0.1로 모두 동일하게 선정하였다.

그림 3은 웨이블릿 신경 회로망을 이용한 Duffing 시스템에 대한 예측 제어 결과이다. 기준 신호는 Duffing 시스템의 1주기 해로 선정하였다. 그림 3의 제어 결과로 웨이블릿 신경 회로망을 이용한 예측 제어의 경우 기준 신호에 대한 평균 제곱 오차는 0.054이며, 약 34초 이후에 기준 신호에 정확히 수렴함을 확인할 수 있다. 한편, 그림 4는 신경 회로망을 이용한 예측 제어 결과이며, 이 경우 기준 신호에 대한 평균 제곱 오차는 0.821이고, 수렴에 도달하는 시간은 약 64초이다. 따라서 본 논문의 예측 제어 결과가 신경 회로망을 이용한 예측 제어 결과 보다 더 우수함을 확인할 수 있다.

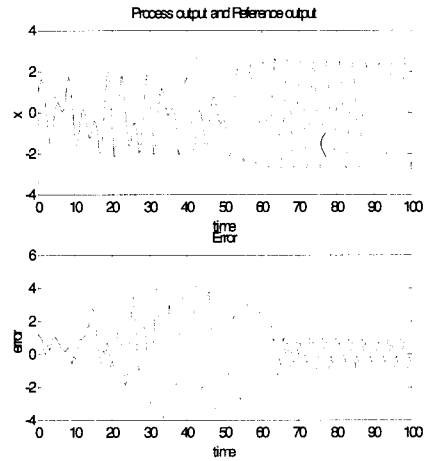


(실선 : WNN 출력, 점선 : 기준 신호)

그림 3. WNN을 이용한 Duffing 시스템 제어 결과

그림 5는 Hénon 시스템에 대한 예측 제어 결과이며, 이때 기준 신호는 상태 x 는 0, 상태 y 는 -1이다. Hénon 시스템의 경우, 웨이블릿 신경 회로망을 이용한 예측 제어는 약 60 스텝 후에 상태 x 가 기준 신호에 수렴하고, 또한 상태 y 는

약 70 스텝 후에 정확히 기준 신호에 수렴하였다. 또한 기준 신호에 대한 평균 제곱 오차는 상태 x 와 상태 y 에 대해 각각 0.000819와 0.000821이다. 한편 신경 회로망을 이용한 예측 제어 결과는 그림 6과 같으며, 상태 x 의 경우 기준 신호에 대한 평균 제곱 오차는 0.00529이며, 약 245 스텝 후에 수렴하였다. 또한 상태 y 의 경우 기준 신호에 대한 평균 제곱 오차는 0.00601이고 약 245 스텝 후에 수렴함을 확인할 수 있었다. 따라서 Hénon 시스템의 경우도 웨이블릿 신경 회로망을 이용한 제어기가 신경 회로망을 사용한 제어기보다 더 우수한 제어 성능을 가짐을 확인할 수 있다.



(실선 : NN 출력, 점선 : 기준 신호)

그림 4. NN을 이용한 Duffing 시스템 제어 결과




그림 5. WNN을 이용한 Hénon 시스템 제어 결과

웨이블릿 신경 회로망과 신경 회로망을 사용한 예측 제어의 경우, Duffing 시스템과 Hénon 시스템에 대한 예측 및 제어 평균 제곱 오차는 각기 표 1, 표 2와 같다. 표들로부터, 웨이블릿 신경 회로망을 사용한 예측 제어기가 신경 회로망을 사용한 예측 제어기에 비해 더 우수한 예측 성능과 제어 성능을 가짐을 확인할 수 있다.




그림 6. NN을 이용한 Hénon 시스템 제어 결과

표 1. Duffing 시스템에 대한 제어 결과

	예측 MSE	제어 MSE
WNN	0.000422	0.054
NN	0.0092	0.821

표 2. Hénon 시스템에 대한 제어 결과

	웨이블릿 신경 회로망		신경 회로망	
	상태 x	상태 y	상태 x	상태 y
예측 MSE	0.000195	0.000342	0.00375	0.00841
제어 MSE	0.000819	0.000821	0.000529	0.00601

5. 결 론

본 논문에서는 혼돈 시스템의 지능 제어를 위해 일반형 예측 제어 기법에 기반하여 웨이블릿 신경 회로망을 이용한 제어기 설계 방법을 제안하였다. 시스템에 대한 예측은 혼돈 비선형 시스템의 출력과 웨이블릿 신경 회로망의 출력의 차를 이용하였고, 제어 신호는 기준 신호와 웨이블릿 신경 회로망의 차를 통해 생성하였다. 웨이블릿 신경 회로망과 제어기의 학습은 각 파라미터에 대한 비용 함수의 편미분을 사용하는 경사 하강법에 의해 온라인으로 수행하였다.

