

역전파 신경망을 이용한 등고선 데이터로부터의 3차원 지형 복원 (II)

김수선[†] · 김동윤^{††} · 김하진^{†††}

요 약

본 논문에서는 프랙탈과 신경망을 이용하여 등고선 데이터로부터 3차원 지형을 복원하는 더욱 개선된 알고리즘을 제안한다. 본 알고리즘은 이미 제안한 것[1, 2, 3]을 바탕으로 인접 패치들과의 관계를 고려하여 개선한 것으로, 지형의 특징을 좀 더 사실적으로 반영할 수 있는 더 많은 조건을 부여한 데이터를 기존의 특징 데이터에 추가하여 학습한다. 학습 결과 평균오차가 줄어든 학습 패턴을 이용하여 산악지형과 평탄지형에 대하여 실험하고 실험 결과 산악지형에 대한 적용이 더 효과적임을 보였다.

Reconstruction of 3D Shapes from Contour Line Data using The Backpropagation Neural Networks (II)

Su-Sun Kim[†] · Dong-Yoon Kim^{††} · Ha-Jine Kim^{†††}

ABSTRACT

We propose a more improved algorithm which can reconstruct the better 3D terrains from contour line data using the fractals and the Neural Networks and which is an improvement based on that in [1, 2, 3] with the consideration on neighboring patch. We have learned the feature data in addition to reflect the characteristics of complicated topography, and have implemented on mountainous and flatness topography using the proposed learning pattern by the reduced average error. The results of implements represented that the mountainous topography is better than that of flatness on the similarity and the visibility.

1. 서 론

지리정보시스템이 저장하고 처리해야할 자료가 다른 정보시스템에 비해 상대적으로 커서 효과적인 지

장과 처리가 이루어지지 않으면 그 기능을 제대로 발휘할 수가 없다. 따라서, 지리정보시스템의 성능을 향상하기 위해서는 지금까지 연구되어 구현된 비공간적인 자료의 처리기능을 사용하면서, 상대적으로 별로 연구되지 못한 공간적인 자료에 대한 저장 및 처리기능을 강화하여야 한다[4].

현존하는 지리정보시스템의 대부분은 2차원 지도로 되어 있고, 일부 특정 지역에만 3차원 지형 자료가 만들어져 있다. 그 이유는 2차원 정보는 지도로부터 직접 혹은 수작업으로 쉽게 얻어낼 수 있는 반면 3차

※본 논문은 한국학술진흥재단의 1993년 자유공모과제 연구비 지원으로 수행되었음.

† 중신회원: 한양여자전문대학 전자계산과 조교수

†† 정회원: 아주대학교 정보통신대학 교수

††† 비회원: 아주대학교 정보통신대학 교수

논문접수: 1996년 11월 5일, 심사완료: 1997년 2월 6일

원 지형정보는 만들기가 어렵다는데 있다. 그런데 미사일 경로의 계획, 건축물 신축예정지의 선정 등 많은 응용분야에서 3차원 지형정보를 필요로 하고 있기 때문에 3차원 지형정보를 만드는 문제는 매우 중요하게 인식되고 있다. 따라서 본 논문에서는 기존의 등고선 데이터로부터 3차원 지형정보를 만드는 보다 개선된 알고리즘을 제안하고자 한다.

등고선으로부터 3차원 지형을 복원하는 기존의 방법으로는 정규격자형 데이터와 등고선을 이용하여 스프라인으로 보간하거나 선형보간하는 방법[5, 6, 7], 삼각분할 기법을 이용하여 스프라인 곡면으로 보간하는 방법[8], 그리고 프랙탈 이론을 응용하여 보간하는 방법[9, 10] 등이 있다. 이러한 방법들은 복원 알고리즘을 평가하는 방법에 따라 계산시간, 메모리 사용량, 그리고 메쉬 구성에 따른 정보의 유실 등을 사용 논문과 복원한 지형의 사실도를 사용한 논문으로 분류할 수 있다. 자연스러운 3차원 지형의 표현을 위해 계산시간이나 사용 메모리에 제한을 두지 않고 랜덤 프랙탈을 응용하여 생성한 지형의 모습을 좀 더 현실감 있게 보이도록한 방법이 있다[9, 10, 11, 12, 13].

