

# Ensemble of Fuzzy Decision Tree for Efficient Indoor Space Recognition

Kisang Kim\*, Hyung-II Choi\*\*

## Abstract

In this paper, we expand the process of classification to an ensemble of fuzzy decision tree. For indoor space recognition, many research use Boosted Tree, consists of Adaboost and decision tree. The Boosted Tree extracts an optimal decision tree in stages. On each stage, Boosted Tree extracts the good decision tree by minimizing the weighted error of classification. This decision tree performs a hard decision. In most case, hard decision offer some error when they classify nearby a dividing point. Therefore, We suggest an ensemble of fuzzy decision tree, which offer some flexibility to the Boosted Tree algorithm as well as a high performance. In experimental results, we evaluate that the accuracy of suggested methods improved about 13% than the traditional one.

▶ Keyword : Indoor space recognition, Fuzzy Decision Tree, Boosted Tree, Adaboost, Super-pixel

## 1. Introduction

최근 사람의 안정성과 편의성을 제공해주는 4차 산업에서 가장 중요한 분야인 인공지능에 대해 국내외에서 많은 연구가 진행되고 있다.[1] 특히, 인공지능의 대표라고 할 수 있는 컴퓨터 비전, HCI(Human-Computer Interaction), 데이터 마이닝 등 가상현실과 증강현실과 연관된 분야에 많은 투자가 이루어지고 있다. 이러한 분야들의 연구들을 융합하여 최근에는 실내 내비게이션[2], 가상 홈 인터리어[3], 환경 정보 인식[4] 등 다양한 분야에서 해당 기술들을 요구하고 있는 실정이다. 하지만, 현재 까지 이러한 기술을 개발하는데 있어, 객체 인식, 실내 공간 인

식 등 다방면의 기술 연구가 상용화 수준으로 올라오지 못한 실정이다. 따라서 해당 기술에 필요한 기초가 되는 연구들인 배경 인식, 객체 인식, 추적 등 다양한 연구가 진행되고 있다.

특히 실내 공간인식에 대해서는 다양한 회사에서 연구가 진행되고 있다. 하지만 현재 진행되고 있는 기술 연구로는 Structure의 3D 스캐너, 구글 탱크 등 깊이 영상 기반으로 제작되어 모바일에 장착된 비전 센서와 연동하기에는 어려움이 있다. 이러한 한계를 극복하기 위해 다양한 연구에 대한 시도가 있었다. [5]에서는 소실점 정보와 기하학적 추론을 통해 공간 정

• First Author: Kisang Kim, Corresponding Author: Hyung-II Choi

\*Kisang Kim (kimkisang@ssu.ac.kr), School of Media, Soongsil University

\*\*Hyung-II Choi (hic@ssu.ac.kr), School of Media, Soongsil University

• Received: 2017. 02. 08, Revised: 2017. 03. 02, Accepted: 2017. 04. 10.

• This work (Grants No. C0342479) was supported by Business for Academic-industrial Cooperative establishments funded Korea Small and Medium Business Administration in 2015.

보 후보군을 생성하고 지향성 지도를 사용하여 후보군에 대해 공간 정보를 평가한다. 이 방법은 통로로 인해 벽이 잘려있거나, 경계가 잘못 정렬된 경우 한계를 보이는 문제가 있다. [6] 지향성 지도를 통하여 공간 정보와 클러스터에 대해 분류하며, 표면 레이어아웃을 통해 공간 정보를 구분하는 방법을 사용하였다. 하지만, 이 방법은 클러스터의 상태에 따라 측정이 잘못되어 오류가 나는 경우도 있으며, 소실점 검출 오류로 인해 공간 정보를 잘못 잡는 문제도 존재한다. [7]는 벽과 벽이 만나는 코너점들에 대해 의미하는 바를 부여하고 이를 이용하여 코너들로 이루어지는 면이 벽인지 바닥인지 클러스터인지 구분하였다.

