ISSN 1598-0170 (Print)
ISSN 2287-1136 (Online)
http://www.jksii.or.kr

단일이미지에 기반한 내벽구조 검출 방법☆

Inside Wall Frame Detection Method Based on Single Image

정 도 욱[1] 정 성 기[1] 최 형 일[1*]
Do-Wook Jeong Sung-Gi Jung Hyung-Il Choi

요 약

본 논문에서는 한 장의 실내이미지에서 내벽구조 검출을 위한 개선된 소실점 검출방법과 세그먼트 레이블링 방법을 제안한다. AR 기술 수요의 증가로 이미지로부터 건축물의 구조를 인식하는 것과 관련된 연구가 많이 이루어 지고 있다. 그러나 폐색을 발생시키는 객체들이 많은 실내 이미지에서 실내 내부 구조를 인식하는 것은 여전히 어려운 문제이다. 소실점 검출 방법을 개선하기 위하여 육면체를 이루는 실내 내벽들 사이의 직교성을 이용하는 방법을 제안하였다. 또한 실내 이미지 내의 세그먼트들을 레이블링 하기 위하여 슈퍼픽셀 기반의 군집화 방법과 트리기반 학습기를 통한 레이블링 방법을 제안하였다. 마지막으로 실험 결과에서 제안한 방법들에 의하여 실내 구조 검출 결과가 개선됨을 보였다.

☞ 주제어 : 내벽구조 검출, 소실점 검출, 트리기반 학습기, 슈퍼픽셀 세그멘테이션

ABSTRACT

In this paper, we are proposing improved vanishing points detection and segments labeling methods for inside wall frame detection from indoor image of a piece of having a colour RGB. A lot of research related to recognizing the frame of artificial structures from the image is being performed due to increase in demand for AR technology. But detect the inside wall frame in indoor images have many objects that caused the occlusion is still a difficult issue. Inner wall frame detection methods are usually segment labeling methods and detect vanishing point methods are used together. In order to improve the vanishing point detection method we proposed using inner wall orthogonality which forms the cube. Also we proposed labeling method using tree based learning and superpixel based segmentation method for labelingthe segments in indoor images. Finally, in experiments have shown improved results about inside wall frame detection according to our methods.

☞ keyword : inside wall frame detection, vanishing points detection, tree based learning, superpixel segmentation

1. 서 론

실내공간이라는 한정된 지역에 대하여 그구조를 인식하는 것과 관련된 연구는 건축, 모델링, 로봇공학등의 분야에서 연구되어 왔다. 그리고 최근에는 AR(artificial reality) 기술의 발전과 보급으로 인하여 이와 접목된 기술로서 연구되어지고 있다. AR 기술에서 실내 공간 구조에 대한 인식에 관련된 기술을 필요로 하는 이유는 렌더링 될 객체들을 실내 공간에 적합하게 렌더링하기 위한 것으로 인식의 정확도와 짧은 수행시간을 필요로 한다.

실내공간인식에 관련된 기술은 실내 공간에서 얻어진 센서데이터로부터 실내 공간에 놓여진 사물들과 벽면의 형태 및 텍스쳐를 인식하는 기술로 천장, 바닥, 벽면, 가구들을 구분할 수 있어야 한다. 이를 위하여 기존의 방법들은 RGB 이미지뿐만 아니라 깊이기반 (depth-based)영상을 사용하며, 이를 통하여 높은 정확도의 공간 인식 성능을 얻는다[1].

이를 위해서는 깊이기반 카메라 또는 라이다(light detection and ranging, LiDAR) 등의 센서를 필요로 하나 스마트폰 어플리케이션 등의 비전문가용 시스템에서는 이를 이용하기 어렵다. 이와 같은 문제를 해결하기 위하여 단일이미지로부터 실내 공간을 인식하는 기술에 대한 연구가 행해지고 있다. 그 중, 소실점(vanishing point)를 사용하여 실내 구조를 파악하려 한 연구들이 있다.

