

DNA 코딩 기반 웨이블릿 신경 회로망을 이용한 혼돈 시스템의 모델링

\*유성진, \*\*최윤호, \*박진배  
\*연세대학교 전기전자공학과 \*\*경기대학교 전자공학부

Modeling of Chaotic Systems Using a DNA Coding Based Wavelet Neural Network

\*Sung Jin You \*\*Yoon Ho Choi \*Jin Bae Park  
\*Dept. of Electrical & Electronic Engineering, Yonsei University  
\*\*School of Electronic Engineering, Kyonggi University

**Abstract** - This paper presents the intelligent modeling method of chaotic systems using a DNA coding based wavelet neural network(WNN). Generally the mathematical learning method such as gradient descent method is used to adjust the parameters of WNN, which has much computational cost. To overcome this kind of problem, we use the DNA coding method as the learning method of WNN, and then combine it with the WNN. Finally, to verify the efficiency of our method, we apply the proposed DNA coding based wavelet neural network for modeling of Duffing system, which is a representative continuous-time chaotic system.

1. 서 론

1990년대를 전후하여 비선형 특성을 갖는 혼돈 현상을 제어하고자 하는 많은 연구들이 수행되었고, 최근에 수학적인 모델이 필요 없는 신경 회로망을 이용하여 혼돈 시스템을 모델링하거나 혹은 제어하고자 하는 연구들이 활발히 진행되고 있다[1]. 한편 주파수와 시간 영역에서의 우수한 해석 능력을 갖는 웨이블릿 함수와 결합된 새로운 형태의 신경 회로망인 웨이블릿 신경 회로망(wavelet neural network: WNN)이 제안되었고, 최근에 이를 이용하여 혼돈 시스템을 포함한 비선형 시스템의 식별 및 제어에 관한 많은 연구 결과들이 발표되고 있다 [2]. 이와 같은 웨이블릿 신경 회로망은 파라미터의 학습을 통해 미지의 시스템을 모델링 혹은 제어하게 되는데, 파라미터 학습 방법은 웨이블릿 신경 회로망의 성능에 주요한 영향을 준다. 웨이블릿 신경 회로망의 학습방법으로는 경사 하강法(gradient descent: GD) 법이 주로 사용되는데, 이와 같은 학습 방법은 웨이블릿 노드와 웨이블릿 신경 회로망의 입력의 수가 증가함에 따라 복잡한 수학적인 계산이 요구되며 아울러 국부 최소치(local minima)에 빠질 위험이 있다. 따라서 본 논문에서는 이와 같은 단점들을 개선하기 위해 수학적 모델이 없이도 모델링 및 제어가 가능한 전역 최적화 방법 중 하나인 DNA 코딩 기반 웨이블릿 신경 회로망을 설계하여 이를 이용한 혼돈 시스템의 모델링 기법을 제안한다. 또한 모델링 방법의 우수성을 검증하기 위해 제한한 DNA 코딩 기반 학습 방법을 연속 시간 혼돈 시스템인 Duffing 시스템의 모델링에 적용하고 아울러 경사 하강법의 의한 학습 방법과 성능을 비교하고자 한다.

2. DNA 코딩 기반 웨이블릿 신경 회로망

본 절에서는 우선 웨이블릿 신경 회로망의 구조에 대해 설명한 후 DNA 코딩 기법에 기반한 웨이블릿 신경 회로망의 파라미터 학습 방법을 제안한다.

2.1 웨이블릿 신경 회로망의 구조

웨이블릿 신경 회로망은 입력 층, 웨이블릿 층, 출력 층인 3 개의 층으로 구성된다[3]. 그림 1은  $N_i$ 개의 입력, 하나의 출력과 웨이블릿 신경 회로망의 구조를 나타낸다.




