

유전 알고리듬 기반 웨이블릿 신경 회로망을 이용한 혼돈 시스템의 간접 적응 제어

김경주, 최종태, *최윤호, 박진배
연세대학교 전기전자공학과, *경기대학교 전자공학부

Indirect Adaptive Control Using Wavelet Neural Networks with Genetic Algorithm

Kyung Ju Kim, Jong Tae Choi, *Yoon Ho Choi, Jin Bae Park
Dept. of Electrical and Electronic Engineering, Yonsei University
*School of Electronic Engineering, Kyonggi University

Abstract - 본 논문에서는 혼돈 비선형 시스템의 지능 제어를 위해 간접 적응 제어 기법에 기반한 웨이블릿 신경 회로망 제어기 설계 방법을 제안한다. 제어기 성능에 큰 영향을 미칠 수 있는 웨이블릿 신경 회로망 구조의 파라미터 동정은 본질적으로 강인하고 전역 최적해에 근사한 값을 결정할 수 있는 유전 알고리듬을 사용한다. 본 논문에서 제안한 제어 방법은 유전 알고리듬을 이용한 혼돈 비선형 시스템의 오프라인 동정 모델 및 기준 신호와 플랜트 출력으로 정의되는 제어 오차를 이용하여 원하는 제어 입력을 생성한다. 한편 본 논문에서 제안한 웨이블릿 신경 회로망 제어기를 대표적인 연속 시간 혼돈 비선형 시스템인 Duffing 시스템에 적용하여 설계된 제어기의 효율성 및 우수성을 검증하고자 한다.

1. 서 론

혼돈(chaos) 현상은 초기 조건에 민감하며 비주기적이고 예측 불가능하다. 이러한 혼돈 현상을 제어하기 위한 기존의 제어 방법[1,2,3]들은 시스템의 정확한 수학적 모델이나 비선형 방정식을 필요로 하므로, 물리적으로 정확한 모델을 알 수 없는 시스템에 적용하기 힘든 단점이 있다. 이러한 기존 제어 방법의 단점을 극복하기 위해 파라미터 추정을 통한 동정 모델을 생성하여 제어하는 적용 제어 기법과[4], 신경 회로망, 퍼지 이론 등이 도입되었다[5]. 그러나 신경 회로망이나 퍼지 이론을 이용한 경우 국부 최소치에 빠지거나, 사용자의 경험 부족으로 혼돈 시스템에 적용하기 어려운 점이 있다[8]. 따라서 시간 및 주파수 특성의 해석 능력이 우수한 웨이블릿 변환을 이용한 지능 제어 연구가 진행되고 있다[6].

본 논문에서는 본질적으로 강인하고 전역 탐색 알고리듬인 유전 알고리듬(Genetic Algorithm : GA)[9]을 이용한 간접 적응 제어 방법을 제안한다. 한편 설계된 웨이블릿 신경 회로망(Wavelet Neural Network : WNN) 제어기를 실제 시스템에 적용하기 위해 컴퓨터 사물레이션을 통하여 이의 적용 가능성을 보이고자 한다.

2. 본 론

2.1 웨이블릿 신경 회로망

웨이블릿 이론은 1980년대 초 다해상도 해석(multi-resolution analysis) 분야에서 푸리에(Fourier) 해석의 단점을 보완하기 위하여 Mallet에 의해 최초로 제안되었다[7]. 이동(translation) 인자와 확장(dialation) 인자로 구성되는 웨이블릿은 식 (1)과 같이 모체 웨이블릿(mother wavelet) 함수로 구성된다.

$$\phi(z) = \phi\left(\frac{z-m}{d}\right) \quad (1)$$

여기서, m 과 $d(>0)$ 는 각각 이동, 확장 인자를 나타내며, 모체 웨이블릿은 식 (2)와 같은 가우시안(Gaussian) 함수의 1차 미분형이다.

