

論文2001-38SC-5-2

# 유전 알고리즘을 이용한 모듈라 웨이블릿 신경망의 최적 구조 설계

## (Optimal Structure of Modular Wavelet Network Using Genetic Algorithm)

徐在龍\*, 趙鉉讚\*, 金鏞宅\*\*, 全洪兌\*\*

(Jae-Yong Seo, Hyun-Chan Cho, Yong-Taek Kim, and Hong-Tae Jeon)

### 요약

단일 신경망에 기반한 웨이블릿 이론과 모듈라 개념을 결합하여 기존의 웨이블릿 신경망이나 모듈라 네트워크의 일종인 모듈라 웨이블릿 신경망이 제안되었다. 본 논문에서는 유전 알고리즘을 사용하여 모듈라 웨이블릿 신경망의 최적구조를 효과적으로 설계하는 방법을 제시하였다. 각 모듈을 구성하는 웨이블릿 신경망의 웨이블릿 기저함수의 팽창과 이동계수를 결정하기 위해 유전 알고리즘을 사용하였다. 제안한 최적 구조 설계 알고리즘을 근사화 문제에 적용하여 우수성을 검증하였다.

### Abstract

Modular wavelet neural network combining wavelet theory and modular concept based on single layer neural network have been proposed as an alternative to conventional wavelet neural network and kind of modular network. In this paper, an effective method to construct an optimal modular wavelet network is proposed using genetic algorithm. Genetic Algorithm is used to determine dilations and translations of wavelet basis functions of wavelet neural network in each module. We apply the proposed algorithm to approximation problem and evaluate the effectiveness of the proposed system and algorithm.

### I. 서 론

일반적인 신경망은 서로 다른 은닉층을 학습시킬 때 가중치 개선으로 말미암아 이전에 학습한 매핑 결과를

잊어버리는 일시적 혼선(temporal crosstalk)현상이 발생한다. 따라서 지역적, 부분적으로 중요한 변화를 가지는 대상함수의 학습이 어렵게 된다. 이러한 현상을 방지하기 위해서 신경망 노드의 상호 연관성과 중복 학습을 줄임으로써 지역화된 응답 특성을 갖는 모듈화 설계방법이 관심의 대상이 되고 있다.<sup>[1~4]</sup>

한편, RBF 회로망은 기저함수들이 일반적으로 직교하지 않기 때문에 필요 이상의 기저함수의 사용으로 효율적이고 고유한 망 구성이 어려운 문제점이 있다. 이러한 문제들을 극복하기 위해 기존의 신경망과 웨이블릿 이론을 결합한 웨이블릿 신경망(wavelet Neural Network)이 제안되었다. 웨이블릿 신경망은 RBF 회로망의 기저함수들을 웨이블릿 함수(wavelet function)로 대체하여 직교성을 갖는 기저함수를 갖도록 한다.<sup>[5,6]</sup>

최근에 웨이블릿 신경망과 모듈화식 설계방식을 도

\* 正會員, 韓國技術教育大學敎 情報技術工學部  
(School of Electrical and Electronics Eng. at Chung-Ang Univ.)

\*\* 正會員, 中央大學校 電子電氣工學部  
(School of Information Technology at Korea Univ. of Tech. and Edu.)

※ 본 연구는 과학기술부의 뇌과학연구 프로그램과 한국과학재단 목적기초연구(2000-1-30200-001-3)의 지원 하에 수행되었습니다.

