

論文94-31B-11-17

시스템의 정밀 모델링을 위한 자율분산 신경망

(Self-organized Distributed Networks for Precise Modelling of a System)

金 焰 梅*, 崔 鍾 淳**, 金 聖 中*

(Hyongsuk Kim, Jong Soo Choi and Sung Joong Kim)

要 約

다차원 시스템(multidimensional system)에 대한 정확한 모델링을 위해 “자율 분산 신경망(Self-organized Distributed Networks, SODN)”을 제안하였다. 제안한 신경망은 자율 신경망(Self-organized Networks)과 다수의 소규모 다층 신경망(Multilayer Neural Networks)이 조합되어 지역적 병렬 학습을 수행하는 부분 학습망으로서 학습 속도가 빠르고 학습의 정밀도를 높일 수 있으며 타 부분망 학습에서 문제가 되는 과다한 학습 메모리 소요와 학습되지 않은 영역에 대한 낮은 일반화능력 등의 문제가 보완된 새로운 신경망이다. 학습 실험 결과, 제안한 신경망은 기존의 다층 신경망과 RBF(Radial Basis Function) 신경망에 비해서 우수한 성능을 보였다.

Abstract

A new neural network structure called Self-organized Distributed Networks (SODN) is proposed for developing the neural network-based multidimensional system models. The learning with the proposed networks is fast and precise. Such properties are caused from the local learning mechanism. The structure of the networks is combination of dual networks such as self-organized networks and multilayered local networks. Each local networks learns only data in a sub-region. Large number of memory requirements and low generalization capability for the untrained region, which are drawbacks of conventional local network learning, are overcomed in the proposed networks. The simulation results of the proposed networks show better performance than the standard multilayer neural networks and the Radial Basis Function(RBF) networks.

* 正會員、全北大學校 制御計測工學科

(Dept. of Control & Instrumentation Eng..
Chonbuk Nat'l Univ.)

** 正會員、(株)포스콘 技術研究所

(R&D CENTER, POSCON CORPORATION)
接受日字：1994年 3月 3日

I. 서 론

다중 신경망과 역전파 학습 규칙^[1]은 1980년 대 이래 패턴 인식을 위한 강력한 수단으로서 혹은 시스템 근사화 도구로서 학자들의 많은 관심을 받아왔다. 간단한 패턴 분류 문제에서 보여주는 잡음에 대한 강인성, 일반화 능력 등은 기존의 알고리즘에 의존한 방법에 비해 매력적이었으며 특히 입력 및 출력 데이터에 대한 학습만으로도 시스템의 모델을 구성할 수 있다는 점은 매우 큰 장점이었다. 그 동안 이 분야에 대한 많은 연구 노력이 있었으며 꾸준히 발전을 해왔다. 그러나 아직 실용화 수준의 발전에는 이르지 못하고 있는데, 그 이유 중의 하나는 학습의 어려움에 있다. XOR 나 parity 문제 같은 간단한 문제에 대한 학습에서 좋은 성능을 보여주었던 다중 신경망은 문제가 복잡해짐에 따라 학습이 급격히 어려워지게 되며, 실생활에 적용할 수 있는 크기의 문제들에 대해서는 그 실현이 불투명할 정도로 학습상의 큰 어려움이 있었다.

다중 신경망 학습이 어려운 이유 중의 하나는 단일 신경망 내에 데이터의 입/출력 조건을 모두 만족시킬 수 있는 공통 연결강도(weights)들을 찾아내야 한다는 데 있다. 이를 해결하기 위해서 데이터들을 특성에 따라 분류하고 특성 별로 다른 파라미터들을 사용하여 학습 성능을 개선하는 연구들이 있었는데 이 신경망을 부분학습망(local learning network)이라고 한다. 이 부분학습망에서는 유사한 특성을 가진 지역적 데이터들 간에서만 공통 파라미터를 찾게 되므로 학습이 훨씬 쉬워지게 된다. 대표적인 부분학습망으로는 CMAC(Cellbellar Model Arithmetic Computer) 신경망과 Radial Basis Function(RBF) 신경망 및 wavelet 신경망 등이 있다. CMAC은 입력 공간을 양자화하여 분할하고 각 상태 공간에 대한 함수값을 랜덤하게 분포한 메모리에 분산 저장하며, 각 상태의 감응영역(receptive field) 내에 있는 상태들과 메모리를 공유케 하는 원리이다.^[3,7] 이 신경망에는 매우 많은 수의 메모리(연결강도)가 요구되며, 입력의 양자화로 인한 출력의 불록화 현상 및 해싱잡음(hashing noise) 등의 문제점들이 있었다. 이를 개선하기 위해서 RBF 신경망이 개발되었는데^[8], 이 신경망은 중심점(center)과 폭(width)이 가변인 감응영역을 갖는 감응 유니트(receptive unit) 층과 단층 신경망이 계층적으로 연결된 구조를 갖는다. RBF 신경망도 함수를 분할하여 부분 학습하므로 학습 속도가 빠르며, 출력값이 연속적으로 표현되는 등의 장점들이 있으므로 많은

연구가 있었으나^[8-13], 학습되지 않은 영역에서의 저조한 일반화 능력과 매우 많은 수의 RBF 유니트를 필요로 한다는 문제점들이 있었다. Wavelet 신경망도 RBF 신경망과 유사한 신경망으로서^[14], 부분 학습 신경망이 갖는 위의 단점들을 해결하지 못했다.

제안한 자율 분산 신경망(Self-organized Distributed Networks, SODN)은 기존의 다중 신경망과 자율 신경망(Self-organized Neural Networks)의 장점들을 조합한 신경망으로서, 입력 공간을 학습 데이터의 분포와 학습의 어려움에 따라 자율적으로 분할하고 각 분할된 공간에 부분망을 분산 배치하여 부분망 학습을 수행하게 된다. 이 신경망은 학습 속도가 빠르며 학습 대상을 정확히 학습하는 등 부분 학습 신경망의 장점과 일반화 능력이 우수한 다중 신경망의 장점을 모두 갖춘 새로운 신경망이다. 제안한 신경망의 학습 특성을 시험하기 위해서 심한 비선형성을 가진 함수들을 대상으로 학습 실험하였다. 또한 다차원에도 적용 가능함을 보이기 위해 종이 지도상의 등고선을 따라 추출한 지형 고도 데이터를 대상으로 학습함으로써 지형 모형을 재현하는 실험을 수행하였다. 실험 결과는 기존의 다중 신경망 및 RBF 신경망의 실험 결과와 비교 제시되었다.

이 논문의 제 2 절에서는 기존의 부분 신경망 중 대표적인 RBF 신경망을 분석했으며, 제 3 절에서는 제안한 SODN을 소개하였다. 제 4 절에서는 제안한 신경망과 RBF 신경망 및 다중 신경망을 대상으로 학습 실험하여 그 결과를 제시하였으며, 제 5 절에서는 본 논문에 대한 요약과 아울러 제안한 신경망의 특징을 기술하였다.

