

# 자기 조직화 지도를 이용한 다중 평면영역 검출

## Multiple Plane Area Detection Using Self Organizing Map

김정현, 등축, 강동중\*  
(Jeong-Hyun Kim<sup>1</sup>, Teng-Zhu<sup>1</sup>, and Dong-Joong Kang<sup>1</sup>)  
<sup>1</sup>Pusan National University

**Abstract:** Plane detection is very important information for mission-critical of robot in 3D environment. A representative method of plane detection is Hough-transformation. Hough-transformation is robust to noise and makes the accurate plane detection possible. But it demands excessive memory and takes too much processing time. Iterative randomized Hough-transformation has been proposed to overcome these shortcomings. This method doesn't vote all data. It votes only one value of the randomly selected data into the Hough parameter space. This value calculated the value of the parameter of the shape that we want to extract. In Hough parameters space, it is possible to detect accurate plane through detection of repetitive maximum value. A common problem in these methods is that it requires too much computational cost and large number of memory space to find the distribution of mixed multiple planes in parameter space. In this paper, we detect multiple planes only via data sampling using Self Organizing Map method. It does not use conventional methods that include transforming to Hough parameter space, voting and repetitive plane extraction. And it improves the reliability of plane detection through division area searching and planarity evaluation. The proposed method is more accurate and faster than the conventional methods which is demonstrated the experiments in various conditions.

**Keywords:** hough transform, randomized hough transform, iterative randomized hough transform, self organizing map, multiple plane detection, stereo camera

### I. 서론

3차원 공간에서 평면 영역 인식은 이동 로봇의 안전한 수행과 지시된 작업 수행을 위해 중요한 정보로 사용된다. 평면 검출은 Honda의 ASIMO와 같은 2족 보행 로봇에 적용되어 계단주행과 장애물 회피 등에 성공적으로 적용되었다[1].

평면 검출을 위한 대표적인 방법은 하프 변환을 이용하는 것이다. 하프 변환은 영상 데이터에서 선, 원, 타원, 다각형과 같은 특징들을 추출하는데 많이 이용된다. 하프 변환을 이용한 평면 검출은  $X-Y-Z$  좌표의 한 데이터를 원점에서의 수직거리와 평면의 회전각을 나타내는  $\rho-\theta-\phi$  로 바꾸어 하프 파라미터 공간에 보팅을 한다. 모든 데이터를 보팅한 후, 하프 파라미터 공간에서 최대값을 검출하여 3차원 공간에서 평면을 찾는다. 하프 변환은 잡음이 많은 환경에서도 정확한 검출 성능을 보이나 많은 메모리 공간의 필요와 처리 속도가 느리다는 단점이 있다.

하프 변환의 단점을 극복하기 위해 조합 하프 변환(HT) [2], 랜덤 하프 변환(RHT) [3,4], 확률 하프 변환(PHT) [5], 그리고 동적으로 일반화된 하프 변환[6] 등의 알고리즘들이 제안되었다.

특히, 랜덤 하프 변환은 하프 변환의 느린 처리속도 문제를 해결하기 위해 제안되었다. 이미지상의 모든 점을 파라미

터 공간에 보팅하는 것이 아니라 구하고자 하는 기하형상에 대한 파라미터를 샘플링 데이터에서 미리 계산하여 하나의 파라미터 값만 보팅한다. 랜덤 하프 변환은 기존 하프 변환 보다 적은 메모리를 사용하며, 빠른 속도로 대상을 검출한다.

보팅된 하프 파라미터 공간은 잡음을 포함하여 다양한 분포를 나타낸다. 잡음의 영향을 피하고 정확한 형상만을 효율적으로 검출하기 위해서 반복적 랜덤 하프 변환(IRHT)이 제안되었다[8].

반복적 랜덤 하프 변환은 하프 파라미터 공간에서 최대값을 찾고, 찾아진 파라미터에 해당되는 형상 데이터를 제거한다. 나머지 데이터에 대해서 다시 랜덤 하프 변환을 수행하고, 새로 보팅된 하프 파라미터 공간에서 최대값을 찾아 두 번째 파라미터를 찾는다. 이 방법을 반복하여 여러 개의 파라미터를 정확하게 찾을 수 있다.

기존의 하프 변환을 이용한 평면 검출 방법은 파라미터 공간에 많은 데이터를 보팅한 후, 하프 파라미터 공간에서 여러 개의 분포 중, 평면 파라미터를 찾는다. 기존 방법은 직교 좌표계에서 구 좌표계로의 변환뿐만 아니라 파라미터 공간에서 평면의 분포를 찾기 위해 많은 계산 시간과 메모리 공간을 요구한다.

본 논문에서는 자기 조직화 지도의 군집화 방법을 이용하여 기존 하프 변환 방법의 파라미터 공간으로 값 변환 및 보팅이나, 다중 평면 검출을 위한 반복 없이 데이터 샘플링시 배정되는 군집화 방법으로 다중 평면을 검출한다. 군집 결과가 바로 추출한 평면 자체이기 때문이다. 기존 군집화 방법은 새로운 샘플 데이터가 입력되면 군집화 과정을 처음부터 다시 수행해야 하지만 자기 조직화 지도는 새로운 샘플이 들어 오면 학습된 신경망으로 그 샘플만 군집 배정을 해주면 된다. 따라서 새로운 패턴이 계속 발생하는 온라인 상황에 효과적

\* 책임저자(Corresponding Author)

논문접수: 2010. 4. 12., 수정: 2010. 11. 4., 채택확정: 2010. 11. 18.

