

論文94-31B-10-13

## 계층적 구조의 신경회로망을 이용한 거리영상의 분할

### (Segmentation of Range Images Using Hierarchical Structure of Neural Networks)

鄭麟甲\*\*, 玄基浩\*, 李駿宰\*\*, 河永浩\*\*

(In-Gab Jeong, Ki-Ho Hyun, Jun-Jae Lee and Yeong-Ho Ha)

#### 要約

3차원 물체 인식에서 거리 영상의 분할은 필수적인 단계이다. 일반적으로 면 곡률은 거리 영상의 분할과 분류과정에서 잘 알려진 특징이지만 잡음에 민감한 단점이 있다. 이를 해결하기 위해 본 논문에서는 곡률을 이용한 거리 영상의 분할을 위해 계층적 구조의 신경회로망을 제안하였다. 계층적 구조의 신경회로망은 기존의 단층 최적화 방법에 비하여 잡음에 강하고 분할 결과가 더욱 동질하였다.

#### Abstract

The segmentation of range image is essential to recognize the three dimensional object. Generally, surface curvature is well-known feature for segmentation and classification of the range image, but it is sensitive to noise. In this paper, we propose the structure of hierarchical neural network using surface curvature for segmentation of range images. The hierarchical structure of neural networks is robust to noise and the result of segmentaion is better than conventional optimization method of single level.

#### I. 서 론

기준면과 물체와의 거리를 명암도로 변환한 거리영상으로 물체를 인식하기 위해서는, 먼저 기하학적 구조가 비슷한 면 영역으로 분할해야 한다. 그러나 거리영상에 포함된 잡음때문에 면 특징들이 민감하여 분할된 결과가 변화하므로 인식을 하기위한 면 표현

에 영향을 끼친다. 따라서 거리영상의 면 분할은 잡음 상태에 관계없이 물체의 구조적 특성에 따라 동일하게 분할되어야 한다.

면 분할에는 법선, 곡률, 다행식 계수등의 특징들이 일반적으로 이용되고 있으나 이를 모두 미분치를 포함하므로 잡음에 민감하다고 알려져 있다.<sup>[1-2]</sup> 면 분할 방법은 영상의 동질한 특성을 갖는 영역들로 합치는 방법과 영역간의 서로 다른 특징을 검출하는 방법으로 크게 나눌 수 있다. 최근에는 잡음에 강한 면 특징을 찾는 것보다 잘못된 면 분할 결과를 제거하기 위해 영역 성장법과 에너지 함수를 이용하여 최적화하는 방법등이 연구되고 있다.<sup>[3-7]</sup> Besl과 Jain<sup>[3]</sup>은 면 극사화로 곡률을 구한후 영역 성장법으로 최종적

\*正會員, 昌信專門大學校 電子科

(Dep. of Elec. Changshin Junior College)

\*\*正會員, 慶北大學校 電子工學科

(Dep. of Elec. Eng., Kyungpook Nat'l Univ.)

接受日字 : 1993年 9月 21日

인 영상분할을 하였으며, Yokoya<sup>[4]</sup>는 이차 방정식으로 미분값을 추정하여 곡률을 구한 다음 초기 분할을 경계와의 복합적인 방법으로 최종 영상 분할을 구하였다. 또한 Sabata<sup>[5]</sup>는 여러 관점의 거리 영상을 피라미드로 구성하여 미분값을 구하고 초기 영상 분할을 합치는 후처리로서 최종분할을 하였다. 그리고 Li<sup>[6-7]</sup>는 곡률로부터 구한 초기 영상 분할을 에너지 함수로 최적화하는 방법을 제시하였다.

본 논문에서는 거리 영상을 분할하기 위해 계층적 구조의 신경회로망을 제안하였다. 거리 영상은 먼저 곡률을 계산하여 계층적 구조로 구성한 다음 곡률이 각 부호에 속하는 가능도(possibility)로서 각 계층의 초기 부호 영상을 구한다. 초기 부호 영상은 주변 가능도를 고려한 신경회로망으로 이완처리하여 최종적인 분할 영상을 얻게된다. 단일층에서의 분할 방법이 잡음의 분포와 임계치에 따라 변화하는 단점을 제거하기 위해 상위 계층에서 분할된 결과가 하위계층의 이완처리시 영향을 끼치는 계층적 구조를 사용한다.

