

## 에라 정보의 실시간 인식을 위한 전파신경망

### Propagation Neural Networks for Real-time Recognition of Error Data

김종만\*, 황종선\*\*, 김영민\*\*  
(Jong-Man Kim\*, Jong-Sun Hwang\*\*, Young-Min Kim\*\*)

#### Abstract

For Fast Real-time Recognition of Nonlinear Error Data, a new Neural Network algorithm which recognized the map in real time is proposed. The proposed neural network technique is the real time computation method through the inter-node diffusion. In the network, a node corresponds to a state in the quantized input space. Each node is composed of a processing unit and fixed weights from its neighbor nodes as well as its input terminal. The most reliable algorithm derived for real time recognition of map, is a dynamic programming based algorithm based on sequence matching techniques that would process the data as it arrives and could therefore provide continuously updated neighbor information estimates. Through several simulation experiments, real time reconstruction of the nonlinear map information is processed.

**Key Words :** Real-time Recognition, inter-node diffusion, dynamic programming, 1-D LIPN hardware

#### 1. 서 론<sup>[1]</sup>

현대 산업사회의 발달과 아울러 컴퓨터 시스템의 큰 발전으로 지리정보의 이용이 활발해지고 있다. 특히 불연속적인 에라 정보등의 비선형 데이터는 실제 사용할 수 없으므로, 이러한 비선형 지형 데이터를 빠른 컴퓨팅 개념을 이용하여 검출, 인식하여 실시간 선형 데이터화 시킬 때 많은 용용효과를 볼 수 있다. 이에 관한 지형정보에 대한 최근의 연구는 국토건설, 도시계획시의 채광 및 통신장애지역 산출, 저고도 항공기의 자율운항 뿐 아니라 군 작전시의 이동가능 경로 계산 등 매우 많은 분야에 활발히 응용되고 있다. 특히 지리정보 시스템(Geographic

Information System:GIS)은 각종 자료의 입지적 구체성을 근간으로 하는 정보시스템의 자료의 활용으로, 각종 정보를 형상화 함으로써 시각적 효과를 증대시켜 정보의 이해 증진을 도모하는 기술로서, 이를 위하여는 지형의 정확한 분석을 위한 지형의 3차원화된 데이터 구축이 필요하다. 아울러 각종 지형의 목적하는 정보를 사용하기 위해 지금까지 범용적으로 사용되어왔던 지형의 고도·윤곽정보인 등고선은 불연속 2차원 데이터로 되어있으므로, 필요시 3차원 지형정보로 보간시켜 사용하는 정보 변환 기술이 반드시 필요하다.

격자점 마다의 고도정보를 항공사진이나 측량에 의해 획득하여 DEM(Digital Elevation Model)이나 DTED(Digital Terrain Elevation Data)등과 같은 포맷으로 보관하여 이용하고 있다. 그러나 항공사진이나 측량에 의한 지형정보 획득에는 비용이 매우 많이 들기 때문에 종이 지도로부터 등고선 정보를

\* : 전남도립 남도대학 전자제어과  
(전남 장흥군 안양면 기산리 산89,  
Fax: 061-860-8609  
E-mail : jongmkim@hanmail.net)

\*\* : 담양대학

취하여 압축 보관하며 필요시 격자점 고도정보를 산출하는 방법이 이용되고 있다[1,2]. 대표적인 방법은 TIN(Triangular Irregular Network)기법[3]인데 등고선상의 임의의 3 점을 취하여 평면의 방정식을 구하고 이로부터 내부의 모든 격자점 고도를 보간화하는 방법으로서 좋은 보간 성능을 갖고 있으나 알고리즘을 구현하기 어렵고, 등고선상의 점들 중 3 점으로 취해지지 않는 점들에 대한 정보의 손실이 불가피하며 계산 시간이 과다하게 소요되는 등의 문제가 있다. 이를 보완한 연구로서 알고리즘 구현이 간단하고 수행시간이 빠른 거리 변환 기법(Distance Transformation)을 이용한 방법도 연구되었다[4].