김정현, 등축, 강동중: 부산대학교 기계공학부

(mare@pusan.ac.kr/tengzhu@pusan.ac.kr/djkang@pusan.ac.kr)

※ 본 연구는 2007년 정부(교육인적자원부)의 한국학술진흥재단(KRF-2007-511-D00198), 2010년도 정부(교육과학기술부)의 한국연구재단의 기초연구사업(No.2010-0027990), 한국산업기술진흥원(KIAT)의 전략기술인력양성사업, 부산대학교 자유연구학술과제사업으로 수행된 결과임.

으로 사용 가능하다. 초기 부류값을 설정하지 않고도 입력 되는 샘플에 대하여 부류를 생성, 갱신, 소멸이 가능하여 평면의 파라미터를 샘플링 중에 사용할 수 있다. 또한 분할 영역 검출 방법과 평면도 검사 방법을 통하여 다중 평면 검출의 신뢰성을 더욱 높인다. 제안된 방법은 실험을 통하여 기존의 방법보다 빠르고 정확함을 보인다.

본 논문의 II 장에서는 하프 변환을 이용한 평면 검출 방법, III 장에서는 자기 조직화 방법을 이용한 평면 검출 방법을 소개하며, IV 장에서는 하프 변환과 제안 방법의 다중 평면 검출 결과를 실험을 통하여 비교하며, V 장에서는 제안된 알고리즘의 신뢰성과 결과에 대하여 요약한다.

**II. 평면 검출을 위한 임의 하프 변환**

**1. 임의 하프 변환**

표준 하프 변환은 잡음에 강인한 장점이 있지만 큰 메모리 공간과 많은 계산 시간을 요구한다. 이 문제를 극복하기 위한 방법으로 임의 하프 변환 방법이 [5,7]에 의하여 제안되었다.

표준 하프 변환은 입력 데이터에서 랜덤하게 한 점을 선택하고 이 점이 표현하는 기하 형태의 파라미터 값들을 하프 파라미터 공간에 보팅한다(그림 1(a)). 반면, 임의 하프 변환은 여러 점을 랜덤하게 선택하고 여러점에 의해 정의된 파라미터 값 하나만을 하프 파라미터 공간에 보팅한다(그림 1(b)). 평면 검출의 경우, 랜덤하게 세 점을 선택하고, 세 점으로 만들어진 평면의 노말 방향의 값을 하프 파라미터 공간에 보팅한다. 그림 1은 평면 검출에서 표준 하프 변환과 임의 하프 변환의 차이점을 보인다.

3차원 공간에서 세 점이 있다면 (1)을 이용하여 평면을 표현할 수 있다. (1)에서 x, y, z는 3차원 공간에서 평면상에 있는 점의 좌표를 나타내고, A, B, C는 평면의 노말 방향을 D는 평면의 원점으로부터의 수직거리를 나타낸다.

$$Ax + By + Cz + D = 0 \tag{1}$$

임의 하프 변환에서 평면 검출을 위해 랜덤하게 선택한 세 점이  $(x_1, y_1, z_1), (x_2, y_2, z_2), (x_3, y_3, z_3)$  라면, 평면을 표현하는 파라미터 A, B, C, D는 (2)을 이용하여 구할 수 있다.




그림 1. 표준 하프 변환과 임의 하프 변환의 차이점.  
Fig. 1. Difference between Standard HT and Randomized HT.




그림 2. 구면 좌표계.  
Fig. 2. Spherical coordinate system.

$$A = \begin{vmatrix} 1 & y_1 & z_1 \\ 1 & y_2 & z_2 \\ 1 & y_3 & z_3 \end{vmatrix} \quad B = \begin{vmatrix} x_1 & 1 & z_1 \\ x_2 & 1 & z_2 \\ x_3 & 1 & z_3 \end{vmatrix} \tag{2}$$

$$C = \begin{vmatrix} x_1 & y_1 & 1 \\ x_2 & y_2 & 1 \\ x_3 & y_3 & 1 \end{vmatrix} \quad D = - \begin{vmatrix} x_1 & y_1 & z_1 \\ x_2 & y_2 & z_2 \\ x_3 & y_3 & z_3 \end{vmatrix}$$

이 때 파라미터 A, B, C, D로는 보팅을 위한 하프 파라미터 공간의 범위를 제한시켜 결정하기 힘들다. 따라서 직교 좌표계인 파라미터 값을 구면 좌표계로 변환한다. 그림 2는 구면 좌표계를 나타낸다. 그림 2에서  $\rho$ 는 원점에서 평면까지의 거리,  $\phi$ 는 x축 기준의 각도,  $\theta$ 는 z축 기준의 각도를 나타낸다. 따라서 직교 좌표계에서 노말 방향은 구면 좌표계에서  $\rho, \phi, \theta$ 의 값으로 변환하여 하프 파라미터 공간의 범위를 (3)으로 결정 할 수 있다.

$$\begin{aligned} \rho &\geq 0 \\ 0 &\leq \theta \leq \pi \\ 0 &\leq \phi \leq 2\pi \end{aligned} \tag{3}$$

구면 좌표계의  $\rho, \phi, \theta$  값은 (4)를 이용하여 구할 수 있다. (4)에서 x, y, z는 직교 좌표계의 한 점으로  $x=A/D, y=B/D, z=C/D$ 를 나타낸다.

$$\begin{aligned} \rho &= \sqrt{x^2 + y^2 + z^2} \\ \theta &= \cos^{-1} \left( \frac{z}{\rho} \right) \\ \phi &= \tan^{-1} \left( \frac{y}{x} \right) \end{aligned} \tag{4}$$

또한 구면 좌표계에서 직교 좌표계로의 변환은 (5)와 같다.

$$\begin{aligned} x &= \rho \sin \theta \cos \phi \\ y &= \rho \sin \theta \sin \phi \\ z &= \rho \cos \theta \end{aligned} \tag{5}$$

**2. 반복적 임의 하프 변환을 이용한 다중 평면 검출**

반복적 임의 하프 변환[8]은 다중 평면을 검출하기 위해 적용될 수 있으며 그림 3과 같은 단계로 처리된다.