거리영상의 특징은 상위계층으로 올라갈수록 잡음의 영향을 줄일 수 있으므로 거리영상의 전체적인 특징이 보존되면서 분할되나 자세한 정보를 상실한다. 또한 하위 계층으로 내려갈수록 자세한 분할정보를 가지나 잡음에 민감하여 잘못 분할되는 영역이 생긴다. 따라서 계층적으로 구성하면 이 두가지 단점을 제거하면서 분할할 수 있다. 각 계층은 분할된 초기 부호의 가능도가 상위계층에서의 분할된 결과와 결합하여 새로운 가능도를 생성하고 주변의 가능도를 고려해 반복처리한다. 결과적으로 계층적 구조로 이완 처리시 신경회로망의 특성을 이용한 빠른 수렴속도로서 더욱 동질한 결과를 얻을 수 있으며 잡음에 강한 방법임을 실험을 통해 확인하였다.

## II. 면 곡률 특징

면 곡률 특징은 물체인식을 위해 임의의 평활한 면의 국부적인 모양을 1차 미분과 2차 미분의 조합으로 표현할 수 있다. 평균 곡률과 가우스 곡률은 곡률 부호에 따라 8가지의 면을 분류할 수 있어 일반적으로 많이 이용되고 있다. 거리영상을  $f(x,y)$ 로 나타낼 때  $x$  및  $y$ 방향의 미분을  $f_x$  및  $f_y$ , 2차 미분을  $f_{xx}$ ,  $f_{xy}$  및  $f_{yy}$ 로 각각 나타낼 수 있다. 이때 평균 곡률  $H$ 와 가우스 곡률  $K$ 는 각각 식 (1) 및 식 (2)로 구할 수 있다.<sup>[8]</sup>

$$H = \frac{(1+f_y^2)f_{xx} + (1+f_x^2)f_{yy} - 2f_x f_y f_{xy}}{2(1+f_x^2 + f_y^2)^{3/2}} \quad (1)$$

$$K = \frac{f_{xx}f_{yy} - f_{xy}^2}{(1+f_x^2 + f_y^2)^2} \quad (2)$$

가우스 곡률과 평균 곡률의 부호를 조합하여 8가지의 가능한 면 모양을 표 1과 같이 구성할 수 있다. 그러나 잡음에 민감한 2차 미분치 계산이 곡률에 포함되어 있어 동일한 임계치로서 부호를 구분하여 일정하게 영역을 나누기 어렵다. 표에서 임계치  $T_k$  및  $T_h$ 는 이론적으로 0 이지만 일반적으로 거리영상에서 물체의 종류 또는 잡음의 분포에 따라 임의의 실수를 지정하여 준다.

또한 잡음의 영향을 줄이기 위해 평활화를 전처리로 수행하지만 영상의 외부 경계 및 내부 경계등 불연속점에서 과도한 평활화로 면 모양에 왜곡이 생길 수 있다. 이를 해결하기 위해 면의 국부적인 성질을 유지하는 방법과 잡음의 제거를 위한 평활화의 조화가 필요하다. 그러므로 최근에 Li<sup>[6-7]</sup>는 이를 에너지 함수로서 모델링하여 최적화된 분할 결과를 얻는 방법을 제안하였다.

표 1. 곡률의 부호에 따른 면 분할

Table 1. Surface segmentation using of curvature sign.

	$K < T_k$	$K = T_k$	$K > T_k$
$H < T_h$	Saddle Ridge	Ridge	Peak
$H = T_h$	Minimal Surface	Flat	(none)
$H > T_h$	Saddle Valley	Valley	Pit

## III. 계층적 구조의 신경회로망

계층적 구조의 신경회로망을 이용한 분할은 먼저 거리영상으로부터 곡률을 구한 후 계층적 구조로 재구성하여 임계치로 초기의 부호화된 곡률 영상을 구한다. 이를 최상위 계층부터 이완 합수로서 반복처리하며 한 계층의 분할된 최종 곡률 부호영상을 얻는다. 최종 분할 결과는 보간한 다음 하위 계층으로 전파되어 하위계층의 각 화소가 부호에 속하는 가능도를 새로운 값으로 지정한 다음 이완 합수로서 다시 반복처리한다. 결과적으로 최하위 계층의 최종 분할 영상은 모든 계층의 최종 분할 결과를 포함하여 수행한 결과이다.