그림 1. 웨이블릿 신경 회로망의 구조

그림에서 A 층은 웨이블릿 신경 회로망의 입력을 나타내며, 입력은  $x = x_1, x_2, \dots, x_N$  벡터로 표현된다. 또한 B 층은 웨이블릿 함수 층이며 각 노드의 웨이블릿 함수는 식 (1)과 같이 정의된다.

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

여기서  $m_j$ 와  $d_j$ 는 각각  $j$  번째 노드의 변형인자 및 확장인자로서 실수 값을 가지며  $d_j \neq 0$  이다. 또한 모체 웨이블릿으로는 식 (2)와 같은 가우시안(Gaussian) 함수의 1차 미분값으로 선택한다.

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

B 층에서 각 웨이블릿 노드에 대한 출력은 식 (3)과 같다.

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

여기서  $j=1, \dots, N_w$ 이고,  $k=1, \dots, N_i$ 이다.  $N_i$ 는 입력의 수와 웨이블릿 차원(dimension)을 나타내고  $N_w$ 는 B 층 웨이블릿 함수의 수를 나타낸다. C 층은 웨이블릿 신경 회로망의 출력을 나타내며, 식 (4)과 같이 나타낸다.

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

여기서  $\theta$ 는 DNA 학습법에 의해 동정되어야 할 파라미터 집합으로서 식 (5)와 같다.

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

여기서  $a_k$ 와  $a_0$ 는 입력노드와 출력노드 사이의 가중치이며,  $c_j$ 는 웨이블릿 노드와 출력노드 사이의 가중치이다.

## 2.2 DNA 코딩 기반 학습 방법

DNA 코딩 기법은 생물학적 DNA의 구조에 기반하여 만들어진 최적화 기법이다. 생물학적 DNA의 기본 구성 요소는 4개의 핵산(nucleotide)이다. 핵산은 Adenine(A), Guanine(G), Cytosine(C) and Thymine(T)으로 구성되고, 3개의 핵산이 모여 하나의 코돈(codon)을 이룬다. 이러한 64개의 코돈은 20개의 아미노산(amino acid)으로 번역되어 진다. 이러한 생물학적 과정을 이용하여 다음과 같은 과정으로 DNA 코딩이 이루어지며 다음 세대로 진화된다[5].

- 1) A, G, C, T로 구성된 여러 개의 DNA 배열을 생산한다.
- 2) DNA 배열에서 코돈을 생산한다. 코돈은 표 1에 근거하여 아미노산 20개로 변환된다.
- 3) 번역된 아미노산을 실수 값으로 변환한다.
- 4) 변환된 값으로 원하는 최적화 함수의 적합도를 조사한다.
- 5) 조사된 적합도를 이용하여 그림 2와 같이 적합도가 낮은 개체들은 도태시키고 유전 연산자를 이용하여 적합도가 높은 개체는 보존하고 새로운 자손 집단을 생성한다. 여기서 사용된 유전 연산자는 교차(crossover), 돌연변이(mutation), 삭제(deletion), 삽입(insertion), 및 도처(inversion) 연산자가 사용된다[7].

표 1. 코돈에서 아미노산의 번역

First Base	Second Base				Third Base
	T	C	A	G	
T	Phe (1)	Ser (10)	Tyr (4)	Cys (19)	F
	Phe (1)	Ser (10)	Tyr (4)	Cys (19)	C
	Phe (1)	Ser (10)	Tyr (4)	Cys (19)	A
C	Leu (9)	Ser (10)	His (5)	Trp (20)	G
	Leu (9)	Pro (7)	His (5)	Trp (20)	T
	Leu (9)	Pro (7)	His (5)	Trp (20)	C
A	Ile (2)	Pro (7)	Gln (14)	Arg (11)	A
	Ile (2)	Pro (7)	Gln (14)	Arg (11)	G
	Ile (2)	Thr (8)	Asn (15)	Arg (11)	T
G	Met (3)	Thr (8)	Asn (15)	Asn (15)	C
	Met (3)	Thr (8)	Lys (16)	Lys (16)	A
	Met (3)	Thr (8)	Lys (16)	Asp (17)	G
G	Val (6)	Ala (12)	Asp (17)	Glu (18)	T
	Val (6)	Ala (12)	Asp (17)	Glu (18)	C
	Val (6)	Gln (14)	Glu (18)	Gly (13)	A
	Val (6)	Gln (14)	Glu (18)	Gly (13)	G




