

# 기하학적인 성장기준을 적용한 웨이블릿 신경망의 적응 구조 설계

## Adaptive Structure of Wavelet Neural Network with Geometric Growing Criterion

서재용\* · 김성주\*\* · 조현찬\*\* · 전홍태\*\*

Jae-Yong Seo\*, Seong-Joo Kim\*\*, Hyun-Chan Cho\*\*, and Hong-Tae Jeon\*\*

\*한국기술교육대학교 정보기술공학부

\*\*중앙대학교 전자전기공학부

### 요 약

본 논문에서는 F-투영법과 기하학적인 성장기준을 적용하여 웨이블릿 신경망의 적응적인 구조를 설계할 수 있는 알고리즘을 제안한다. 기하학적인 성장기준은 지역오차를 고려한 예측 오차기준과 준직교성을 보장하는 웨이블릿 신경망의 노드를 추가하기 위한 각도기준으로 구성되어 있다. 이러한 성장기준은 웨이블릿 신경망을 설계자 의도에 부합하도록 구성할 수 있는 방법론을 제시할 수 있다. 제안한 웨이블릿 신경망의 적응구조 설계알고리즘을 1차원과 2차원의 함수 근사화 문제에 적용하여 적응성과 근사화 능력의 우수성을 검증하였다.

### Abstract

In this paper, we propose an algorithm to design the adaptive structure of wavelet neural network with F-projection and geometric growing criterion. Geometric growing criterion consists of estimated error criterion considering local error and angle criterion which attempts to assign a wavelet function that is nearly orthogonal to all other existing wavelet functions. These criteria provide a methodology that a network designer can construct wavelet neural network according to one's intention. We apply the proposed constructing algorithm of the adaptive structure of wavelet neural network to approximation problems of 1-D and 2-D function, and evaluate the effectiveness of the proposed algorithm.

**Key Words** : Wavelet neural network, Geometric growing criterion, F-projection

### 1. 서 론

웨이블릿 신경망(Wavelet Neural Network; WNN)은 방사기저함수망(RBFN)의 기저함수들을 웨이블릿 함수(wavelet function)로 대체하여 직교성을 갖는 기저함수를 사용한다 [1-6]. WNN의 많은 장점에도 불구하고 대상 문제에 적합한 WNN의 최적구조 설계 및 초기 매개변수 값의 설정 문제는 아직도 연구과제로 남아 있다. 최근 WNN의 활용분야가 확대되면서 최적구조 및 초기 매개변수 설정문제를 다룬 연구 결과가 보고되고 있다[7-10].

위에서 제안한 대부분의 알고리즘은 웨이블릿 함수의 매개변수나 가중치의 초기 값을 결정하기 위해서 웨이블릿 역변환을 수행하거나 시행착오 방법을 사용하였다. 따라서 본 논문에서는 이러한 단점을 극복할 수 있는 WNN의 성장 알고리즘을 제안한다. 제안한 성장 알고리즘은 직교 웨이블릿을 사용하지 않고 망의 구성에 유연성을 제공하는 웨이블릿

프레임을 사용하며, 추가하는 웨이블릿 프레임의 근사적인 직교성을 보장하기 위해 F-투영(F-projection)법[11]을 사용하여 이동단의 크기(translation step size)를 결정한다. 그리고 망이 무한히 증가하는 것을 방지하기 위해 망의 성장기준을 설정한다. 초기 한 개의 노드에서 시작하고, 시스템의 전체 오차를 감소시키기 위해 이동계수를 자동으로 결정하여 노드를 추가한다. 또한 웨이블릿 프레임의 매개변수와 가중치의 초기 값을 결정하여 원하는 수행능력에 도달할 때까지 WNN을 성장시킨다. 제안한 알고리즘을 함수 근사화 문제에 적용하여 수행능력을 검증하였다.

### 2. F-투영법을 이용한 기하학적인 성장기준의 결정

WNN의 출력은 은닉층-출력층의 변환이 선형조합(linear combination)이기 때문에 그 값이 (0,1)로 제약되지 않는다. 이러한 구조에서 은닉층의 노드가 매핑을 수행하고, 은닉층의 전체 개수가  $K$ 일 때  $\psi_j \in H, j=1, \dots, K$ 을 만족하는 기저함수(basis function)로 생각할 수 있다. 이산화된 웨이블릿 변환을 적용하면 WNN의 최종 출력은 식 (1)과 같이 표현된다.