본 논문에서는 3차원 지형을 복원하는 기존의 랜덤 프랙탈 방법에 신경망을 도입하여 실제 지형에 더욱 가깝게 표현할 수 있는 알고리즘을 제안한다. 본 알고리즘은 [1, 2, 3]에서 제안된 알고리즘을 개선한 것이다. 지형의 특징이 좀 더 사실적으로 반영될 수 있는 특징 데이터의 조건으로, 폐치한 이웃 삼각형과의 관계를 이용한 특징 데이터를 입력패턴에 반영한다. 학습 결과 평균오차가 줄어들었음을 보이고, 평균오차가 줄어든 학습 결과를 이용하여 산악지형과 평탄 지형에 대하여 실험하고 결과 산악지형에 대한 적용예가 더 효과적임을 보였다.


2장에서는 본 연구의 전처리 과정에 해당하는 다각 근사화 및 삼각 패치 구성 방법에 대하여 기술하고, 3장에서는 프랙탈 이론과 신경회로망의 학습을 이용하여 보간하는 3차원 데이터 획득을 위한 알고리즘을 제시한다. 4장에서는 본 논문의 알고리즘에 따른 실험 예를 보이고, 실험 결과에 대한 근사도 평가와 비대칭 지형에 대한 적용 예가 더 우수함을 보이며, 5장에서 결론을 맺는다.

2. 다각 근사화 및 삼각 패치


본 논문에서는 3차원 지형의 복원을 위한 원시 데이터로서 등고선을 사용한다. 이 장에서는 등고선을 사용한 지형의 특징 데이터 추출과 삼각 패치에 대해서 약술한다. 보다 자세한 것은 [1, 2, 3]을 참고할 수 있다.

2.1 다각 근사화

본 논문에서는 자동화 과정을 거친 등고선의 좌표 데이터와 격자 데이터를 원시 데이터로 한다. 등고선 데이터는 등고선 단위의 XYZ 직교좌표계로 구성되어 앞으로 진행할 3차원 복원 데이터의 기저 데이터로 이용하고, 격자 데이터는 신경회로망 입력 데이터와 복원 결과와의 평가 데이터로 사용한다.



(a) 입력 등고선



(b) 다각 근사화한 등고선

(그림 1) 등고선의 특징점 추출
(Fig. 1) Extracted feature points of contour line

본 연구 목적의 하나로 자연영상에 대한 저장 데이터 양의 축소를 들 수 있다. 랜덤 프랙탈은 데이터를 증폭하는 과정을 통하여 아주 세밀한 단계까지 생성할 수 있기 때문에, 일반적인 인공물에 비해 매우 많은 데이터 양으로 표현된다. 또한 증폭을 위한 데이터의 저장장소도 많이 필요로 하기 때문에 되도록 적은 양의 데이터를 사용하여 근사도가 높은 형상을 생성하고자 하는 노력이 필요하다. 따라서 복원을 위한 원시 데이터, 즉 등고선 데이터에서 특징점을 추출하는 것으로 저장 데이터 양의 축소를 행한다.

특징점을 추출하기 위해 분할점이 둘레 위에 존재하고 연속인 다각 근사화 기법 중 순차적으로 분할점을 결정하는 근사화 알고리즘을 이용한다. 등고선의 특징점을 추출한 예를 (그림 1)의 (b)에 표시한다.

(그림 1)의 (a)는 원시 데이터로 사용할 등고선이고, (그림 1)의 (b)는 (그림 1)의 (a)에 나타난 등고선의 특징점을 추출한 후 이것을 직선으로 연결한 모형이다.

2.2 삼각 패치 구성

(1) 이웃 등고선간의 삼각 패치


정상과 정상이 속한 다음 등고선에 대해서 삼각 패치를 행한다. 이것은 산봉우리와 각 특징점을 직선으로 연결하여 생성한다. 그리고, 나머지 등고선에 대하여 이웃하는 두 등고선간에 대응하는 대응점을 검색한다. 이 검색은 이웃 등고선의 각 특징점들을 연결한 직선에 외측 등고선의 한 점을 기준으로 하여 안쪽의 임의의 한 점, 즉 상위 등고선에 대응한 등고선의 특징점 사이에서 가장 가까운 점을 대응시킨다. 이러한 과정은 그 등고선의 시작점을 만날 때까지 계속 진행된다. 마지막으로 대응점을 검색한 후 삼각형으로의 형성 여부를 탐색한다. 그리고 삼각형이 아닌 다각형을 구성하고 있는 경우는, 임시 기준점을 바깥쪽 등고선의 특징점에서 안쪽 등고선의 특징점으로 옮겨서 대각선 거리가 짧은 점을 대응시킨다.