먼저 단계 ①에서 스테레오 카메라로부터 3차원 데이터를 입력 받는다. 단계 ②는 입력된 3차원 데이터에서 랜덤하게

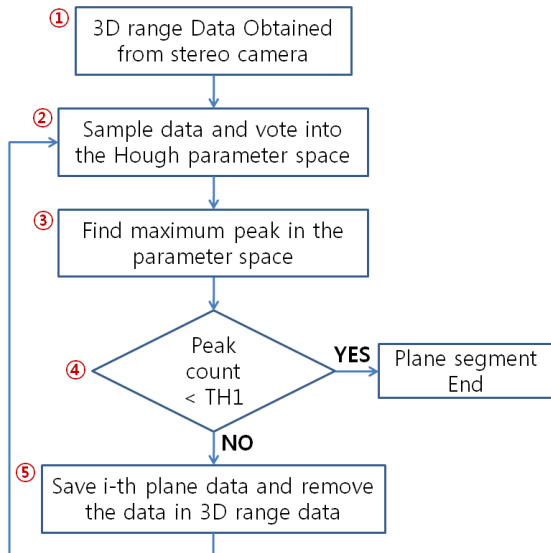


그림 3. 다중 평면 검출을 위한 반복적 임의 하프 변환.  
Fig. 3. IRHT for multiple plane detection.

선택한 3점의 노말 방향인  $\rho$ ,  $\theta$ ,  $\phi$  를 하프 파라미터 공간에 보팅한다. 단계 ③은 하프 파라미터 공간에서 가장 많이 보팅된 파라미터 값을 찾는다. 이 파라미터는 3차원 데이터에서 가장 큰 평면을 나타낸다. 단계 ④에서는 평면 검출을 계속 할 것인지 아니면 멈출 것인지를 결정한다. 만약 ③에서 찾아진 파라미터의 보팅값이 임계값 TH1보다 작을 경우 3차원 데이터에서 평면이 없다고 판단하고 검출 과정을 끝낸다. 마지막 단계인 ⑤에서는 검출된 평면에 해당하는 데이터를 저장하고 입력 데이터에서 삭제한다. 평면 데이터를 삭제하는 이유는 다음 반복에서 다른 평면을 검출하기 위해서이다. (6)은 어떤 3차원 데이터가 평면에 해당되는지를 평가한다. 만약 3차원 데이터가 평면상에 있다면 평면 방정식의 값은 0 이 된다. 하지만 데이터의 잡음을 고려하여 임계값 TH2 크기의 여유를 두고 평면 데이터를 찾는다.

$$|Ax + By + Cz + D| < TH2 \quad (6)$$

임계값 TH1은 검출할 평면의 개수에 영향을 준다. 왜냐하면 TH1의 값이 낮을수록 평면 검출의 반복이 많아지기 때문이다. TH1 값의 결정은 데이터 샘플링의 횟수, 평면일 때와 평면이 아닐 때의 보팅값을 실험을 통하여 결정한다. 임계값 TH2는 검출된 평면의 허용 오차이다. TH2 값 역시 센서의 성능과 외부 환경에 의한 잡음을 실험을 통하여 결정한다.

그림 4는 반복적 임의 하프 변환의 검출 과정을 실험을 통하여 나타낸다. 그림 4(a)는 입력된 3차원 데이터의 영상이며, (b)는 입력된 2차원 영상, (c-e)는 하프 파라미터 공간으로  $\rho$  를 빼고  $\theta$ ,  $\phi$  보팅 값을 그래프로 나타낸 그림이다. 실험은 3개의 평면이 있는 환경이다. 임의 하프 변환의 수행으로 (c)와 같이 하프 파라미터 공간에 그림 4의 서로 다른 세 평면에 해당하는 3개의 분포가 나타난다. 이 때 먼저 최대 피크 값 하나만을 찾고 3차원 데이터에서 찾아진 파라미터 값의 평면에 해당하는 데이터를 제거하고 임의 하프 변환을 다시 수행한다. (d)와 (e)는 두 번째, 세 번째 반복에서 하프 공간에

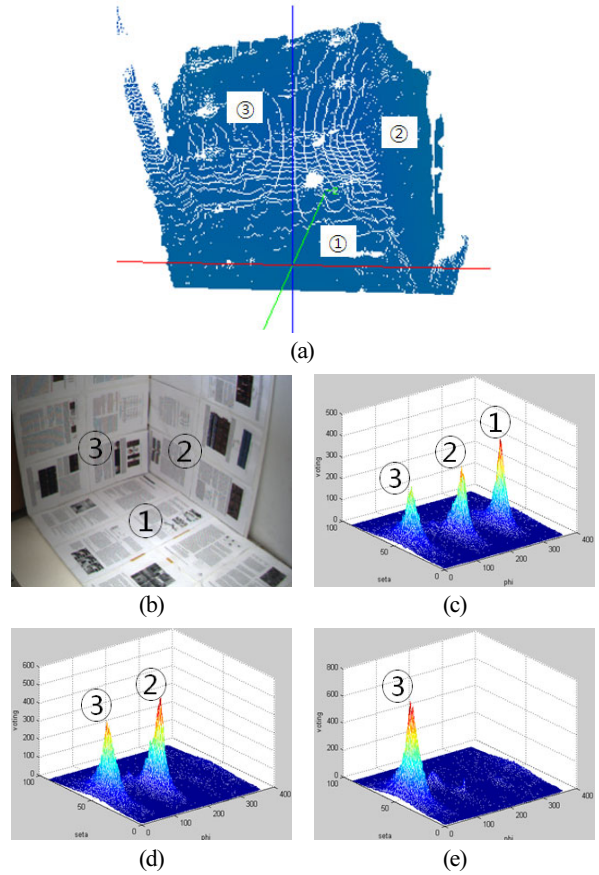


그림 4. 반복적 임의 하프 변환을 이용한 다중 평면 검출 과정.  
Fig. 4. Process of Multiple Plane Detection using IRHT.