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

그림 1은 N_w 개의 입력과 1개의 출력을 갖는 WNN의 구조를 나타낸다.

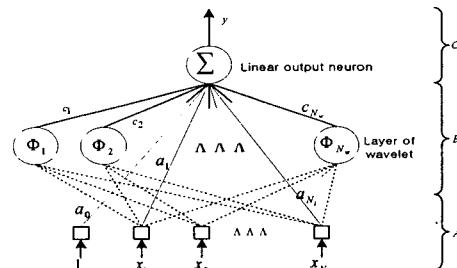


그림 1 웨이블릿 신경 회로망의 구조

그림 1에서 웨이블릿 노드(B)의 각 웨이블릿은 식 (3)과 같이 각 입력에 대한 모체 웨이블릿의 곱으로 표현된다.

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

여기서, $k = 1, \dots, N_i$, $j = 1, \dots, N_w$ 이며, N_i 는 입력의 수, N_w 는 웨이블릿 노드의 웨이블릿 수이다.

그림 1에서 WNN의 출력 값은 식 (4)와 같이 입력, 웨이블릿 및 각 파라미터들로 구성된다.

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

여기서, a_0 와 a_k 는 입력 노드와 출력 노드 사이의 가중치(weighting), c_j 는 웨이블릿 노드와 출력 노드 사이의 가중치이고 θ 는 학습을 통하여 생성되는 WNN의 파라미터 집합이다.

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

2.2 유전 알고리듬

유전 알고리듬은 본질적으로 강인하고 전역 최적해에 대한 근사값을 결정할 수 있으며, 풀고자하는 문제에 대한 가능한 해들을 염색체로 표현하고 이를 적당한 알고리듬에 의해 변형하여 최적해를 구해나간다.

각 개체는 풀고자 하는 문제의 해에 관한 정보를 가지며, 이는 각각의 정보를 2진수화 해서 나열된 비트형태의 스트링으로 표현된다. 이러한 스트링은 염색체(chromosome)라고 불린다. 이런 염색체들은 재생산(reproduction), 교차(crossover), 돌연 변이(mutation) 연산자

들에 의해서 다음 세대로 정보를 전달한다.

이 같은 독특한 연산구조 때문에 유전 알고리듬은 기존의 최적화 방법과 다른 몇 가지 차이점을 나타낸다. 유전 알고리듬은 최적화되어야 할 요소 자체가 아닌 그 요소의 염색체 표현에 근거하여 동작하고, 임의로 생성된 개체들의 군을 사용하여 가능한 해를 탐색한다. 또한, 적합도 함수를 이용하여 탐색의 방향을 정한다.

이러한 유전 알고리듬의 특징은 다양한 분야에서 유전 알고리듬을 사용할 수 있게 한 원인이 된다.

2.3 간접 적응 제어

2.3.1 시스템의 동정 및 학습방법

시스템 동정의 구조는 모델 출력의 과거 값을 모델 입력을 사용하는 병렬 동정 구조와 플랜트 출력의 과거 값을 모델 입력으로 사용하는 직-병렬 동정 구조가 있다. 본 논문에서는 양호한 성능과 수렴성을 내포하는 모델인 직-병렬 동정 구조를 이용하여 혼돈 비선형 시스템을 동정한다.

학습을 통해 생성되는 웨이블릿 신경 회로망의 파라미터 $a_0, a_k, c_j, m_{jk}, d_{jk}$ 는 유전 알고리듬에 맞게 각각 2진수로 변환되어, 그림 2와 같이 연속된 2진수 스트링으로 표시된다. 이렇게 표현된 하나의 스트링은 각각 하나의 개체를 이루고, 이런 개체가 여러 개 모여서 한 세대를 이룬다.

