

스케일링-웨이블릿 혼합 신경회로망 구조 설계

Design the Structure of Scaling-Wavelet Mixed Neural Network

김성주, 김용택*, 서재용**, 조현찬**, 전홍태

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

중앙대학교 일반대학원 전자전기공학부

*한국전력기술주식회사 전력기술개발연구소

**한국기술교육대학교 정보기술공학부

요 약

신경회로망은 차원이 확장됨에 따라 학습에 필요한 계산량이 기하급수적으로 증가하는 문제가 발생한다. 이를 극복하기 위해 적교성을 지닌 웨이블릿 신경회로망이 제안되었다. 웨이블릿 함수의 경우 스케일과 중심을 결정함으로써 신경회로망의 노드로 구성된다. 본 논문에서는 웨이블릿 함수를 이용하여 망을 구성하는 과정에 스케일링 함수를 함께 은닉층의 노드로 복합 구성함으로써 스케일링 함수를 이용하여 대강 근사(rough approximation)를 행한 다음, 웨이블릿 함수를 이용하여 미세 근사(fine approximation)를 행하도록 구성하는 복합 신경회로망을 제안한다. 또한, 복합 신경회로망을 구성하는 과정에서 미세 근사에 필요한 웨이블릿 함수의 개수를 유전 알고리즘을 이용하여 결정한다.

ABSTRACT

The neural networks may have problem such that the amount of calculation for the network learning goes too big according to the expansion of the dimension. To overcome this problem, the wavelet neural networks(WNN) which use the orthogonal basis function in the hidden node are proposed. One can compose wavelet functions as activation functions in the WNN by determining the scale and center of wavelet function. In this paper, when we compose the WNN using wavelet functions, we set a single scale function as a node function together. We intend that one scale function approximates the target function roughly, the other wavelet functions approximate it finely. During the determination of the parameters, the wavelet functions can be determined by the global search for solutions suitable for the suggested problem using the genetic algorithm and finally, we use the back-propagation algorithm in the learning of the weights.

Key words : Scaling Function, Wavelet Function, Neural Network, Wavelet Neural Network, Genetic Algorithm

1. 서 론

신경망의 다차원시 구조 거대화의 문제, 방사기준함수망의 함수 중복 등의 문제들을 극복하기 위해 기존의 신경회로망과 웨이블릿 이론을 결합한 웨이블릿 신경회로망(Wavelet Neural Network)이 제안되었다[1]. 웨이블릿 신경회로망은 RBF 회로망의 기준 함수들을 웨이블릿 이론(Wavelet Theory)의 웨이블릿 함수(Wavelet Function)로 대체하여 적교성을 갖는 기준 함수를 갖도록 한다. 웨이블릿 신경회로망은 알려지지 않은 함수에 대하여 효율적이고 고유한 망 구성을 제공한다. 그러나 웨이블릿 함수들은 강한 직교 조건을 만족해야 하며 이러한 직교 조건은 망의 유연성을 저해하는 요소로 작용하고, 또한 시간-스케일의 지역화에는 낮은 성능을 나타낸다[1][2].

다중 분해 분석(Multi-Resolution Analysis) 이론에 의하면 복잡한 함수가 몇 개의 간단한 함수로 분리됨을 알 수 있다. 이 과정에서 근사 대상 함수를 포함하는 전체 영역은 스케일링 함수와 웨이블릿 함수로 표현됨을 알 수 있다[2]. 또한 웨이블릿 함수의 파라미터를 적절히 구성할 때, 더욱 효율적인 구성을 할 수 있다. 이에 본 논문에서는 일반적인 웨이블릿 구조의 은닉층(Hidden Layer)에 적절히 선택된 하나의 스케일 함수를 이용하여 대상 함수를 대강 근사(rough approximation)하며 웨이블릿 함수를 이용하여 대상 함수를 미세 근사(fine approximation)할 수 있는 스케일링 함수와 웨이블릿 함수로 구성된 복합 구조를 제안하며 각 함수의 파라미터를 적절히 구성하고 학습시키는 최적 구조 설계 알고리즘을 제안한다. 이런 구성을 적용할 경우 장점은 다중으로 근사를 이룰 수 있으며, 전체 구조의 크기를 줄여나갈 수 있다는 점이다.