접수일자 : 2001년 6월 18일

완료일자 : 2001년 12월 8일

본 연구는 과학기술부의 뇌과학연구 프로그램의 지원 하에 수행되었습니다.

$$f(x) = \sum_m \sum_n c_{m,n} \psi_{m,n}(x) \quad (1)$$

연속추정(sequential estimation) 문제에 WNN을 적용할 경우 추정이 각 시간간격  $j$ 에서 요구된다. WNN이  $K$ 번째 시간에서 관측(observation) 데이터  $O_K$ 를 이용하여 학습을 수행하고 출력한 결과를  $f_K$ 로 표현하자. 이것은 사전추정(prior estimation)  $f_{K-1}$ 을 이용한 대상함수의 사후추정(posterior estimation)으로 생각할 수 있다. 결국 연속함수 추정문제는 사전추정  $f_{K-1}$ 과 관측 데이터  $O_K$ 가 주어지면 이 두 가지 정보를 적절하게 조합하여 사후추정  $f_K$ 를 얻는 문제로 규정할 수 있다. 위와 같은 정보가 주어지고, 관측이 노이즈에 무관하다면 연속추정은 각 단계에서 최적추정을 결정하는 문제가 된다. 단계별 최적추정은 다음과 같은 F-투영(F-projection)의 원리로 주어질 수 있다[11].

$$f_K = \arg \min_{f \in H} \|f - f_{K-1}\| \quad st \quad f_K \in H_K \quad (2)$$

여기서  $H_K$ 는 억제조건  $f(t_K) = y_K$ 을 만족하는  $H$ 공간에서 모든 함수로 구성된 집합이다. 사후추정은  $H_K$ 공간에서 사전추정을 투영한 것이다. 위에서 언급한 억제조건  $f(t_K) = y_K$ 는 함수공간에서 내적으로 다음과 같이 표현할 수 있다.

$$\langle f, \delta_K \rangle = y_K \quad (3)$$

여기서,  $\delta_K = \delta(t - t_K)$ 인 임펄스 함수이다. 위의 억제된 최소화 조건에서 다음과 같은 식을 얻을 수 있다.

$$f_K = f_{K-1} + e_K h_K \quad (4)$$

여기서  $e_K = y_K - f_{K-1}(t_K)$ 는 예측 오차이고  $h_K = \frac{\delta_K}{\|\delta_K\|^2}$

이다. 위의 해는 관측함수의 가장자리가 매끈(smooth)하고, 관측은 입력시간  $D$ 에서 함수의 인접영역과 관련이 된다. 이러한 매끈함에 대한 억제조건은 사후추정을 위해 첨가되어야 한다. 매끈함에 대한 억제조건은  $H_K$ 의 다음과 같은 특성에 의해 지배받고, 이러한  $f_K(t_K) = y_K$ 의 매끈한 억제조건에서 임펄스 함수 대신에 식 (1)과 같은 웨이블렛 함수  $\psi_{m,n}(t_K)$ 을 사용할 수 있다. 이 경우 사후추정은 다음과 같다.

$$f_K(t) = \sum_{j=1}^{K-1} c_j \psi_{m,n}^j(t_j) + e_K \phi_{m,n}^K(t_K) \quad (5)$$

따라서 사후추정은 WNN에 새로운 은닉층 노드를 추가함으로써 매핑이 가능하다. 그림 1은  $K-1$ 개의 노드로 구성된 WNN에  $K$ 번째 노드가 추가된 모양을 나타낸 것이다.

그림에서 점선은  $f_K$ 를 매핑하기 위해 은닉층에 하나의 노드가 추가된 것을 나타낸다. 관측 데이터  $t_K$ 는 웨이블렛 프레임의 이동계수 값을 얻기 위해 사용되고, 오차는 가중치를 초기화하는데 사용될 수 있다. 이러한 성장 알고리즘은 관측 데이터를 연속적으로 얻을 경우, 망의 크기가 무한정 커질 수 있기 때문에 성장 기준을 정하는 것이 필요하다. 데이터를 연속적으로 입력받는 연속추정 문제에서 망은 대상함수를 충분한 정확도로 근사화할 수 있지만 최종추정에 기여도가 적은 은닉층의 노드를 계속 추가할 수 있다. 따라서 망의 복잡도가 불필요하게 증가하게 되고 계산속도가 느려지기 때문에 망의 성장에 제약이 필요하다.