(2) 협곡 등고선의 삼각 패치

분기점을 포함하고 있는 협곡 등고선에서는, 즉 2개 이상의 봉우리로 나누어진 등고선과 봉우리들을 포함하고 있는 등고선에서 각 특징점의 대응점을 검색한다. 협곡 등고선에 대한 검색은 진행각이 예각에서

둔각으로 변경되는 부분으로 근처의 점을 중심으로 협곡의 시작과 끝점을 찾아 협곡 중심점을 이용해서 가상 등고선을 작성한다.

이상의 순서로 각각의 등고선에 대해 각 순서에 따라서 삼각형으로 패치한다. 최종적으로 패치된 삼각형을 (그림 2)에 표시한다.



(그림 2) 삼각형 패치
(Fig. 2) Triangular patches

3. 3차원 데이터 획득

3.1 프랙탈과 신경망의 특성

본 논문에서는 3차원 데이터 획득을 위해 다음과 같은 방법을 이용한다. 실세계의 자연영상을 모델링하는 기법으로 B. Mandelbrot에 의해 제안된 랜덤 프랙탈 그래픽스 방법이 많이 이용되고 있다[14]. 프랙탈 곡선으로 자연영상을 표현하기 위해 재귀적으로 구간을 나누어 그 중간점에서의 변위를 랜덤 프랙탈 중간점 변위 방법에 따른 값으로 한 모양은 불규칙하게 보이지만 중간점을 중심으로 좌우균형을 이루고 있으나, 자연영상 가운데는 어느 한쪽으로 더 많이 일그러진 모습이 있는 것을 볼 수 있다. 랜덤 프랙탈 프로세스는 통계적 자기 유사성을 근간으로 하기 때문에 좌우 비대칭인 이러한 자연영상들을 랜덤 프랙탈 중간점 변위 방법만으로 표현하려는 시도[15]가 있었으나 내재된 불규칙성을 보다 완벽하게 표현하는 데는 부족함이 있다. 따라서 우리는 내재된 불규칙성을 표현하기 위해 랜덤 프랙탈 중간점 변위 방법에 역전파 신경망을 도입하였다.

수 많은 사람들의 관심을 끌게 된 신경회로망은 기

본적으로 인간의 정보처리를 모델로 하여 인간의 정보처리 메카니즘과 유사하게 작동하도록 고안되어 왔으며, 폰 노이만형의 컴퓨터로는 해결하기 어려운 패턴 인식, 비선형 신호처리 등의 분야에서 병렬처리 능력, 예제학습 능력, 잡음에 강한 특성을 가지고 비선형적인 정보처리로 선형적인 정보처리의 한계를 넘으려는 연구가 많이 진행되고 있다[16, 17].


역전파 신경망은 복원하고자 하는 지형의 등고선 데이터를 학습패턴으로 구성하고, 이를 학습하여 학습된 환경을 뉴런과 뉴런 사이의 가중치에 내재시킴으로 지형의 3차원 데이터를 추출할 때, 추출하고자 하는 지형의 특성을 충분히 살릴 수 있는 장점이 있다. 따라서 각 지형의 모양에 대한 통계적 특성을 잘 활용할 수 있는 역전파 신경망을 도입한 개선된 알고리즘을 제안하고자 한다.

3.2 학습패턴의 구조

지형의 특성함수를 근사화하기 위하여 입력층, 은닉층, 그리고 출력층으로 구성된 역전파 신경망을 사용한다. 본 논문에서 사용하는 신경회로망의 입력은 다음과 같이 구한다.

등고선의 원시 데이터로부터 얻어지는 삼각형 패치의 세 점은 x 좌표, y 좌표, z 좌표를 가지는 3차원 데이터이므로 한 삼각형 패치를 T라고 할때, 삼각형 T는 식 (1)과 같이 나타낼 수 있다.


$$T = \{P_1(x_1, y_1, z_1), P_2(x_2, y_2, z_2), P_3(x_3, y_3, z_3)\} \quad (1)$$




(그림 3) 삼각형 T와 높이값 G
(Fig. 3) Triangle T and height value G

이 삼각 패치에서 구하고자 하는 것은 무게중심에서의 높이값 G이며, (그림 3)과 같이 나타낼 수 있다.