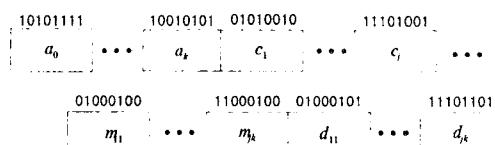


그림 2 웨이블릿 파라미터의 유전자 표현

동정오차 e_m 은 $e_m = y_p - y_m$ 으로 정의되고, 유전 알고리듬의 적합도 함수는 전체 시간 구간에 대한 동정오차의 Mean Square Error(MSE) 값으로 설정한다.

$$fitness = \left(\sum_{t=0}^{final\ time} e_m^2(t) \right)^{\frac{1}{2}} \quad (6)$$

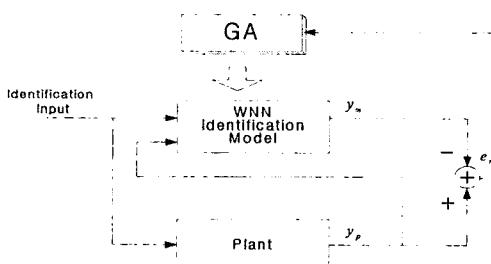


그림 3 유전 알고리듬을 이용한 시스템 동정 구조

2.3.2 간접 적응 제어

간접 적응 제어 방식에 기초한 WNN 제어기 설계 방법은 동정 모델을 2.3.1절과 같이 오프라인(off-line) 상에서 적절히 생성한 후, 생성된 동정 모델을 이용해서 제어 대상 플랜트를 온라인(on-line)으로 제어하는 방법이다. 본 논문에서 제안한 간접 적응 제어 방식에 기초한 웨이블릿 신경 회로망 제어기의 구조는 그림 4와 같다.

그림 4에서 혼돈 비선형 시스템의 제어를 위한 동정 모델과 제어기는 2.1절에서 서술한 웨이블릿 신경 회로망을 사용하며, 동정 오차 e_m 으로 유전 알고리듬을 이용

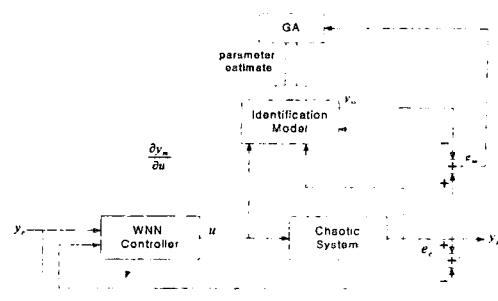


그림 4 WNN를 이용한 간접 적응 제어기의 구조

하여 웨이블릿 신경 회로망의 온라인 동정을 수행한다. 또한, 플랜트 출력과 기준 출력의 차로 정의되는 제어 오차 e_c 로부터 오차 역전파(back propagation) 알고리듬을 이용하여 웨이블릿 신경 회로망 제어기의 파라미터를 조정한다. 이때 온라인 동정에서는 임의의 시간 전부터 현재까지의 측정한 e_m 으로부터 계산한 MSE(e_m)를 적합도 함수로 설정한다.

웨이블릿 신경 회로망 제어기의 파라미터를 학습하기 위한 제어기 출력단의 오차 신호 e_c 는 플랜트로부터 직접 구할 수 없기 때문에, 제어 입력 u 에 대한 동정 모델의 미분 이득을 이용하여 웨이블릿 신경 회로망 제어기의 파라미터를 학습한다. 웨이블릿 신경 회로망 제어기의 설계는 식 (7)과 같은 비용 함수를 최소화하는 제어기의 파라미터 집합 $\theta(n)$ 을 구하는 것이다.

$$J(\theta(n)) = \frac{1}{2} (y_p(n) - y_m(n))^2 = \frac{1}{2} e_c^2(n) \quad (7)$$

여기서, $y_p(n)$ 과 $y_m(n)$ 은 n 번째 혼돈 비선형 시스템의 출력과 기준 출력이다. $\theta(n)$ 은 식 (8)과 같은 웨이블릿 신경 회로망 제어기의 파라미터 집합이며, 식 (9)와 같은 학습 과정을 통하여 생성된다.