보팅된 그래프이다. 그림 4의 실험에서는 세 번의 반복으로 모든 평면을 찾을 수 있다.

### III. 자기 조직화 지도를 이용한 평면 검출

#### 1. 자기 조직화 지도

자기 조직화 지도는 Kohonen에 의하여 제안된 신경망의 하나로서 부류 정보가 주어지지 않은 데이터를 군집화 하기 위한 신경망의 대표적인 방법 중 하나이다[9]. 또한 다른 군집화 알고리즘은 새로운 데이터가 들어오면 이것을 기존 데이터 집합에 합치고 군집화를 처음부터 다시 해야 하지만 자기 조직화 지도는 새로운 샘플이 들어오면 학습된 신경망으로 그 샘플만 군집 배정을 해주면 된다. 따라서 새로운 패턴이 계속 발생하는 온라인 상황에 사용 가능하다.

그림 5는 자기 조직화 지도의 아키텍처이다. 입력층은  $d$ 차원의 특징 벡터를 입력 받기 위해  $d$ 개의 노드를 갖는다. 경쟁층은  $m$ 개의 노드로 구성되며 이들 노드가 군집을 형성하기 위해 (7)과 같이 서로 경쟁한다. 여기서  $\mathbf{x}$  는 입력데이터이고  $\mathbf{w}_m$  은 모든 노드와의 연결을 나타낸다. 따라서  $\mathbf{x}$  와  $\mathbf{w}_m$  의 거리를 (7)과 같이 계산하고 그 중에서 가장 최소값을 승자 노드  $\mathbf{y}$  로 선택한다.

$$\text{winner } \mathbf{y} = \arg \min_m \|\mathbf{x} - \mathbf{w}_m\| \quad (7)$$

승자 노드  $\mathbf{y}$  의 웨이트는 (8)과 같이 업데이트 된다. (8)에




그림 5. 자기 조직화 지도 아키텍처.  
Fig. 5. Architecture of SOM (Self Organizing Map).

서  $t$  는 시간을 나타내는 값으로 모든 샘플을 학습에 한번씩 참여하는 세대(epoch)를 의미한다.  $w(t)$  와  $x(t)$  는 현재의 웨이트와 입력을 나타내며,  $w(t+1)$  은 업데이트 후의 웨이트를 의미한다.  $\lambda(t)$  는 학습률을 나타내며,  $\theta(t)$  는 업데이트할 이웃 노드의 반경을 나타낸다.

$$w(t+1) = w(t) + \theta(t) \cdot \lambda(t) \cdot (x(t) - w(t)) \quad (8)$$

(8)의 업데이트 식에 의해  $w(t)$  는  $x(t)$  에 가까워 지는데,  $\lambda(t)$  는 학습 비율을 의미한다. 극단적으로  $\lambda(t)$  를 1로 하면  $w(t+1)$  는  $x(t)$  가 된다.  $\theta(t)$  는 이웃 노드의 반경으로 승자노드와 같이 업데이트 된다.  $\lambda(t)$ ,  $\theta(t)$  는 [0,1] 사이의 값을 가지며, 안정적인 학습을 위하여 시간  $t$  가 커질수록 지수적으로 작은 값을 갖도록 한다. 최종적으로 군집을 형성한 노드와 그렇지 못한 노드가 생긴다. 따라서 최종 군집을 형성한 노드가 해가 된다.

본 논문에서는 자기 조직화 지도의 군집화 방법을 이용하여 기존 하프 변환 방법에서의 하프 파라미터 공간으로 값 변환 및 보팅, 다중 평면 검출을 위한 반복등에 대한 요구 없이 데이터 샘플링시 배치되는 군집화 방법으로 다중 평면을 검출한다.

2. 자기 조직화 지도를 이용한 다중 평면 영역 검출 방법

본 논문에서는 자기 조직화 지도를 다중 평면 검출 방법에 적용하기 위하여 경쟁층 노드의 생성과 병합 그리고 업데이트 횟수를 카운팅하는 방법을 새로이 적용하였다. 전체 알고리즘은 표 1과 같다.

표 1의 (a)는 알고리즘에 사용되는 입력 파라미터를 나타낸다.  $x_p$  는 랜덤하게 선택된 세 점의 평면 파라미터로 (1)의  $A, B, C, D$  를 나타낸다.  $v_x$  는 (9)으로 구해진 노말 방향을 나타낸다.

$$v = \begin{bmatrix} A & B & C \\ D & D & D \end{bmatrix}^T, \quad v_x = \frac{v}{\|v\|} \quad (9)$$

$N$  은 샘플링 횟수를 나타낸다.  $M$  은 경쟁층에서 군집화된 노드의 집합을 말한다. 즉,  $c_n$  은 각 군집의 대표값을 나

표 1. 자기 조직화 지도를 이용한 평면 검출 알고리즘.  
Table 1. Algorithm of Plane Detection using SOM.