삼각형 T가 주어졌을 때 무게중심에서의 높이값 G를 구해야 하므로 역전파 신경망의 학습에 사용할 학습 데이터는 T와 G에서 얻어진다. 이때 T와 G가 삼각형을 이룬다는 사실에 착안하여 삼각형의 형태를 특징 지을 수 있는 특징 벡터로 경사(steeptness), 너비(width), 기울기(tilt), 길이(length)를 정의하였다[1, 2, 3]. 삼각 패치의 특징 데이터를 좀 더 다양하게 반영하기 위해 이웃하는 삼각 패치와의 관계를 이용하여 인접(adjacency)을 식 (2), (3), (4)와 같이 정의하였는데 이것들은 삼각형 T의 세 중선에 인접하는 세 삼각 패치들의 중선과 만나는 교각으로 (그림 4)와 같은 개념으로 표현할 수 있다. 특징 벡터 중 경사는 지평면과 삼각형이 이루는 각도로, 너비는 밑변과 마주하는 각의 각도로, 기울기는 낮은 고도점에서 접선을 그어 생성되는 값으로, 그리고 밑변의 길이를 길이로



(a)인 접



(b)인접 상세도

(그림 4) 특징 데이터
(Fig. 4) Feature data

하였고, 인접은 기준 삼각 패치의 각 변에 이웃하는 삼각 패치가 이루는 각도로 두 중선의 교각으로 다음과 같이 3가지로 정의한다.

(1) 왼편 인접: (2)

$$\text{sideL} = \cos^{-1} .$$

$$\frac{(x_3 - x_{\text{mid}})(x_L - x_{\text{mid}}) + (y_3 - y_{\text{mid}})(y_L - y_{\text{mid}}) + (z_3 - z_{\text{mid}})(z_L - z_{\text{mid}})}{\sqrt{(x_3 - x_{\text{mid}})^2 + (y_3 - y_{\text{mid}})^2 + (z_3 - z_{\text{mid}})^2} \sqrt{(x_L - x_{\text{mid}})^2 + (y_L - y_{\text{mid}})^2 + (z_L - z_{\text{mid}})^2}}$$

(2) 오른편 인접: (3)

$$\text{sideR} = \cos^{-1} .$$

$$\frac{(x_2 - x_{\text{mid}})(x_R - x_{\text{mid}}) + (y_2 - y_{\text{mid}})(y_R - y_{\text{mid}}) + (z_2 - z_{\text{mid}})(z_R - z_{\text{mid}})}{\sqrt{(x_2 - x_{\text{mid}})^2 + (y_2 - y_{\text{mid}})^2 + (z_2 - z_{\text{mid}})^2} \sqrt{(x_R - x_{\text{mid}})^2 + (y_R - y_{\text{mid}})^2 + (z_R - z_{\text{mid}})^2}}$$

(3) 밑·위 인접: (4)

$$\text{sideBT} = \cos^{-1} .$$

$$\frac{(x_1 - x_{\text{mid}})(x_{\text{BT}} - x_{\text{mid}}) + (y_1 - y_{\text{mid}})(y_{\text{BT}} - y_{\text{mid}}) + (z_1 - z_{\text{mid}})(z_{\text{BT}} - z_{\text{mid}})}{\sqrt{(x_1 - x_{\text{mid}})^2 + (y_1 - y_{\text{mid}})^2 + (z_1 - z_{\text{mid}})^2} \sqrt{(x_{\text{BT}} - x_{\text{mid}})^2 + (y_{\text{BT}} - y_{\text{mid}})^2 + (z_{\text{BT}} - z_{\text{mid}})^2}}$$

여기서 L, R, BT 등의 첨자는 삼각뿔을 기준으로하여 왼편, 오른편, 밑 또는 위의 의미로 그리고 mid는 인접변의 중간점 좌표를 표현한 것이다.