제안한 스케일링-웨이블릿 복합 신경회로망의 최적 구조 설계 알고리즘은 다음과 같은 세 과정으로 구성되어 있다.

첫 번째 과정은 대상 함수를 최소 분해할 수 있는 스케일링 함수를 선택하며 파라미터를 결정한다. 두 번째 과정은

접수일자 : 2001년 11월 22일

완료일자 : 2002년 10월 31일

본 논문은 과학기술부 뇌신경정보학연구사업의 지원에 의해 작성되었습니다.

최적화 알고리즘으로 널리 알려진 유전 알고리즘을 사용하여 웨이블릿 신경회로망의 기준 함수들을 최적으로 구성한다. 세 번째 과정은 문제 해결에 적합한 최적의 기준 함수를 이용하여 스케일링-웨이블릿 복합 신경회로망을 구성하고 기존의 역전파 학습으로 은닉층과 출력층 사이의 가중치를 조절한다. 제안한 스케일링-웨이블릿 복합 신경회로망의 최적 구조 설계 알고리즘을 함수 근사화 문제에 적용하여 그 결과를 기존의 다층 전방향 신경회로망과 직교 웨이블릿 신경회로망의 결과와 비교하여 우수성을 검증하고자 한다.

2. 스케일링 함수, 웨이블릿 함수 그리고 다중 분해 분석

근사 대상 함수를 다중분해분석을 이용하여 분석할 경우, 낮은 분해도의 분석과 높은 분해도의 분석이 가능함을 알 수 있다. 이런 사실을 근거로, 근사 대상 함수를 스케일링 함수와 웨이블릿 함수의 복합적인 구성으로 보다 효율적으로 근사할 수 있다.

이차원 스케일링 함수의 집합은 다음과 같은 정수 팽창(dilation)변수와 이동(translation)변수에 의하여 정의된다 [2].

$$\varphi_{m,n}(x) = \varphi(2^m x - n) \quad (1)$$

여기서 $\varphi(x) \in L^2(R)$ 는 유한한 에너지를 갖는 함수, m, n 은 정수이며 이동에 의하여 서로 직교하며 식(2)와 같이 표현할 수 있다.

$$\int_{-\infty}^{\infty} \varphi(x)\varphi(x-n)dx=0, \quad n \neq 0 \quad (2)$$

이 함수에 의하여 표현할 수 있는 $L^2(R)$ 의 부분공간을

$$V_m = \overline{Span_n\{\varphi_{m,n}(x)\}} \quad (3)$$

와 같이 정의하고 임의의 함수 $f(x) \in V_m$ 을 식(4)와 같이 나타낼 수 있다.

$$f(x) = \sum_n a_n \varphi(2^m x - n) \quad (4)$$

$m > 0$ 일 때, m 이 커질수록 $\varphi_{m,n}(x)$ 의 폭은 좁아지고 작은 간격으로 이동되기 때문에 더욱 정밀한 표현이 가능하고 그 부분공간 또한 커진다. 따라서 부분 공간간의 다음의 포함관계를 이끌어낼 수 있고,

$$\{0\} \subset \dots \subset V_{-1} \subset V_0 \subset V_1 \subset V_2 \subset \dots \subset L^2 \quad (5)$$

다중 분해 분석의 고유한 성질인 다음의 두 결과를 얻을 수 있다.

$$f(x) \in V_m \Leftrightarrow f(2x) \in V_{m+1} \quad (6)$$

$$\varphi(x) = \sum_n a_n \varphi(2x - n) \quad (7)$$

부분공간 V_{m+1} 과 V_m 의 직교 웨이블릿 여공간 W_m 은 다음과 같이 정의된다.

$$V_m \cap W_m = 0 \quad (8)$$

$$V_m \oplus W_m = V_{m+1} \quad (9)$$

여기서, 부분공간 W_m 은 웨이블릿 함수 $\psi_{m,n}(x) = \psi(2^m x - n)$ 에 의하여 표현되는 공간이다. 이를 이용하면 $L^2(R)$ 공간은 다음과 같이 분해될 수 있다.

$$L^2 = V_0 \oplus W_0 \oplus W_1 \oplus \dots = \dots \oplus W_{-1} \oplus W_0 \oplus W_1 \oplus \dots \quad (10)$$




그림 1. 스케일링 함수와 웨이블릿 벡터 공간
Fig. 1. Scaling Function And Wavelet Vector Space

그림 1은 다른 스케일 m 에 대한 스케일링 함수 공간 V_m 과 웨이블릿 공간이 어떻게 나누어지는가를 보여준다.