接受日字: 2001年1月17日, 수정완료일: 2001年7月20日

입한 웨이블렛 모듈라 신경망이 제안되었다. 제안한 구조에서는 기존의 모듈라 신경망의 구조를 수용하고 각 모듈을 구성하는 웨이블렛 신경망의 기저함수를 웨이블렛 함수와 웨이블렛 신경망으로 구성하고 시간-주파수 분석법을 사용하여 대상문제에 적합한 최적구조를 설계하는 알고리즘을 제안하였다.<sup>[7]</sup>

이에 본 논문에서는 직교성을 갖는 웨이블렛 함수 대신에 망에 유연성을 제공하고 직교 웨이블렛 함수와 비슷한 알고리즘을 제공하는 웨이블렛 프레임(frame) 함수<sup>[8][9]</sup>로 모듈라 웨이블렛 신경망을 구성한 뒤, 망의 각 파라미터들을 적절히 구성하고 학습시키는 최적 구조 설계 알고리즘을 제안한다. 제안한 모듈라 웨이블렛 신경망의 최적 구조 설계 알고리즘은 최적화 알고리즘으로 널리 알려진 유전 알고리즘을 사용하여 모듈라 웨이블렛 신경망의 기저함수들을 최적으로 구성한 다음 대상문제에 적합한 최적의 기저 함수를 이용하여 모듈라 웨이블렛 신경망을 구성하고 확률적인 기울기 상승 학습(stochastic gradient ascent learning)으로 각 모듈의 은닉층과 출력층 사이의 가중치를 조절한다. 제안한 모듈라 웨이블렛 신경망의 최적구조설계 알고리즘의 우수성을 검증하기 위해 기존에 제안된 모듈라 신경망과 직교 웨이블렛 함수를 사용한 모듈라 웨이블렛 신경망을 함수 균사화 문제에 적용하고 모의실험 결과를 비교하여 그 우수성을 검증하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서 모듈라 웨이블렛 신경망의 구조를 살펴보고, 3장에서는 유전 알고리즘을 이용한 모듈라 웨이블렛 신경망의 최적 구조 설계 알고리즘을 소개한다. 4장에서 임의의 비선형 함수에 대한 균사화 모의 실험 결과를 검토하고, 마지막으로, 5장에서는 결론과 앞으로의 연구방향에 대하여 고찰한다.

## II. 모듈라 웨이블렛 신경망의 최적구조 설계

### 1. 가우스 혼합 모듈라 신경망

본 장에서는 가우스 혼합 모듈라 신경망을 토대로 새로운 구조인 모듈라 웨이블렛 신경망을 소개하고, 확률적인 강화 학습 알고리즘을 유도한다. 모듈라 웨이블렛 신경망의 구조는 그림 2와 같다. 각 모듈을 구성하는 엑스퍼트 네트워크는 최적구조를 설계하기 위한 이

론적인 배경을 제공하는데 용이하도록 다층 신경망 대신에 웨이블렛 신경망으로 구성하였다.

그림 2에서 차원이  $P$ 인 입력벡터는  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_P]^T$ 이고, 최종출력인  $Q \times 1$  벡터는  $\mathbf{y} = [y^1 \ y^2 \ \dots \ y^Q]^T$ 이다. 또한  $k$ 번째 엑스퍼트 네트워크 출력벡터는  $\mathbf{y}_k = [y_k^1 \ y_k^2 \ \dots \ y_k^Q]^T$ 이고, 원하는 응답벡터는  $\mathbf{d} = [d^1 \ d^2 \ \dots \ d^Q]^T$ 이다.

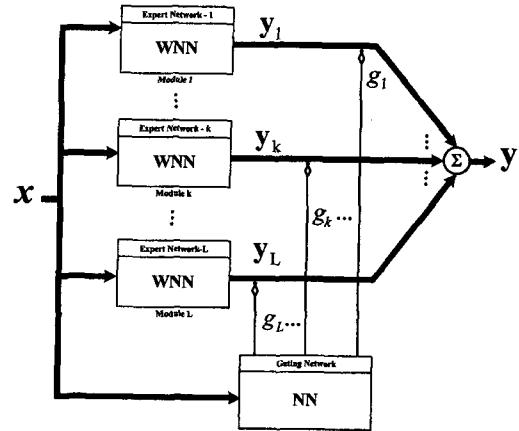


그림 1. 모듈라 웨이블렛 신경망  
Fig. 1. Modular Wavelet Network.