3.3 학습 알고리즘

본 논문에서 사용할 신경회로망의 출력값은 다음과 같이 정한다.

$$y_i = f\left(\sum_{i=1}^L u_{ii} v_i\right) \quad (5)$$


$$o_k = g\left(\sum_{i=1}^J w_{ki} y_i\right) \quad (6)$$

여기서 u_{ii} 는 입력층의 1 번째 뉴런에서 은닉층의 i 번째 뉴런으로 가는 가중치를 나타내며, w_{ki} 는 은닉층의 i 번째 뉴런에서 출력층의 k 번째 뉴런으로 가는 가중치를 나타낸다. y_i, o_k 는 각각 은닉층과 출력층의 출력값이다. 함수 $f(x)$ 는 비선형 함수를 사용해야 하며 유니폴라 시그모이드 함수를 사용하였다. 함수 $g(x)$ 는 특정 데이터로부터 원하는 출력값을 근사화 하는 특


성함수를 생성하는 것이므로 단조 증가하는 일차함수를 사용하였다. 가중치의 학습은 학습 속도를 빠르게 하기 위하여 모멘트가 부가된 역전파 신경망의 학습 알고리즘을 사용한다.

4. 실험 및 근사도 평가 결과

실험을 위한 입력 데이터로는 탄천지역의 등고선 데이터와 격자 데이터를 이용하였다. 탄천지역 중 평탄지형(그림 5)의 (a) 및 산악지형(그림 5)의 (b)을 선정하여 등고선과 정규격자점을 실험 데이터로 하였다. 평탄지형 및 산악지형의 분류는 어떤 수학적인 수치에 의한 것이 아니라 본 연구자의 주관에 의하여



(a) 평탄지형 입력 등고선도



(b) 산악지형 입력 등고선도

(그림 5) 입력 등고선도
(Fig. 5) Input contour line

이루어졌다. 탄천지역에서 산악지형의 입력 데이터로는 격자점의 간격을 10m로 한 157×139 크기에 해당하는 영역의 10m 간격의 등고선과 격자 데이터로 하고 Z좌표의 높이 구간은 110.0m에서 230.0m이다. 평탄지형의 입력 데이터로는 격자점의 간격을 5m로 한 56×59크기에 해당하는 영역의 5m 간격의 등고선과 2.5m 간격의 111×117 크기의 격자 데이터로 하고 Z좌표의 높이구간은 360.0m에서 405.0m이다.

산악지형에 대해서는 2579개의 원시 데이터로부터 1548개의 특징 데이터를 추출하여 적용하였고, 평탄지형에 대해서는 513개의 원시 데이터로부터 410개의 특징 데이터를 추출하여 실험에 적용하였다.

다각 근사화 된 등고선에 대하여 삼각형으로 패치한다. 높은 고도에서 낮은 고도 순으로 바깥쪽 등고선을 기준으로 각 정점에 대하여 특징점들을 연결함으로써 삼각형으로의 패치를 행한다. 또한 봉우리가 2개 이상인 협곡 등고선이나, 돌출 부분이 심한 만곡 등고선에 대해서는 가상 등고선을 작성하여 이웃한 두 등고선의 중간 높이값으로 보간하였다. 삼각형으로의 패치를 완료한 후 각각의 삼각형을 기본형으로 하여 패치에 따른 학습을 한다.

신경망 학습을 위해 평탄지형에서는 620개의 삼각 패치 데이터에서 72개의 데이터를 학습 패턴으로 하였고, 산악지형에서는 2579개의 삼각 패치 데이터에서 288개의 삼각형 데이터를 사용하였다. <표 1>의 (a)는 평탄지형, (b)는 산악지형에 대한 학습을 위한 입력 파라미터이다.

학습을 위한 신경망의 구조는 은닉층과 출력층을 각각 1개 층으로 하고, 입력층은 입력패턴(경사, 너비, 기울기, 길이, 인접3)의 수가 7개이므로 각각의 성분에 대응하도록 7개의 신경세포를 설정하였고, 출력층의 경우 목적패턴(높이)의 성분수가 1개이므로 1개의 신경세포를 설정하였다. 은닉층의 신경세포는 평탄지형과 산악지형에 대하여 각각 15와 16개로 설정하였다. 학습률은 신경망의 학습 성능을 결정하는 상수로 여기서는 0.1과 0.01로 하고, 학습 속도를 조절하는 모멘텀은 0.7로 하였다. 학습 결과 평균오차는 입력패턴의 수가 4개-경사, 너비, 기울기, 길이-일 때 평탄지형은 2.28, 산악지형은 354.85이었고, 학습 조건을 좀 더 많이 부여하여 입력패턴의 수를 7개-경사, 너비, 기울기, 길이, 3인접-로 했을 때 평탄지형은