그림 1. 성장된 WNN의 망구조

Hilbert 공간  $H$ 를 고려하자. 망의 해는 무한차원 공간으로 확장될 수 있다. 만약 망이  $K-1$ 개의 은닉층 노드( $K-1$ 개의 기저함수)로 구성되어 있고, 기저함수의 파라미터가 고정된다면 망의 해는  $K-1$ 개의 기저함수로 형성된  $K-1$ 차원의  $H_{K-1}$ 의 부분공간에 존재하게 된다. 그림 2는 새로운 노드  $K$ 가 추가되었을 때 3차원적으로 망의 해를 표현한 것이다[11].




그림 2. Hilbert 공간에서 망의 해를 표현

사전추정  $f_{K-1}$ 과  $K-1$ 개의 기저함수를 이용해서 매핑한 사후추정  $f_K^*$ 은 모두  $H_{K-1}$ 공간에 존재하게 된다. 또한 사후추정  $f_K$ 는 새로운 기저함수  $\phi_K$ 를 추가해서 얻을 수 있다.  $f_K$ 와  $f_K^*$  사이의 거리는  $\|f_K - f_K^*\|$ 로 정의할 수 있다. 이러한 거리는 새로운 기저함수를 추가하지 않았을 경우 잘못된 근사화 정도를 의미하기도 한다. 따라서 은닉층의 노드를 추가하기 위한 기준으로써 이러한 거리가 특정한 문턱치(threshold)를 초과하는지 여부를 판단할 수 있다. 그림 2와 같이 망 해의 기하학적인 모양에서 새로운 은닉층 노드를 추가하기 위한 기준을 다음과 같이 표현할 수 있다.

$$\|f_K - f_K^*\| = |e_K| \sin(\alpha_K) > \epsilon \quad (6)$$

여기서  $\epsilon$ 은 문턱치,  $|e_K| = \|f_K - f_{K-1}\|$ ,  $\alpha_K$ 는  $f_{K-1}$ 에서  $K-1$ 개의 기저함수에 의해 정의된 부분공간  $H_{K-1}$ 에 새로운 기저함수  $\phi_K$ 를 추가하여 얻어진 각도를 나타낸다. 기하학적인 기준은 다음과 같이 예측 에러 기준(prediction error criterion)과 각도 기준(angle criterion)으로 단순화해서 생각할 수 있다.

$$e_K > e_{mn}, \alpha_K > \alpha_{K_{min}} \quad (7)$$

일반적으로 각도  $\alpha_k$ 는 계산하기가 어렵기 때문에 새로운 기저함수와 이미 존재하는 모든 기저함수 사이의 가장 작은 각도가 임의의 문턱치를 초과하도록 각도 기준치를 근사적으로 선택하여 사용한다. 웨이블릿 신경망의 경우,  $\{\psi_1, \dots, \psi_{k-1}\}$ 의 공간에 존재하는 다음 식과 같은  $\cos(\alpha_k)$ 을 계산하여  $\alpha_k$ 을 얻을 수 있다.

$$\cos(\alpha_k) = \sup_{i=1, \dots, k-1} \left\{ \left| \frac{\langle \psi_k, \psi_i \rangle}{\|\psi_k\| \|\psi_i\|} \right| \right\} \leq 1 - \delta \quad (8)$$

여기서  $\delta \leq 1$ 이다. 위의 식에서 각도  $\alpha_k$ 를 계산하기 위해  $\langle \psi_k, \psi_i \rangle$ 을 고려한다. 웨이블릿 프레임은 일반적으로 많이 사용되고 있는 Mexicanhat 웨이블릿 함수  $(1 - x^2)e^{-\frac{x^2}{2}}$ 을 사용한다. 식 (8)에서 내적의 계산 결과는  $\forall j \in \{1, \dots, n-1\}$ 일 때 다음과 같다.

$$\cos(\alpha_k) = e^{-\frac{a^{2m}d_j^2}{2}} \left( 1.0 - a^{2m}d_j^2 + \frac{1}{12} a^{4m}d_j^4 \right) \quad (9)$$