이 방법들은 지형도의 복원 능력 면에서는 우수하지만 지형정보의 실시간 제시가 요구되는 응용에 이용하는 데는 적합하지 않다. 예를 들면 저고도 항공기 등의 자동 항진을 위해서는 지형정보가 비행체와 같은 속도로 제시되어 처리되어야 한다. 또한 군 작전시 전장 상황을 종합 판단하기 위해서는 각 지역의 지형 윤곽을 관련 정보와 함께 신속히 제시하여야 한다. 이와 같은 목적에 지형정보를 이용하기 위해서는 1) 지형정보가 압축된 형태로 표현되어야 하고 2) 실시간 재생이 가능해야 하며 3) 넓은 지역의 정보 취급이 용이해야 한다. 앞에서 언급한 TIN 기법 등은 on-line으로 이용할 경우, 실시간 재생이 어려우며 off-line으로 이용할 경우에는 재생된 정보의 량이 매우 많기 때문에 저장과 취급이 어렵다는 문제점이 있다.

본 연구에서는 이와 같은 정보전파 특성을 응용하여 등고선 정보가 인접 노드에 신속히 전파되어 지형정보를 실시간으로 보간하여 얻을 수 있는 정보전파 신경회로망을 제안하였다. 제안한 신경회로망은 단층 신경회로망으로서 각 노드는 자신의 입력과 인접 노드의 출력들과의 연결을 갖는 구조이다. 각 노드는 인접 노드들로부터 입력된 정보를 이용하여 출력을 위한 목표값을 설정하고 자신의 출력을 점차 이 목표값에 접근 개선시킴으로서 인접한 노드로 정보가 전파해 가도록 하는 원리로 불연속 비선형 지형정보를 선형 지형정보로 실시간 처리하여 얻어내는 실험 결과를 실시하여 보였다.

## 2. 실시간 정보전파 신경회로망(LIPN)

### 2.1 불연속 데이터의 인식을 위한 LIPN

본 연구에서 제안한 정보전파 신경회로망(LIPN)은 그림 1과 같이 그 구조가 단층 신경망 노드로 구성되어 있

다. 각 노드가 자신의 입력값 뿐 아니라 인접한 노드의 출력값에 점점 수렴하도록 하는 연결구조를 가지며, 임의의 위치 정보를 주변의 상태 공간에 신속하게 전파시켜 자연스런 정보의 보간화가 이루어진다. 그림 1은 제안한 정보전파 신경회로망의 1차원구조이다. 그림에서  $I_i$ 와  $P_i$ 는 각각  $i$  번째 입력과 출력을 나타내며,  $N_i$ 는  $i$  번째 노드를 나타낸다. 연결강도  $c_{ij}$ 는  $i$  번째 노드의 입력연결 연결강도이다. 이러한 1차원 LIPN의  $i$  번째 노드의 출력은 식(1)과 같다.

$$P_i = f [c_i I_i + \sum c_{i,i+l} P_{i+l}]; l = \pm 1 \quad (1)$$

여기서  $f$ 는 신경망 노드의 활성화 함수이다.

신경회로망의 각 노드는 양자화된 입력공간상의 상태와 일치한다. 노드의 입력 신호와 인접노드의 신호정보는 평균 가중되어 출력력을 산출시킨다.

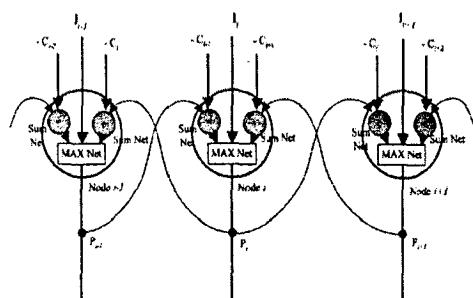


그림 1 제안한 신경회로망의 1차원 연결과 노드의 구조

Fig. 1 1-Dimension Link of proposed LIPN and node structures

위 신경회로망 구조는 Sum과 MAX 등의 연산을 수행하는 부 신경망(sub networks)들의 합성구조(compound structure)를 가지며 입력된 cost에 의해 최소의 비용이 소요되는 방향을 찾는 역할을 한다. 각 노드에는 자신의 입력  $I$ 가 인가되며 인접노드의 출력으로부터 노드간의 cost가 감해진 값들도 함께 인가된다. 각 노드의 출력으로는 인가된 값들 중 최대의 값이 출력된다.