1.53, 산악지형은 125.28로 나타났다. 학습 결과 평균 오차면에서 볼 때, 기존의 패치한 삼각형에 대한 특징 데이터만을 이용하여 학습한 결과보다 인접한 삼각 패치와의 관계에 대한 특징 데이터를 부가 데이터로 하여 학습한 결과가 개선되었음을 알 수 있다.

<표 1> 입력 파라미터
<Table 1> Input parameters

신경망의 파라미터	설정치
Number of Layers (Hidden + Output)	2
Number of Input Neurons	7
Number of Training Patterns	72
Number of Hidden (1) Neurons	16
Number of Hidden (2) Neurons	0
Number of Output Neurons	1
Learning Parameter	0.1
Momentum Parameter	0.7
Maximum Error	2.0
Parameter of a Sigmoid Function	1.5

(a) 평탄지형

신경망의 파라미터	설정치
Number of Layers (Hidden + Output)	2
Number of Input Neurons	7
Number of Training Patterns	288
Number of Hidden (1) Neurons	15
Number of Hidden (2) Neurons	0
Number of Output Neurons	1
Learning Parameter	0.01
Momentum Parameter	0.7
Maximum Error	10
Parameter of a Sigmoid Function	2.5

(b) 산악지형

<표 2>는 인접 삼각 패치들의 관계를 특징 데이터에 부가했을 때의 평탄지형과 산악지형에 대한 학습 데이터 중 일부분을 나타낸 것이다.

패치한 각 삼각형 무게중심에서의 높이값은 학습 결과치로, 랜덤 프랙탈 중간점 변위 방식에 의한 계산값을 각 변의 중점에서의 높이값으로 하여 패치한 각각의 삼각형에 대하여 표현 가능한 해상도까지 재귀적으로 반복하여 보간점들을 구하여 복원한다. (그림 6)의 (a)는 랜덤 프랙탈 방법에서 사용하는 복원 기준 삼각형이고, (b)는 본 논문에서 제안하는 복원 기준 삼각형이다. (그림 6)에서 각 변의 중점 a, b, c

〈표 2〉 학습 데이터
 〈Table 2〉 Learning data


경사	너비	기울기	길이	왼편 인접	오른편 인접	밑-위 인접	바이어스	높이
0.324	0.800	1.249	1.296	2.107	1.010	1.285	-1.000	4.227
0.430	1.058	1.456	1.095	1.106	1.989	2.626	-1.000	2.453
0.282	0.964	0.581	1.479	2.001	1.536	0.432	-1.000	2.080
0.206	0.330	1.494	1.609	2.295	1.811	1.573	-1.000	3.148
0.487	0.696	0.759	0.758	1.428	1.174	0.703	-1.000	2.689
0.325	1.280	1.421	1.605	1.908	1.802	0.508	-1.000	1.445
0.122	0.459	0.351	0.694	0.000	0.994	0.000	-1.000	4.319
0.335	0.124	0.803	0.594	0.878	1.165	1.534	-1.000	3.891
0.245	1.123	1.347	0.757	0.000	1.210	0.000	-1.000	3.767
0.359	0.524	0.694	0.893	0.000	2.234	0.000	-1.000	2.152

(a) 평탄지형


경사	너비	기울기	길이	왼편 인접	오른편 인접	밑-위 인접	바이어스	높이
0.426	0.910	0.398	2.102	2.295	1.811	1.573	-1.000	3.702
0.281	1.135	0.358	2.178	1.428	1.174	0.703	-1.000	4.160
0.316	0.795	1.055	3.262	1.908	1.802	0.508	-1.000	5.757
0.272	1.579	0.173	2.299	0.000	0.994	0.000	-1.000	7.497
0.369	0.856	0.689	3.898	0.878	1.165	1.534	-1.000	5.614
0.363	0.629	1.046	2.239	0.000	1.210	0.000	-1.000	3.480
0.417	1.452	0.588	1.654	2.489	2.234	1.469	-1.000	2.072
0.282	1.004	1.411	3.060	2.090	2.103	1.871	-1.000	4.538
0.432	1.106	0.543	3.029	1.469	1.097	2.405	-1.000	7.123
0.481	0.938	1.499	2.147	2.305	1.461	0.976	-1.000	6.589

(b) 산악지형

에서의 높이값은 랜덤 프랙탈 중간점 변위로, (b)에서 무게중심 d에서의 높이값은 학습에 의한 결과치로 한다. (그림 6)에서 2는 한번 보간한 결과이고, 3은 두번 보간한 결과이다.