<p><b>(a) Description of Parameters</b>  <math>x_p</math> : Plane parameters of sampled data  <math>v_x</math> : normal vector of <math>x_p</math>  <math>N</math> : number of sampling  <math>M = \{c_1, c_2, \dots, c_n\}</math> : class set in competitive layer  <math>l_A</math> : The lowest angle in <math>M</math>  <math>l_D</math> : The lowest distance in <math>M</math>  <math>Th_A</math> : The threshold of minimum angle  <math>Th_D</math> : The threshold of minimum distance</p> <p><b>(b) Initialize:</b> <math>M = \{\}</math>, set <math>N, Th_A, Th_D</math></p> <p><b>(c) For</b> <math>n=1</math> to <math>N</math>                  Sample a data randomly in inputted 3D data and Calculate <math>x_p</math>                  ① <b>If</b> <math>M</math> is empty                  Add node into <math>M</math> by <math>x_p</math>                  ② <b>Else</b>                  a Find minimum angle (<math>l_A</math>) node <math>c_i</math> in <math>M</math> through comparing with <math>v_x</math> and calculate the difference of normal distance <math>l_D</math> between <math>x_p</math> and <math>c_i</math>                  b <b>If</b> <math>l_A &lt; Th_A</math> and <math>l_D &lt; Th_D</math>                  Update node <math>c_i</math> closely to <math>x_p</math>                  Increase update counts of <math>c_i</math>                  c <b>Else</b>                  Add new node into <math>M</math> by <math>x_p</math>  <b>End</b>  <b>End</b>  <b>End</b></p> <p><b>(d) Output</b>                  Sort nodes in <math>M</math> by descending order of update counts                  Sorted <math>M</math> describes dominant plane parameter in order.</p>
---




그림 6.  $Th_A$ 와  $Th_D$ 의 기하학적 의미.  
Fig. 6. Geometrical representation of mean of  $Th_A$  and  $Th_D$ .

타낸다.  $l_A, l_D$  는 입력층과 경쟁층에서 가장 작은 각도와 거리의 값을 나타낸다. 즉,  $l_A$  는 입력  $x$  와  $c_n$  에서 가장 작은 각도를  $l_D$  는  $x$  와  $c_n$  에서 가장 가까운 거리를 나타낸다.

$Th_A, Th_D$  는 경쟁층 노드를 갱신하기 위한 최소 각도와 거리의 임계값을 나타낸다(그림 6).

$Th_A$  는 두 평면 사이의 각도를 의미한다. 두 평면이  $Th_A$  값 보다 작으면 하나의 평면으로 병합한다.  $Th_D$  는 두 평면의 노말 방향이 같을 때, 두 평면 사이의 수직 거리를 의미한다.  $Th_A$  와 같이 두 평면 사이의 거리가  $Th_D$  값 보다 작으면 하나의 평면으로 병합한다. 따라서  $Th_A$  와  $Th_D$  은 다중 평면 분류의 정밀도와 관계된 값으로, 두 값이 작으면  $M$  에 많은 군집이 생성되어 많은 평면을 검출된다. 하지만 한 평면을 여러 개로 분류 할 수 있으며, 두 값이 크면 검출된 평면의 개수는 작지만, 다른 평면을 같은 평면으로 분류 할 수 있다.  $Th_A, Th_D$  의 값은 다중 평면 검출의 환경에 맞게 실험에 의해 결정한다. (b)에서는 경쟁층의 노드를 초기화 하고  $N, Th_A, Th_D$  값을 설정한다. (c)에서 데이터를  $N$  번 샘플링 하면서 군집화를 위한 학습을 한다. 랜덤하게 선택된 데이터는 평면 파라미터  $\mathbf{x}_p$  를 준다.

①에서 만약  $M$  에 노드가 없다면 샘플링한 데이터의  $\mathbf{x}_p$  를 경쟁층의 새 노드로 추가하고 다음 반복을 한다. 반면  $M$  에 노드가 있다면 입력값으로 군집과정 ②를 수행 한다.

군집화 과정에서 ①은 입력된  $\mathbf{x}_p$  와 경쟁층에서 가장 가까운 노드를 찾는다. 유사도는 노말 방향의 각도로 결정한다. 각도는 (10)와 같이 내적을 이용해 구할 수 있다.

$$\alpha = \mathbf{n} \cdot \mathbf{n}' \quad (10)$$

입력된  $\mathbf{x}_p$  와 가장 작은 각도  $I_A$  의 경쟁층 노드  $\mathbf{c}_i$  를 찾고  $\mathbf{x}_p$  와  $\mathbf{c}_i$  의 거리  $I_D$  를 구한다. ②에서 구해진  $I_A$  와  $I_D$  가 임계값  $Th_A$  와  $Th_D$  보다 작은 경우  $\mathbf{c}_i$  를 갱신하며 아닌 경우는 ③에서  $\mathbf{x}_p$  를  $M$  에 새로운 노드로 추가한다. ②에서 경쟁층 노드 갱신은  $\mathbf{c}_i$  를  $\mathbf{x}_p$  에 가깝게 만드는 (11)을 이용한다. 여기서  $\lambda$  는 [0,1]사이의 값으로  $\mathbf{c}$  가  $\mathbf{x}$  에 가까워 지도록 조정하는 값이다. (11)에서는 (8)과 같이 세대를 나타내는 시간  $t$  가 없다. 왜냐하면 기존의 자기조직화 지도는 고정된 입력 데이터를 여러 번 반복 학습하여 군집화를 하였지만, 본 논문에서는 입력 데이터가 랜덤하게 선택되며 많은 샘플링 데이터로 군집화가 이루어 지기 때문이다. 또한 군집의 생성, 병합의 방법이 적용되어 이웃하는 노드의 업데이트 반영값은 없고 해당 노드만 업데이트 된다.