거리영상의 면 모양을 분할하기 위해 제안한 계층

적 구조의 각 계층은 한 화소의 -, 0, + 부호를 포함하는 3층 구조로 이루어져 있다. 이 모델은 상호 연결된 뉴런들로 구성되어 있으며 가우스 곡률과 평균 곡률에 대한 각각의 모델로 구성된다.

### 1. 계층적 구조

계층적 데이터 구조는 최하위 계층에서 최상위 계층까지 영상의 해상도를 감소시키면서 구성된다. 입력 영상은 영상의 각 화소가 한 노드를 구성하는 최하위 계층으로 저장되고 각 계층의 노드는 바로 아래 계층 노드의 평균으로 구한다.<sup>[5,9]</sup> 즉  $h$ 개의 계층중 계층  $L$ 의 노드는 계층  $L+1$ 의 노드 및 계층  $L-1$ 의 노드와 각각 연결되어 있다. 계층  $L$ 의  $n$ 노드에 연결된 계층  $L+1$ 의 노드는  $n$ 노드의 아버지 노드(father node)라 하고, 계층  $L-1$ 의 노드는 아들 노드(son node)라 한다. 계층  $L$ 의 임의의 노드  $[i, j, L]$ 의 아버지 노드는  $f = [i', j', L+1]$ , 아들 노드는  $s = [i', j', L-1]$ 로 표현한다. 계층  $L$ 에 포함된 모든 노드는 식(3)과 같이 나타낸다.

$$X_L = \{[i, j, L]\}, \quad 0 \leq i, j \leq 2^{h-1}, \quad 0 \leq L \leq k \quad (3)$$

계층 피라미드의 초기화는 입력 영상이  $2^h \times 2^h$ 이고  $h$  레벨의 계층을 구성할 때  $L$  레벨의 노드는  $L-1$  레벨의  $2 \times 2$  노드의 평균으로  $2^{h-L} \times 2^{h-L}$ 의 영상을 그림 1과 같이 구성한다.

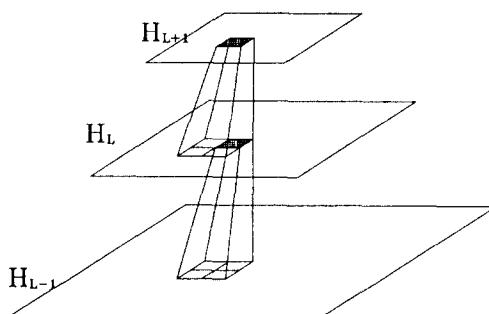


그림 1. 계층적 구조

Fig. 1. Hierarchical structure.

$L$  레벨의 노드  $n$ 의 특성을  $c[i, j, L]$  이라고 할 때 계층 피라미드의 초기화는 식(4)와 같다.

$$c[i, j, L] = \frac{\sum_{\substack{(i', j', L-1) \in X_{L-1} \\ (i', j', L-1) \in X_{L-1}}} c[i', j', L-1] w_{sn}}{\sum_{\substack{(i', j', L-1) \in X_{L-1} \\ (i', j', L-1) \in X_{L-1}}} w_{sn}} \quad (4)$$

$\forall [i, j, L] \in X_L$

여기서  $w_{sn} = w(i', j', i, j, L-1)$  은 식(5)와 같이  $L-1$  레벨에서  $L$  레벨의 노드에 대한 아들 노드의 가중치이다.

$$w_{sn} = w(i', j', i, j, L-1) \quad (5)$$

$$\begin{cases} 1 & \text{if } f[i', j', L-1] \in \{son[i, j, L]\} \\ 0 & \text{otherwise} \end{cases}$$

계층적 구조의 신경회로망은 먼저 계층 피라미드의 초기화를 수행하여야 한다. 계층적 구조의 초기화는 입력 영상으로 곡률값을 이용하며, 하위계층의  $2 \times 2$  노드의 평균으로 상위계층의 노드를 구성한다.

### 2. 계층적 구조의 이완함수

계층적 구조의 이완처리는 그림 2와 같은 구조로 수행이 되며 이를 위해 초기 가능도를 구하고 상위계층의 결과를 하위계층으로 전파하며 주변의 가능도를 고려하여야 한다.