3. 복합 신경회로망 설계

3.1 스케일링-웨이블릿 복합 신경회로망(SWNN)

일반적으로 구성된 웨이블릿 신경회로망의 구조에서 다중 분해 분석을 통해 스케일링 함수를 추가로 구성하여 스케일링 함수와 웨이블릿 함수로 구성된 복합 구조를 이끌어낸다. 스케일링-웨이블릿 복합 구조는 웨이블릿망의 은닉층을 구성하는 웨이블릿 함수들 중 하나의 함수를 스케일링 함수로 대체하여 구성할 수 있으며 다음 그림과 같이 표현된다.




그림 2. 스케일링-웨이블릿 복합 신경회로망의 구조
Fig. 2. Structure of Complex SWNN

위 그림에서 D_1, D_2, \dots, D_n 은 각각 1, 2, ..., n 번째 웨이블릿의 신축 계수이며, ϕ_T 는 이동 계수를 T 로 하는 스케일링 함수이며 자체적으로 스케일 변수(a)를 포함하고 있다. 또한, ψ_n 는 웨이블릿 함수를 표현한다. 은닉층과 출력층 사이의 가중치는 $\omega_1, \omega_2, \dots, \omega_{n+1}$ 로 표현되며, 여기서 n 은 웨이블릿만으로 이루어진 은닉층의 개수이다. 그림 2에서는 스케일링을 하나만 사용하여 전체적인 스케일링-웨이블릿 복합 구조를 형성하고 있다. 경우에 따라서, 스케일링 함수를 늘릴

수 있다.

제한한 구조를 결정함에 있어서 가장 중요한 문제는 스케일링 함수를 선택하고 웨이블릿 변수를 결정하는 일이다. 본 논문에서는 스케일링 함수와 웨이블릿 함수 사이에 연관성이 강하며 시간 축에서 스케일링 함수와 웨이블릿 함수를 모두 동일하게 표현할 수 있는 싱크(Sinc)함수를 기본으로 하여 싱크 스케일링 함수(Sinc Scaling Function)와 싱크 웨이블릿 함수(Sinc Wavelet Function)를 사용한다.

결정된 스케일링 함수의 스케일 변수와 이동 변수는 대상 함수와의 단순 비교를 통하여 대강 근사를 이룰 수 있는 최소한의 값을 부여한다. 근사 대상 함수의 시간 축에서의 범위와 함수 값의 범위를 근거로 하여 스케일 변수와 이동 변수를 결정하였다. 스케일링 함수를 결정하면 전체 구조를 완성하기 위해 웨이블릿 함수의 변수를 결정해야 한다. 본 논문에서는 일반적인 최적해 탐색 알고리즘인 유전 알고리즘을 이용하여 결정하고자 한다. 그림 2에서 제안한 구조의 전체 출력식을 표현하면 다음과 같다.

$$Y = \sum_{i=1}^T \phi_T(X_i(t)) W_i + \sum_{h=1}^n \sum_{i=1}^T \phi_h(X_i(t)) W_{h+1} \quad (11)$$

여기서, i 는 입력의 개수, T 는 스케일 변수값, h 는 웨이블릿으로 구성된 은닉층 개수이며, W 는 은닉층과 출력층 사이의 가중치이다. 스케일 변수는 앞에서 설명한 것처럼 근사 대상 함수를 효과적으로 근사할 수 있는 최소값을 선택하며, 웨이블릿 함수는 신축과 이동 변수를 파라미터로 갖으며 유전 알고리즘을 이용하여 출력층에서 에러(error)를 최소화할 수 있는 적절한 값을 선택한다. 가중치는 일반적으로 사용되는 역전파 알고리즘을 통하여 갱신된다.