Hoiem은 표면정보를 이용하여 벽면을 분류하는 방법을 제안하였다[2]. Hedau는 Hoiem의 방법을 개선하기 위하여 실내 구조가 3차원 Box형태를 띄고 있다는 가정하

1 School of Media, Soongsil Univ, Seoul, 156-881, Korea
*Corresponding author (chi@ssu.ac.kr)
[Received 31 August 2016, Reviewed 9September 2016(R2 21 November 2016), Accepted 26 December 2016]
☆ 본 논문은 중소기업청에서 지원하는 2015년도 산학연협력 기술개발사업(기업부설연구소 신규설치)(No. C0342479)의 연구수행으로 인한 결과물임을 밝힙니다

https://doi.org/10.7472/jksii.2017.18.1.43

에 공간 구조 추정하는 방법을 제시하였다.

실내 객체의 존재에 매우 민감한 문제를 개선하기 위하여 표면정보를 이용하는 방법을 제시하였다[3].

Lee는 orientation map 특징을 이용하여 기하학적 구조를 검출하는 방법을 제시하였다[4].

Gupta는 표면정보를 이용한 특징과 Orientation map 특징을 이용하여 공간 구조를 검출하고 실내 객체를 고려해 기하학적 구조를 보정하는 방법을 제시하였다[5].

Pero는 객체의 위치, 크기, 방향 정보를 베이지안 추론을 통하여 실내 기하학적 구조를 3차원으로 추론하는 방법을 제시하였으나, 매우 복잡한 모델에 비하여 충분한 효과가 나타나지는 않았다[6].

위 연구들은 실내 모서리의 영역이 폐색(occlusion) 되었을 때 실내 구조를 인식하기 어렵다는 문제를 해결하기 위한 시도이다.

본 연구에서는 이 문제를 다루기 위하여 소실점 (vanishing point) 인식과, 슈퍼픽셀 (superpixel)로 군집화된 이미지를 트리기반 학습기로 학습하는 방법을 적용 한다.

소실점 인식 방법은 이미지가 촬영된 실내 공간이 삼차원 공간상에서 육면체의 구조를 가짐으로써 세 개의 직교하는 법선 벡터를 가지고 있다는 가정을 바탕으로, 실내 공간의 구조적 정보를 얻는 단서를 얻는데 사용되어진다.

이미지 상에서의 3개의 소실점은 2차원 이미지 안에 놓이는 실내 구조의 회전 정보로서 이를 바탕으로 그림 1과 같이 실내 이미지에서 각 벽면이 위치하게 될 후보를 파악하는데 기여한다.

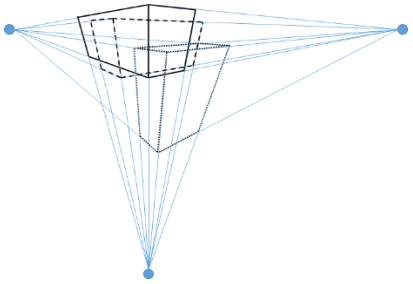

(그림 1) 소실점으로부터 예측 가능한 실내 구조
(Figure 1) Available indoor structure prediction from vanishing points

슈퍼픽셀로 이미지를 군집화 하는 것은 각 세그먼트별로 천장, 바닥, 벽으로 레이블링 하기 위한 것으로 이미지 내에서 내벽구조의 위치를 파악함으로써 벽면의 위치를 결정한다.

본 논문의 구성은 다음과 같다. 2.1 장에서는 소실점을 이미지 상의 에지로부터 구해진 선분들로 교점을 검출하고 검출된 교점들로부터 세 개의 소실점을 구하는 방법에 대하여 설명한다. 2.2 장에서는 두 개의 소실점만 검출됐을 때에 나머지 소실점을 구하는 방법에 대하여 설명한다. 3.1 장에서는 실내 이미지에 대하여 세그먼트를 구하는 방법에 대하여 설명하고 3.2 장에서 각 세그먼트에 대하여 학습하는 방법에 대하여 설명한다. 4장에서는 소실점을 통하여 실내 구조의 후보를 만들고 각 후보 중 레이블링 된 세그먼트를 통하여 평가하는 방법에 대하여 설명한다. 마지막으로 5장에서 실험과정과 그 결과에 대하여 설명하고 6장에서 결론과 향후 연구에 대하여 설명한다.