신경회로망의 각 노드는 양자화된 입력공간상의 상태와 일치한다. 노드의 입력 신호와 인접노드의 신호정보는 평균 가중되어 출력력을 산출시킨다.

### 2.2 정보전파신경회로망(LIPN)의 연결강도

도로의 주행중에 임의의 물체를 영상 데이터를 잡아 실시간으로 신경망으로 인식하기 위해서는 비선형 영상정보 부분에 대하여 선형적인 보간기능으로 출력을 생성시키며 이를 이때 연결강도도 새롭게 생성시키게 된다. 본 연구에서 제안한 LIPN의 연결강도는 보간을 위해서 다음과 같이 최적으로 정해지는 출력 특성을 갖는다.

[A] 입력이 있는 노드는 입력과 같은 연결강도의 값을 출력시킨다.

[B] 입력이 없는 노드는 인접 노드로부터의 연결강도의 평균된 값을 출력시킨다.

(1)식의  $f$  가 선형 활성함수이면, 이 방정식은

$$O_i = w^s(w^i I_i + \sum_{j=i+1}^N w^o_{i,j+1} O_{j+1}) ; I = \pm 1 \quad (2)$$

만일  $w^o$  가  $w^i$ 보다 작고  $w^s$ 가  $w^i$ 의 역관계이면, (2)식은

$$O_i \cong w^s(w^i I_i) = I_i \quad (3)$$

여기서, 노드의  $w^o$  은 [A]조건을 만족시키기 위해 선 입력이 있는 노드에 있어서 매우 작아야 한다.

또한 만일  $w^o$  가  $w^i$  보다 매우 크면, (2)는

$$O_i \cong w^s(\sum_{j=i+1}^N w^o_{i,j+1} O_{j+1}) ; I = \pm 1 \quad (4)$$

$w^s$  가  $\frac{1.0}{\sum_{j=i+1}^N w^o_{i,j+1}}$  이면, 입력값이 없는 노드는

인접노드의 연결강도의 평균값으로 보간시키게 된다. 그러므로 [B]조건을 만족시키도록 노드의 연결강도  $w^o$ 는  $w^i$ 보다 훨씬 커야 한다.

따라서 프로그램 수행 중 보간망은 입력값의 존재 유무에 의존하여 다른 고정된 연결강도의 값을 할당시키므로써 새로운 연결강도 값을 생성시킨다.

### 3. 정보전파 신경회로망을 이용한 보간

이 절에서는 신경망 출력을 통하여 정보전파 신경회로망의 보간 특성을 설명하기로 한다.

특성 설명의 간소화를 위해서 그림 1의 2차원 보간 신경망에서 두 개의 입력을  $X$  와  $X'$ 라 하고, 각각 신경 노드 0번째와  $N+1$ 번째 신경 노드라고 하자.  $w^s$ 에 의해 일반화된 연결강도를  $w_1$  와  $w_2$  으로 하여 각각 노드의 좌, 우 값으로 놓는다. 이때 연결강도는

$$\begin{aligned} 0.0 &\leq w_1, w_2 \leq 1.0 \\ w_1 + w_2 &= 1.0 \end{aligned} \quad (5)$$

이 되도록 한다.

2.2절에서 언급된 노드 특성에 따라서 0번째와  $N+1$  번째 신경노드 입력변수를 각각  $I$  와  $I'$ 로 놓을 때 다른 신경 노드들의 출력값은

$$O_1 = w_1 I + w_2 O_2 \quad (6)$$

$$O_2 = w_1 O_1 + w_2 O_3 \quad (7)$$

$$O_k = w_1 O_{k-1} + w_2 O_{k+1} \quad (8)$$

$$O_{N-1} = w_1 O_{N-2} + w_2 O_N \quad (9)$$

$$O_N = w_1 O_{N-1} + w_2 I' \quad (10)$$

이다.

연결강도  $w_1, w_2$ 는 (5)식으로 조건화시키고,

$O_k$  를  $O_{k-1}$  와  $O_{k+1}$  사이의 평균 출력값이고, 그 범위는  $[O_{k-1}, O_{k+1}]$  이다. 여기서 주어진 입력  $I$  와  $I'$ 의 항목으로  $O_k$  를 계산시킨다.