$k$ 번째 엑스퍼트 네트워크는 그림 2와 같이 웨이블렛 신경망을 이용하여 구성한다. 게이팅 네트워크는 일반적으로 혼합형 모듈라 신경망의 구조와 유사하게 다층 신경망을 이용하여 구성한다.

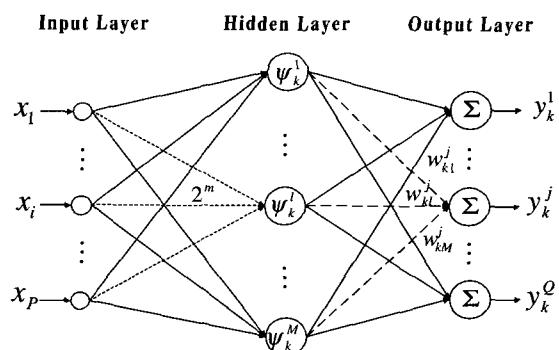


그림 2. 웨이블렛 신경망으로 구성한 엑스퍼트 네트워크  
Fig. 2. Expert network consisting of wavelet neural network.

## 2. 확률적인 기울기 상승 학습 알고리즘

확률적인 기울기 상승학습의 목표는 주어진 학습패턴 집합의 분포를 모델링하는 것이다. 즉, 시스템의 입출력 쌍이나 근사화 대상함수의 샘플 데이터를 이용하여 원하는 응답함수를 모듈화된 웨이블릿 신경망이 학습하도록 가우스 혼합형 밀도함수를 비용함수로 정의하고, 기울기 상승 학습 알고리즘을 이용하는 것이다.

### (1) 엑스퍼트 네트워크 학습알고리즘

웨이블릿 신경망으로 구성된 엑스퍼트 네트워크의 미지의 매개변수는 은닉층과 출력층 사이의 가중치 벡터  $\mathbf{w}_k$ 이다. 따라서 비용함수에 대한  $\mathbf{w}_k$ 의 변화정도인 민감도를 구하여 강화 학습에 이용할 수 있다. 식 (2)는 비용함수

$$\begin{aligned} l(\mathbf{w}, \mathbf{g}) &= \ln f(\mathbf{d}|\mathbf{x}) \\ &= \ln \sum_{k=1}^L g_k \exp\left(-\frac{1}{2}\|\mathbf{d} - \mathbf{y}_k\|^2\right) \end{aligned} \quad (1)$$

에 대한  $k$ 번째 모듈의  $j$ 번째 가중치  $\mathbf{w}_k^j = [w_{k1}^j \ w_{k2}^j \ \dots \ w_{kM}^j]^T$ 에 대한 변화량을 체인룰을 적용하여 나타낸 것이다.

$$\frac{\partial l(\mathbf{w}, \mathbf{g})}{\partial \mathbf{w}_k^j} = \frac{\partial l(\mathbf{w}, \mathbf{g})}{\partial \mathbf{y}_k} \cdot \frac{\partial \mathbf{y}_k}{\partial \mathbf{w}_k^j} \quad (2)$$

위의 식에서 오른쪽 항에 편미분을 적용하면 민감도 벡터는 아래 식과 같다.

$$\frac{\partial l(\mathbf{w}, \mathbf{g})}{\partial \mathbf{w}_k^j} = \frac{h_k}{\sigma_k^2} e_k^j \phi_{k, mn}(\mathbf{x}) \quad \begin{cases} k = 1, 2, \dots, L \\ j = 1, 2, \dots, Q \end{cases} \quad (3)$$

기울기 상승(gradient ascent) 방법을 이용한 미소조정 값은 다음과 같다.

$$\Delta \mathbf{w}_k^j = \eta \frac{\partial l(\mathbf{w}, \mathbf{g})}{\partial \mathbf{w}_k^j} \quad (4)$$

결국  $k$ 번째 모듈의 웨이블릿 신경망의 시냅스 가중치는 식 (5)에 의해서 매 샘플링 시간마다 갱신된다.