II. 부분 학습 신경망

시스템을 단일 신경망을 이용하여 학습하려고 하면 모든 학습 데이터를 공통으로 만족시킬 수 있는 연결강도들의 공통 해가 학습을 통하여 구해져야 한다. 만약 주어진 함수가 크고 복잡하여 학습 데이터의 수가 많으면 많을 수록 공통 해를 구하는 문제는 더욱 어려워진다. 부분 학습 신경망(local learning neural networks)은 소 단위의 신경망들이 입력 공간을 분할하여 부분적 학습을 수행함으로써 학습의 어려움을 경감시키는 신경망 구조이다. CMAC 신경망, wavelet 신경망 및 RBF 신경망 등이 이 범주에 속하는 부분 학습 신경망들로서 학습이 빠르다는 공통적 특징이 있다. RBF 신경망은 대표적인 부분 학습망으로서 그 구조와 동작 원리는 다음과 같다.

RBF 신경망은 그림 1과 같이 감응 유니트 층과

출력 유니트 층이 계층적으로 연결된 구조이다. 감응 유니트 층의 활성화 함수(kernel)는 주로 Gaussian 이 사용되며, 유니트의 출력은

$$o_i = R_i(\vec{x}) = \exp\left[-\frac{\|\vec{x} - \vec{c}_i\|^2}{\sigma_i^2}\right], \quad i = 1, 2, \dots, H \quad (1)$$

로 계산된다. 여기서 \vec{x} 는 입력 벡터이고 \vec{c}_i 는 Gaussian 함수의 중심이며 σ_i 는 Gaussian 함수의 폭이다. 또 H 는 감응 유니트의 개수이다. RBF 신경망의 출력은 연결 강도가 곱해진 감응 유니트 출력의 합으로서 다음과 같이 계산된다.

$$f(\vec{x}) = \sum_{i=1}^H o_i w_i \quad (2)$$

위 식 (1)에서 감응 유니트 층의 출력은 감응 유니트의 중심과 입력 벡터 간의 거리의 자승에 따라 역 지수함수적으로 감소하므로 입력 벡터로부터 원거리에 위치하는 감응 유니트들의 출력의 크기는 무시할 수 있을 만큼 작아지게 되므로 0으로 근사화 할 수 있다. 이 0이 아닌 출력을 갖는 입력 공간의 범위를 그 유니트의 감응영역이라고 한다. 식 (2)의 RBF 신경망의 출력 계산에는 유니트의 감응영역이 입력 벡터를 포함하고 있는 유니트들만 참여한다.

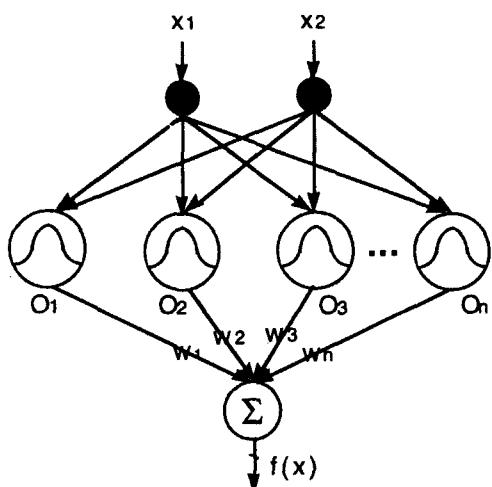


그림 1. RBF 신경 회로망의 구조

Fig. 1. A structure of the RBF neural networks.

학습 시에도 입력 벡터를 감응영역 내에 포함하는 감응 유니트들만 참여하며, 이 때 유니트의 중심점 c_i 및 폭 σ_i 는 차울 신경망 학습 알고리즘을 사용하고^[2]

출력층의 가중치는 LMS 혹은 Adaline과 같은 단층 신경망 학습 규칙을 사용하거나^[1], 이 파라미터들을 직교 최소 자승법(orthogonal least square)을 이용하여 계산한다.^[4] 따라서 기존의 단층 신경망 학습이 모든 학습 데이터들의 임. 출력 조건을 만족 시킬 수 있는 연결 강도를 찾는 문제임에 비하여 RBF 신경망의 학습은 학습 데이터 중 감응영역에 속하는 데이터들만의 임. 출력 조건을 만족시키는 파라미터를 찾는 문제로 단순화되므로 학습이 용이해진다.

위와 같은 구조와 특징을 갖는 RBF 신경망은 충분한 개수의 RBF 유니트가 주어지는 경우에 임의의 학습에 대한 근사화가 가능함이 이론적으로 증명되었다.^[11] 그러나 RBF 신경망 학습에는 매우 많은 수의 RBF 유니트를 필요로 하므로^[13] 학습 함수의 입력 변수의 수가 증가하게 되어 학습해야 하는 데이터의 수가 크게 증가하게 되면, RBF 신경망의 크기가 비현실적으로 커져야 되는 문제점을 갖고 있다. 또한 하나의 문제점은 일반화 능력이 약하다는 점이다. RBF 신경망은 학습을 위해서 일반적으로 많은 수의 RBF 유니트를 사용하게 되는데 이 때, RBF 유니트의 자유도(degree of freedom)가 증가하게 되며, 이로인해서 일반화 능력은 떨어진다.^[13] RBF 유니트의 출력 함수는 심한 비선형성을 가지며, 동일 감응 영역 내에서도 영역에 따라 타 감응영역들과의 중첩 정도가 다르므로, 구해진 RBF 파라미터가 일부 영역의 학습 조건을 만족 시켰다고 하더라도 다른 테스트 영역에서는 대상 함수와는 전혀 다른 값을 출력할 수 있다. 또한 학습 데이터가 충분치 못하여 유니트의 폭에 대한 제한을 갖지 못하는 경우, 출력이 거리에 따라 자연 감소하는 문제점도 발생한다. 이를 보완하기 위해서 다음식 (3)과 같이 RBF 유니트들의 출력을 정규화하여 출력값의 상대적인 크기를 사용하는데 결과적으로 각 RBF 유니트마다 주도적으로 동작하는 영역이 넓어지고, 유니트의 출력값이 거리에 따라 자연 감소하지 않으므로 일반화 능력을 향상시킬 수 있다.

$$f(\vec{x}) = \frac{\sum_{i=1}^H o_i w_i}{\sum_{i=1}^H o_i} \quad (3)$$

그러나 정규화된 출력을 사용할 경우, 폭이 큰 RBF 유니트의 출력은 원거리의 입력 공간에 대한 과간섭(over interference) 현상을 일으켜서 또 다른 종류의 일반화 문제를 야기할 수 있다. 즉 입력 공간에 폭이 다른 RBF 유니트들이 존재하는 경우,

폭이 큰 RBF 유니트의 출력은 거리에 따라 서서히 감쇠하는 반면, 폭이 작은 RBF 유니트의 출력은 급격히 감쇠한다. 입력 공간 상에는 폭이 작은 RBF 유니트에 가까운 위치라 하더라도 원거리의 폭이 큰 유니트의 영향을 많이 받게되어 원거리 유니트의 간섭에 의한 예상치 못한 출력을 갖을 수 있다. RBF 신경망의 감응영역은 전 방향 대칭이므로 데이터 학습 시 어느 한 방향으로의 폭이 확장되면 모든 다른 방향으로도 동시에 확장되어 원거리에 위치한 유니트에 의한 간섭으로 뜻하지 않은 값을 출력할 수 있다. 이 현상은 식 (3)과 같이 정규화된 출력을 사용할 경우에 증폭되어 나타난다.