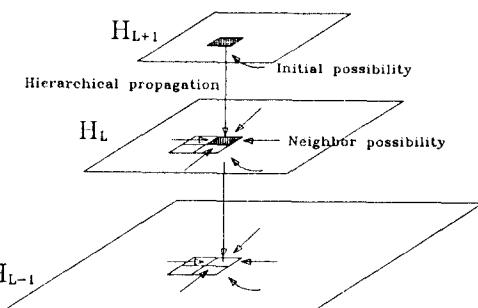


그림 2. 계층적 이완처리 구조

Fig. 2. Hierarchical relaxation structure.

먼저 곡률값이 부호에 속하는 초기 가능도를 정하기 위해 거리 영상에서 계산된 곡률로 부터 초기 분류는 0에 가까운 임계치를 정하여 -, 0, +의 부호값으로 식(6)과 같이 분류할 수 있다.

$$h^{(0)}(i, j) = \begin{cases} -, \quad \eta(i, j) < -T_k \\ 0, \quad |\eta(i, j)| < T_k \\ +, \quad \eta(i, j) > T_k \end{cases} \quad (6)$$

여기서  $\eta(i, j)$ 는 각 화소의 곡률값을 나타내며  $T_k$ 는 부호를 나누기 위한 임계치이고  $h^{(0)}(i, j)$ 는 초기 분류된 부호화 영상이다. 그러나 임계치에 의한 초기 부호 분류는 잡음에 민감하여 영역 분류에 오차가 크므로 곡률값이 각 부호에 속하는 가능도를 구하고 주

변의 가능도를 고려한 계층적 구조의 이완함수를 이용하여 반복 처리 한다. 따라서 초기에 구한 곡률값이 한 부호의 영역에 속할 가능성  $p_{i,j,k,L}^{(0)}$ 은 식 (6)에서 임계치  $T_k$ 에 가까운 값은 부호에 속하는 가능도를 주도록 하여 식 (7), 식 (8) 및 식 (9)와 그림 3으로 나타낼 수 있다.

$$p_{i,j,-,L}^{(0)} = \begin{cases} 1, & \eta(i,j) < -d_2 \\ \frac{\eta(i,j) - d_1}{d_2 - d_1}, & -d_2 < \eta(i,j) < -d_1 \\ 0, & \eta(i,j) > -d_1 \end{cases} \quad (7)$$

$$p_{i,j,+,L}^{(0)} = \begin{cases} 1, & |\eta(i,j)| < d_1 \\ 1 - \frac{\eta(i,j) - d_1}{d_2 - d_1}, & d_1 < |\eta(i,j)| < d_2 \\ 0, & |\eta(i,j)| > d_2 \end{cases} \quad (8)$$

$$p_{i,j,*,L}^{(0)} = \begin{cases} \frac{\eta(i,j) - d_1}{d_2 - d_1}, & d_1 < \eta(i,j) < d_2 \\ 1, & \eta(i,j) > d_2 \end{cases} \quad (9)$$

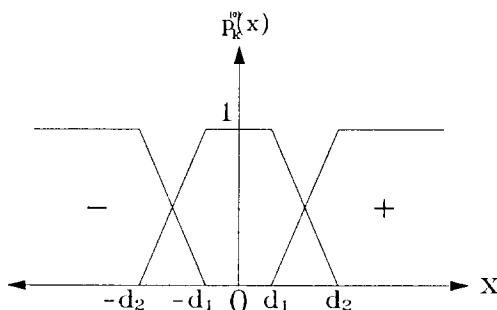


그림 3. 각 부호의 가능도 함수

Fig. 3. Possibility function of each signs.

계층적 구조의 신경회로망에서 한 화소가 부호영역에 속하는 가능성은 곡률값에 따른 초기 가능성  $p_{i,j,k,L}^{(0)}$ 과 계층간의 동일한 화소 영역에서 부호 유사성은 비슷하므로 상위 계층의 최종 분할 결과  $p_{i',j',k,L+1}^{(0)}$ 을 포함하는 새로운 가능성  $p_{i,j,k,L}^{(1)}$ 을 식(10)과 같이 정하였다.  $p_{i,j,k,L}^{(1)}$ 는 세밀한 분할 정보를 가진 하위 계층의 가능성  $p_{i,j,k,L}^{(0)}$ 과 잡음에 강한 상위계층의 최종결과  $p_{i',j',k,L+1}^{(0)}$ 를 가중치를 주어 더한 결과로서 단층의 경우보다 잡음에 강한 분할을 할 수 있다. 제안한 계층적 구조의 신경회로망은 앞의 두가지 요소를 포함한 가능도를 초기치로 하며 주변 가능도를 고려하여 반복적으로 출력값을 결정하게 된다.