그림 2. DNA 진화 과정

본 논문에서는 이와 같은 DNA 코딩 기법을 웨이블릿 신경 회로망의 학습 방법에 적용한다. DNA 코딩 기반 학습을 위해 우선 하나의 세대(generation)동안의 개체군(population)을 형성한다. 각각의 개체(individual)는 다음과 같이 표현된다.

$$S^n = \{m_k^n, d_k^n, c_k^n, a_k^n, a_0^n\}$$

$$G = \{S^1, S^2, S^3, \dots, S^g\}$$

여기서  $S^n$ 은  $n$ 번째 개체로서 웨이블릿 신경 회로망의 실수 파라미터 스트링을 나타내고,  $G$ 는 세대를 나타낸다. 또한  $n=1, \dots, g$ 이며  $g$ 는 개체군을 나타낸다. DNA 배열에서 코돈은 아미노산으로 번역되고, 아미노산이 가

지는 유전정보에 따라 웨이블릿 신경 회로망의 파라미터 값의 생성은 그림 3과 같은 과정으로 이루어진다. 여기서의  $M, D, C, A, A_0$ 는 파라미터 집합  $\theta$ 의 각각의 원소의 행렬 표현이다. 각각의 행렬 값들을 스트링으로 나열하여 하나의 개체로 표현한다.




그림 3. 아미노산에서 WNN 파라미터의 번역

그림 3에서의 코돈과 아미노산의 번역은 표 1에 근거하여 번역된다. 표에서 나타난 각각의 아미노산이 가지는 유전정보를 나타내는 괄호안의 값은 웨이블릿 신경 회로망의 파라미터 값의 범위에서 임의로 분할된 값을 지정하는 역할을 한다. 위의 과정에 의해 웨이블릿 신경 회로망의 파라미터의 집합은 하나의 개체를 형성한다. 각각의 개체들은 다음 절에서 논의될 적합도 함수(fitness function)에 근거하여 평가된다.

## 3. DNA 코딩 기반 웨이블릿 신경 회로망을 이용한 혼돈 시스템의 모델링

본 논문에서는 연속 시간 혼돈 비선형 시스템을 모델링 대상으로 한다. 모델링의 목적은 웨이블릿 신경 회로망의 최적의 파라미터  $\theta$ 를 동정함으로써 주어진 시스템을 정확하게 모델링 하는 것이다. 그림 4는 DNA 코딩 기반 웨이블릿 신경 회로망의 혼돈 시스템의 모델링 구조를 나타낸다. 그림에서의 웨이블릿 신경 회로망은 입력, 출력, 웨이블릿의 3개층으로 구성된다. 신경 회로망의 파라미터 학습 알고리즘은 DNA 코딩 기법을 이용한다. 모델링 기법은 실제 시스템의 출력을 웨이블릿 신경 회로망의 입력으로 사용하는 예측기법을 이용한다. 따라서  $n$ 번째 웨이블릿 신경 회로망의 출력  $\hat{y}(n)$ 과 입력  $x_k$ 은 각각 식 (6), (7)과 같이 나타낸다[2].

$$\hat{y}(n) = f(y(n-1), y(n-2), \dots, y(n-N_s)) \quad (6)$$

$$x_k = y(n-k) \text{ with } k = 1, \dots, N_s \quad (7)$$

여기서  $N_s$ 는 상태 입력의 수를 의미한다.