III. 자율 분산 신경망

제안한 자율 분산 신경망(SODN)은 임의의 비선형 함수에 대해서도 학습이 용이하며, 정보가 압축되어 저장되므로 소요되는 연결강도의 수를 줄일 수 있으며 일반화 특성도 좋은 새로운 신경망이다. SODN의 구조는 그림 2와 같으며 학습 신경망(Learning Networks)과 부분망의 분산 배치용인 자율 신경망으로 구성된다.

1. 학습 신경망과 자율 신경망

학습 신경망

학습 신경망은 소규모의 다층 신경망(2~3개의 은닉 유니트)으로 구성되므로 여러 역전파 알고리즘에 의해서 임의의 비선형 함수에 대해서도 학습이 가능하다.^[1] 다층 신경망의 k 층에 있는 j 번째 유니트의 출력을 x_j^k 라고 하면 출력은

$$\begin{aligned} x_j^k &= f\left(\sum_i w_{ji}^k x_i^{k-1} + b_j^k\right) \\ &= f(W_j^k)^T X^{k-1} + b_j^k \\ &= f(\text{net}_j) \end{aligned} \quad (4)$$

로 계산된다. 여기서 w_{ji}^k 는 k-1 층의 i 번째 유니트와 k 층의 j 번째 유니트 간의 연결강도이고 b_j^k 는 j 번째 유니트의 바이어스이다. 또한 net_j 는 입력 값의 총합인 $(W_j^k)^T X^{k-1} + b_j^k$ 이고 f는 유니트의 활성화 함수이며 주로 시그모이드 함수(sigmoid function)를 사용한다.

역전파 학습은 합자승 오차 함수의 최대 경사면 방향으로 연결강도를 점차 변화시켜 가는 학습 원리인데 입력 패턴 x_i 에 대해 연결강도의 변화값 Δw_{ji} 는 다음과 같이 계산된다.

$$\Delta w_{ji} = \eta \delta_j x_i \quad (5)$$

여기서

η : 학습 계수

$$\delta_j = \begin{cases} (t_j - x_j) f'(\text{net}_j) & : j \text{ 가 출력단 유니트일 때 } (6a) \\ f'(\text{net}_j) \sum_k \delta_k w_{kj} & : j \text{ 가 은닉층 유니트일 때 } (6b) \end{cases}$$

이고 t_j 는 학습 목표값이고 x_j 는 j 번째 유니트의 출력이다.

자율 신경망

제안한 SODN에서 사용한 자율 신경망은 0과 1의 2 진수를 출력하는 경쟁망으로서 각 유니트 내에 신경망의 생성/소멸에 관련된 에너지 저장소(energy storage)를 갖는 점을 제외하면 Kohonen의 자율 신경망과 같다. 이 자율 신경망은 단층 신경망으로 구성되며 각 유니트는 입력단으로부터 연결강도를 통하여 연결된다. 또 각 자율 신경 유니트의 출력은 다른 자율 신경 유니트들의 입력 사이에서 억제적 연결(inhibitory connections)을 가지므로 입력 벡터가 인가되면 입력 벡터와 가장 유사한 연결강도를 갖는 유니트만 활성화되는 winner-take-all 동작을 한다. 기하학적 의미로서의 자율 신경망의 연결강도는 각 유니트의 공간적 위치를 나타내므로 winner-take-all 동작은 입력 벡터와 가장 근거리에 위치한 유니트만 활성화됨을 의미한다. 이 원리를 이용하면, 입력 공간 상의 모든 위치의 점들은 주어진 자율 신경 유니트들 중 가장 가까운 유니트에 각각 할당되게 할 수 있으며, 결과적으로 입력 공간이 자율 신경망 내의 유니트 위치에 의해 자연스럽게 분할될 수 있게 된다.

자율 신경망 내의 i 번째 유니트 위치(연결강도 벡터)를 C_i 라고 하면, 입력 벡터 X 가 인가될 때의 유니트 위치 이동은 다음과 같은 학습 규칙을 따른다.

$$\begin{aligned} C_i(k+1) &= (1-\alpha)C_i(k) + \alpha X & ; \text{ for winning unit} \\ C_i(k) & & ; \text{ for losing units} \end{aligned} \quad (7)$$

여기서 α 는 학습 계수(learning rate)이다. 이 학습 규칙에 의하면 활성화된 유니트의 연결강도 벡터만 입력 벡터 방향으로 이동하게 되므로 학습 후, 유니트들은 현재의 위치에서 가장 가까운 데이터 그룹의 중심으로 이동하게 된다. 이 Kohonen의 학습 규칙은 동일한 데이터 그룹 내에서는 유니트 위치가 자율 조정되어 이동이 용이하지만^[2] 연결강도 벡터의 분포가 학습 공간상에 동일한 확률로 분포하지 않는 경우, 각 유니트에 대한 데이터의 할당이 불균등하게 될 수 있다.는 문제점이 있다.^[15] 또한 유니트의 위치는 학습 데이터의 위치에만 의존하여 자율 조정되므로 학습 데이터

의 통계적 분류 목적으로만 사용되어 왔다.

2. SODN의 동작 원리

제안한 SODN에서는 학습용 신경망 내의 부분 다층 신경망 한 세트와 자율 신경망 내의 유니트 한 개는 짹이되어 한 세트의 부분망을 구성하며 분할된 공간의 함수 학습을 수행한다. 입력 벡터는 학습 신경망과 자율 신경망에 공통으로 연결되고 자율 신경망과 학습 신경망의 출력들은 상호 짹이되는 신경망의 출력과 곱하여 연결된다. 다수의 출력을 갖는 SODN의 경우는 부분 다층 신경망의 출력 유니트 수가 최종 출력의 수와 같게 되며, 한 세트의 부분 다층 신경망의 모든 출력에는 한 개의 자율 신경 유니트 출력이 동일하게 곱해져서 출력단 유니트에 하나씩 인가된다. 출력단 유니트는 모든 입력값을 단순히 합하여 그대로 출력하는 선형 결합기(linear combiner)이다.

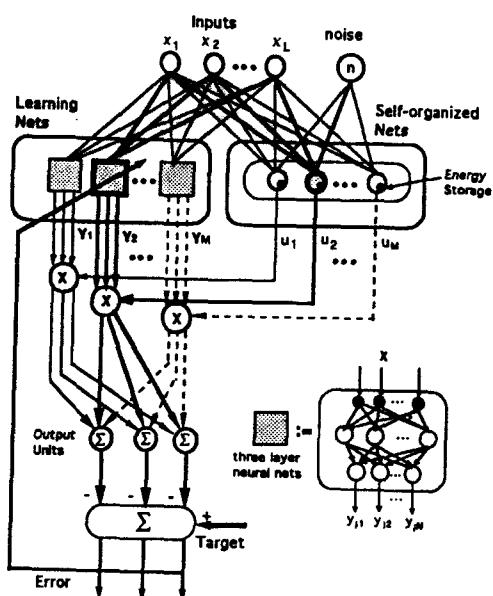


그림 2. 자율 분산 신경망의 구조

Fig. 2. A structure of the Self-organized Distributed Networks.