2. 강인한 소실점 검출 방법

2.1 소실점 검출

본 연구에서는 소실점을 검출하기 위하여 실내 이미지로부터 선분을 검출하고, 라인으로부터 라인간의 교점을 구하여 각각의 교점들 중 소실점에 해당하는 교점을 찾는다.

소실점을 검출하기 위한 선분을 검출하기 위하여 우선 에지를 검출한다. 에지 검출에는 RGB 이미지를 gray 이미지로 변환시킨 후 캐니 에지(canny edge) 를 적용하여 검출하였다[7].

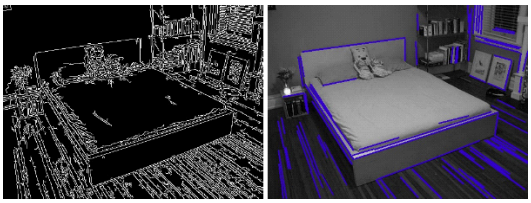

(그림 2) 캐니 에지 검출 (좌), 선분 검출 (우)
(Figure 2) Canny edge detection (left), line detection (right)

구해진 캐니에지로부터 연속된 픽셀 성분들을 레이블링하고 레이블링 된 픽셀들에 대하여 공분산을 구하는 방법으로 선분을 검출하였다[8].

검출된 선분의 양 끝점 L_i, L_j에 대하여 이미지의 수직 성분 상으로 거리 z가 1만큼 떨어져 있다고 가정한 벡터

의 외적 $\overline{L'}$을 구한다. 이때 모든 선분에서 구해진 외적들에 대하여 다시 각 선분의 외적 $\overline{L'_m} \times \overline{L'_n}$끼리 외적을 수행한 결과 $\overline{C}$에 대하여 $z = 1$로 정규화하여, 이미지 상에서 모든 쌍의 선분이 그리는 교점 $C' = (x', y')$을 구한다.

$$\overline{L'} = \left(L_i + \begin{bmatrix} 0 \\ 0 \\ z \end{bmatrix}\right) \times \left(L_j + \begin{bmatrix} 0 \\ 0 \\ z \end{bmatrix}\right) \quad (z = 1,\ i \neq j) \tag{1}$$

$$\vec{C} = (\overline{L'_m} \times \overline{L'_n}) \quad (m \neq n) \tag{2}$$

$$\overline{C'} = (x', y', z')/z' \tag{3}$$

위와 같이 구해진 교점 C'들에 대하여 모든 교점의 세 쌍이 이루는 삼각형의 한 각이 둔각을 이루는 교점 C'을 소실점의 후보로 판단한다. 구해진 소실점 후보에 대하여 검출된 선분들과의 관계식(4)를 통하여 각 소실점 후보의 점수를 계산한다. 이때 소실점의 후보를 계산하여 가장 큰 값을 가지는 후보를 소실점으로 지정한다.

각 선분 l의 소실점 후보 C'에 대한 점수 p를 계산하기 위하여 선분의 중심점과 소실점 후보 C' 사이의 거리 d와, 선분의 중심과 소실점 후보 C'을 잇는 직선과 선분 l의 사잇각 θ에 의하여 아래와 같이 정의하였다.

$$p = |l| * exp - \left(\frac{\theta}{0.02}\right) \quad (d > l) \tag{4}$$

하나의 소실점 v 가 구해지면 소실점에 대하여 일정한 임계값(threshold) t 이상을 투표한 선분 l을 소실점 v에 속한 선분으로 결정한다. 이 선분을 소실점 v에 대한 멤버라인(member line)이라고 결정하고 다음 점수 계산에서 제외한다. 구해진 소실점과의 소실점 후보 두 쌍이 그리는 삼각형이 둔각을 이루는 소실점 후보에 대하여 선분에 대한 점수 계산을 세 개의 소실점이 구해질 때까지 반복한다. 이때 이미지의 중심에 가까운 소실점을 v_m, 수직으로 멀리 떨어져 있는 소실점을 v_v, 수평으로 멀리 떨어져 있는 소실점을 v_h로 정의한다.