$$\theta = \{a_0, a_k, c_j, m_{jk}, d_{jk}\} \quad (8)$$

$$\theta(n+1) = \theta(n) - \Delta\theta(n) \quad (9)$$

여기서, $\frac{\partial J(\theta(n))}{\partial \theta(n)}$ 는 $\theta(n)$ 에 대한 비용 함수의 기울기로서, 식 (10)에 의해 계산된다.

$$\begin{aligned} \frac{\partial J(\theta(n))}{\partial \theta(n)} &= e_c(n) \frac{\partial y_m(n)}{\partial \theta(n)} \\ &= e_c(n) \frac{\partial y_m(n)}{\partial u(n)} \frac{\partial u(n)}{\partial \theta(n)} \end{aligned} \quad (10)$$

여기서, $\frac{\partial y_m(n)}{\partial u(n)}$ 은 제어 입력 $u(n)$ 에 대한 웨이블릿 신경 회로망 동정 모델의 미분 이득이며, 식 (11)에 의해 계산된다.

$$\begin{aligned} \frac{\partial y_m(n)}{\partial u(n)} &= \frac{\partial y_m(n)}{\partial x} \frac{\partial x}{\partial u(n)} \\ &= \left[\sum_{j=1}^{N_e} c_j \frac{\partial \Phi(x)}{\partial z_{jk}} + a_k \right]_k \end{aligned} \quad (11)$$

여기서, $\frac{\partial x}{\partial u(n)} = [0, 0, \dots, 0, 1, 0, \dots, 0]^T$ 이며, N_e 와 N_e 는 웨이블릿 신경 회로망 동정 모델의 입력으로서 플랜트의 과거 출력 값 개수와 제어 입력의 개수를 나타낸다.

식 (10)의 $\frac{\partial u(n)}{\partial \theta(n)}$ 은 파라미터 집합 $\theta(n)$ 에 대한 웨이블릿 신경 회로망 제어기 출력 $u(n)$ 의 기울기이다[10].

3. 모의실험 및 결과 고찰

본 논문에서는 제안된 제어기의 성능을 평가하기 위하여 대표적인 연속 시간 혼돈 비선형 시스템인 Duffing 시스템에 대한 모의실험을 수행하였다.

Duffing 시스템의 상태 방정식은 다음과 같다.

$$\begin{bmatrix} \dot{x}(t) \\ \dot{y}(t) \end{bmatrix} = \begin{bmatrix} y(t) \\ -p_1x(t) - x^3(t) - py(t) + q\cos(wt) \end{bmatrix} \quad (12)$$

여기서, 파라미터 집합은 다음과 같다.

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

3.1 Duffing 시스템 동정결과

동정 입력은 $1.0e^{-3}\cos(t)$ 로서 혼돈 현상이 유지되도록 충분한 실험을 통하여 얻어졌다.

그림 5는 Duffing 시스템의 오프라인 동정 결과를 보여준다. 이때 사용된 웨이블릿 신경 회로망 모델의 모의실험 환경과 실험 결과는 표 1과 같다.

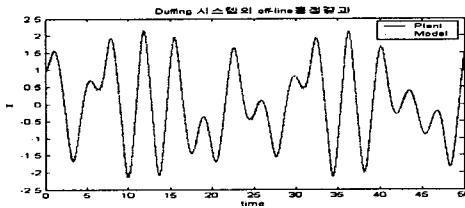


그림 5 Duffing 시스템의 오프라인 동정 결과

표 1 WNN 모델의 모의실험 환경 및 동정 결과

Number of wavelet function	5
Number of past state	2
Number of past input	2
Sampling time	0.02
Learning rate	0.01
Generation	60
Population	20
Off-line identification result (MSE)	0.0083

3.2 Duffing 시스템의 간접 적응 제어 결과

3.1절의 동정 모델을 사용하여 간접 적응 제어를 실현하였으며, Duffing 시스템의 기준 신호는 Duffing 시스템의 1주기 해로 설정하였고, Duffing 시스템의 1주기 해는 식 (12)에서 파라미터 q 값이 2.3일 때 얻어진다. 그림 6는 본 논문에서 제안된 간접 적응 제어 기법에 기초한 온 라인 동정 결과 및 제어 결과를 나타낸다. 또한 표 2는 웨이블릿 신경 회로망 제어기의 모의실험 환경 및 제어 결과를 보여준다.