신경망에 입력 벡터가 인가되면 자율 신경망 내의 유니트 중 입력 벡터와 가장 유사한 연결강도 벡터를 갖는 유니트만 활성화되며, 이 유니트와 짹을 이루는 학습 신경망의 출력이 선택되어 전체 신경망의 출력으로 사용된다. 이 때 자율 신경 유니트의 입력 벡터 X 에 참가되는 잡음은 각 부분 입력 공간의 경계 부

분에서 학습 데이터들의 위치를 상호 이동시켜 부분망 간에 교차 학습에 함으로써 부분 함수 간의 연결성을 확보케 하는 역할을 한다. 이 잡음은 표준편차 s 인 랜덤한 값이며 각 자율 신경 유니트마다 독립적인 값이다. 그림 2에서 굵은 실선은 주어진 입력 벡터에 의해서 활성화된 자율 신경 유니트의 출력과 이것에 의해서 선택된 부분 다층 신경망의 출력을 표현하고 있다.

3. 부분망의 선택 및 학습

입력 벡터 X 에 대한 i 번째 부분 학습 신경망의 출력 벡터를 Y_i 라 하고 i 번째 신경망 중의 j 번째 출력을 y_j 라 하면 학습 신경망의 출력은 행렬로 표현할 수 있다. 이 행렬을 Y 라 하고 자율 신경망의 출력 벡터를 U 라 하자. 여기서 U 는 자율 신경 유니트 중에서 활성화된 유니트의 출력에 해당하는 요소만 1이고 나머지는 0인 벡터이다. 또 부분 학습망의 갯수를 M , 출력의 갯수를 N 이라고 k 번째 출력 유니트에 대한 입력의 총합을 net_k^o 라 하면

$$net_k^o = \sum_{i=1}^M y_i u_i \quad (8)$$

이다. 그런데, 출력 유니트의 활성화 함수를 f 라고 하면 k 번째 출력 유니트의 출력 o_k 는

$$\begin{aligned} o_k &= f(net_k^o) \\ &= f\left(\sum_{i=1}^M y_i u_i\right) \end{aligned} \quad (9)$$

가 된다. 여기서 y 는 학습 신경망의 출력이며 f 는 출력단의 활성화 함수이므로 출력단은 입력이 y 이고 연결강도 벡터가 U 이며 활성화 함수가 f 인 신경망과 동가이다. 따라서 SODN은 학습 신경망과 출력 유니트 층이 연결강도 벡터 U 로 연결된 다층 신경망으로 취급할 수 있으며 예전 역전파 학습 규칙을 이용하여 학습할 수 있다. t_k 를 k 번째 출력 유니트의 target 벡터라고 하면, k 번째 유니트의 출력 error $error_k$ 는

$$error_k = t_k - o_k$$

이다. k 번째 출력 유니트로 부터 역전파될 예전 벡터 δ_k^o 를 계산하기 위해서 식 (6-a)와 (9)를 이용하면

$$\begin{aligned} \delta_k^o &= error_k O_k (net_k^o) \\ &= error_k f'(net_k^o) \end{aligned} \quad (10)$$

이다. 또 모든 출력 유니트는 선형 결합기로서 그 활

성화 함수 f 는 램프 함수 이므로 미분값 f' 는 1 이다. 따라서 식 (10) 은

$$\begin{aligned}\delta_k^o &= \text{error}_k \\ &= (t_k - o_k)\end{aligned}\quad (11)$$

가 된다. 또 각 학습 신경망에 역전파될 에러 성분은 등가적 연결강도 벡터 U 를 따라 전파 시켜 얻을 수 있으며, 이 때 j 번째 부분망에 역전파될 에러 성분은 식 (6-b)과 (11)에 의해서

$$\begin{aligned}\delta_j &= f' \sum_{k=1}^N \delta_k^o u_j \\ &= u_j f' \sum_{k=1}^N (t_k - o_k)\end{aligned}\quad (12)$$

이다. 여기서의 u_j 는 자율 신경망의 출력 벡터 U 중의 j 번째 요소로서 자율 신경망 중의 j 번째 유니트 가 선택된 경우에만 값이 1 이고 나머지 경우에는 0 이다. 따라서 최종 출력에서 발생된 에러는 자율 신경망에 의해 선택된 부분망에만 전파되어 식 (5)와 같은 규칙에 의해 연결강도들이 학습됨을 의미한다.

4. 부분망의 생성 및 소멸

Kohonen 신경망의 입력 공간 분할 원리는 입력 데이터의 통계적 분포에 의존하며, 대상 함수 학습의 부분적 난이도는 고려되지 않는다. 그러나 학습 대상 함수 내에는 학습이 상대적으로 어려운 영역과 용이한 영역이 존재하므로 학습이 어려운 영역에는 추가적인 부분망을 생성시켜서 그 영역의 학습을 용이하게 하고 학습에 기여도가 낮은 부분망은 소멸시켜 재활용함으로써 신경망을 효율적으로 이용할 수 있게 한다. 그림 2 에서 점선으로 연결된 신경망은 새로 생성된 부분망을 의미한다.

U 로 정의된 학습 신경망과 출력 유니트 사이의 가상적 연결강도는 출력단에서 생성된 에러를 식 (12) 와 같이 부분 학습망으로 역전파하는 역할을 할 뿐 아니라 자율 신경망에도 역전파 시킨다. 여기서 자율 신경망에 역전파되는 에러 성분은 연결강도 U 자신에 대한 생신 성분이다. 이 생신 성분을 Δu 라 하면, 연결강도 생신량 계산식 (5)를 이용할 수 있으며 j 번째 출력 유니트로 부터 i 번째 자율 신경망으로 전파될 에러 성분 Δu_i 는

$$\begin{aligned}\Delta u_{ji} &= \eta \delta_j u_i \\ &= \eta(t_j - o_j) u_i\end{aligned}\quad (13)$$

이다. 이 생신 성분은 자율 신경 유니트의 출력값에

대한 변화 요구량을 의미한다. 이 값의 크기는 해당 부분망의 학습 정도와 반비례 관계가 있으므로 제안한 SODN에서는 이 에러 성분을 누적시켜 각 부분 신경망의 생성/소멸을 위한 에너지로 이용한다. 예를 들면, 학습이 어려운 영역을 담당하는 부분망의 자율 신경 유니트에는 큰 에러가 전파되므로 이것을 부분망 생성을 위한 에너지로 간주하면 이 부분망에 에너지 생성될 확률이 높아진다. 이 에너지 성분은 그림 2 에서의 ES(energy storage)라고 하는 에너지 저장소에 매 학습 주기마다 누적 저장시킨다. i 번째 부분망의 에너지 Δe_i 는

$$\begin{aligned}\Delta e_i &= \sum_{j=0}^N (\Delta u_{ji})^2 \\ &= \sum_{j=0}^N \eta^2 (t_j - o_j)^2 u_j^2\end{aligned}\quad (14)$$

로 계산되며,

$$E_i = \sum_{\text{iteration}} \Delta e_i \quad (15)$$

로 매 학습 주기마다 누적되어 저장된다. 임의의 학습 시점에서 E_i 가 큰 값이면 i 번째 부분망의 학습이 어렵다는 것을 의미하고, 작은 값이면 학습이 용이함을 의미한다.