(11)은 그림 7과 같이 기하학 적으로 해석이 가능하다. 또한  $\mathbf{c}_i$  의 갱신 횟수를 증가 시킨다. ③에서는 입력값  $\mathbf{x}_p$  가 군집 배정이 되지 않았기 때문에  $M$  에 새로운 노드로 추가한다.

$$\mathbf{c}_{update} = \mathbf{c}_{old} + \lambda(\mathbf{x}_p - \mathbf{c}_{old}) \quad (11)$$

(d)에서는  $N$  번 샘플링하며 군집화된  $M$  집합에서 평면 파라미터의 노드를 선택한다. 노드를 업데이트 횟수의 내림 차순으로 정렬하고 많이 업데이트 된 노드 순서로 입력된 3D 데이터에서 지배적인 평면의 파라미터로 간주한다.

그림 8은 그림 4의 실험 환경을 자기 조직화 지도를 이용




그림 7. 자기 조직화 지도의 학습을 기하학적으로 해석. Fig. 7. Geometric representation for learning process of SOM.




그림 8. 자기 조직화 지도를 이용한 다중 평면 검출 과정. Fig. 8. Multiple plane detection using SOM.

하여 다중 평면을 검출한 과정이다. 한 점은 샘플링한 3점의 평면 파라미터를 의미하며 (9)의  $\mathbf{v}$  같이 A/D를 x축, B/D를 y축, C/D를 z축으로 표현한다. 회색 점은 샘플링된 값, 검은색 점은 군집화 결과로 각 군집의 대푯값  $\mathbf{c}_i$  를 나타낸다. (a)는 62번 샘플링, (b)는 264번 샘플링, (c)는 1064번 샘플링, (d)는 3154번 샘플링한 데이터의 군집화 결과이다. (a)에서는 5개의 군집이 만들어 졌지만 샘플 데이터가 많아지면서 군집의 중심이 갱신되고, 가까운 군집은 병합되어 (b)에서는 3개의 군집이 만들어 진다. 샘플링 횟수가 많아질수록 정확한 군집화가 이루어지고 반복적인 과정 없이 샘플링만으로 각 평면의 파라미터 값이 구해진다.

### 3. 분할 검색 방법

레이저 영상의 전체 영역에서 학습 데이터를 샘플링 하는 방법의 경우 작은 크기의 평면을 찾기가 어렵다. 왜냐하면 크기가 작은 평면은 샘플링 확률이 낮고 보팅값이 작기 때문에 큰 평면에 비해 검출 우선순위가 낮아지고 또한 잡음과 구별하기 힘들다. 따라서 본 논문에서는 그림 9와 같이 평면 검출 영역을 분할하여 검색한다.

각 검색 영역은 III-2 장의 표 1의 방법으로 평면을 검출한다. 각 영역에서 검출된 평면 파라미터들은 유사도를 평가하여 유사한 것은 하나의 파라미터로 합쳐진다. 유사도는 표 1



그림 9. 평면 검출을 위한 검색 영역 분할.  
Fig. 9. Division of detection area for plane detection.




그림 10. 부분 검색 영역에서 평면을 검출한 결과. (a)-(c) 녹색 검색 영역의 평면 검출 결과, (d) 모든 영역 검색 후 최종 평면 검출 결과.  
Fig. 10. Results of Plane Detection in Partial Search Area. (a)-(c) Results of Plane Detection in Green Box Area, (d) Final Result of Plane Detection in All Area.

의 ⑥와 같이 두 파라미터의 각도와 길이가  $Th_a$ ,  $Th_b$  보다 작을 때 같은 평면의 파라미터라고 간주한다. 두 파라미터를 합칠 때는 (11)의 경쟁층 노드의 업데이트 방법을 사용한다. 이때  $c_{old}$  는 합쳐질 두 파라미터 중, 업데이트 횟수가 많은 것으로 하고  $x_p$  는 업데이트 횟수가 작은 것으로 한다. 그림 10은 분할 검색 방법의 과정과 결과를 나타낸다. (a)-(c)는 녹색 검색 영역 부분에서 자기 조직화 지도를 이용하여 평면 파라미터를 검출하고 그 결과를 이미지에 나타낸 것이며, (d)는 모든 검색 영역에서 검출된 평면 파라미터를 통합하여 나타낸 최종 결과이다. 그림 10(a)에서는 검색 영역이 바닥면의 일부로 검출된 파라미터는 바닥의 평면을 나타낸다. (b, c)는 상자의 한 면에 해당되는 평면 파라미터를 검출하였다. (d)는 모든 검색 영역에서 검출된 평면 파라미터를 통합하여 다중평면검출 결과를 나타낸다.

4. 평면도 검사에 의한 필터링

입력된 3차원 데이터에는 센서의 성능, 외부 환경변화 등으로 많은 잡음이 포함되어 있다. 잡음의 영향을 피하고 정확한 값을 검출하기 위해서는 가능한 많은 데이터를 샘플링 하면 된다. 하지만 많은 샘플링은 검출의 성능은 높이지만 처리 속도를 증가시키는 문제점이 있다.




그림 11. 평면 검출 셀.  
Fig. 11. Plane detection cell.





그림 12. 평면도 검사를 위한 셀.  
Fig. 12. Cell for planarity evaluation.


최근 잡음의 영향을 줄이고 정확한 평면을 검출하기 위하여 평면 검출 셀(PDC) 방법이 제안되었다[10]. 그림 11은 평면 검출 셀을 나타낸다. 평면 검출 셀은 랜덤하게 선택된 세 개의 위치 데이터를  $180^\circ$  회전하여 회전된 세 점과 원래 세 점의 위치에 놓인 레인지 데이터로부터 노말 방향의 각도를 비교한다. 두 노말 방향의 각도가 임계값보다 크면 샘플링된 점의 영역은 평면이 아니거나 잡음의 영향이 있다고 판단하고 평면 검출을 위한 데이터로 이용하지 않는다. 이 방법은 샘플링된 데이터를 필터링하여 계산의 정확성과 속도를 향상 시켜준다.