(a) 랜덤프랙탈중간점변위 기준 삼각형




(b) 본논문에서 제안한 기준 삼각형


(그림 6) 복원 기준 삼각형

(Fig. 6) Basic triangles for reconstruction

최종 복원 결과를 (그림 7)에 보인다. (그림 7)의 (a)는 원래의 격자 데이터를 나타낸 것이고, (b)는 프랙탈 방법에 의한 복원 결과 그리고, (c)는 본 논문에서 제안한 방법으로 평균오차가 개선된 학습 결과를 복원 데이터로 이용하여 보간한 복원 결과이다.




① 평탄지형




② 산악지형

(a) 격자 데이터에 의한 표현



① 평탄지형




② 산악지형

(c) 제안한 방법에 의한 복원

(그림 7) 복원 결과

(Fig. 7) Result of reconstruction



② 산악지형

(b) 프랙탈 방법에 의한 복원

근사도의 평가 방법으로는 입력 데이터로서 주어지는 데이터가 등고선 데이터와 격자 데이터이기 때문에 재생한 지형의 표면들 중에서 입력 데이터에 있는 격자 데이터와의 SNR(Signal to Noise Ratio)과 RMSE(Root Mean Square Error) 비교로 근사도를 평가한다. <표 3>에 근사도 평가 결과를 보인다. 평가 결과 복원하고자 하는 지형의 형태에 따라, 즉 불규칙성의 내포 정도에 따라 복원 방법에 따른 결과에 차이가 있음을 볼 수 있다. 실험 결과 제안한 알고리즘은 불규칙성을 많이 내포하고 있는 산악지형의 복원에 더 효과적임을 알 수 있었다.


<표 3> 근사도 평가 결과

<Table 3> Result of reality evaluation

(a) 평탄지형

(b) 산악지형

Method	SNR(dB)	RMSE	Method	SNR(dB)	RMSE
프랙탈 방법	8.80	29.45	프랙탈 방법	6.01	43.62
제안된 방법	9.18	27.29	제안된 방법	9.51	29.17



① 평탄지형

5. 결 론

본 논문에서는 등고선 데이터로부터 3차원 지형을 복원하는 개선된 알고리즘을 제안하여 3차원 지형의 의사부호화가 가능함을 보였다. 신경망 학습의 입력

패턴에 패치한 이웃 삼각형과의 관계를 추가한 더 많은 조건을 부여한 학습 결과를 복원에 이용하여 좀 더 사실적으로 표현할 수 있었다. 제안한 알고리즘으로 평탄지형과 비대칭성을 많이 내포하고 있는 산악지형에 대해 실험한 결과 근사도에 있어서 산악지형의 복원 결과가 더 우수함을 볼 수 있었다. 이는 신경망 학습을 이용함으로써 각 지형의 모양에 대한 비정형적인 데이터가 갖는 통계적 특성을 잘 활용할 수 있었기 때문이다.

앞으로 좀 더 많은 데이터를 사용한 실험과 본 논문에서 제안한 알고리즘의 병렬화를 추진할 예정이며, 복원된 지형의 근사도를 더욱 높이기 위한 연구가 계속 진행되어야겠다.