본 논문에서 제안한 스케일링-웨이블릿 복합 신경회로망의 구조의 장점은 여러 개의 웨이블릿 함수의 역할을 스케일링 함수가 대신함으로써 전체적인 구조의 크기를 줄일 수 있다는 것이다. 또한, 웨이블릿만으로 구성된 일반적인 웨이블릿 신경회로망에 비해 근사의 효과를 극대화할 수 있다는 것이다. 이는 다중 분해 분석을 통한 결과이기도 하다.

4. 유전 알고리즘을 이용한 복합 신경회로망의 최적 구조 설계

본 논문에서는 함수에 대한 다중분해분석 기법을 이용하여 대상함수를 근사하는 과정을 다음과 같이 분리하였다. 가장 낮은 수준 분해도의 근사에 스케일링 함수를 이용하고 더 높은 분해도의 근사는 웨이블릿 함수를 이용하여 대상 함수를 근사하는 방법적 근거를 검증하기 위한 복합 구조를 제안하고자 한다. 여기서 분해도는 스케일링 함수의 스케일 조절 변수, 웨이블릿의 팽창 변수에 해당하고 데이터 포인트들은 스케일링 함수의 최초 이동 변수에 의한 기저함수가 되는 동시에, 이동 변수에 의하여 이동되는 웨이블릿 기저함수에 해당되기 때문에 효율적인 함수 근사의 문제는 결국 낮은 수준 분해도에 따른 스케일링 함수의 최초 스케일 조절 변수와 이동 변수에 좌우되며 웨이블릿 이론의 팽창과 이동의 결정에 좌우된다고 할 수 있다. 따라서 본 연구에서는 대상 함수를 가장 낮은 수준으로 분해하였을 경우에 대상 함수를 적절히 표현할 수 있는 스케일링 함수를 결정하고 유전 알고리즘을 사용하여 근사 대상 함수에 대한 웨이블릿 신경회로망의 팽창과 이동의 최적 값을 찾는다. 이제 좀더 자세히 제안한 최적 구조 설계 알고리즘의 처리 과정에 대하여 알아본다.

[단계 1] 스케일링 함수 변수 결정

근사 대상 함수를 가장 낮은 수준 분해도로 분석을 한 후에 근사 대상 함수를 표현하기에 적당한 스케일링 함수의 초기 변수를 결정한다.

[단계 2] 각 개체의 초기화

유전 알고리즘의 초기 개체군을 이루는 각 개체의 초기화는 다음 그림과 같이 개체마다 스케일링-웨이블릿 복합 신경회로망의 은닉층을 구성하는 스케일링 함수를 제외한 웨이블릿 함수 결정에 필요한 모든 팽창과 이동의 정보를 가질 수 있도록 코딩한다.




그림 3. 각 개체의 초기화

Fig. 3. Initialization of a Chromosome

[단계 3] 망 고정 및 적합도 평가

각 개체의 이진 정보를 적절한 팽창(a_i), 이동(t_i)으로 변환시킨 다음 스케일링-웨이블릿 복합 신경회로망에 대입하여 역전파 학습을 수행한 후, 각 개체마다의 적합도 값을 계산한다. 변환될 수 있는 팽창의 최대값을 d_{max} , 최소값을 d_{min} 이라 하면, 팽창의 정밀도 d_{π} 는 다음과 같이 계산되고,

$$d_{\pi} = \frac{d_{max} - d_{min}}{2^m - 2^0} \quad (12)$$

a_i 의 변환된 값은 다음 식에 의하여 구할 수 있다.

$$a_{i(real)} = (a_{i(bin)})_{10} \times d_{\pi} + d_{min} \quad (13)$$

여기서, 변환될 수 있는 팽창의 최소값(d_{min})은 단일 웨이블릿 함수를 사용하여도 근사 대상 함수의 영역을 충분히 포함할 수 있도록 설정하며, 최대값(d_{max})은 근사 대상 함수에 따라 적절히 선택하여 준다. 적합도는 다음 식에 의하여 구한다.

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

여기서 $f(x_i)$ 와 $g(x_i)$ 는 각각 i 번째 입력의 근사 대상 함수와 스케일링-웨이블릿 복합 신경회로망의 출력이다.

[단계 4] 새로운 집단 생성

개체군에서 높은 적합도를 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 5] 새로운 최고의 개체나 원하는 적합도 값이 얻어질 때까지 상기 단계를 반복한다.