본 논문에서는 평면 검출 셀 방법을 응용한다. 그림 12와 같이 한 점 ( $R$ ) 을 랜덤하게 선택하고 이 점을 기준으로 첫 번째 세 점 ( $P_1, P_2, P_3$ ) 과 두 번째 세 점 ( $P_1', P_2', P_3'$ ) 을 랜덤하게 선택한다. 단 기준 점으로부터 정해진 반경 내에서 랜덤하게 선택한다. 그리고 평면 검출 셀과 같이 두 평면의 노말 벡터의 방향을 비교하여 임계값 보다 각도가 작으면 학습에 참여 시킨다. 본 논문에서는 평면 검출 셀에서 사용한 회전을 사용하지 않는다. 왜냐하면 데이터 위치의 회전 계산은 검출 시간에 영향을 미치기 때문이다.


그림 13은 평면도 검사를 이용한 샘플링 방법의 잡음 제거 효과를 실험으로 나타낸다. (a)는 입력 환경으로 구겨진 종이를 흘려버려서 평면이 없는 조건을 만들었다. (b)는 기존 샘플링 방법으로 하프 파라미터 공간에 보팅한 결과이며, (c)는 평면도 검사를 이용한 샘플링 방법의 하프 파라미터 공간에 보팅 결과이다. (b)에서는 하프공간에 잡음이 많이 보팅되었고 가장 많이 보팅된  $\theta, \phi$  의 값의 피크는 158개로 평면으로 오인될 수 있다. 반면 (c)는 잡음이 많이 필터링 된 것을 볼 수 있으며, 최대 피크 값은 61개로 비교적 낮다. 따라서 평면도 검사는 기존 샘플링 방법보다 잡음의 영향을 덜 받을 수 있다.



(a)



(b)



(c)

그림 13. 평면도 검사를 이용한 데이터 필터링 결과.  
Fig. 13. Results of data filtering using planarity evaluation.

#### IV. 실험

##### 1. 실험 환경

제안된 내용은 Intel(R) Core™2 CPU 2.00 GHz 노트북 컴퓨터에서 실험하였고 범블비 스테레오 카메라[11]로 레인지 영상인 3차원 데이터를 획득하였다. 그리고 영상의 크기는 320x240 크기로 실험 하였다.

##### 2. 비교 결과

본 논문은 다중 평면 검출을 반복적 임의 하프 변환[8]과 제안 방법을 비교 실험 하였다.

임의 하프 변환은 각 반복에서 100,000개의 데이터를 임의로 샘플링 하였고, 그림 3의 TH1은 10으로 설정하였다.

제안 방법은 7x7로 영역을 분할하였고, 각 영역에서는 7,820개의 데이터를 샘플링하여 총 샘플링 횟수는  $7,820 \times 49 = 383,180$ 이다. 하지만 평면도 검사에 의해 보통 10~7%의 데이터만이 평면 검출에 사용된다. 평면도 검사를 위한 각도는 2도를 사용하였다. 또한 (6)의 TH2는 두 알고리즘 모두 0.04로 설정하였다.


그림 14-18는 두 알고리즘의 실험 결과로 (a)원본 영상, (b)는 제안 방법, (c)는 반복적 임의 하프 변환의 실험 결과를 나타낸다.

실험 결과 검출된 평면의 영역은 비슷하였지만, 임의 하프 변환은 잡음에 영향을 많이 받아 한 평면에서 여러 개의 다른 평면을 포함하고 있다.


표 2는 위 실험에 대한 두 알고리즘의 검출 시간을 비교하였다. 제안 방법이 임의 하프 변환 방법보다 10배 이상 빨랐으며, 초당 약 5-6장의 처리가 가능하여 실시간에서 평면 검출이 가능하다.



(a) Origin image.



(b) Proposed method.




(c) IRHT method.


그림 14. 울퉁불퉁한 바닥과 두 개의 벽면(실험 1).  
Fig. 14. Uneven flat and two walls (experimental 1).



(a) Origin Image.



(b) Proposed method.



(c) IRHT method.

그림 15. 나무 주위의 낙엽이 있는 완만한 평면과 배경에서의 좁은 바닥(실험 2).  
Fig. 15. Rolling on the floor around the tree with leaves and narrow floor in the background (experimental 2).




그림 16. 평면도가 높은 계단과 벽면(실험 3).  
Fig. 16. Stairs of good planarity and walls (experimental 3).

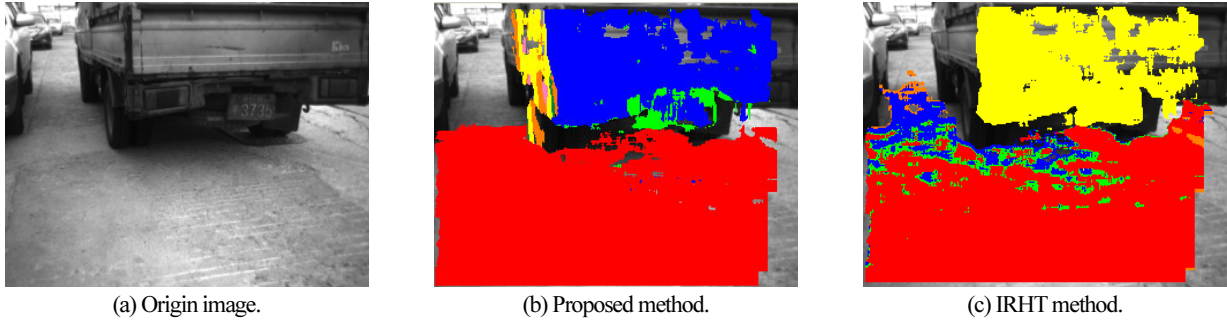


그림 17. 평평한 도로 상의 차량(실험 4).  
Fig. 17. Flat road and vehicles (experimental 4).