E_i 의 값을 이용한 부분망의 생성 및 소멸 조건은 다음 2 가지 중 선택하여 사용 할 수 있다.

(a) 임계치 비교

- E_i ($i \in N$) 의 값이 임계치 $E_{th,h}$ 보다 크면 i 번째 부분망을 복제하여 새로운 부분망을 생성시킨다.
- E_i 의 값이 임계치 $E_{th,l}$ 보다 작으면 i 번째 부분망을 소멸시킨다.

(b) 주기적 에너지 점검

- 주기 p 마다의 에너지 상태 점검으로
- MAX { E_i , $i \in N$ } 인 부분망 k 를 복제하여 새로운 부분망을 생성시킨다.
- MIN { E_i , $i \in N$ } 인 부분망 k 의 에너지가 임계치 $E_{th,l}$ 이하이면 소멸시킨다.

조건 (a)에서는 한 학습 주기에 복수 개의 부분망이 생성하거나 소멸시킬 수 있으며 조건 (b)에서는 식 (16)과 같이 정의된 주기 p 마다 에너지의 상태를 점검하여 생성/소멸 활동을 수행한다.

$$p = K / T_{err} \quad (16)$$

여기서 K 는 상수고 T_{err} 는 한 학습 주기 동안의 학습 데이터에 대한 에러의 합이다. 매 생성/소멸 활

동이 일어나는 시점에서의 T_{err} 를 이용하여 p 를 계산함으로서 다음의 생성/소멸 시기를 결정할 수 있게 한다. 이와 같은 부분망의 생성/소멸 조건을 이용하면 학습의 초기에는 에러의 값이 크므로 생성/소멸 주기가 짧게되며, 학습이 진행되어 에러값이 작을 때에는 그 주기가 길어지게 된다. 생성/소멸 활동이 완료되면 식 (7)에 의해서 위치가 미세하게 이동되어 담당 영역이 조정된다. 여기서 부분망의 생성/소멸 활동이 수행될 때마다 모든 ES 내의 에너지 값을 초기화하고, 다시 에너지의 누적을 시작한다.

이 생성 및 소멸 원리는 에러 함수를 재조정케 하는 역할을 하므로, 부분 최소치(local minima)에 빠져있는 부분망들의 학습 속도가 가속화될 수 있게 된다. 부분망의 생성 및 소멸 원리는 인간 뇌세포의 발달 및 쇠퇴 원리에 근거하며, 자주 사용되거나 강조하여 학습하는 뇌세포는 점차 증가하여 발달하고, 사용처 않는 뇌세포는 퇴화되는 원리와 같다. 맹인들의 시각 기능은 퇴화하는 대신 청각 기능은 발달하는 이치가 그 예이다.

IV. 실험 및 검토

제안한 신경망의 학습 성능을 시험하기 위해서 굴곡이 심하고 비선형성이 강한 일차원 함수들을 합성하여 이를 대상으로 다층 신경망, RBF 신경망 및 제안한 신경망의 학습 실험을 수행하였으며 그 결과를 비교하였다. 또한 제안한 신경망이 다차원 입력을 가진 문제에서도 우수함을 보이기 위해 위의 3 가지 신경망에 의한 실제 지형 윤곽의 학습 및 압축 저장 실험을 수행하였다. 여기서 비교의 척도로 사용한 학습 에러 TSS(Total Sum of Squared Error)는

$$TSS = \sum_{p=0}^N (t(p) - o(p))^2 \quad (17)$$

이다. 신경망의 생성 및 소멸 조건으로는 3.4 절의 두번째 조건을 사용했으며 주기 상수 K 는 500 이었다. 다층 신경망의 초기 연결강도와 바이어스로는 최대값이 0.3인 랜덤값을 사용하였으며 자율 신경망 학습 계수 α 로는 0.9를 사용하였다. 이 실험들에서는 자율 신경망에 참가되는 잡음의 s 를 0으로하여 그 영향을 고려하지 않았다. 또한 각 SODN의 한 부분 학습망은 2 개의 은닉 유니트를 갖는 3 층(1 개의 은닉층 포함) 신경망을 사용했다. 연결강도와 바이어스 등 메모리를 필요로하는 소자의 합을 파라미터의 수로 정의하였고 제안한 신경망의 유니트 수는 학습 신경망과 자율 신경망의 유니트 수를 합한 것이다.

첫번째 실험을 위해서 합성한 함수는 굴곡이 심하고 비선형성이 강한 곡선으로써

$$f(x) = \sin^2 x \{e^{(x+4.0) \sin^3 x} (\sin x + \cos 2x) + 10.0\} / 60.0 \quad (18)$$

이고 x 및 y 는 $x = [-10.0, 10.0]$, $y = [0.0, 1.0]$ 영역의 값을 갖는 함수이다. 이 때 함수로 부터 취한 학습 데이터의 수는 100 개였다.

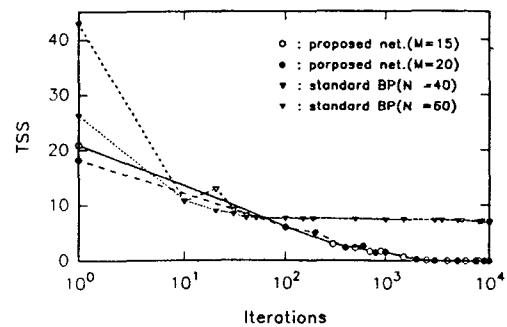


그림 3. 다층 신경망과 제안한 신경망의 학습오차

Fig. 3. A comparison of learning error between the standard multilayer neural networks and the proposed networks.

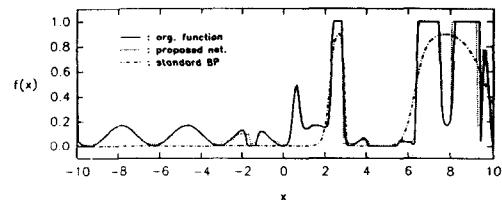


그림 4. 다층 신경망과 제안한 신경망의 비선형 함수 학습결과

Fig. 4. Results of a nonlinear function learning with the standard multilayer networks and the proposed networks.

그림 3은 기존의 신경망에 의한 학습과 제안한 신경망의 학습 오차(TSS)를 보여준다. 여기서 M 은 제안한 신경망의 부분망 갯수이고 N 은 기존의 다층 신경망의 은닉 유니트 갯수이다. 10 세트의 초기 연결강도 벡터들과 다양한 크기의 신경망에 대한 학습 결과. 제안한 신경망은 15 세트 이상의 부분망을 사용할 경우 모두 빠른 속도로 학습하였으나, 기존의

다중 신경망은 신경망의 크기에 관계없이 학습이 매우 어려웠다.