4. 결 론

본 논문에서는 혼돈 비선형 시스템의 지능 제어를 위해 유전 알고리듬을 이용한 간접 적응 제어 웨이블릿 신경 회로망 제어기 설계 방법을 제안하였다. 동정 모델에 대해서는 학습 방법으로 유전 알고리듬을 사용하였고, 웨이블릿 신경 회로망 컨트롤러의 학습 방법은 경사 하강법과 오차 역전파 알고리듬을 사용하였다.

본 논문에서 제안된 방법의 가능성을 검증하기 위하여 대표적인 혼돈 비선형 시스템인 Duffing 시스템에 적용한 결과 만족할 만한 성능을 보였다.

표 2 WNN 제어기의 모의실험 환경 및 실험 결과

Number of wavelet function (controller)	3
Number of past state (controller)	1
Number of past input (controller)	1
Sampling time (controller)	0.02
Learning rate (controller)	0.05
Population	20
On-line identification result (MSE)	0.0801
Control result (MSE)	0.0312

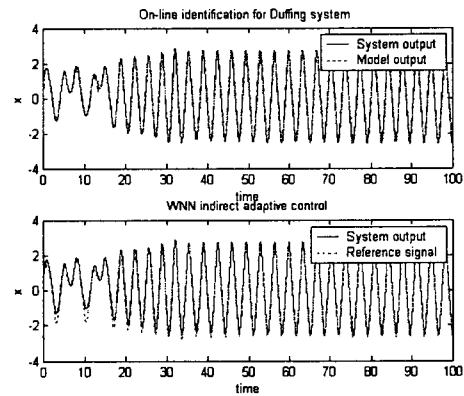


그림 6 Duffing 시스템의 온라인 동정 및 제어 결과

【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. Hübner, "Periodic Entrainment of Chaotic Logistic Map Dynamics", Physica D, Vol. 44, 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", Int. Jour. of Bifurcation and Chaos, Vol. 8, No. 7, pp. 1591-1597, 1998.
 - [5] K. B. Kim, J. B. Park, Y. H. Choi and G. Chen, "Control of Chaotic Dynamical Systems Using Radial Basis Function Network Approximators", Information Sciences, Vol. 130, pp. 165-183, 2000.
 - [6] Y. Oussar, I. Rivals, L. Personnaz and G. Dreyfus, "Training Wavelet Networks for Nonlinear Dynamic Input-Output Modeling", Neurocomputing, Vol. 20, pp. 173-188, 1998.
 - [7] S. Mallat, "A Theory for Multiresolution Signal Decomposition : The Wavelet Transform", IEEE Trans. on Pattern Anal. Machine Intell., Vol. 7, No. 7, pp. 674-693, 1989.
 - [8] 오준섭, 최윤호, 박진배, "혼돈 비선형 시스템을 위한 퍼지 제어기의 설계에 관한 연구", 대한 전자공학회 추계 학술대회 논문집, vol.20, no. 2, pp. 277-280, 1997.
 - [9] 장욱, 손유석, 박진배, 주영훈, "유전 알고리듬을 이용한 퍼지 제어기의 최적화", 대한 전기학회 학술대회 논문집, pp.1158-1160, 1996.7.
 - [10] 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.
- * 본 논문은 한국과학재단의 목적기초연구사업(R01-2001-00316)에 의해 지원되었습니다.