$$\begin{aligned} \mathbf{w}_k^j(t+1) &= \mathbf{w}_k^j(t) + \Delta \mathbf{w}_k^j(t) \\ &= \mathbf{w}_k^j(t) + \eta \frac{h_k}{\sigma_k^2} e_k^j \phi_{k, mn}(\mathbf{x}) \end{aligned} \quad (5)$$

### (2) 게이팅 네트워크 학습 알고리즘

식 (1)의 비용함수를 게이팅 네트워크의 가중치 벡터  $\mathbf{a}_k$ 에 대한 변화량을 체인룰에 의해서 구하면 다음 식

과 같다.

$$\frac{\partial l(\mathbf{w}, \mathbf{x})}{\partial \mathbf{a}_k} = \frac{\partial l(\mathbf{w}, \mathbf{x})}{\partial u_k} \cdot \frac{\partial u_k}{\partial \mathbf{a}_k}, \quad k = 1, 2, \dots, L \quad (6)$$

편미분을 적용하면 게이팅 네트워크의  $k$ 번째 가중치에 대한 확률적인 강화 학습법에 의한 미소 조정치는

$$\begin{aligned} \partial \mathbf{a}_k &= \eta \frac{\partial l(\mathbf{w}, \mathbf{x})}{\partial \mathbf{a}_k} \\ &= \eta(h_k - g_k)\mathbf{x} \end{aligned} \quad (7)$$

이고, 시냅스 가중치 벡터  $\mathbf{a}_k$ 는 식 (8)과 같이 매 시간 갱신된다.

$$\mathbf{a}_k(t+1) = \mathbf{a}_k(t) + \eta(h_k(t) - g_k(t))\mathbf{x}(t) \quad (8)$$

## III. 유전 알고리즘을 이용한 모듈라 웨이블릿 신경망의 설계

직교 스케일링 함수를 사용하여 웨이블릿 신경망을 구성한 방법은 대상함수에 대하여 고유한 표현식을 제공하지만, 함수의 다중분해분석이라는 웨이블릿의 특성과는 거리가 있으며 국부적으로 높은 주파수의 대상함수를 근사하기 위하여 동일한 평창계수를 사용되기 때문에 필요 이상으로 많은 뉴런을 사용하게 된다. 만약 임의의 함수를 단일 분해도에서 표현하고자 할 때, 함수의 가장 낮은 수준 분해도의 근사와 더 높은 분해도에서의 근사로 더 적은 데이터 포인트들을 사용하여 원래 함수를 정확히 표현할 수 있음을 알 수 있다. 여

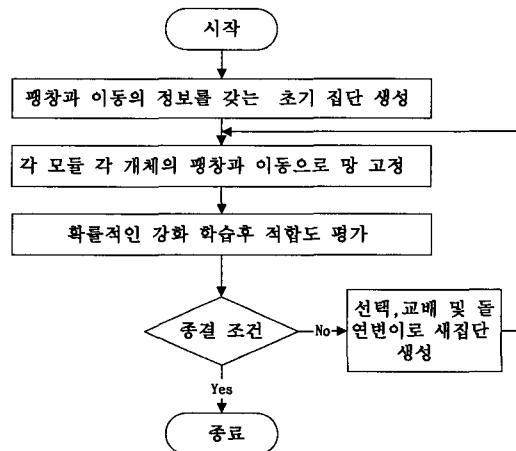


그림 3. 제안한 최적구조 설계 알고리즘의 흐름도  
Fig. 3. Flow Chart of the proposed Algorithm.

기서 분해도는 웨이블릿의 팽창 변수에 해당하고 데이터 포인트들은 이동변수에 의하여 이동되는 웨이블릿 기저함수에 해당되기 때문에 효율적인 함수 근사의 문제는 결국 웨이블릿 이론의 팽창과 이동의 결정에 좌우된다고 할 수 있다. 따라서 본 연구에서는 유전 알고리즘<sup>[10,11]</sup>을 사용하여 근사 대상함수에 대하여 각 모듈을 구성하는 웨이블릿 신경망의 팽창과 이동의 최적 값을 찾는다. 이를 위한 모듈라 웨이블릿 신경망의 최적구조 설계 알고리즘의 흐름도는 그림 3과 같다.