여기서  $d_j = x_{ji} - x_{jk}$ 이다. 이 결과에서 만약 영점 교차점에서 거리  $d$ 를 유지할 수 있다면 각도  $\alpha_k = 90^\circ$ 를 얻을 수 있고, 결국 두 노드사이의 직교성을 보장할 수 있다. 이러한 개념을 바탕으로 다음과 같은 조건을 만들 수 있다.

$$|d| > d_{min}(m) \quad (10)$$

여기서  $d_{min}(m)$ 은 팽창계수  $m$ 이 주어지면 고정되는 값이다.

### 3. 웨이블릿 신경망의 성장 알고리즘

가장 인접한 노드의 거리와 직교성을 유지하기 위해 정의한 식 (10)과 비교하여 on-line 상에서 웨이블릿 신경망의 노드를 추가할 수 있는 하나의 근거를 만들 수 있다. 성장 알고리즘의 단계별 구성은 다음과 같다. 각 차원은 독립적으로 구분하여 고려하고, 각 차원별로 동일한 단계를 반복한다.

#### [단계 1] 초기화

먼저 임의의 두 개의 노드에 의해 표현되는 완전한 공간 영역  $[x_n(l), x_n(l)]$ 을 포함하도록 주파수의 하한극한(lower limit) 값  $L(l)$ 을 정의하기 위해서 두 노드간의 폭을 다음과 같은 식으로 표현할 수 있다.

$$L(l) = -\frac{\log(x_n(l) - x_l(l)) - \log(b(l))}{\log(a)} \quad (11)$$

식 (11)의 초기 팽창계수는  $m(l) = L(l)$ 로 정의하고 팽창계수가  $m(l)$ 일 때 준직교성을 유지할 수 있는 두 노드사이의 거리  $d(l)$ 은

$$d(l) = \frac{a^{-m(l)}b(l)}{2} \quad (12)$$

로 정의한다. 또한 첫 번째 노드(이동계수)는 다음 식을 이용하여 정수에 가장 가까운 값을 선택한다.

$$n_{first(l)} = \frac{x(l)a^{L(l)}}{b(l)} \quad (13)$$

위의 초기화 단계에서 결정된 WNN을 이용하여 학습을

수행한다.

#### [단계 2] 새로운 노드 추가

새로운 이동계수를 가진 노드를 추가하기 위해 학습 데이터  $l$ 에서 이미 존재하는 노드들 중에서 가장 인접한 노드의 거리  $d'_n(l)$ 을 계산한다. 만약 이전 거리와 비교하여  $d'_n(l) > d(l)$ 이고,  $|y'_d - y^l| > \epsilon_{MAE}$ 이면 다음과 같은 이동계수를 갖는 새로운 노드를 추가한다.

$$n(l) = \frac{x(l)a^{m(l)}}{b(l)} \quad (14)$$

여기서  $\epsilon_{MAE}$ 는 수행목표치를 의미한다.

#### [단계 3] 새로운 노드의 가중치 선택

새로 추가된 노드에 연결되는 가중치는 현재 입력되는 학습 데이터에 의해 발생하는 에러와 웨이블릿 함수의 출력을 고려하여 다음과 같은 식을 이용하여 결정한다.

$$w_{new} = \frac{|y'_d - y^l|}{\phi_p(x)} \quad (15)$$

여기서 팽창계수가  $m(l)$ 이고, 이동계수가  $n(l)$ 일 때  $\phi_p(x) = \phi_1(x) \dots \phi_n(x)$ 이고, 분자항인 에러의 절대값은 웨이블릿 팽창계수를 고려하여 입력공간에 적용되는 폭을 결정하여 평균 에러를 사용한다.

#### [단계 4] 학습단계

현재 주어진 학습데이터를 이용하여 각 차원별로 [단계 2]와 [단계 3]을 반복 수행한다. 만약 더 이상 추가되는 노드가 없을 경우 역전파 학습 알고리즘이나 LMS 학습 알고리즘을 이용하여 가중치를 조절한다. 웨이블릿 신경망이 원하는 목표치의 출력을 내도록 학습을 수행한다. 만약 더 이상 에러가 감소하지 않을 경우 전체 에러가 원하는 목표치에 도달하는지 여부  $(|y_d - y^l| < \epsilon_n)$ 를 검사하여 만약 도달하지 않을 경우 다음 단계를 수행하고, 전역에러가 원하는 목표치에 도달하면 성장 알고리즘을 종료한다.