참 고 문 헌

- [1] 김 수원, 김 동윤, 김 하진, "신경망을 이용한 3차원 형상 복원", 한국정보과학회 학술발표논문집, 제 23 권, 제 1 호, pp. 1041-1044, 1996.
- [2] 김 수선, 김 동윤, 김 하진, "역전과 신경망을 이용한 등고선 데이터로부터 3차원 지형 복원", 한국정보과학회논문지, 제 23 권, 제 10 호, 1996.
- [3] 김 수선, "등고선 데이터로부터 3차원 지형 복원", 아주대학교 대학원 박사학위논문, 1997.
- [4] O. Guenther and A. Buchmann, "Research Issues in Spatial Databases", ACM SIGMOD Record, Vol. 19, No. 4, pp. 61-68, 1990.
- [5] 이 진선, 정 성중, "등고선 지도로부터 3차원 지형의 복원을 위한 래스터기반 알고리즘", 한국정보과학회논문지, 제 22 권, 제 8 호, pp. 1137-1145, 1995.
- [6] W. Barrett, E. Mortensen and D. Taylor, "Automated Height Information Acquisition from Topographic Map", Proceedings of IAPR Workshop on Machine Vision Applications, pp. 219-221, Nov. 1990.
- [7] K. Cheng and M. Idesawa, "A Simplified Method of Data Form Conversion from Contour Line Surface Model to Mesh Surface Model", Proceedings of IEEE International Conference on Pattern Recognition, pp. 582-585, 1986.
- [8] D. Meyers, S. Shelley, and S. Kenneth, "Surfaces From Contours", ACM Transactions on Graphics, Vol. 11, No. 3, pp. 228-258, July 1992.
- [9] A. Fournier, D. Fussell, and L. Carpenter, "Computer Rendering of Stochastic Models", Communication of ACM, Vol. 25, No. 6, pp. 371-384, June 1982.
- [10] A. D. Kelley, M. C. Malin, and G. M. Nielson, "Terrain Simulation using a Model of Stream Erosion", In ACM SIGGRAPH, Vol. 22, pp. 263-268, Aug. 1988.
- [11] J. P. Lewis, "Generalized Stochastic Subdivision", In ACM Transactions on Graphics, Vol. 6, pp. 167-190, July 1987.
- [12] F. K. Musgrave, G. E. Kolb, and R. S. Mace, "The Synthesis and Rendering of Eroded Fractal Terrains", In ACM SIGGRAPH, Vol. 23, pp. 41-50, July 1989.
- [13] 安居院, 官田, 中嶋, "3次元 自然形態の擬似符號化について", グラフィックスとCAD, Vol. 26, No. 2, 1986.
- [14] B. Mandelbrot, The Fractal Geometry of Nature, W. H. Freeman and Company, 1982.
- [15] 송 행숙, "확장된 랜덤프랙탈", 아주대학교 대학원 박사학위논문, 1995.
- [16] K. I. Funanashi, "On the Approximate Realization of Continuous Mappings by Neural Networks", Neural Networks 2: pp. 183-192, 1989.
- [17] K. Hornik, M. Stinchcombe, and H. White, "Multilayer Feedforward Networks Are Universal Approximators", Neural Networks 2: pp. 359-366, 1989.



김수선

- 1984년 서울산업대학교 전자계산학과(학사)
- 1986년 한양대학교 산업대학원 산업공학과(공학석사)
- 1997년 아주대학교 대학원 컴퓨터공학과(공학박사)
- 1991년 3월~현재 한양여자전문대학 전자계산과 조교수

관심분야: 컴퓨터 그래픽스, 컴퓨터 비전 등



김동윤

- 1974년 서울대학교 수학과(학사)
- 1976년 한국과학기술원 전산학과(공학석사)
- 1985년 미국 M.I.T. 응용수학과(이학박사)
- 1976년~1991년 국방과학연구소 책임연구원

1988년~1989년 Univ. of Maryland 컴퓨터 비전 연구소 과학재단 교환 연구원

1994년~1995년 영국 Cambridge Univ. 전산학과 인촌교환교수

1991년~현재 아주대학교 정보통신대학 교수

1997년~현재 아주대학교 정보통신대학 학장

관심분야: 컴퓨터 비전, 알고리즘



김하진

- 1962년 서울대학교 물리과학대학 수학과(이학사)
- 1978년 Grenoble 1 대학교 대학원 응용수학과 D.E.A. (이학석사)
- 1980년 Saint-Etienne 대학교 대학원 응용수학과(이학박사)

1984년~1985년 프랑스 INRIA 초빙교수

1989년~1992년 한국 정보과학회 부회장 및 회장

1993년~1995년 아주대학교 공과대학 학장

1974년~현재 아주대학교 정보통신대학 교수

관심분야: 컴퓨터 그래픽스, 수치해석 등.