(10)

이때 최상위 계층의 경우  $p_{i',j',k,L+1}^{(0)}$ 이 존재하지 않으므로  $p_{i,j,k,L}^{(0)}$ 만으로 반복처리하며 한 화소의 뉴런 값은 0과 1 사이의 값으로 제한하기 위해  $\alpha$  및  $\beta$ 는 합이 1이 되도록 한다.

새로운 가능성  $p_{i,j,k,L}^{(1)}$ 는 뉴런의 출력값으로 반복적인 이완처리를 하며 수렴해야 하므로 식(11) 및 그림 4와 같이 sigmoid함수로 정의하였다.

$$p_{i,j,k,L}^{(1)} = \frac{1}{1 + \exp[-\lambda(u^{(0)} - 0.5)]} \quad (11)$$

식 (11)은 출력 가능성으로 뉴런의 입력값  $u$ 는 식 (12)에 의해 역으로 계산되어진다.

$$u^{(1)} = 0.5 - \frac{1}{\lambda} \times \ln(\frac{1 - p_{i,j,k,L}^{(0)}}{p_{i,j,k,L}^{(0)}}) \quad (12)$$

식 (11)에서 계층 L의 하위 계층 L-1의 임의의 점  $[i', j', k, L-1]$ 이 부호 k에 속할 가능성은 곡률값에 따른 가능성  $p_{i',j',k,L}^{(0)} = 1$ , 상위 계층의 화소인  $[i, j, k, L]$ 의 최종 분할 결과인  $p_{i',j',k,L+1}^{(0)} = 1$ 일 경우를 1이 되도록 하는 상대적인 가중치로 계층 L의 초기 가능성에  $\alpha$ , 상위 계층의 최종 부호 결과에 가중치  $\beta$ 를 곱한값으로서 새로운 가능도를 정하였다. 만약  $\alpha$ 가 1,  $\beta$ 가 0이면 단층의 최적화와 같은 결과이다. 또한  $\lambda$ 의 값에 따라 함수의 기울기가 결정되고 결과적으로  $\lambda$ 가 커짐에 따라 변환된 가능도는 보다 넓은 분포를 가지게 된다.

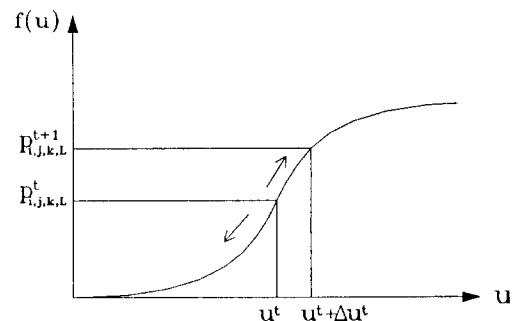


그림 4. Sigmoid 함수에 의한 뉴런의 입력

Fig. 4. Input of neuron using sigmoid function.

이와 같이 구해진 가능성은 각 계층이  $2^{h_L} \times 2^{h_L} \times 3$  크기의 뉴런으로 구성된 신경회로망의 초기값  $p_{i,j,k,L}^{(1)}$ 이 된다. 각 위치에서 초기치가 결정된 후에는 주변 값을 고려하여 각 뉴런의 상태값을 수렴할때까지 바꾸어 준다. 임의의 계층 화소  $[i, j, k, L]$ 에서 뉴

런의 새로운 값  $p_{i,j,k,L}^{t+1}$  은 식 (13) 및 식(14)에 따라 결정된다.

$$p_{i,j,k,L}^{t+1} = f(u^{t+1}) \quad t > 1 \quad (13)$$

$$f(u^{t+1}) = \frac{1}{1 + \exp[-\lambda(u^{t+1} - 0.5)]} \quad (14)$$

이때 뉴런의 입력값  $u^{t+1}$ 은 식 (15)와 같이 임의의  $t$ 에서 뉴런의 입력값  $u^t$ 와 주변 뉴런에 의해 기여되는 출력 가능성도  $\Delta u^t$ 로 새로운  $t+1$ 의 뉴런 입력값  $u^{t+1}$ 이 결정된다.