#### [단계 5] 새로운 팽창계수 정의

만약 웨이블릿 신경망이 충분히 학습되어 더 이상 에러가 감소하지 않을 경우 새로운 팽창계수를  $m(l) = m(l) + 1$ 로 정의하고, [단계 2]를 반복한다. 만약 웨이블릿 신경망의 출력이 원하는 문턱치  $\epsilon_n$ 에 도달하면 성장 알고리즘을 종료한다.

## 4. 모의실험 및 검토

Mexicanhat 웨이블릿 함수에 대한 Daubechies의 계산결과[12]를 참조하여  $a=2$ (최대 고주파수 표현이 가능한 최소 정수)로 정의하고,  $b \in (0.25, 1.875)$ 에 속하는  $b=1.0493$ 을 선택하였다.

### 4.1 모의실험 1

모의실험 1에서는 비주기적인 근사화 대상 함수를 사용했다. 근사화 대상 함수는 식 (16)과 같으며 시간축 상에서  $[0, 1]$ 을 고려했고, 100개의 학습 데이터를 사용하였다.

$$f(t) = t \sin t \cos 5t \sin 10t \cos 30t \sin 50t \quad (16)$$

그림 3은 최대 절대치 오차(Maximum Absolute Error;

MAE)를  $\epsilon_{MAE}=0.005$ 와  $\epsilon_{MAE}=0.002$ 로 설정하고 모의실험을 수행한 결과를 나타낸 것이다.  $\epsilon_{MAE}=0.005$ 인 경우보다  $\epsilon_{MAE}=0.002$ 인 경우가 각 성장단계에서 추가되는 노드 수가 증가하여 RMSE가 감소함을 확인할 수 있다.

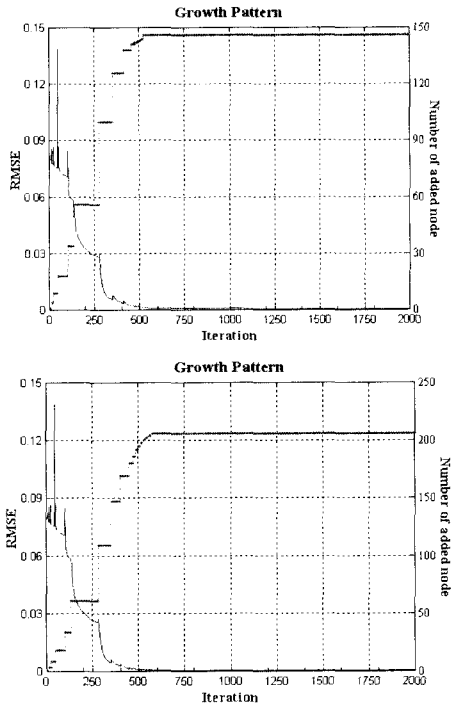


그림 3. 추가된 노드의 개수와 RMSE(MAE : 0.005, 0.002)

표 1은 최종 노드 수와 반복 횟수, RMSE를 비교하여 나타낸 것이다. 표에서  $m_1$ 은 입력패턴의 시간영역을 커버할 수 있는 팽창계수(주파수 하한)이고, 최종 팽창 계수(주파수 상한)는 성장 알고리즘의 최종 수행 단계별로 다르게 적용되었다.

표 1. 비주기 함수에서 WNN의 성장

MAE	최종 노드 개수	RMSE	final dilation
Mexicanhat ( $m_1 = 0$ )	0.005	0.016935	$m_{14} = 13$
	0.002	0.010668	$m_{21} = 20$

#### 4.2 모의실험 2

모의실험 2에서는 주기성을 갖고 있는 근사화 대상 함수를 사용했다. 이 함수는 3가지 다른 주파수 특성(3 종류의 동작모드)을 가지고 있는 정현파의 조합으로 식 (17)과 같고, 시간축 상에서  $[0, 2]$ 를 고려하였으며, 학습과 테스트 데이터는 201개를 사용하였다.

$$y(t) = \begin{cases} \sin(2\pi \times 2t) + \sin(2\pi \times 4t) & \text{if } t \leq 0.51 \\ \sin(2\pi \times 5t) + \sin(2\pi \times 10t) & \text{if } 0.51 < t \leq 1.51 \\ \sin(2\pi \times 3t) + \sin(2\pi \times 6t) & \text{if } t > 1.51 \end{cases} \quad (17)$$

주기성 함수의 근사화 문제에서는 MAE를 0.02와 0.01로 설정하고 모의실험을 수행하였다.