그림 4는 여러 종류의 학습 실험 중, 비슷한 갯수의 파라미터를 사용한 다중 신경망(121 개)과 제안한 신경망(120 개)의 출력으로서 두 신경망에 대한 300 개의 비학습 위치를 포함하는 400 개의 위치점에 대하여 테스트한 결과의 비교이다. 제안한 회로망의 출력은 학습 대상 함수를 매우 정밀하게 학습하였으며 비학습 위치점들에 대한 테스트 결과도 학습 대상 함수와 크게 다르지 않았다. 반면 기존의 다중 신경망의 경우는 학습도 어려웠고, 테스트 결과도 많은 에러를 포함하고 있음을 알 수 있다. 표 1은 그림 4의 실험에 사용된 실험 조건 및 결과이다.

표 1. 그림 4 의 실험에 사용된 실험 조건 및 학습결과

Table 1. Simulation conditions and learning results for the Fig. 4.

	파라미터 수	온닉층의 유니트 수	학습오차(TSS)	평균오차	학습 횟수
제안한 신경망	120	30	0.005829	0.02713	10,000
다중 신경망	121	40	6.527261	0.10220	10,000

두번째 실험은 신경망의 효율적 이용에 관한 실험이다. 일반적으로 시스템의 함수는 영역에 따라 평탄한 구역과 매우 복잡한 구역이 있을 수 있으므로 부분망의 분포도 구역의 복잡도에 따라 달라져야 할 것이다. 이런 특성에 대한 만족 여부를 확인하기 위한 함수를 합성하였다. 학습 데이터는 이 함수의 [-8.0, 0.0] 구간을 제외한 전 구간에서 61개의 데이터를 일정한 간격으로 취하였다.

이) 함수는

$$f(x) = \begin{cases} (-\cos \frac{x}{4.0} - 0.4) / 4.0 & ; x < 0.0 \\ \sin^2 x [e^{(x+4.0 \sin^3 x)} (\sin x + \cos 2x) + 10.0] / 60.0 & ; x \geq 0.0 \end{cases} \quad (19)$$

이고 $f(x)=[0.0, \sim 1.0]$ 인 제한을 갖는 비선형 함수이다.

위 함수에 대해, Moody 등이 제안한 RBF 신경망^[8]과 제안한 신경망의 학습 실험을 수행하였다. RBF 신경망에서는 식 (3)의 정규화된 출력을 사용하였고 유니트의 폭은 각 유니트 중심에 인접하는 데 이타들의 평균값을 사용하였다. 제안한 신경망과 RBF 신경망의 연결강도 개선을 위한 학습율은 0.1 이었다. 또 사용한 RBF 유니트 중심은 Kohonen의 방법^[2]을 사용하여 구하였다. 그림 5는 비슷한 갯수

의 파라미터를 사용하여 학습한 두 신경망을 61개의 학습 데이터를 포함하는 400 개의 데이터 점에 대해서 테스트한 결과이다. 그림에서 x 축 상의 점들은 제안한 신경망의 부분망 위치를 나타내는데 함수가 평탄한 부분인 음의 영역에는 한 개의 부분망만 위치하여 이용되는데 반하여 함수가 복잡한 양의 영역에는 많은 수의 부분망이 위치함을 알 수 있다. 그림 5에서 보는 바와 같이 RBF 신경망은 1 보다 큰 값을 갖거나 0 보다 작은 값을 갖는 등 비학습 위치점들에서 기이한 값을 보였으며, 넓은 비 학습영역인 [-8.0, 0.0] 구간에서는 원거리의 학습 데이터의 간섭을 받아 최인접점인 -8.0 과 0.0 부근의 값과는 매우 다른 값을 출력하는 등 일반화 능력에 있어서의 문제점을 보여주었다. 반면 제안한 신경망은 적은 수의 파라미터를 효율적으로 이용하여 대상 함수를 매우 극사하게 학습하였고, 학습 데이터가 취해지지 않은 [-8.0, 0.0] 구간을 비롯한 모든 영역에서 매우 좋은 일반화 특성을 보였다.

표 2는 이 실험의 조건 및 학습 결과 비교표이다.

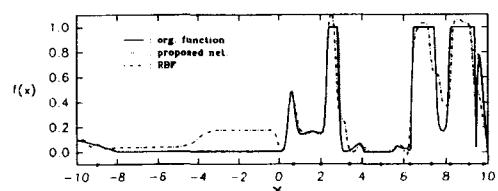


그림 5. RBF 신경망과 제안한 신경망의 비선형 함수 학습결과

Fig. 5. Results of nonlinear function learning with the RBF networks and the proposed networks.

표 2. 그림 5 의 실험을 위한 조건 및 학습 오차

Table 2. Simulation conditions and learning results for Fig. 5.

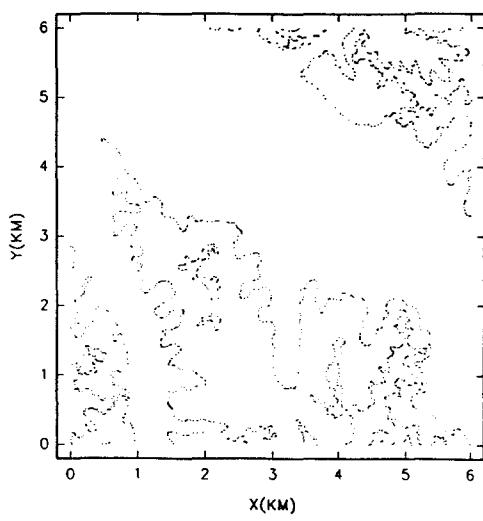
	파라미터 수	온닉층의 유니트 수	학습오차 (TSS)	학습 횟수
제안한 신경망	80	20	0.001797	10,000
RBF 신경망	81	27	1.295797	10,000

다차원 함수에 대한 학습 성능을 시험하기 위해서 지형 고도 정보의 학습을 통한 지형 운과 재현 실험을 수행하였다. 학습 데이터는 그림 6(a) 와 같이 1/50,000 지도의 등고선을 따라 추출한 6 Km X 6 Km 지역의 2200개 데이터였다. 이 고도 데이터에 대해서 수학적 보간(interpolation) 기법으로 구한 3

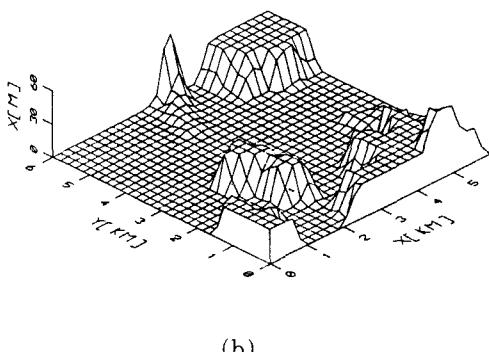
차원의 지형 모형은 그림 6(b) 와 같다.