2.2 불안전한 소실점 보완 방법

소실점을 검출하기 위하여 에지로부터 선분을 검출할 때 실내에서 얻어진 이미지에 따라서 (그림 4)와 같이 선분이 충분하게 검출되지 않을 수 있다. 이와 같은 경우에는 검출된 두 개의 소실점으로부터 나머지 소실점을 검출한다.

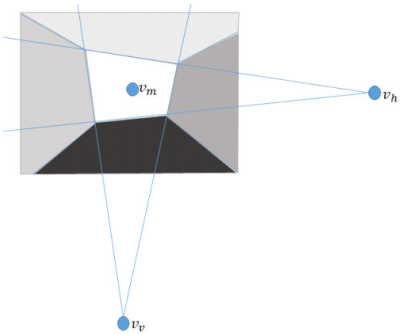

(그림 3) 세 소실점에 대한 정의
(Figure 3) Definition of three vanishing points

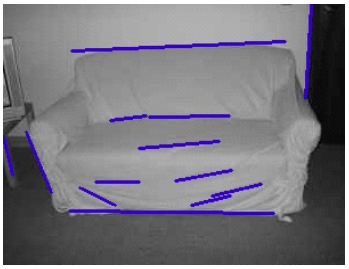

(그림 4) 소실점 검출을 위한 선분의 부족
(Figure 4) Lack of lines for vanishing points detection

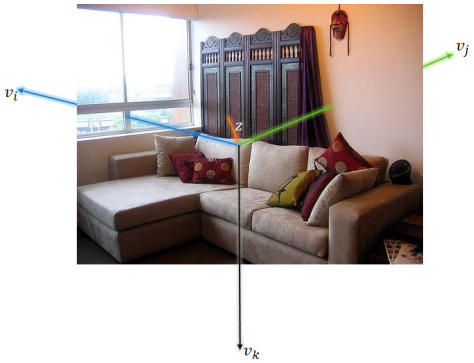

(그림 5) 2D 이미지와 3차원 좌표 z의 관계
(Figure 5) Coordination with 2D image and 3D coordinate z

이미지가 촬영된 실내 공간을 육면체로 가정 하였을 때, 3차원에서 실내 공간의 각 벽이 이루는 법선 벡터는 서로 직교한다. 따라서 두 개의 소실점이 3차원 공간에서 지각을 이루는 이미지 평면과의 거리 z를 알면 이미지 상에서 알고자 하는 소실점의 위치를 추정 가능하다.

검출된 두 개의 소실점을 v_i, v_j라고 하였을 때 영상평면으로부터 수직거리 z 에 의하여 다음과 같이 정의된다.

$$f(z) = \left(v_i + \begin{bmatrix}0\\0\\z\end{bmatrix}\right) \cdot \left(v_j + \begin{bmatrix}0\\0\\z\end{bmatrix}\right) = 0 \quad (5)$$

두 개의 소실점 v_i, v_j에 대하여 직교를 이루게 하는 거리 z를 (5)에서 구하게 되면, 세번째 소실점 v_k는 아래 식과 같이 구해진다.

$$\overrightarrow{v_k'} = \left(v_i + \begin{bmatrix}0\\0\\z\end{bmatrix}\right) \times \left(v_j + \begin{bmatrix}0\\0\\z\end{bmatrix}\right) \quad (6)$$

$$v_k' = (x', y', z') \quad (7)$$

$$\overrightarrow{v_k} = v_k' * z/z' \quad (8)$$

3. 세그먼테이션과 레이블링

3.1 슈퍼픽셀 기반의 세그멘테이션

실내 이미지에서 실내 각 벽을 구성하는 바닥, 천장, 벽면을 구분하는데 있어서 각 면의 최소 원소를 분할하기 위한 방법으로 슈퍼픽셀 (superpixel) 기반의 세그멘테이션 방법을 사용하였다[9].