[단계 6] 최종적으로 얻어진 개체의 팽창과 이동 값과 스케일링 변수를 이용하여 스케일링-웨이블릿 복합 신경회로망을 고정시켜 최적 구조를 결정한 후 은닉층과 출력층 사이의 가중치 값을 역전파 학습 알고리즘을 이용하여 충분히 학습을 수행한 후 모의실험을 종료한다.

5. 임의의 비선형 함수에 대한 근사화 모의 실험 결과

이 장에서는 웨이블릿 신경회로망의 최적구조 설계 알고리즘을 임의의 비선형 함수에 대한 근사화 문제에 적용하여 우수성을 검증하고자 한다. 1차원 함수와 2차원 함수에 대하여 근사화 실험을 수행하였으며 비교 대상으로는 기존의 다층 전방향 신경 회로망과 단일 팽창과 균일한 이동을 사용하는 직교 기저 스케일링 함수를 사용한 웨이블릿 신경회로망을 이용하였다.

5.1 1차원 비선형 함수에 대한 근사화 실험

스케일링-웨이블릿 복합 신경회로망에 사용된 스케일링 함수는 싱크 함수로 구성된 싱크 스케일링(Sinc Scaling) 함수인 $\phi(t) = \frac{\sin(\pi t)}{\pi t}$ 를 사용했고, 웨이블릿 함수는 싱크 스케일링 함수에서 유도된 싱크 웨이블릿 함수 $\psi(t) = \frac{\sin(2\pi t) - \sin(\pi t)}{\pi t}$ 이다. 근사 대상 함수 $f(x)$ 는 구간 $[-10, 10]$ 에서 다음과 같이 구간별로 정의된 함수이다.

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

유전 알고리즘에 사용된 제어 파라미터들은 표 1과 같으며 초기 구성은 스케일링으로 구성된 한 개의 뉴런과 웨이블릿으로 구성된 9개를 사용하였다. 실험결과에서 알 수 있듯이 유전 알고리즘 적용 결과 표 2의 초기 변수가 표 3과 같이 결정되었다. 이 중 동일한 변수를 제외하고 표 4와 같이 웨이블릿의 변수를 최종 결정하여 총 8개의 뉴런을 사용하였다.

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

개체군 크기	교배율	돌연변이율
60	100 %	30 %

비교 대상인 다층 전방향 신경회로망에는 총 12개의 뉴런을 사용했고 활성화 함수는 다음과 같은 시그모이드 함수를 사용하였다.

$$\sigma(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (16)$$

역전과 학습의 학습률 η 는 0.05를 사용하였고, 총 2000번의 반복 학습을 수행하였다.

직교 기저 웨이블릿 신경 회로망의 웨이블릿 함수로는 직교 기저 스케일링 함수로 널리 알려진 식(17)과 같은 싱크 함수를 사용하였다.

$$\varphi(x) = \frac{\sin x}{x} \quad (17)$$

여기서, 단일 팽창은 2^{-1} 을 사용하였고, 근사 대상 함수의 영역이 완전히 포함될 수 있도록 총 11개의 뉴런을 사용하였다.

그림 4~그림 6은 각 신경회로망의 근사 결과를 나타낸 것이다. 결과에서 확인할 수 있듯이 유전 알고리즘에 의하여

구성된 스케일링-웨이블릿 복합 신경회로망이 적은 수의 뉴런으로도 더 좋은 근사 결과를 나타냄을 알 수 있다.

표 2. 유전 알고리즘 적용 이전의 초기 팽창과 이동
Table 2. Initial dilations and translations before tuning by the genetic algorithm

뉴런	1	2	3	4	5	6	7	8	9
팽창	2^{-2}	2^{-2}	2^{-2}	2^{-2}	2^{-1}	2^{-1}	2^{-1}	2^{-1}	2^0
이동	-2.0	-1.0	0.0	2.0	-1.0	0.0	1.0	2.0	4.0

표 3. 유전 알고리즘 적용 이후의 팽창과 이동
Table 3. Dilations and translations after tuning by the genetic algorithm

뉴런	1	2	3	4	5	6	7	8	9
팽창	2^{-2}	2^{-2}	2^{-1}	2^0	2^{-2}	2^{-1}	2^{-1}	2^{-1}	2^{-2}
이동	0.0	-4.0	0.0	7.0	3.0	2.0	3.0	0.0	3.0