실험에서는 비슷한 개수의 파라미터를 사용한 다층 신경망, RBF 신경망 및 제안한 신경망의 학습 결과를 비교하였다. 다층 신경망은 2 개의 입력 유니트와 220 개의 은닉 유니트를 가지며 1 개의 출력 유니트가 있는 완전 연결형 전향 신경망 구조이며 모든 연결강도와 바이어스 등을 합한 파라미터의 수는 881이다. 또한 RBF 신경망은 2 개의 입력 유니트와 220 개의 RBF 유니트 및 1 개의 출력 유니트를 갖는 구조이며 모든 연결강도 및 RBF 유니트의 폭을 합한 파라미터의 수는 880 개이다. 한편 제안한 신경

망은 각 부분망마다 2 개의 은닉 유니트 및 1 개의 출력 유니트로 구성된 학습 신경망과 1 개의 차울 신경 유니트로 구성되어 전체적으로 80 개의 부분망을 갖는 구조로서 총 파라미터의 수는 880 개이다. 여기서 부분망의 생성 및 소멸에 이용되는 차울 신경 유니트 내의 에너지 저장소는 학습 시에만 보조적으로 사용되므로 파라미터 수 계산에 포함시키지 않았다. 학습 계수로는 제안한 신경망에 0.1 을 사용하였고 RBF 신경망에 0.01 을 그리고 다층 신경망에 0.0001



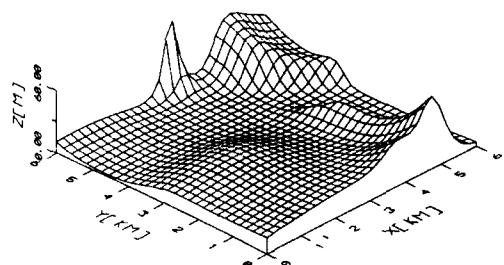
(a)



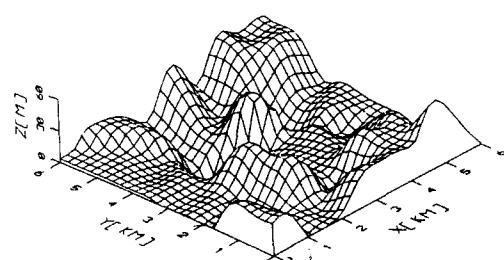
(b)

그림 6. (a) 학습용 지형 고도 데이터의 위치와
(b) 수학적 보간법으로 재생한 지형 모형

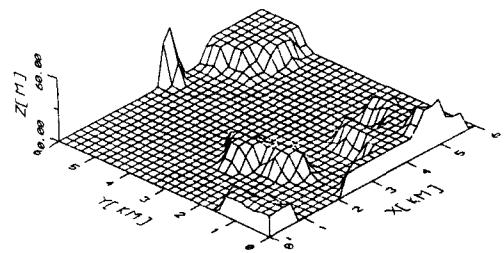
Fig. 6. (a) Positions of terrain elevation data and (b) the terrain structure constructed with a mathematical interpolation.



(a)



(b)



(c)

그림 7. 재생된 지형 모형들 (a) 다층 신경망 (b)
RBF 신경망 (c) 제안한 신경망

Fig. 7. The reconstructed terrain structures with (a) multilayer neural networks (b) RBF neural networks (c) the proposed networks.

를 사용하였는데 RBF 신경망과 다층신경망에 사용된 작은 학습계수는 여러 번의 실험을 거쳐서 선정한 값으로서 학습이 발산하지 않고 수행되는 최대값이다.

이 실험에서 다층 신경망의 학습은 매우 어려웠으며 RBF나 제안한 신경망에 비해 10 배의 학습 횟수를 사용한 결과 그림 7(a)와 같은 결과를 얻었다. 재현된 결과에서 일반화는 잘 이루어져 있으나, 그림 6의 등고선 및 수학적 보간법에 의해 재현 결과와 비교하면 많은 차이가 있음을 알 수 있다. 그림 7(b)는 RBF에 의한 재생 결과인데 실제 지형을 정밀하게 재현하지 못했으며, 특히 비 학습 영역에서는 음의 값을 갖거나 비현실적으로 큰 값을 출력하는 등 일반화에 있어서의 문제점을 보였다. 학습 결과가 나쁜 이유는 제한된 수의 유니트를 사용했기 때문이다. 그림 7(c)는 제안한 SODN에 의한 학습 결과인데 수학적으로 재현된 그림 6(b)의 지형 모형과 매우 흡사함을 알 수 있다. 특히 좌상 부분에 넓게 존재하는 비 학습 영역에 대해서도 RBF 신경망과는 달리 잘 일반화된 결과를 보여준다.

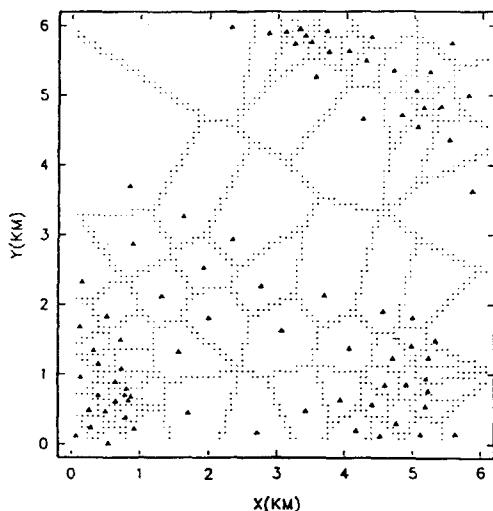


그림 8. 제안한 신경망에서 사용한 부분망의 위치와 부분망 관할 구역의 경계

Fig. 8. Local networks' center positions and boundaries with the proposed networks in learning the terrain data.

그림 8은 제안한 신경망의 학습 결과로 나타난 부분망의 위치와 부분망의 관할 구역 경계이다. 제안한 신경망은 지형의 복잡도에 따라 자율 배치되어 굽곡이 심한 지역에서는 부분망이 조밀한 반면 완만한 지

역에서는 듬성 듬성한 배치를 보여준다. 표 3은 실험에 사용된 조건들과 학습 결과이다.

표 3. 그림 7에 대한 학습 조건과 학습 결과

Table 3. Simulation conditions and learning results for Fig. 7.