$$u^{t+1} = u^t + \Delta u^t \quad (15)$$

여기서 주변 뉴런들에 의해 기여되는 출력 가능성도  $\Delta u^t$ 는 식 (16)처럼 주변 뉴런의 출력 가능성도 평균값과 중심 화소인  $(r,c)$ 의 가능성 차이이다.

$$\Delta u^t = \overline{p_N^t} - p_{r,c,k,L}^t \quad (16)$$

$$\text{where } \overline{p_N^t} = \frac{1}{M} \sum_i \sum_j \sum_k p_{r,c,k,L}^t,$$

for each  $L$  and  $(i,j) \neq (r,c)$

이때  $M$ 은 동일한 부호값을 갖는 주변의 뉴런 갯수이다.

이완화 과정을 거친 다음 식(17)과 같이 가능성도가 최대로 되는 부호값을 계층  $L$ 의 화소 출력값으로 결정하였다. 반복처리는 더이상 값이 변하지 않을 때까지 한다.

$$p_{i,j,k,L}^{\infty} = \begin{cases} 1, & \text{if } \max(p_{i,j,k,L}^t) \leq -0.5 \\ 0, & \text{otherwise} \end{cases} \quad (17)$$

이와같이 구한 계층  $L$ 의 최종 분할 결과는 다시 계층  $L-1$ 의 초기 부호 가능성도 중  $p_{i',j',k',L-1}^{\infty}$  값으로 입력되어 반복된다. 최종적으로 최하위 계층의 분할 결과인 가우스 곡률 및 평균 곡률의 모델에서 구한 결과값을 조합하여 곡률에 의한 최종 영역 분할 결과를 구할 수 있다.

제안한 계층적 구조의 신경회로망은 주변의 동일한 부호값을 갖는 뉴런들간에 강화가 일어나고 외부경계를 포함하는 뉴런은 주변값을 고려하지 않으므로서 과도한 평활성을 줄일 수 있다. 또한 상위 레벨의 최종 부호 결과에 따라 하위 레벨의 부호 결과가 영향을 받으므로 애러가 전파되는 효과를 생각할 수 있으나, 가중치  $\alpha$  및  $\beta$ 에 의해 상위 레벨의 가중치를 조정함으로서 애러 전파를 줄이고 최종 결과를 더욱

동질한 영역으로 수렴시킬 수 있다. 또한 초기 분할에서 구한 예지 정보에 의해 처리 과정 중 병합되는 영역이 물체의 불연속점을 넘어가는 것을 방지할 수 있고, 초기에 분할하지 못한 영역을 다시 분할 한다.

#### IV. 실험 및 고찰

거리영상의 곡률을 구한 후 잘못된 초기 부호영상을 단층을 이용한 분할 방법과 계층적 구조의 신경회로망을 이용한 분할은 그림 5의 합성된 256 명암도의 거리영상에 가우스 잡음은 평균은 0이고 표준 편차  $\sigma$ 는 1, 2, 3인 영상에 대하여 각각 실험하였다. 실험 영상의 크기는 100x100이고 초기 부호영상을 구하기 위한 임계치는 가우스 곡률 및 평균 곡률에 대하여 각각 0.0003의 값으로서 거의 0에 가까운 값이다. 또한 초기 가능도를 정하기 위한 기울기는  $d_2$ 를 0.0006으로서 고정하였고, 계층적 구조의 신경회로망을 구하기 위한 레벨은 3레벨로 정하였으며 반복횟수는 두 가지 방법 모두 20번으로 정하였다.  $\alpha$ 와  $\beta$ 는 각각 0.5로 하였고  $\lambda$ 는 4로 하였다. 그림 6은 곡률 값으로부터 구한 단층 구조의 영상 분할을 위한 초기 가우스 곡률 부호 영상과 초기 평균 곡률 부호 영상을 각각 나타내었다. 각 부호영상은 물체의 외부경계를 포함하여 최적화 단계를 수행할 때 인접영역이 외부경계일 경우 주변의 영향을 제거하도록 하였다. 그림 7은 torus 영상의 초기 부호 영상을 단층 구조의 에너지 함수에 의해 최적화한 결과로서 그림 7(a)는 가우스 잡음이 1일 경우, 그림 7(b)는 가우스 잡음이 2일 경우, 그림 7(c)는 가우스 잡음이 3일 경우를 각각 나타낸다. 결과에서 알 수 있듯이 초기 부호 영상의 모든 임계치를 일정하게 할 경우 영상 분할의 결과가 변화하나 이를 보완하기 위해서는 각 경우마다 경험적인 임계치를 주어야 한다.