본 논문에서 제안한 제어기의 성능 평가를 위해, 모의 실험을 통해 연속 시간 혼돈 시스템인 Duffing 시스템과 이산 시간 혼돈 시스템인 Hénon 시스템에 각기 적용한 결과, 제어기가 혼돈 시스템을 효율적으로 제어함을 확인할 수 있었다. 또한 모의 실험을 통해 얻어진 제어 결과를 신경 회로망을 사용한 예측 제어기와 비교한 결과, 본 논문의 제어 방법이 기존의 혼돈 제어 방법에 비해 더 우수한 제어 성능을 가짐을 확인할 수 있었다.

참 고 문 헌

- [1] E. Ott, C. Grebogi and J. A. Yorke, "Controlling Chaos," *Phys. Rev. Lett.*, Vol. 64, No. 11, pp. 1196-1199, 1990.
- [2] E. A. Jackson and A. W. Hübler, "Periodic Entrainment of Chaotic Logistic Map Dynamics," *Physica D*, Vol. 44, Issue 3, pp. 407-420, 1990.
- [3] G. Chen and X. Dong, "On Feedback Control of Chaotic Continuous-Time Systems," *IEEE Trans. on Circuits and Systems*, Vol. 40, No. 9, pp. 591-601, 1993.
- [4] K. S. Park, J. B. Park, Y. H. Choi, T. S. Yoon and G. Chen, "Generalized Predictive Control of Discrete-Time Chaotic Systems," *Intl J. of Bifur. and Chaos*, Vol. 8, No. 7, pp. 1591-1597, 1998.
- [5] 오기훈, 최윤호, 박진배, 임계영 "연속 시간 혼돈 비선형 시스템을 위한 신경 회로망 제어기의 설계," *전자공학회 논문집*, 39권, 1호, pp. 51-65, 2002.
- [6] Y. Oussar, I. Rivals, L. Personnaz and G. Dreyfus, "Training Wavelet Networks for Nonlinear Dynamic Input-Output Modeling," *Neurocomputing*, Vol. 20, Issues 1-3, pp. 173-188, 1998.
- [7] S. Mallat, *Wavelet Tour of Signal Processing*, Academic Press, 1999.
- [8] S. Mallat, "A Theory for Multiresolution Signal Decomposition : The Wavelet Transform," *IEEE Trans. on Pattern Anal. Machine Intell.*, Vol. 11, Issue 7, pp. 674-693, 1989.
- [9] M. Cannon, J. J. E. Slotine, "Space-Frequency Localized Basis Networks for Nonlinear System Estimation and Control," *Neurocomputing*, Vol. 9, Issue 3, pp. 293-342, 1995.

부 록

N 차 예측의 경우 사용되는 예측 제어 신호의 생성 과정은 다음 식들로 나타낼 수 있다. 여기서 앞의 괄호는 식(29)의 행렬 위치를 의미한다.

$$(1.N) \frac{\partial \hat{y}(n+N)}{\partial u(n)} = \sum_{k=1}^N \sum_{j=1}^N \left[\frac{c_j}{d_{\mu}} \frac{\partial \Phi_j(\mathbf{x})}{\partial z_{\mu}} \frac{\partial x_i}{\partial u(n)} \right] = \frac{\partial \hat{y}(n+N)}{\partial \mathbf{x}} \frac{\partial \mathbf{x}}{\partial u(n)}$$

$$= \begin{bmatrix} \frac{\partial \hat{y}(n+N)}{\partial x_1} & \frac{\partial \hat{y}(n+N)}{\partial x_2} & \dots & \frac{\partial \hat{y}(n+N)}{\partial x_N} \end{bmatrix} \begin{bmatrix} 0 \\ \frac{\partial \hat{y}(n+N-1)}{\partial u(n)} \\ \frac{\partial \hat{y}(n+N-2)}{\partial u(n)} \\ \vdots \\ \frac{\partial \hat{y}(n+1)}{\partial u(n)} \\ 0 \\ \vdots \\ 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$(2, N) \frac{\partial \hat{y}(n+3)}{\partial u(n+1)} = \sum_{k=1}^N \sum_{j=1}^N \left[\frac{c_j}{d_{jk}} \frac{\partial \Phi_j(\mathbf{x})}{\partial z_{jk}} \frac{\partial x_k}{\partial u(n)} \right] = \frac{\partial \hat{y}(n+N)}{\partial \mathbf{x}} \frac{\partial \mathbf{x}}{\partial u(n+1)}$$