일반적인 수식을 다음 (11)식과 같이 나타낸다.

$$\begin{aligned} O_k &= \frac{w_1}{1-w_2 a_{k+1}} c_{k-1} I + \frac{w_2 b_{k+1} + w_1 d_{k-1}}{1-w_2 a_{k+1}} I' \\ &= c_k I + d_k I' \end{aligned} \quad (11)$$

여기서 연결강도  $c_k$  와  $d_k$  의 범위가 모두 [0.0 1.0]이고 이들의 합이 1.0 이므로, 임의의 노드의 출력은 (11)식의 두 입력값  $I$  와  $I'$  사이의 가중치 평균값으로 계산시켜 복원시킬 수 있다.

그림 2는 0번째 노드와 8번째 노드에 각각 30과 1의 값을 인가하여 연결강도를 각각 달리하여 보간 시킨 결과값을 나타낸 것이다. 그림에서 보인 것처럼 제안한 정보전파 신경회로망은 연결강도값이

$w_1=0.5$  와  $w_2=0.5$  인 (3)의 경우에 선형보수행함을 알 수 있으며, 또한 다른 여러 경우의 연결강도 설정시에 비선형 보간을 수행할 수 있음을 보여주고 있다.

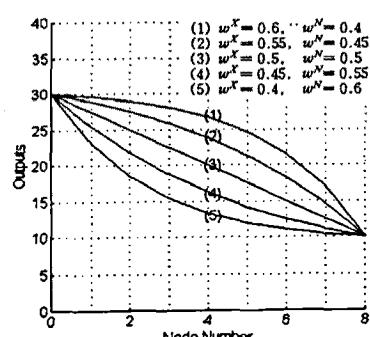


그림2. 다양한 연결강도를 갖는 LIPN의 보간 곡선

Fig. 2 An interpolation curve of LIPN with various weights

## 4. 실험 및 고찰

제안한 신경회로망의 보간 능력을 시험하기 위해서 1 차원 비선형 함수와 단순한 등고선 및 복잡한 등고선 등을 대상으로 재생 실험을 수행하였다. 지형정보의 실시간 이용이 본 연구의 목적이므로 실시간 보간이 가능한 신경회로망 기법들을 대상으로 보간 성능을 비교하였다.

### 4.1 일차원 비선형 곡선에 대한 보간

학습 대상으로 하는 일차원 함수는  $G(x) = [(x-2)(2x+1)]/(1+x^2)$ , 샘플 점들의 값은  $[-5, 10]$  구간에서 매 정수 위치마다 취하였다. 다층 신경회로망은 12 개의 은닉 유니트를 가진 신경회로망을 사용하였고 제안한 신경회로망으로는 그림 1과 같은 1 차원 보간신경망을 이용하였으며 매 10 번째 노드마다 샘플 데이터의 입력이 인가되게 하였다. 그림 3은 다층신경망과 제안한 신경회로망에 의한 보간 결과의 비교이다. 여기서 실선은 원함수  $G(x)$ 를 나타내며 점선은 10,000회 학습한 다층 신경회로망에 의한 보간 결과이다. 또한 대쉬(dash)선은 제안한 보간 기법에 의해 수행된 결과로 1,000회의 출력값 개선 후 보간된 150개의 점에 대한 출력이다. 또한 표 1은 각 신경회로망의 평균 오차를 보여주는데 이 실험 결과 제안한 신경회로망은 다층 신경회로망보다 미세하지만 나은 결과를 보여줄 수 있다.