그림 18. 층이 있는 바닥과 벽면(실험 5).  
Fig. 18. Layer floor and walls (experimental 5).

표 2. 평면 검출 속도 비교.

Table 2. Computing time comparison of plane detection.

	제안 방법	입의 하프 변환
실험 1	0.187s	3.156s
실험 2	0.141s	1.781s
실험 3	0.172s	2.719s
실험 4	0.188s	2.203s
실험 5	0.188s	2.891s

표 3. 실험 5에 대한 알고리즘의 기능별 속도 측정.

Table 3. Speed measurement for each module of algorithm about experimental 5.

총 샘플링 수	383,180개
평면 검출에 사용한 샘플 수	17,962개
샘플링 시간	0.079s
평면도 평가 시간	0.077s
SOM 계산 시간	0.032s

표 3은 실험 5에 대한 기능별 속도 측정 값을 나타낸다. 우선 총 샘플링 수는 383,180개이며 이중 평면도 검사에 의해 17,962개의 샘플만 평면 검출에 사용되었다. 본 연구에서는 평면도 검사를 위해 6개의 좌표를 샘플링 하는데, 3차원 데이터를 샘플링한 전체 시간은 0.079초, 평면도 검사를 수행한 전체 시간은 0.077초, 검사된 데이터를 SOM에 학습하는데 걸린 전체 시간은 0.032초가 걸렸다.

### V. 결론

본 논문에서는 자기 조직화 지도의 군집화 방법을 이용하여 기존 반복 랜덤 하프 변환 방법보다 빠르고 정확하게 다중 평면을 검출 하였다.

제안된 방법은 군집화 방법의 일종으로 하프 파라미터 공간으로 보팅없이 데이터의 부류를 찾아 낸다. 제안된 방법의 속도는 평면의 개수에 상관없이 샘플링 개수에 영향을 받는 반면, 반복 랜덤하프 변환은 샘플링 개수와 검출 평면의 개



수에 영향을 받는다. 왜냐하면 평면이 많아지면 반복 횟수가 늘어나기 때문이다.

제안된 방법은 한 장의 3차원 레인지 데이터에서 평균 0.175초가 걸렸다. 따라서 초당 약 5.7장의 처리가 가능하여 실시간으로 평면 검출이 가능하다. 하지만 매 프레임마다 평면 검출을 다시 시작한다.

향후에는 한번 검출된 평면의 파라미터들을 소멸하지 않고, 실시간으로 샘플링된 데이터에 의하여 값을 갱신하거나 생성 또는 소멸하는 확률 기반의 방법론을 적용하여 계산 속도를 줄이고 보다 효율적인 실시간 다중 평면 알고리즘을 연구한다.

### 참고문헌

- [1] K. Okada, S. Kagami, J. Inaba, and H. Inoue, "Plane segment finder: algorithm, implementation and applications," *IEEE Int. Conf. on Robotics and Automation*, vol. 2, pp. 2120-2125, 2001.
- [2] D. Ben-Tzvi and M. B. Sandler, A combinatorial hough transform, *Pattern Recogn. Lett.* 11, 167-174, 1990.
- [3] L. Xu and E. Oja, "Randomized Hough Transform (RHT): basic mechanisms, algorithms, and computational complexities, *CVGIP: Image Understanding* 57, pp. 131-154, 1993.
- [4] L. Xu, E. Oja, and P. Kultanen, "A new curve detection method: Randomized Hough Transform (RHT)," *Pattern Recogn. Lett.* 11, pp. 331-338, 1990.
- [5] N. Kiryati, Y. Eldar, and A. M. Bruckstein, "Probabilistic hough transform," *Pattern Recogn. Lett.* 24, pp. 303-316, 1991.
- [6] V. F. Leavers, "The dynamic generalized hough transform: its relationship to the probabilistic hough transforms and an application to the concurrent detection of circles and ellipses," *CVGIP: Image Understanding* 56, pp. 381-398, 1992.
- [7] H. Kälviäinen, P. Hirvonen, L. Xu, and E. Oja, "Comparisons of probabilistic and non-probabilistic hough transforms," *In Proceedings 3rd European Conference on Computer Vision*, pp. 351-360, 1994.
- [8] W. Lu and J. Tan, "Detection of incomplete ellipse in images with strong noise by Iterative Randomized Hough Transform

(IRHT)," *Pattern Recognition* 41, pp. 1268-1279, 2008.

- [9] T. Kohonen, "The self-organizing map," *Proc. of the IEEE*, vol. 78, no. 3, pp. 226-239, Mar. 1998.
- [10] D. J. Kang, S. J. Lim, J. E. Ha, and M. H. Jeong, "A detection cell using multiple points of a rotating triangle to find local planar regions from stereo depth data," *Pattern Recogn. Lett.* 30, pp. 486-493, 2009.
- [11] PointGray company, <http://www.point-gray.com>.



**김정현**

2005년 창원대 컴퓨터공학과 졸업. 2005년~2007년 동명대 메카트로닉스공학과 석사. 2007년 부산대 지능기계공학과 박사과정. 관심분야 컴퓨터 비전, 지능형 로봇, 패턴인식.



**등족**

2006년 중국 중남대학교 정보과학공학과 졸업. 2008년 9월 현재 부산대 지능기계공학과 석박사통합과정. 관심분야 지능형 로봇, 패턴인식.



**강동중**

1988년 부산대 정밀기계공학과 졸업. 1990년 한국과학기술원 기계공학과 석사. 1999년 동대학원 자동화및설계공학과 공학박사. 2006년~현재 부산대학교 기계공학부 부교수. 관심분야는 머신비전, 이동로봇, 영상기반 검사시스템 개발.