다음은 제안한 최적구조 설계 알고리즘의 단계별 처리 과정을 설명한 것이다.

[단계 1] 유전 알고리즘의 초기 개체군을 이루는 각 개체의 초기화는 다음 그림과 같이 개체마다 각 모듈 웨이블릿 신경망에 필요한 모든 팽창과 이동의 정보를 가질 수 있도록 코딩한다.

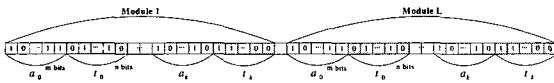


그림 4. 모듈의 각 개체의 초기화

Fig. 4. Initialization of a Chromosome.

팽창 변수( $a_i$ )와 이동 변수( $t_i$ )에 각각  $m, n$  비트(bit)를 할당하고, 모듈의 개수가  $L$ 개이고 은닉층 뉴런의 개수가  $k$ 개면 각 개체에 필요한 비트 수는  $((m+n) \times k) \times L$ 이다.

[단계 2] 각 개체의 이진 정보를 적절한 팽창( $a_i$ ), 이동( $t_i$ )으로 변환시킨 다음 웨이블릿 신경망에 대입하여 확률적인 기울기 상승 학습을 수행한 후, 각 개체마다의 적합도 값을 계산한다. 변환될 수 있는 팽창의 최대 값을  $d_{\max}$ , 최소값을  $d_{\min}$ 이라 하면, 팽창의 정밀도  $d_{\pi}$ 는 다음과 같이 계산되고,

$$d_{\pi} = \frac{d_{\max} - d_{\min}}{2^m - 2^n} \quad (9)$$

$a_i$ 의 변환된 값은 다음 식에 의해 구할 수 있다.

$$a_{i(\text{real})} = (a_{i(\text{bin})})_{10} \times d_{\pi} + d_{\min} \quad (10)$$

여기서, 변환될 수 있는 팽창의 최소값( $d_{\min}$ )은 단일 웨이블릿 함수를 사용하여도 근사 대상함수의 영역을 충분히 포함할 수 있도록 설정하며, 최대값( $d_{\max}$ )은 근

사 대상함수에 따라 적절히 선택하여 준다. 마찬가지로, 변환될 수 있는 이동의 최대 값을  $t_{\max}$ 라고, 최소값을  $t_{\min}$ 이라 하면, 이동의 정밀도  $t_{\pi}$ 는 다음과 같이 계산되고,

$$t_{\pi} = \frac{t_{\max} - t_{\min}}{2^n - 2^0} \quad (11)$$

$t_i$ 의 변환된 값은 다음 식에 의해서 구할 수 있다.

$$t_{i(\text{real})} = (t_{i(\text{bin})})_{10} \times t_{\pi} + t_{\min} \quad (12)$$

변환될 수 있는 이동( $t_i$ )의 최대 값과 최소값은 대상함수의 영역 [ $x_{\min}, x_{\max}$ ]과 팽창( $a_i$ )에 의하여 다음과 같이 결정된다.

$$t_{\max} = x_{\max} \times a_i, \quad t_{\min} = x_{\min} \times a_i \quad (13)$$

위와 같은 억제 조건(constraint condition)은 변환된 이동에 따라 웨이블릿 함수가 이동하여 근사 대상함수의 영역을 벗어나는 것을 방지해준다.