표 4. 제안한 최적구조 설계 알고리즘으로 결정된 팽창과 이동

Table 4. Dilations and Translations decided by the proposed Algorithm

뉴런	1	2	3	4	5	6	7
팽창	2^{-2}	2^{-2}	2^{-1}	2^0	2^{-2}	2^{-1}	2^{-1}
이동	0.0	-4.0	0.0	7.0	3.0	2.0	3.0

표 5. 함수 근사 결과 오차 비교

Table 5. Comparison of the error after approximation of the target function

방식	SWNN	MLNN	MNN
RMSE	2.351	2.942	2.736
뉴런수(개)	8	12	11

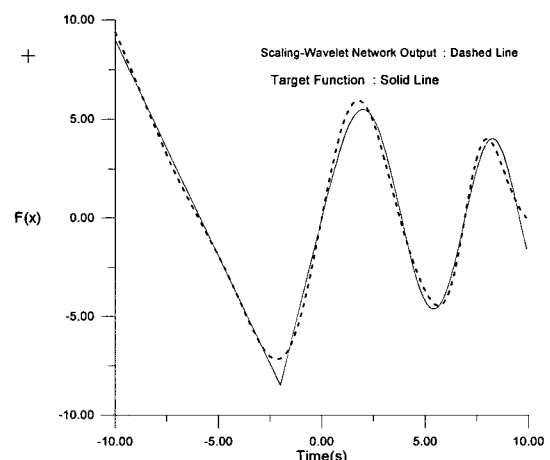


그림 4. 제안한 SWNN의 근사 결과
Fig. 4. Approximation of Complex SWNN




그림 5. 다차원 전방향 신경회로망의 근사 결과
Fig. 5. Approximation of MLNN




그림 6. 직교기저 웨이블릿 신경회로망의 근사 결과
Fig. 6. Approximation of Orthogonal WNN

5.2 2차원 비선형 함수에 대한 근사화 실험

2차원 함수의 근사에 사용된 스케일링 함수와 웨이블릿 함수는 각각 1차 스케일링 함수와 웨이블릿 함수의 텐서 곱 형태인

$$\psi(x) = \frac{\sin(\pi t)}{\pi t} \frac{\sin(\pi t)}{\pi t} \quad (18)$$

$$\psi(x) = \frac{\sin(2\pi t) - \sin(\pi t)}{\pi t} \frac{\sin(2\pi t) - \sin(\pi t)}{\pi t} \quad (19)$$

을 사용하였으며, 근사 대상 함수로 영역 $[-10,10] \times [-10,10]$ 사이에 있는 $f(x) = (x_1^2 - x_2^2)\sin(0.5 x_1)$ 을 이용하였다. 유전 알고리즘에 사용된 제어 파라미터는 다음과 같다.

표 6. 유전 알고리즘의 제어 파라미터 II
Table 6. Control Parameters of GA for a 2D function

개체군 크기	교배율	돌연변이율
300	100 %	30 %

표 7. 최적구조 설계 알고리즘을 적용한 웨이블릿 신경회로망과 직교기저 웨이블릿 신경회로망과의 비교
Table 7. Comparison between WNN by the proposed Algorithm and Orthogonal WNN

	뉴런 수	RMSE
SWNN	64	3.552
WNN	121	3.246




그림 7. 2차원 근사 대상 함수
Fig. 7. 2-dimensional Target Function




그림 8. 스케일링-웨이블릿 복합 신경회로망의 근사 결과
Fig. 8. Approximation of proposed SWNN

2차원 함수의 근사에 있어서는 직교기저 웨이블릿 신경회로망과의 근사 결과를 비교하였다. 결과에서 확인할 수 있듯이, 최적구조 설계 알고리즘을 적용한 스케일링-웨이블릿 복합 신경회로망이 절반 정도의 뉴런으로도 직교 기저 웨이블릿 신경회로망과 유사한 결과를 얻었음을 알 수 있다. 그림 7과 그림 8에서 각각 2차원 근사 대상 함수와 최적구조 설계 알고리즘을 적용한 스케일링-웨이블릿 복합 신경회로망에 의하여 근사된 함수를 보였다.