슈퍼픽셀은 각 방법에 따라서 기울기 기반 방법[9,10]과 그래프 기반 방법[11]으로 나눌 수 있으며 본 논문에서는 그래프 기반 방법을 사용하였다. 이 방법은 각 화소를 노드로 하고 화소 간의 관계를 그래프의 에지값으로 하여 그래프를 구성하고 그래프의 모든 노드에 대한 가중치로부터 그래프를 반복적으로 두 개의 부 그래프로 나누는 방법이며 최종적으로 (그림 6)과 같은 형태의 세그먼트로 나누어진다.

(그림 6) 입력영상 (좌), 세그멘테이션 결과 (우)
(Figure 6) Input image (left), result of segmentation (right)

3.2 트리 기반 학습기

본 논문에서 기하학적 영역을 분류하기 위해 재귀적 아다부스트 (Adaboost)와 실수형 아다-부스트를 적용한 부스티드 결정트리(boosted decision tree)를 사용하였다.

전통적인 아다부스트 방법을 개선한 재귀적 아다부스트는 기존의 방법과 갱신 규칙(updata rule)에서 약간의 차이가 있다.

기존의 아다부스트는 학습 단계 이전의 분류기의 결과만을 고려하지만 재귀적 아다부스트는 이전 학습한 모든 분류기의 결과를 고려하여 가중치 w를 보정한다.

$$w_{t+1} = \frac{1}{1+exp\left(y_i \sum_{t'=1}^{t} f_{t',k_{t'}}\right)}, \quad k_t' : D_i \in T_{t',k_{t'}} \quad (9)$$

긍정데이터(positive data) 인 경우 미리 학습된 트리에 대한 인식결과 총 합이 클수록 적은 가중치를 가지며 부정데이터(negative data)의 경우 인식 결과의 총 합이 클수록 높은 가중치를 가진다.

박스 레이아웃(box layout)을 평가하기 위한 레이블링 결과를 만들어 내는데 있어서 각 레이블의 경계는 실제 벽면의 경계와 같이 직선으로 나타나지 않으므로 불연속 아다부스트의 경우 경계의 모호함이 박스 레이아웃을 평가하는데 악영향을 미칠 수 있다. 이를 보완하기 위해 본 논문에서는 실수형 아다부스트에 데이터의 가중치를 적용한 로그 비율함수 (weighted log-ratio) 함수를 사용하였다.

$$f_{t,k} = \frac{1}{2}\log\left(\frac{\sum_{i:y_i=1, D_i \in T_{t,k}} w_{t,i}}{\sum_{i:y_i=-1, D_i \in T_{t,k}} w_{t,i}}\right) \quad (10)$$

(10) 에서 함수의 분모는 t번째 트리의 k번째 말단노드에서의 부정데이터의 가중치 합이며 분자는 긍정데이터의 가중치 합이다. 가중치를 적용한 로그비율 함수는 긍정데이터와 부정데이터의 가중치 합의 비율에 의해 출력값이 결정된다. 이산 아다부스트의 경우 약한 분류기의 신뢰도를 따로 계산해야 하지만 실수형 아다부스트의 경우 약한 분류기의 신뢰도가 확률로서 결과에 포함되어 있다는 점이 가장 큰 차이점이다.

부스티드 결정트리의 경우 하나의 트리에서 과적응이 발생 하였을 경우 결과값의 왜곡이 발생 할 수 있다. 이를 방지하기 위해 다섯 개의 제한 조건을 설정한다.

(1) 트리의 깊이는 4이하이다.
(2) 노드 분할 시 모든 데이터가 한 개의 자식 노드에

할당 될 경우 현재의 노드가 리프 노드이다.

(3) 결정 경계보다 큰 데이터는 왼쪽 노드, 작은 경우 오른쪽 노드에 할당한다.