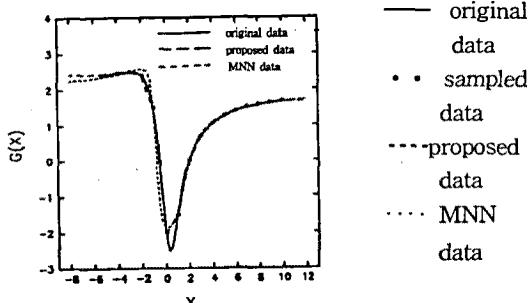


그림 3 일

차원 함수의 보간 결과

Fig. 3 Interpolation Results for One Dimensional Function

표 1 함수  $G(x) = [(x-2)(2x+1)]/(1+x^2)$  보간 결과 비교표

Table 1 A comparison of interpolation results of the function  $G(x) = [(x-2)(2x+1)]/(1+x^2)$

신경회로망의 종류	갱신대상 및 갱신 횟수	평균 오차
제안한 신경회로망	출력값을 1000회 갱신	0.0599
다층 신경회로망	연결강도를 10000회 갱신	0.1357

### 4.2 능선을 갖는 단순한 등고선에 대한 지형 정보 복원 실험

지형정보 복원 능력을 비교하기 위해서 그림 4 와 같은 형태의 능선이 있는 등고선 지형정보를 대상으로 실험하였다. 등고선의 x, y축의 격자 크기는  $20 \times 20$ 이며, 등고선 샘플 데이터는 외부 등고선이 30m이고 내부 등고선이 60m 되게 하였다. 이 등고선 데이터를 대상으로 13 개의 은닉 유니트를 가진 3 층 신경회로망을 이용하여 학습시켰는데 학습이 매우 어려웠다. 이 때 10,000회씩 수행한 10 차례의 학습 실험 중 최소 학습오차는 1.292 이었다. 그림 5는 이 최소 학습오차를 갖는 신경회로망 연결 강도를 이용하여 지형도를 재생한 결과이다. 원 지형의 등고선과 비교할 때 능선의 모양과 지형의 골곡 표현이 정확치 않음 알 수 있다.

부분 신경회로망은 다층 신경회로망에 비하여 정확한 학습을 시킬 수 있는 신경회로망으로 알려져 있다. 그림 4의 지형정보를 이용하여 부분 신경회로망으로 학습시켜 재생 실험하였다. 사용한 신경회로망은 10 개의 부분 신경회로망을 가진 신경회로망으로써 각 부분 신경회로망은 3개의 은닉 유니트를 가진 2 층 신경회로망이었다. 5000회의 학습 실험 후의 학습 오차는 0.179였는데 이 때 재생된 지형도는 그림 6과 같다. 학습오차는 다층 신경회로망에 비해 크게 줄어들었으나 전체적인 일반화 능력의 부족으로 곳곳에 급격한 경사가 생겨서 지형의 유연한 연속성이 부족함을 알 수 있다.

제안한 신경회로망의 보간 능력을 확인하기 위해서  $20 \times 20$ 의 크기를 가진 측량 보간 신경회로망을 구성하였으며, 등고선 데이터를 입력에 인가하여

1000 회 출력값 생신 실험하였다. 그림 7은 제안한 신경회로망의 보간 결과로서 다른 신경회로망에 비해 지형도 굴곡이 잘 나타나 있으며 능선도 잘 재생되어 있음을 볼 수 있다.

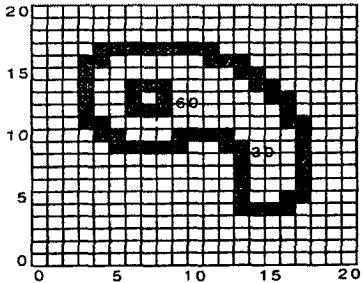


그림 4 능선 모양의 단순한 등고선  
Fig. 4 Original contour map of ridge shape

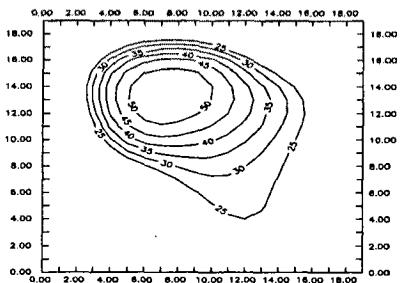


그림 5 다층신경회로망의 보간 결과  
Fig. 5 An interpolation result of multilayer neural networks