그림 8은 단층 구조의 영상 분할 경우와 같은 임계치를 정하고 수행한 계층적 구조의 신경회로망 결과이다. 결과에서 알 수 있듯이 계층적 구조를 이용한 방법은 잡음의 분포에 따라 임계치를 일정하게 유지 하여도 분할 결과가 단층구조의 영상 분할에 비하여 거의 변화가 없어 동질하고 일정한 결과를 얻을 수 있다. 또한 두 가지 결과를 비교하여 보면 거리영상의 평면으로 가정할 수 있는 배경 부분에서 단층 구조의 영상 분할 결과보다 계층적 구조의 신경회로망의 결과가 더욱 동질하게 수렴하였음을 확인할 수 있다. 이와 같은 결과를 그림 9의 정육면체에 대하여 실험 하므로서 확인하였다. 계층적 구조의 신경회로망 방법은 앞으로 거리 영상의 크기가 더욱 세밀하게 표현

하기 위해 커지더라도 층의 갯수를 조절하여 더욱 동질하고 일정한 결과를 얻을 수 있을 것이다.

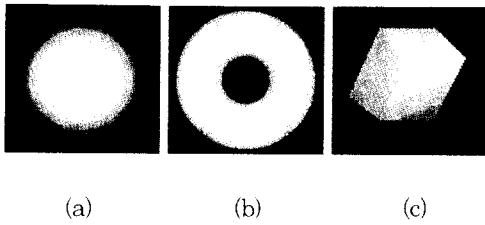


그림 5. 원 거리 영상

(a) 구형 (b) 도너츠형 (c) 정육면체

Fig. 5. Original range images.

(a) sphere (b) torus (c) cubic

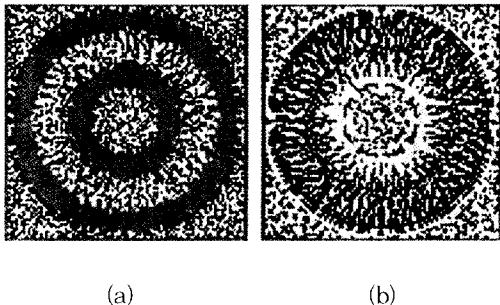


그림 6. Torus의 초기 분할 영상

(a) 가우스 곡률( $\sigma=3$ )

(b) 평균 곡률( $\sigma=3$ )

Fig. 6. Initial segmentation of torus.

(a) gauss curvature( $\sigma=3$ )

(b) mean curvature( $\sigma=3$ )

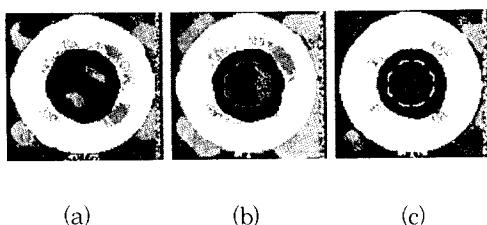


그림 7. 단층 구조를 이용한 Torus의 분할 영상

(a)  $\sigma = 1$  (b)  $\sigma = 2$  (c)  $\sigma = 3$

Fig. 7. Segmentation results of torus using single level.

(a)  $\sigma = 1$  (b)  $\sigma = 2$  (c)  $\sigma = 3$

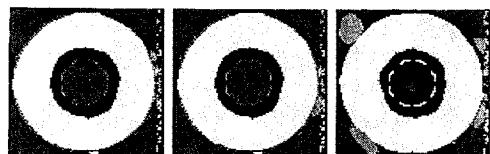


그림 8. 계층적 구조를 이용한 Torus의 분할 영상

(a)  $\sigma = 1$  (b)  $\sigma = 2$  (c)  $\sigma = 3$

Fig. 8. Segmentation results of torus using hierarchical structure.