(4) 상위 노드에서 사용한 특징은 하위 노드에서 사용을 제한한다.

(5) 모든 특징이 사용되었을 경우 노드 분할을 종료한다.

상위 노드에서 하위 노드로 분할 할 때, 하위 노드들은 상위 노드보다 데이터가 편중되어야 한다. 이를 엔트로피의 관점에서 보면 상위노드의 엔트로피는 적고 하위 노드의 엔트로피는 높은 결과가 노드 분할 조건으로 바람직하다. 본 논문에서는 information gain 함수를 이용하여 노드 분할 여부를 결정한다.

$$H(Y) = -\sum_{i=1}^{k} P(Y = y_i)\, log_2\big(P(Y = y_i)\big) \tag{11}$$

$$H(Y|X) = -\sum_{j=1}^{v} P(X = x_j) \sum_{i=1}^{k} P(Y = y_i|X = x_j) * log_2\Big(P(Y = y_i|X = x_j)\Big) \tag{12}$$

$$IG(X) = H(Y) - H(Y|X) \tag{13}$$

학습된 트리의 출력 결과는 입력된 데이터가 도달하는 말단 노드에 할당된 weighted log-ratio이며 모든 트리의 출력값을 합산한 뒤 시그모이드 함수로 정규화 하여 분류기의 결과값으로 가진다.

$$H(x) = sigmoid\big(\textstyle\sum_{t'=1}^{t} T_{t'}(x)\big) \tag{14}$$

4. 내벽구조 평가 방법

3장에서 설계된 인식기를 학습하는데 사용된 세그먼트 특징정보는 (표 1)과 같다. 이를 통하여 인식된 레이블링된 세그먼트 이미지는 2장에서 구해진 소실점들을 통하여 생성할 수 있는 내벽구조의 후보군을 평가하는데 사용된다.

2장에서 구해진 소실점에 의한 실내 내벽구조의 후보는 (그림 7) (좌)의 이미지와 같이 입력 이미지와 같은 사이즈의 구조로 만들어진다.

(표 1) 각 세그먼트를 레이블링 하는데 사용된 특징 목록
(Table 1) List of features using for segment labeling

Red Value Average
Green Value Average
Blue Value Average
Hue Value Average
Satuation Value Average
Hue Histogram (6bin)
Satuation Histogram (4bin)
Edge Pixel Count
Edge Pixel Gradiant Average
X-position Average
Y-Position Average
Vertical Line Memvership Pixel Count
Horizontal Line Memvership Pixel Count
Middle Line Memvership Pixel Count
Segment Area Persentage / Image size
Relative Y Position to Horizontal Vanishing Point
Relative Y Position to Middle Vanishing Point
Relative X Position to Vertical Vanishing Point

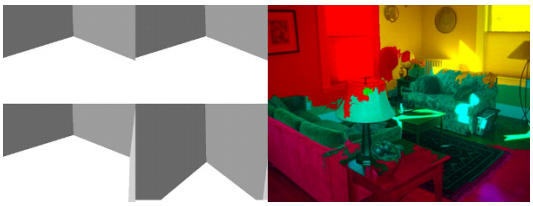

(그림 7) 내벽구조 후보군 (좌), 레이블링 결과 (우)
(Figure 7) Inside wall candidates (left), result of labeling (right)

이와 같이 생성된 내벽구조의 후보로부터 내벽의 정확한 위치를 찾아내기 위하여 내벽구조 후보군들의 이미지와 레이블링 된 세그먼트 이미지의 동일 좌표에 대하여 같은 레이블일 때 높은 점수를 부가하여 높은 점수가 할당된 후보를 검출한다.

5. 실 험

제안된 방법에 따라 실험한 결과를 측정하기 위하여 정확도에 영향을 미치는 세그먼트 레이블링 결과를 학습에 사용된 참값과 비교하여 픽셀 간의 레이블링 오차를 측정하였다.