그림 4. DNA 코딩 기반 WNN을 이용한 혼돈 시스템 모델링

한편 그림과 같은 구조에 의해 혼돈 시스템을 모델링 하기 위한 과정은 다음과 같은 단계로 구성된다.

- 1) 초기 파라미터 집합  $\theta$ 의 원소는 모두 0으로 한다.
- 2) 웨이블릿 신경 회로망에 혼돈 시스템의 출력을 입력으로 사용한다.
- 3) 웨이블릿 신경 회로망의 출력  $\hat{y}(n)$ 을 계산한다.
- 4) 웨이블릿 신경 회로망의 출력  $\hat{y}(n)$ 과 혼돈 시스템의 출력  $y(n)$ 의 오차 값을 계산한다.

5) 일정한 샘플 수만큼 2)~4)의 단계를 반복하여 식 (8)과 같이 4)에서 구한 오차의 합을 구한다.

$$J = \frac{1}{n} \sum_{t=1}^n (y(t) - \hat{y}(t))^2 = \frac{1}{n} \sum_{t=1}^n e^2(t) \quad (8)$$

6) 식 (8)의 최소값을 구하기 위해 DNA 코딩 학습 방법을 적용하여 웨이블릿 신경 회로망의 파라미터를 최적화 한다. 이 때 각 개체가 갖는 적합도는 식 (9)과 같은 적합도 함수에 의해 평가된다.

$$f(J) = 1/J \quad (9)$$

7) 식 (9)에 의해 구해진 최적의 파라미터는 혼돈 시스템을 모델링 하기 위해 웨이블릿 신경 회로망에 사용된다.

8) 모델링 에러가 최소가 되는 파라미터를 동정할 때까지 2)~7)까지의 단계를 계속적으로 반복 수행한다.

#### 4. 시뮬레이션 결과 및 고찰

본 논문의 모델링 대상인 Duffing 시스템은 혼돈 현상을 나타내기 위해 주로 이용되며, Duffing 시스템의 상태 방정식은 식 (10)과 같다.

$$\begin{pmatrix} \dot{x} \\ \dot{y} \end{pmatrix} = \begin{pmatrix} y \\ a_1 x - x^3 - a_2 y + b \cos(\omega t) + u \end{pmatrix} \quad (10)$$

여기서  $a_1 = 1.1$ ,  $a_2 = 0.4$ ,  $b = 2.1$ ,  $\omega = 1.8$ 이고,  $t$ 는 시변수이다[5].

본 실험에서는 우선 Duffing 시스템을 모델링 하기 위해 DNA 코딩 기반 WNN을 적용한다. 한편 제안된 DNA 학습 방법의 성능을 검증하기 위해, 경사 하강법을 사용한 WNN의 모델링 결과와 비교한다. 실험을 위한 초기 조건은 표 2 및 3과 같다.

표 2. WNN의 초기 조건

매개변수	값
웨이블릿 노드 수	5
웨이블릿 신경 회로망의 입력의 수	2
샘플링 간격	0.01

표 3. DNA 학습의 초기 조건

매개변수	값
세대 수	300
개체군 크기	40
교차율	1
돌연변이율	0.01
식제&삽입&도치율	0.01

위와 같은 초기 조건에서의 DNA 학습 방법을 사용한 WNN에 의한 Duffing 시스템의 모델링 결과는 그림 5와 같다. 또한 DNA 학습 방법에 의해 나타난 최적의 파라미터 값과 모델링 오차는 표 4와 같다. 한편 표 5는 성능 비교 대상인 경사 하강법을 사용한 WNN에 의한 모델링 결과이다. 표 4와 5의 모델링 오차 결과들로부터, DNA 학습 방법과 경사 하강법을 사용한 WNN의 경우 모델링 오차가 각기 0.00062, 0.00094임을 알 수 있고, 이 결과로부터 DNA 학습 방법을 사용한 경우가 경사 하강법을 사용한 경우에 비해 모델링 오차가 더 작음을 확인할 수 있다. 따라서 본 논문에서 제안한 DNA 학습에 의한 전역 최적화 방법이 많은 수식적인 계산을 필요로 하는 경사 하강법에 비해 더 우수한 모델링 성능을 가짐을 알 수 있다.