각 개체의 적합도 값은 변환된 팽창과 이동으로 웨이블릿 신경망의 입력층과 은닉층 사이의 기중치 및 각 뉴런의 임계값을 고정시킨 후 은닉층과 출력층 사이의 기중치 값을 확률적인 기울기 상승 학습을 이용하여 구한다. 학습은 출력층 뉴런이 선형조합 형태이고 입력과 은닉층 사이의 기중치는 학습할 필요가 없기 때문에 기존의 신경망의 학습보다는 단순한 구조이지만 너무 많은 반복횟수는 많은 시간이 소요되므로 각 개체의 적합도 차이를 확인할 수 있는 범위에서 학습을 중단한다. 적합도는 다음 식을 이용하여 구한다.

$$\text{fitness} = \frac{1}{\sqrt{\sum_{i=1}^n (f(x_i) - g(x_i))^2 / n + 1}} \quad (14)$$

여기서  $f(x_i)$ 와  $g(x_i)$ 는 각각  $i$ 번째 입력의 근사 대상 함수와 웨이블릿 신경망의 출력이다.

[단계 3] 개체군에서 높은 적합도 값을 갖는 개체에 높은 선택 확률을 주고, 선택된 개체 사이에 교배와 돌연변이의 진화과정을 통하여 새로운 개체군을 얻는다. 본 논문에서 개체 선택에 사용된 방법은 룰렛 선택법과 엘리트 보존 선택법이며, 교배와 돌연변이는 각각 단순 교배와 다점 돌연변이가 사용되었다.

[단계 4] 새로운 최고의 개체나 원하는 적합도 값이 얻어질 때까지 상기 단계를 반복한다.

[단계 5] 최종적으로 얻어진 개체의 팽창과 이동으로 웨이블릿 신경망을 고정시켜 최적구조를 결정한 후 은닉층과 출력층 사이의 가중치 값을 확률적인 강화 학습을 이용하여 충분히 학습을 수행한 후 모의실험을 종료한다.

#### IV. 임의의 비선형 함수에 대한 근사화 모의실험

본 장에서는 모듈라 웨이블릿 신경망의 최적구조 설계 알고리즘을 임의의 비선형 함수에 대한 근사화 문제에 적용하여 우수성을 검증하고자 한다. 1차원 비선형 함수에 대하여 근사화 실험을 수행하였으며 비교 대상으로는 기존의 가우스 혼합형 모듈라 신경망과 단일 팽창과 균일한 이동을 사용하는 직교 기저 스케일링 함수를 사용한 모듈라 웨이블릿 신경망을 사용하였다. 각 엑스퍼트 네트워크의 웨이블릿 신경망에 사용된 웨이블릿 프레임 함수는 웨이블릿 프레임 조건 및 함수 근사 이론을 만족하는 가우시안(Gaussian) 함수의 미분 형태를 사용하였다.<sup>[5]</sup> 근사 대상함수  $f(x)$ 는 구간  $[-10, 10]$ 에서 다음과 같이 구간별로 정의된 함수이다.

$$f(x) = \begin{cases} -2.186x - 12.864 & , -10 \leq x < -2 \\ 4.246x & , -2 \leq x < 0 \\ 10e^{-0.05x-0.5} \cdot \sin[(0.03x+0.7)x] & , 0 \leq x \leq 10 \end{cases} \quad (15)$$

유전 알고리즘에 사용된 제어 파라미터들은 표 1과 같으며 3개의 모듈 그리고 각 모듈마다 5개의 뉴런을 사용하였다.

표 1. 유전 알고리즘의 제어 파라미터  
Table 1. Control Parameters of GA for a 1D function.

개체군 크기	교배율	돌연변이율
30	100 %	70 %

첫 번째 비교대상인 단일 신경망 가우스 혼합 모듈라 신경망에는 3개의 모듈을 사용하였다. 확률적인 기울기 상승학습의 학습률  $\eta$ 는 0.05를 사용하였고, 총

2000번의 반복 학습을 수행하였다. 두 번째로 직교 기저 웨이블릿 함수를 사용한 모듈라 웨이블릿 신경망에는 역시 3개의 모듈 5개의 뉴런을 사용하였다. 직교 기저 스케일링 함수로 널리 알려진 sinc 함수를 사용하였다. 또한 단일 팽창은  $2^{-1}$ 을 사용하였고, 근사 대상함수의 영역이 완전히 포함될 수 있도록 총 11개의 뉴런을 사용하였다. 그림 4~그림 6은 각 신경망의 근사 결과를 나타낸 것이다. 결과에서 확인할 수 있듯이 유전 알고리즘을 이용 제안한 모듈라 웨이블릿 신경망이 단일신경망 그리고 균일한 이동을 사용한 모듈라 웨이블릿 신경망보다 우수한 근사 결과를 나타낸다 알 수 있다. 표 2는 제안한 최적구조 설계 알고리즘과 기존의 혼합형 모듈라 신경망의 모의실험 결과를 수치적으로 비교하여 나타낸 것이다.