	파라미터 수	온니층의 유니트 수	학습오차 (TSS)	학습 횟수
다층 신경망	881	220	5.942581	100,000
RBF 신경망	880	220	1.709154	10,000
제안한 신경망	880	180	0.001797	10,000

V. 결론

복잡한 문제를 다수의 단순한 문제로 분할 학습하는 새로운 신경망 SODN을 제안하였다. 제안한 신경망은 함수를 분할하여 지역적 학습을 수행하므로 학습 속도가 빠르며, 타 부분망의 단점인 일반화 능력이 개선된 신경망이다. 이 신경망은 입력 공간의 분할 역할을 담당하는 자율 신경망과 공간에 대한 학습을 담당하는 학습 신경망으로 구성된다. 자율 신경망은 다수의 자율 신경 유니트로 구성되고 학습 신경망은 다수의 소규모 다층 신경망으로 구성된다. 자율 신경망의 유니트 한 개와 학습 신경망의 다층 신경망 1 세트는 분할된 한 공간의 학습을 담당하는 부분망을 구성하며 담당 공간의 중심에 위치한다. 부분망의 분포는 학습 데이터의 분포 뿐만 아니라 학습의 나이도에 따라 이뤄지게 되며, 이를 위해서 자율 신경망에 역전파된 여러 성분이 부분망의 생성 및 소멸을 위한 에너지로서 이용된다. 또한 부분망 출력들 간의 연결성을 향상시키기 위해서 자율 신경망의 입력에는 Gaussian type의 잡음을 첨가하여 부분망들 간의 데이터를 교차 학습케 한다.

제안한 신경망의 학습 성능을 기존의 다층 신경망 및 RBF 신경망과 비교하기 위해서 일차원 함수에 대해서 학습 실험하였다. 제안한 신경망은 같은 크기의 다층 신경망에 비하여 훨씬 빠른 속도로 학습하였으며, 학습 결과의 정밀도 면에서도 매우 우수한 결과를 보여주었다. 일반화 면에서도 기존의 RBF 신경망에서 나타나는 출력 함수의 돌출 현상이 없었으며 원거리의 폭이 큰 감응영역에 의한 간섭 현상도 나타나지 않았다. 제안한 신경망의 또 다른 장점은 RBF 신경망처럼 많은 수의 유니트가 필요치 않으므로 하드웨어 크기 면에서도 우수하다는 점이다.

제안한 신경망의 다차원 시스템에 대한 모델링 능

력을 테스트하기 위해서 1/50,000 지형도 상의 등고선을 따라 6 km × 6 km 지역의 지형 고도 정보를 추출하여 학습 데이터로 사용하였다. 기존의 다층 신경망을 이용한 학습의 경우, 지형 고도 정보에 대한 정밀 학습이 매우 어려웠으며 RBF 신경망의 학습에서는 비학습 영역에서의 저조한 일반화 능력이 문제점으로 나타났다. 반면 제안한 SODN을 사용한 경우, 지형 데이터를 정밀 학습하였고, 그 출력은 수학적 보간기법으로 재구성한 지형 모형과 매우 흡사한 결과를 얻었다.

제안한 신경망의 단점은 부분망 출력을 간의 연결성이 부족하다는 문제인데 자율신경망 층의 입력단에 잡음을 추가 학습케 하여 연결성을 증진시켰음에도 불구하고 그 효과는 아직 미흡한 상태이다. 이에 대한 보완 발전이 추후의 연구과제이다.

参考文献

- [1] D. E. Rumelhart, G. E. Hinton, and R. J. Williams. "Learning representations by back-propagating errors." *Nature* 323, pp. 533-536, 1986.
- [2] T. Kohonen. "Self-organized formation of topologically correct feature maps." *Biological Cybernetics*, vol. 43, pp. 59-69, 1982.
- [3] J. Albus. "A new approach to manipulator control: The cerebellar model articulation controller (CMAC)." *Journal of Dynamic System and Measurement Control*, pp. 220-227, Sept. 1975.
- [4] C.-S. Lin and H. Kim. "CMAC-based Adaptive Critic Self-learning Control." *IEEE Transactions on Neural Networks*, vol. 2, no. 5, pp. 530-533, Sept. 1991.
- [5] C.-S. Lin and H. Kim. "Selection of learning parameters for CMAC-based Adaptive Critic Learning." *IEEE Transactions on Neural Networks*, will be appeared.
- [6] W. T. Miller. "Sensor-based control of robotic manipulators using a general learning algorithm." *IEEE Journal of Robot Automation*, vol. RA-3, no. 2, pp. 157-165, 1987.
- [7] W. T. Miller, F. H. Glanz, and L. G. Kraft III, "CMAC: An associative neural network alternative to backpropagation." *Proceedings of the IEEE*, vol. 78, no. 10, pp. 1561-1567, 1990.
- [8] J. Moody and C. J. Darken, "Fast learning in networks of locally-tuned processing units." *Neural Computation*, vol. 1, pp. 281-294, 1989.
- [9] S. Chen, C. F. N. Cowan, and P. M. Grant, "Orthogonal least square learning algorithm for radial basis function networks." *IEEE Transactions on Neural Networks*, vol. 2, no. 2, Mar. 1991.
- [10] J.-S. R. Jang and C.-T. Sun, "Functional equivalence between radial basis function networks and Fuzzy inference system." *IEEE Transactions on Neural Networks*, vol. 4, no. 1, Jan. 1993.
- [11] J. Park and I. W. Sandberg, "Universal approximation using Radial-Basis-Function Networks." *Neural Computation*, vol. 3, pp. 246-257, 1991.
- [12] M. Hirahara and N. Oka, "A hybrid model composed of a multilayer perceptron and a radial basis function network." *Proceedings of IJCNN*, pp. 1353-1356, 1993.
- [13] C. Bishop, "Improving the generalization properties of Radial Basis Function neural networks." *Neural Computation*, vol. 3, 579-588, 1991.
- [14] Q. Zhang and A. Benveniste, "Wavelet networks." *IEEE Transactions on Neural Networks*, vol. 3, no. 6, Nov. 1992.
- [15] R. Hecht-Nielsen, *Neurocomputing*, pp. 67-70, Addison-Wesley Publishing Company.

著者紹介



金炯奭(正會員)

1956年 1月 21日生. 1980年 2月
한양대학교 전자공학과 졸업(학
사). 1982년년 8月 전북대학교 대
학원 전기공학과 졸업(석사).
1992年 5月 (미)미조리 주립대(콜
롬비아) 전기 및 컴퓨터 공학과 졸
업(박사). 1982年 1月 ~ 1993年 8月 국방과학연구
소 선임 연구원. 1993年 9月 ~ 현재 전북대학교 제
어계측공학과 전임강사. 주관심 분야는 신경회로망
구조, 신경망제어 및 로보트 비전 등임.



崔鍾洙(正會員)

1969年 1月 18日生. 1990年 2月
전북대학교 전기공학과 졸업(학
사). 1992年 2月 전북대학교 대학
원 전기공학과 졸업(석사). 1994
年 2月 전북대학교 대학원 전기공
학과 박사과정 수료. 1994年 3月
~ 현재 (주)포스콘 기술연구소 선임연구원. 주관심
분야는 신경회로망, 퍼지 시스템, 뉴로-퍼지 제어 등
임.



金聖中(正會員)

1942年 3月 7日生. 1965年 전북
대학교 전기공학과 졸업(학사).
1973年 전북대학교 대학원 전기공
학과 졸업(석사). 1985年 전남대
학교 대학원 전기공학과 졸업(박
사). 1981年 ~ 1982年 (미)미조
리대 교환교수. 현재 전북대학교 제어계측공학과 교
수. 주관심 분야는 대규모시스템 제어, 지능 제어,
신경회로망 및 퍼지 제어 등임.