(표 2) 레이블링 정확도 결과
(Table 2) Accuracy of labeling result

분류기준	성능
Ceil, Wall, Floor 분류정확도	74.50% (σ=0.009458)
Left, Middle, Right Wall의 분류 정확도	74.06% (σ=0.021876)

학습과 실험에 사용된 데이터는 Hoiem 이 실험에 사용한 308장의 실내 이미지와 8장의 복도에서 촬영된 이미지를 추가하여 구성하였다.

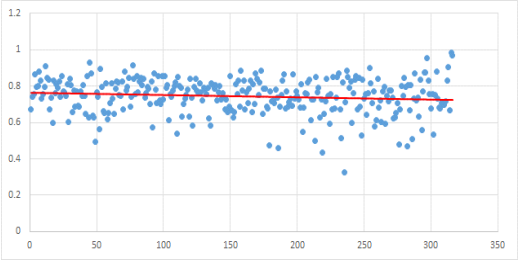

(그림 8) 천장, 벽, 바닥 분류 정확도 74.50% (σ= 0.009458)
(Figure 8) Ceil, Wall, Floor labeling accuracy 74.50% (σ=0.009458)

왼쪽, 가운데, 오른쪽 벽 의 레이블은 사전에 레이블된 벽에 대하여 다시 레이블링한 것으로 천장, 벽, 바닥의 레이블링 결과에 비하여 높은 분산을 보였는데 이는 Hoiem 의 실험 결과에 비해 약 12.56% 개선된 것으로 2.2장의 소실점 보완 방법으로부터 영향을 받았다[2].

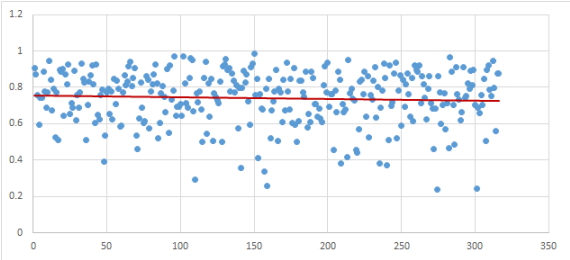

(그림 9) 왼쪽, 가운데, 오른쪽 벽 분류 정확도 74.06% (σ=0.021876)
(Figure 9) Left, Middle, Right labeling accuracy 74.06% (σ=0.021876)

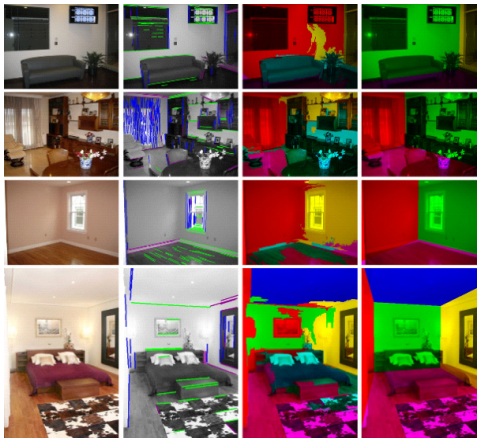

(그림 10) 내벽구조 검출 이미지 (성공)
(Figure 10) Inside wall frame detected images (success)

(그림 11) 내벽구조 검출 이미지 (실패)
(Figure 11) Inside wall frame detected images (failed)

내벽구조 검출에 성공한 이미지 (그림 10)에 비하여 (그림 11)의 내벽구조검출에 실패한 이미지에 대하여 분석해본 결과 잡음에 해당하는 선분의 검출이 시스템 초기의 소실점 인식에 에러를 발생시킨 경우가 316장의 이미지중 6건이 발생하였으며, 학습기의 성능과 학습시킨 특징들의 부족으로 인하여 세그먼트의 레이블이 잘못된 경우가 대부분을 차지하였다.

6. 결 론

실내에서 촬영된 한 장의 RGB 영상으로부터 실내 공간을 인식하는 연구와 관련하여 내벽구조를 인식하기 위한 연구를 수행하였고 본 논문을 통하여 관련된 연구와 그 결과를 보였다.