표 2는 성장 알고리즘을 적용한 결과와 성장 알고리즘이 완료된 후 테스트 데이터를 이용하여 근사화를 수행한 결과를 나타낸 것이다.




그림 4. 성장 패턴과 RMSE(MAE : 0.02, 0.01)

표 2. 주기 함수에서 WNN의 성장

MAE	최종 노드 개수	RMSE	final dilation
Mexicanhat ( $m_1 = -1.0$ )	0.02	0.051629	$m_{21} = 19.0$
	0.01	0.030689	$m_{16} = 14.0$

#### 4.3 모의실험 3

모의실험 3에서 2차원 근사화 대상함수는 식 (18)과 같은 Harmonic 함수이고, 시간축 상에서  $[0, 1] \times [0, 1]$ 을 고려하였으며, 학습과 테스트 데이터는 225개를 사용하였다.

$$f(t_1, t_2) = 42.659[0.1 + \hat{t}_1(0.05 + \hat{t}_1 - 10\hat{t}_1\hat{t}_2 + 5\hat{t}_2^2)] \quad (18)$$

여기서,  $\hat{t}_1 = t_1 - 0.5$ 이고,  $\hat{t}_2 = t_2 - 0.5$ 이다.

표 3은 성장 알고리즘을 적용한 결과와 성장 알고리즘이 완료된 후 테스트 데이터를 이용하여 근사화를 수행한 결과를 나타낸 것이다.

표 3. 2차원 함수에서 WNN의 성장

MAE	최종 노드 개수	RMSE	Iteration	final dilation
Mexicanhat ( $m_{1_1}=0, m_{1_2}=0$ )	0.4	0.068943	42152	$m_{12_1}=11, m_{12_2}=11$
	0.2	0.012033	97207	$m_{19_1}=18, m_{19_2}=18$

### 5. 결 론

본 논문에서 제안한 WNN의 성장 알고리즘은 기하학적인 방법을 사용하여 프레임의 직교기준을 구하고, 근사적으로 직교하도록 이동계수의 크기를 결정하여 성장 알고리즘 적용 시 프레임의 선택 기준으로 삼았다. 제안한 알고리즘을 1차원의 비주기, 주기 함수와 2차원 함수의 근사화 문제에 적용하여 알고리즘의 성공적인 적용 가능성과 근사화 능력을 검증하기 위해 모의실험을 수행하였다.

모의실험 결과에서 확인할 수 있듯이 웨이블릿 신경망의 성장과정에서 지역적인 오차를 보상하기 위해 필요한 웨이블릿 프레임이 자동으로 추가됨을 확인할 수 있었다. 특히 성장단계가 반복되면서 발생하는 지역오차를 감소시키는 방향으로 입력공간에서 부분적으로 노드가 추가되었다. 또한 MAE를 작은 값으로 설정하여 지역오차를 미세하게 고려하여 노드를 추가할 경우 각 단계별로 추가되는 노드의 수가 증가하고, 성장 알고리즘의 종료단계에서 최종 팽창계수(주파수 상한)를 정의할 수 있다.

제안한 알고리즘의 장점은 원하는 수렴 한계치를 설계자가 임의로 설정할 수 있기 때문에 대상문제에 적합한 적응적인 웨이블릿 신경망의 설계가 가능하다는 것이다.

추후과제는 대상문제를 시스템 동정이나 제어 분야로 적용분야를 확대하고, 다양한 조건과 환경에서 제안한 알고리즘의 성능을 검증하는 것이다. 또한 다차원 문제에 적용할 경우 비교적 많은 노드가 사용되는 문제점을 해결하기 위해 소거 알고리즘의 개발과 모듈화식 설계 방식을 도입하는 것이다.