(a)  $\sigma = 1$  (b)  $\sigma = 2$  (c)  $\sigma = 3$

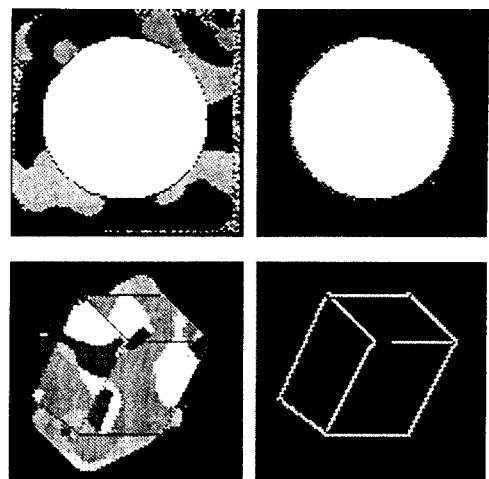


그림 9. 단층과 계층적 구조를 이용한 분할 영상

(a) 단층 결과 (b) 계층적 결과

Fig. 9. Segmentation results using hierarchical structure and single level.

(a) single level (b) hierarchical structure

## V. 결 론

본 논문에서는 기존의 단층을 이용한 거리영상의 분할이 잡음에 따라 결과가 변화하므로 이를 개선한 계층적 구조의 신경회로망을 제안하였다. 면 특징은 계층적 구조로 구성하여 최상위 계층부터 이완 함수로서 반복처리하며 최종 곡률 부호영상을 얻었다. 최

종 분할 결과는 보간한 다음 하위 계층으로 전파되어 하위계층의 각 화소가 부호에 속하는 정도를 새로운 값으로 지정한 다음 이완 합수로서 다시 반복처리한다. 이는 거리 영상에 잡음이 있을 경우 단일 계층의 영상보다 더욱 동질한 결과를 얻을 수 있어 잡음에 강한 방법임을 여러가지 실험을 통해 확인하였다.

앞으로 계층적 구조의 신경회로망을 이용한 최종 분할 결과를 연속적인 값으로서 하위계층에 전달하는 방법과 계층의 수에 따른 분할 결과의 분석이 더욱 연구되어야 한다. 또한 계층의 구조를 연구하여 원영상의 화소수와 같은 계층의 화소수를 구성하는 계층적 구조에 대한 연구도 필요하다.

### 参考文献

- [1] M. Oshima and Y. Shirai, "Object recognition using three dimensional information," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. PAMI-5, pp. 353-361, 1983.
- [2] A. P. Reeves and R. W. Taylor, "Identification of three dimensional objects using range information," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol.11, no.4, pp. 403-410, 1989.
- [3] P. J. Besl and R. C. Jain, "Segmentation through variable-order surface fitting," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 10, no. 2, pp. 167-192, March 1988.
- [4] N. Yokoya and M. D. Levine, "Range image segmentation based on differential geometry:a hybrid approach," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 11, no. 6, pp. 643-649, June 1989.
- [5] B. Sabata, F. Arman, and J. K. Aggarwal, "Segmentation of 3D range images using pyramidal data structures," *CVGIP:Image Understanding*, vol.57, no. 3, pp. 373-387, May 1993.
- [6] S. Z. Li, "Invariant surface segmentation through energy minimization with discontinuities," *International Journal of Computer Vision*, vol. 5:2, pp. 161-194, 1990.
- [7] S. Z. Li, "Toward 3D vision from range images:an optimization framework and parallel networks," *CVGIP:Image Understanding*, vol.55, no. 3, pp. 231-260, May 1992.
- [8] P. J. Besl, *Surfaces in Range Image Understanding*, Springer-Verlag, New York, pp. 86, 1988.
- [9] R. Szeliski, "Fast surface interpolation using hierarchical basis functions," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 12, no. 6, pp. 513-528, June 1990.

---

### 著者紹介

---

**鄭麟甲**(正會員) 第29卷B編第7號 參照  
현재 대구 경북대학교 대학원 전자  
공학과 박사 과정 재학중

**李駿宰**(正會員) 第31卷B編第4號 參照  
1994年 8月 경북대학교 대학원 전  
자공학과 박사 학위 취득

**玄基浩**(正會員) 第28卷B編第11號 參照  
현재 마산 창신 전문대학교 전자공  
학과 조교수

**河永浩**(正會員) 第28卷B編第11號 參照  
현재 경북대학교 전자공학과 부교수