6. 결론

함수 근사화 문제에 있어서 다중 분해 분석을 통해 낮은

수준 분해도의 분석을 통한 대강 근사와 높은 분해도의 분석을 통해 미세 근사를 시도하기 위해 본 논문에서는 스케일링-웨이블릿 복합 신경회로망을 제안하였다. 스케일링-웨이블릿 복합 신경회로망에서 적합한 스케일 변수, 팽창과 이동 값의 선택은 더욱 효율적인 함수 근사를 위하여 매우 중요하다. 이에 본 논문에서는 스케일링-웨이블릿 복합 신경회로망의 팽창과 이동을 최적으로 구성하고 학습시키는 알고리즘을 제안하였다. 이 알고리즘은 유전 알고리즘을 이용하여 주어진 문제 해결에 적합한 팽창과 이동 값을 결정한 후에, 다시 역전파 학습 알고리즘을 이용하여 은닉층과 출력층 사이의 가중치를 학습하는 것에 그 특징이 있으며, 이와 같이 구성된 스케일링-웨이블릿 복합 신경회로망이 임의의 비선형 함수에 대한 근사화 실험 결과에서 기존의 다차원 전방향 신경회로망이나 작고 기저 웨이블릿 신경회로망보다 더 적은 뉴런수로도 더 좋은 근사 결과를 나타냄을 확인하였다. 그러나, 일반적으로 스케일링-웨이블릿 복합 신경회로망은 입력 차원이 높아질수록 많은 수의 뉴런이 필요하며 이는 곧 유전 알고리즘이 탐색해야 할 해 공간이 늘어나게 되어 최적해 탐색에 많은 시간이 필요함과 동시에 최적해가 아닌 공간으로 수렴할 가능성 또한 늘어난다고 할 수 있다. 따라서, 향후에는 이와 같은 문제점을 극복할 수 있도록 보다 발전된 형태의 유전 알고리즘이나 다른 탐색 알고리즘을 적용하여 해 공간 탐색의 효율성 및 정확성을 높이는 방향으로의 연구가 필요하다.

참 고 문 헌

- [1] Q. Zhang and A. Benveniste, "Wavelet networks," *IEEE Trans. On Neural Networks*, vol. 3, pp. 889-898, Nov. 1992.
- [2] Jaideva C. Goswami and Andrew K. Chan, *Fundamentals of Wavelets*, Wiley Interscience, 1999.
- [3] C. S. Burrus, R. A. Gopinath, and H. Guo, *Introduction to Wavelets and Wavelet Transforms*. Upper Saddle River, NJ : Prentice-Hall, 1998.
- [4] Seung-Jin Seo and Hong-Tae Jeon, "Wavelet network for stable direct adaptive control of nonlinear systems," *Proceedings of the ITC-CSCC'99*, vol. 1, pp. 332-335, July. 1999.
- [5] Ali N. Akansu, Richard A. Haddad, *Multiresolution Signal Decomposition*, Academic Press, 1992.

저 자 소 개

김성주 (Seong-Joo Kim)

1999년 중앙대학교 전자공학과 공학사
 2001년 동 대학원 전자공학과 공학석사
 현재 동 대학원 전자전기공학부 박사과정

관심분야 : 신경망, 로봇틱스, 퍼지, 웨이블릿, 신경망 등

E-mail : ksj1212@ms.cau.ac.kr

김용택 (Yong-Taek Kim)

1992년 중앙대학교 전자공학과 공학사
 1994년 동 대학원 전자공학과 공학석사
 1996년9월~현재 동 대학원 전자전기공학부 박사과정
 현재 KOPEC, 전력기술개발연구소 재직

관심분야 : 신경망, 로봇틱스, 퍼지, 2족로봇

서재용 (Jae-Yong Seo)

1996년 중앙대학교 전자공학과 공학사
 1998년 동 대학원 전자공학과 공학석사
 2001년 9월 동 대학원 전자공학과 공학박사
 현재 한국기술교육대학교 정보기술공학부 객원교수

관심분야 : 퍼지, 유전알고리즘, 신경망, FNN, 웨이블릿 신경망

조현찬 (Hyun-Chan Cho)

현재 한국기술교육대학교 정보기술공학부 전자공학과 교수

전홍태 (Hong-Tae Jeon)

현재 중앙대학교 전자전기공학부 교수