현재 연구되고 있는 방법들은 대부분 소실점 인식을 기반으로 두고 있으며, 더 개선된 방법에 대한 연구가 진행되더라도 초기에 소실점에서 검출에서 실패하면 내벽구조 인식 결과가 나올 수 없다는 점에서 출발하여 강인한 소실점 검출 방법을 제안하였다.

추후 이미지 표면에 대한 세그멘테이션 결과를 개선하는 방향으로 추가 연구를 진행하면 내벽구조 인식의 전체적인 성능을 개선할 수 있을 것으로 예상한다.

참 고 문 헌(Reference)

[1] Chen, Y., Pan, D., Pan, Y., Liu, S., Gu, A., & Wang, M., "Indoor scene understanding via monocular RGB-D images." Information Sciences, 320, pp. 361-371 , Nov. 2015.

[2] D. Hoiem, A. A. Efros, M. Hebert. "Recovering surface layout from an image." International Journal of Computer Vision, 75.1: 151-172, 2007.

[3] Hedau, Varsha, Derek Hoiem, David Forsyth. "Recovering the spatial layout of cluttered rooms." 2009 IEEE 12th international conference on computer vision. IEEE 2009, pp. 1849-1856, 2009.

[4] D. C. Lee, M. Hebert, T. Kanade. "Geometric reasoning for single image structure recovery." Computer Vision and Pattern Recognition, IEEE Conference on. IEEE, 2009. pp. 2136-2143, 2009.

[5] A. Gupta, M. Hebert, T. Kanade, D. M. Blei. "Estimating spatial layout of rooms using volumetric reasoning about objects and surfaces." In NIPS, pp. 1288-1296, 2010.

[6] L. Del Pero, J. Bowdish, D. Fried, B. Kermgard, E. Hartley, K. Barnard. "Bayesian geometric modeling of indoor scenes." In CVPR, 2012, pp. 2719-2726, 2012.

[7] Canny, John. "A computational approach to edge detection." IEEE Transactions on pattern analysis and machine intelligence, 6, pp. 679-698, 1986.

[8] Košecká, Jana, Wei Zhang. "Video compass." European conference on computer vision. Springer Berlin Heidelberg, 2002.

[9] Felzenszwalb, Pedro F., and Daniel P. Huttenlocher. "Efficient graph-based image segmentation." International Journal of Computer Vision 59.2: 167-181, 2004.

[10] Shi, Jianbo, and Jitendra Malik. "Normalized cuts and image segmentation." IEEE Transactions on pattern analysis and machine intelligence 22.8: 888-905, 2000.

[11] Achanta, Radhakrishna, et al. Slic superpixels. No. EPFL-REPORT-149300. 2010.

[12] Y. Zhao and S.-C. Zhu. "Scene parsing by integrating function, geometry and appearance models." In CVPR. IEEE, 2013, pp. 3119-3126, 2013.

[13] A. G. Schwing, R. Urtasun. "Efficient exact inference for 3d indoor scene understanding." In ECCV, pp. 299-313, 2012.

◐ 저 자 소 개 ◑

정 도 욱 (Do-Wook Jeong)
2014년 한국산업기술대학교 컴퓨터공학과 공학사
2017년 숭실대학교 미디어학과 공학석사
관심분야 : 컴퓨터 비전, 머신 러닝

정 성 기 (Sung-Gi Jung)
2015년 한국산업기술대학교 컴퓨터공학과 공학사
2016년~현재 숭실대학교 미디어학과 석사과정
관심분야 : 컴퓨터 비전, 머신 러닝

최 형 일 (Hyung-Il Choi)
1979년 연세대학교 전자공학과 공학사
1983년 미시간대학 전기전산학과 공학석사
1987년 미시간대학 전기전산학과 공학박사
1987년~1999년 숭실대학교 컴퓨터학부 교수
2000년~현재 숭실대학교 미디어학부 교수
관심분야 : 컴퓨터 비전, 패턴인식, 증강현실 등