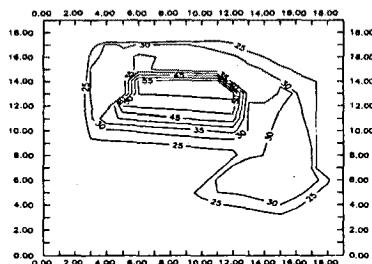


그림 6 부분 신경회로망의 보간 결과  
Fig. 6 An interpolation result of local neural networks

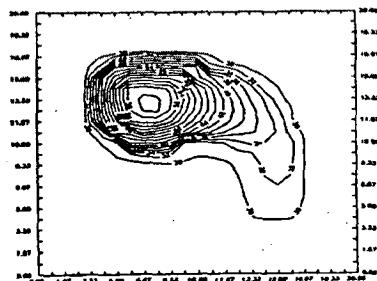


그림 7 제안한 정보전파신경의 보간 결과  
Fig. 7 An interpolation result of proposed LIPN

### 3. 결 론

불연속적인 에라 정보등의 비선형 데이터를 선형데이터로 실시간정보를 얻는 방법으로 기존의 신경회로망들은 주어진 함수나 데이터를 학습하는데 주로 이용하고 있다[4-7]. 본 논문에서는 각 노드의 정보를 인접한 노드에 전파시킴으로서 정보의 보간화가 되게 하는 새로운 측향 정보전파 신경회로망을 제안하였으며 등고선 정보로부터 지형도를 재생하는 데 활용하였다.

제안한 측향 정보전파 신경회로망은 인접 노드 간의 정보전파를 주된 기능으로 한다. 이 신경회로망의 각 노드는 자신의 입력단 및 인접 노드의 출력단과의 사이에 상호 정보교환을 할 수 있는 연결강도를 갖는 구조이다. 입력정보가 있는 노드는 자신의 입력정보를 목표로 출력을 재생하며 입력정보가 없는 노드는 인접노드들로부터 입력된 정보를 이용하여 목표값을 설정하고 자신의 출력을 점차 이 목표값에 접근 재생시킨다. 결과적으로 정보는 입력정보가 있는 노드로 부터 입력정보가 없는 노드로 전파해가게 되며 노드들간에는 자연스럽게 정보의 보간이 이루어 지게 된다.

제안한 신경회로망의 보간 성능 시험을 위해서 일차원 함수에 대한 보간 결과를 제시하였으며 등고선 정보로부터 지형정보의 복원 성능을 확인하기 위해 단순한 등고선 정보를 대상으로 실험하였다.

일 차원 함수에 대해서는 제안한 신경회로망과 기존의 신경회로망의 보간 결과가 큰 차이를 보이지 않았지만 실제 지형 등고선에 대한 실험 결과, 제안한 신경회로망이 크게 우수함을 보였다. 불연속 비선형 지형정보를 가진 등고선을 대상으로 학습실험한 결과, 다중신경망과 부분 신경망의 경우 등에 있어서 많은 오차가 존재한 등고선의 모양으로 보간되는 것을 보여주는 반면, 본 연구에서 제안한 신경회로망의 학습 결과는 선형학습특성이 잘된 모양의 지형도 굴곡이 잘 드러나며 작은 오차로 능선이 재생됨을 보여주고 있다.

#### [참 고 문 헌]

- [1] J.S. Lee and S.J Chung, "Reconstruction of 3-D Terrain Data from Contour Map," IAPR Workshop on Machine Vision Applications, pp 28 1~284, December 1994.
- [2] INTERGRAPH, *MGE Terrain Modeler(MTM) Reference Manual*.
- [3] D. Meyers, et al, "Surfaces From Contours," ACM Transaction on Graphics, Vol. 11, No. 3, pp 228~258, July 1992.
- [4] G. Borgefors, "Distance Transformations in Digital Images," Computer Vision, Graphics, and Image Processing, Vol. 34, pp 344~371, 1986.
- [5] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by backpropagating errors," Nature 323, pp. 533-536, 1986.
- [6] T. Kohonen, "Kohonen's self-organizing maps: exploring their computational capabilities," Proceeding. IEEE Int. Conf. on Neural Networks, ICNN 88(San Diego, CA., 1988) pp. I-109~116
- [7] J. J. Hopfield, "Neural networks and physical systems with emergent collective Computational abilities," Proc. Nail. Acad. Sci., 79, 1982.
- [8] H. Freeman, "On the encoding of arbitrary geometric configurations," IRE Transactions on Electronic Computation, vol. EC-10, pp. 260-268, June 1961.