### 참 고 문 헌

- [1] 서승진, 서재용, 원경재, 연정흠, 전홍태, "비선형 시스템의 안정한 직접 적용 제어를 위한 웨이블릿 신경회로망," *대한전자공학회 논문지*, 제36권 S편, 10호, pp. 51-57, 1999.
- [2] Y. C. Pati, "Wavelets and Time-Frequency Methods in Linear Systems and Neural Networks," *Institute for Systems Research*, Ph.D. Dissertation, 1992.
- [3] 김용택, 서재용, 연정흠, 김종수, 전홍태, "웨이브릿 이론을 이용한 퍼지-신경망 구조의 최적화," *한국퍼지 및 지능 시스템학회 논문지*, vol. 10, no. 6, pp. 591-596, 2000.
- [4] 조일, 서재용, 연정흠, 김용택, 전홍태, "동적 다차원 웨이블릿 신경망을 이용한 제어 시스템 설계," *대한전자공학회 논문지*, 제37권 SC편 4호, pp. 22-27, 2000.
- [5] 이창민, 서재용, 전홍태, "유전알고리즘을 이용한 웨이블릿 신경회로망의 최적 구조 설계," *한국퍼지 및 지능 시스템학회 논문지*, vol. 10, no. 4, pp. 338-342, 2000.
- [6] T. Kugarajah and Q. Zhang, "Multidimensional wavelet frames," *IEEE Trans. on Neural Networks*, vol. 72, pp. 1552-1556, Nov. 1995.
- [7] Q. Zhang and A. Benveniste, "Wavelet networks," *IEEE Trans. on Neural Networks*, vol. 3, pp. 889-898, Nov. 1992.
- [8] Daniel Clancy and Ümit Özgüner, "Wavelet Neural

- Networks : A Design Perspective," *IEEE Int. Symposium on Intelligent Control*, August, pp. 376-381, 1994.
- [9] Kai-chiu Kan and Kwook-wo Wong, "Self-construction algorithm for synthesis of wavelet networks," *Electronics Letters*, vol. 34, no. 20, pp. 1953-1955, 1995.
- [10] Bhavik R. Bakshi and George Stephanopoulos, "Wavelets as Basis Functions for Localized Learning in a Multi-resolution Hierarchy," *Int. Joint Conf. on Neural Networks(IJCNN)*, vol. 2, pp. 140-145, 1992.
- [11] Visakan Kadirkamanathan and Mehasan Niranjana, "A Function Estimation Approach to Sequential Learning with Neural Networks," *Neural Computation*, vol. 5, pp. 954-975, 1999.
- [12] Ingrid Daubechies, *Ten Lectures on Wavelets*, CBMS-NSF regional conference series in applied mathematics, Philadelphia, PA: SIAM, 1992.
- [13] 서재용, 김용택, 조현찬, 전홍태, "시간-주파수 분석을 이용한 모듈라 웨이블릿 신경망의 최적 구조 설계," *대한전자공학회 논문지*, 제38권, SC편, 제2호, pp. 12-19, 2001.

## 저 자 소 개

#### 서재용(徐在龍)

1969年 7月 21日生  
 1996년 2월 중앙대학교 전자공학과 졸업(학사)  
 1998년 2월 중앙대학교 대학원 전자공학과 졸업(석사)  
 2001년 9월 중앙대학교 대학원 전자공학과 졸업(박사)  
 2000년 8월 ~ 현재 : 한국기술교육대학교 정보기술공학부 객원교수

주관심분야 : 퍼지, 유전알고리즘, 신경망, FNN, 웨이블릿 신경망 등임

#### 김성주(金成柱)

정회원, 1971年 12月 12日生  
 1999년 2월 중앙대학교 전자공학과 졸업(학사)  
 2001년 2월 중앙대학교 대학원 전자공학과 졸업(석사)  
 2001년 3월 ~ 현재 : 중앙대학교 대학원 전자전기공학부 박사과정 재학중

주관심분야 : 신경망, 로보틱스, 퍼지, 웨이블릿 신경망 등임

#### 조현찬(趙鉉讚)

현재 : 한국기술교육대학교 정보기술공학부 전자공학과 교수

#### 전홍태(全洪兌)

현재 : 중앙대학교 전기전자공학부 교수