### 3. 결 론

본 논문에서는 DNA 코딩 기반 웨이블릿 신경 회로망을 이용한 혼돈 시스템의 모델링 방법을 제안하였다. 제안된 방법에서는 웨이블릿 신경 회로망의 파라미터들이 DNA 코딩 학습 방법에 의해 동정되도록 설계되었으며, 설계된 웨이블릿 신경 회로망을 혼돈 시스템의 동정에 적용한 결과, 기존의 경사 하강법을 사용한 웨이블릿 신경 회로망에 비해 모델링 성능이 더 우수함을 확인할 수 있었다.

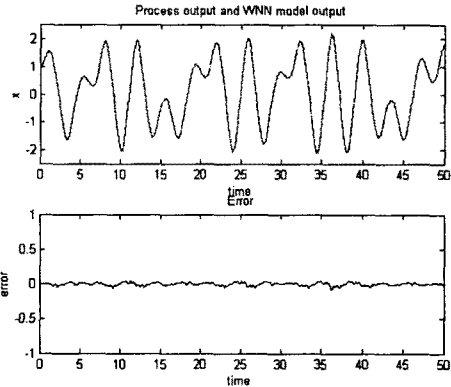


그림 5. DNA 학습 방법에 의한 모델링 결과

표 4. 최적의 파라미터 값과 모델링 오차

M	D	C	A	A0	MSE
-0.8107	0.8185	0.1380	0.5850	-0.2464	0.00062
-0.5070	0.2079	0.8085	0.9203	0.1464	
0.2075	-0.8107	-1.0913	-1.0913	-0.3446	
-0.1997	0.5984	0.8085	0.6968	-0.3446	
0.8186	1.0221	1.0320	0.8085	-0.4428	
				6.1250	

표 5. 경사 하강법에 의한 모델링 결과[6]

웨이블릿/뉴런 노드 수	모델 학습율	MSE
5	0.2	0.00094

#### [참 고 문 헌]

[1] G. Chen and X. Dong, "From chaos to order-perspectives and methodologies in controlling nonlinear dynamical systems," IJBC, vol. 3, no. 6, pp. 1363-1409, 1993.  
 [2] Y. Oussar, I. Rivals, L. Perronnaz, G. Dreyfus "Training wavelet networks for nonlinear dynamic input-output modeling," Neurocomputing, vol. 20, Issues 1-3, pp. 173-420, 1998.  
 [3] Q. Zhang and A. Benveniste, "Wavelet networks," IEEE trans. on Neural Networks vol. 3, pp. 889-898, 1992.  
 [4] L. Cao, Y. Hong, H. Fang, G. He, "Predicting chaotic time series with wavelet networks," Physica D, vol. 85, pp. 225-238, 1995.  
 [5] Y.S. Ding and L.H. Ren, "DNA genetic algorithm for design of the generalized membership-type Takagi-Sugeno fuzzy control system," Pro. of IEEE Int. Conf. on Systems, Man, and Cybernetics, pp. 3862-3867, Oct., 2000.  
 [6] 박상우, 최종태, 윤태성, 박진배, 최운호, "웨이블릿 신경 회로망을 이용한 혼돈 비선형 시스템의 모델링," 대한전기학회 학회논문집, pp 2034-2036, 2002.  
 [7] 이범직, 주영훈, 박진배, "기동 표적 추적을 위한 DNA 코딩 기반 상호작용 다중모델 기법," 한국 퍼지 및 지능 시스템 학회 논문지, vol. 12, no. 6, pp. 497-502, 2002.  
 ※ 본 논문은 한국과학기술재단의 목적기초연구사업(R01-2001-00316)에 의해 지원되었습니다.