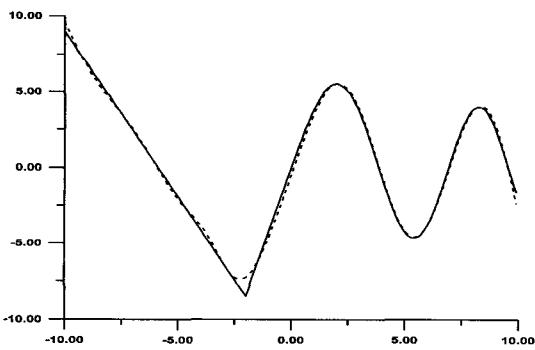


그림 5. 최적화된 모듈라 웨이블릿 신경망의 근사 결과

Fig. 5. Approximation of optimized modular wavelet Network.

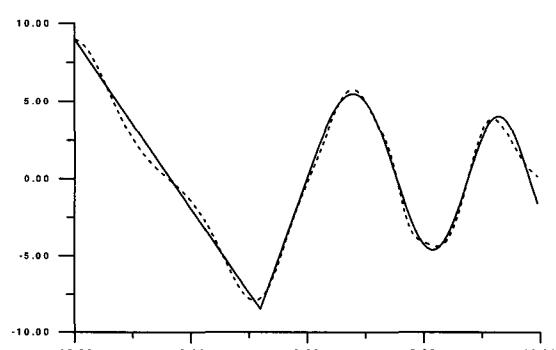


그림 6. 단일신경망 가우스 혼합 모듈라 신경망의 근사 결과

Fig. 6. Approximation of Associative Gaussian Model.

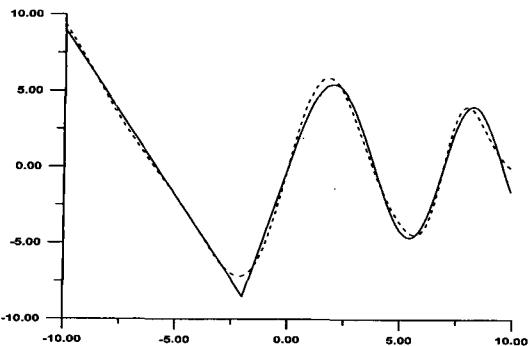


그림 7. 직교 웨이브릿 함수를 사용한 모듈라 웨이브릿 신경망의 근사 결과  
Fig. 7. Approximation of Modular wavelet network based on Orthogonal wavelet function.

표 2. 모의실험 결과의 수치적 비교  
Table 2. Numerical Comparison of computer simulation.

모듈라 신경망 구성	최적구조 설계 알고리즘 적용 유무	RMSE
직교 기저 웨이브릿 신경망	적용	1.456
단일 신경망	미적용	3.246
직교 기저 웨이브릿 신경망	미적용	3.452

## V. 결 론

본 논문에서는 모듈라 웨이브릿 신경망의 최적구조 설계 알고리즘을 제안하였다. 제안한 알고리즘은 선행 처리 단계로써 유전 알고리즘을 이용하여 주어진 문제 해결에 적합한 팽창과 이동 값을 결정한 후에 확률적인 기울기 상승 학습 알고리즘을 통해 최적구조를 설계할 수 있는 방법론을 제시하였다. 또한 미세조정을 위해 기울기 상승 학습 알고리즘을 이용하여 은닉층과 출력층 사이의 가중치를 학습하는 것에 그 특징이 있다. 모의실험 결과 모듈라 웨이브릿 신경망과 최적구조 설계 알고리즘에 의하여 적은 수의 모듈과 뉴런으로도 좋은 근사 결과를 얻을 수 있음을 확인하였다.