$$= \begin{bmatrix} \frac{\partial \hat{y}(n+N)}{\partial x_1} & \frac{\partial \hat{y}(n+N)}{\partial x_2} & \dots & \frac{\partial \hat{y}(n+N)}{\partial x_N} \end{bmatrix} \begin{bmatrix} 0 \\ \frac{\partial \hat{y}(n+N-1)}{\partial u(n+1)} \\ \frac{\partial \hat{y}(n+N-2)}{\partial u(n+1)} \\ \vdots \\ \frac{\partial \hat{y}(n+2)}{\partial u(n+1)} \\ 0 \\ \vdots \\ 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$(3, N) \frac{\partial \hat{y}(n+3)}{\partial u(n+2)} = \sum_{k=1}^N \sum_{j=1}^N \left[\frac{c_j}{d_{jk}} \frac{\partial \Phi_j(\mathbf{x})}{\partial z_{jk}} \frac{\partial x_k}{\partial u(n)} \right] = \frac{\partial \hat{y}(n+N)}{\partial \mathbf{x}} \frac{\partial \mathbf{x}}{\partial u(n+2)}$$

$$= \begin{bmatrix} \frac{\partial \hat{y}(n+N)}{\partial x_1} & \frac{\partial \hat{y}(n+N)}{\partial x_2} & \dots & \frac{\partial \hat{y}(n+N)}{\partial x_N} \end{bmatrix} \begin{bmatrix} 0 \\ \frac{\partial \hat{y}(n+N-1)}{\partial u(n+2)} \\ \frac{\partial \hat{y}(n+N-2)}{\partial u(n+2)} \\ \vdots \\ \frac{\partial \hat{y}(n+3)}{\partial u(n+2)} \\ 0 \\ \vdots \\ 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$\vdots$$

$$(N, N) \frac{\partial \hat{y}(n+N)}{\partial u(n+N-1)} = \sum_{k=1}^N \sum_{j=1}^N \left[\frac{c_j}{d_{jk}} \frac{\partial \Phi_j(\mathbf{x})}{\partial z_{jk}} \frac{\partial x_k}{\partial u(n)} \right] = \frac{\partial \hat{y}(n+N)}{\partial \mathbf{x}} \frac{\partial \mathbf{x}}{\partial u(n+N-1)}$$

$$= \begin{bmatrix} \frac{\partial \hat{y}(n+N)}{\partial x_1} & \frac{\partial \hat{y}(n+N)}{\partial x_2} & \dots & \frac{\partial \hat{y}(n+N)}{\partial x_N} \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

여기서,

$\mathbf{x} = [1 \ \hat{y}(n+N-1) \ \hat{y}(n+N-2) \ \wedge \ \hat{y}(n+1) \ y(n) \ \wedge \ y(n+N-N) \ u(n+N-1) \ \dots \ u(n+2)u(n+1)u(n) \ \dots \ u(n+N-N_c)]^T$ 이다.

저 자 소 개



박상우(Sang Woo Park)

2001년 : 경기대학교 전자공학과 졸업(학사)
2001년~현재 : 연세대학원 전기 전자 공학과 석사과정

관심분야 : 지능제어, 웹 기반 제어 시스템, 강인제어

Phone : 02-2123-2773

Fax : 02-362-4539

E-mail : swpark@control.yonsei.ac.kr



최종태(Jong Tae Choi)

1998년 : 경기대학교 전자공학과 졸업(학사)
2000년 : 동 대학원 졸업(석사)
2000년~현재 : 연세대학원 전기전자공학과 박사과정

관심분야 : 지능 제어 알고리즘, 적응 제어, 강인 제어

Phone : 02-2123-2773

Fax : 02-362-4539

E-mail : jtchoi@control.yonsei.ac.kr



최운호(Yoon Ho Choi)

1980년 : 연세대학교 전기공학과 졸업(학사)
1982년 : 동 대학원 졸업(석사)
1991년 : 동 대학원 졸업(박사)
1993~현재 : 경기대학교 전자·기계공학부 부교수

2000년~2002년 : 미국 오하이오 주립대학교 방문교수

2003년~현재 : 제어자동화시스템 공학회 이사

관심분야 : 지능제어, 혼돈제어, 강인제어 및 필터, 이동로봇

Phone : 031-249-9801

Fax : 031-249-9796

E-mail : yhchoi@kyonggi.ac.kr



박진배(Jin Bae Park)

1977년 : 연세대학교 전기공학과 졸업(학사)
1990년 : Kansas State University 전기 및 컴퓨터 공학과 졸업(공학박사)

1990년~1991년 : Kansas State University 전기 및 컴퓨터공학과 조교수

1994년~현재 : 연세대학교 전기 전자 공학과 교수

2000년~현재 : 대한전기학회 평의원, 편집이사

2000년~현재 : 제어자동화시스템 공학회 이사

관심분야 : 강인제어, 지능제어, 필터링 이론, 이동로봇

Phone : 02-2123-2773

Fax : 02-362-4539

E-mail : jbpark@yonsei.ac.kr