일반적으로 모듈라 웨이브릿 신경망은 입력 차원이 증가할수록 많은 수의 모듈과 뉴런이 필요하며 이는 곧 유전 알고리즘이 탐색해야 할 해 공간이 늘어나게 되어 최적해 탐색에 많은 시간이 필요함과 동시에 최적해가 아닌 공간으로 수렴할 가능성 또한 늘어날 수 있다. 앞으로 개선할 점은 다양한 문제에 적용하여 최적화 알고리즘의 우수성을 검증하고, 각 모듈을 구성하

는 뉴런을 효과적으로 구성하기 위한 다양한 방법론의 제시하는 것이다.

## 참 고 문 헌

- [1] R. A. Jacobs, M. I. Jordan, s. J. Nowlan, and G. E. Hinton, "Adaptive Mixtures of Local Experts," *Neural Computation*, Vol. 6., pp.181-214, 1994.
- [2] Michael I. Jordan and Robert A. Jacobs, "Hierarchical Mixtures of Experts and the EM Algorithm," *Neural Computation*, Vol. 6, No. 1, pp.181-214, 1994.
- [3] Jacobs R. A. and Jordan M. I., "Learning Piecewise Control Strategies in a Modular Neural Network Architecture," *IEEE Trans. Sys. Man and Cybernetics*, Vol. 23, No. 2, pp. 337-345, 1993.
- [4] Gasser Auda and Mohamed Kamel, "Modular Neural Network Classifiers: A Comparative Study," *Journal of Intelligent and Robotic Systems*, Vol. 21, pp.117-129, 1998.
- [5] Q. Zhang and A. Benveniste, "Wavelet networks," *IEEE Trans. on Neural Networks*, vol. 3, pp.889-898, 1992.
- [6] J. Zhang, G. G. Walter, Y. Miao and W. N. W. Lee, "Wavelet neural networks for function learning," *IEEE Trans. Signal Processing*, vol. 43, pp.1485-1497, 1995.
- [7] 서재용, 김용택, 조현찬, 전홍태, "시간-주파수 분석을 이용한 모듈라 웨이브렛 신경망의 최적 구조 설계," 대한전자공학회 논문지, 제38권, SC편, 제2호, pp.12-19, 2001
- [8] Martin Vetterli and Jelena Kovacevic, *Wavelets and Subband Coding*, Prentice Hall, 1995.
- [9] C. S. Burrus, R. A. Gopinath, and H. Guo, *Introduction to Wavelets and Wavelet Transforms*, Upper Saddle River, NJ : Prentice-Hall, 1998.
- [10] David E.Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley Publishing, 1989.

- [11] L. Davis, *Handbook of Genetic Algorithm*, Van Nostrand Reinhold, 1991
- [12] 서승진, 서재용, 원경재, 연정희, 전홍태, “비선형 시스템의 안정한 직접 적용 제어를 위한 웨이블렛 신경회로망,” *대한전자공학회 논문지*, 제36권 S편, 10호, pp.51-57, 1999

## 저자 소개

**徐 在 龍(正會員)**

정회원, 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 BK 책임교수. 주관심분야 : 퍼지, 유전알고리즘, 신경망, FNN, 웨이블렛 신경망 등 임

**趙 錦 讚(正會員)**

현재 : 한국기술교육대학교 정보기술공학부 교수

**金 鐏 宅(正會員)**

1967年 2月 23日生. 1992년 2월 중앙대학교 전자공학과 졸업(학사). 1994년 8월 중앙대학교 대학원 전자공학과 졸업(석사). 1996년 9월~현재 : 중앙대학교 대학원 전자공학과 박사과정 재학중. 주관심분야 : 신경망, 로보틱스, 퍼지 등임

**全 洪 兑(正會員)**

현재 : 중앙대학교 전기전자공학부 교수