이러한 한계점으로 인해 본 논문은 위의 방법들과 융합 할 수 있는 실내 공간 정보는 슈퍼픽셀을 통하여 구분하는 방법에 대해 연구하였다. 슈퍼픽셀이란 이웃픽셀간의 유사도를 측정하여 영상의 영역을 세그먼트 하는 방법이다. 기존의 배경 정보를 구분하는 방법으로는 슈퍼픽셀과 부스트 트리를 이용한 방법[4]이 많이 사용되었다. 이 방법은 실외 환경에서 건물, 하늘, 바닥을 구분하는 방식이다. 사용되는 알고리즘으로는 학습에 필요한 영상들을 슈퍼픽셀 알고리즘을 이용하여 연관성이 있는 픽셀들을 묶고, 해당 슈퍼픽셀이 어느 환경에 속하는지 부스트 트리 알고리즘을 이용하여 인식하는 방식이다. 이 방법을 응용하여 실내 공간 정보를 분류하는데 사용하는데 있어 효과적인 결과를 얻기는 힘들었다. 그러한 이유는 이 방법의 부스트 트리 알고리즘은 결정 트리를 기반으로 한 아다부스트 학습 알고리즘이다. 기존의 결정 트리는 경관정을 기반으로 구성되어 있기 때문에, 참 혹은 거짓으로 분류하는 특징이 있다. 하지만 상황에서는 특정 특징의 특징값이 참 혹은 거짓을 구분하기 어려울 수도 있다. 하지만, 결정 트리 상 참 혹은 거짓으로만 구분은 되고 이에 따른 오차가 발생하는 문제가 생긴다. 따라서 본 논문에서는 이런 문제를 해결한 퍼지 결정 트리와 이에 대한 앙상블을 이용한 실내 공간 정보 인식 방법에 대해 제안한다. 그림 1에서는 본 논문에 대한 전체 흐름도를 나타낸다.

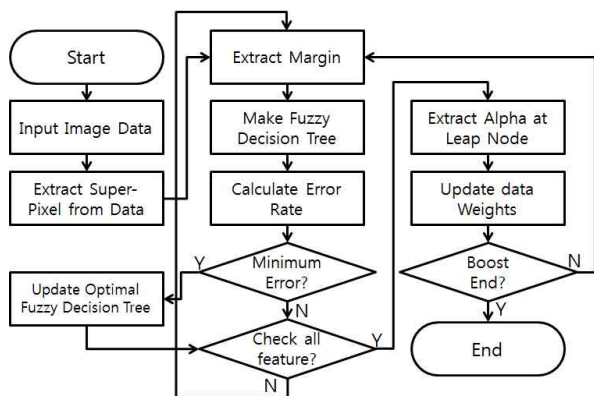


Fig. 1. Overall process.

본 논문의 2-1장에서는 기존의 부스트 트리의 문제점을 지적하며, 퍼지 결정 트리의 방법과 효율성에 대해 검증한다. 2-2장에서는 여러 개의 퍼지 결정 트리를 결합하는 퍼지 부스

트 트리에 대해 설명한다. 3장에서는 기존의 부스트 트리 방식과 퍼지 부스트 트리 간의 인식률 및 예시 그림들을 나타내며 마지막으로 4장에서는 결론 및 추후 연구의 필요성에 대해 설명한다.

## II. The Proposed Scheme

### 1. Fuzzy Decision Tree

기존의 부스트 결정 트리[4]는 결정 트리와 아다부스트를 융합한 방법으로, 아다부스트의 약분류기를 생성하는데 있어 결정 트리를 사용함으로써 학습을 통해 입력된 변수들로부터 목표의 값을 예측하는 모델을 생성하는 방법이다. 이 방법은 제한적인 환경에서 약분류기를 학습하는데 있어 최적의 특징 선택과 특징 데이터의 융합을 통해 좋은 성능을 보여주는 학습 방법이다. 하지만 결정 트리 자체는 경관정을 통해 이루어진 결과이다. 다시 말하면, 루트 노드에서의 판단이 이후 판단에 대해 큰 영향을 미치게 된다. 이러한 판단은, 상위 노드에서 판단을 잘못할 경우 인식 결과가 오류를 낼 확률이 높아진다. 특히, 연속성이 있는 데이터의 경우, 결정이 모호 할 수 있으며, 이에 대해 보정은 필요하다. [8]

따라서, 본 논문에서는 기존의 부스트 트리에서 사용된 결정 트리가 아닌 연관성이 가능한 퍼지 결정 트리를 이용하여 모호한 판단에 대해서는 해당 노드에서 유보할 수 있는 방법에 대해 제안한다. 그림 2은 퍼지 결정 트리의 입력과 결과에 대한 예를 나타낸다.

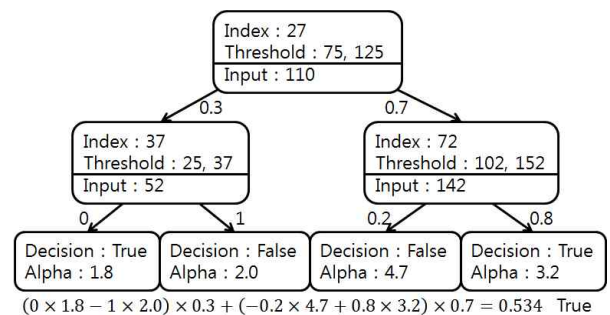


Fig. 2. Example of Fuzzy Decision Tree.

이러한 퍼지 결정 트리는 상위 노드의 판단이 기존의 결정 트리보다 비중이 낮아지는 효과를 나타낸다. 특히 그림 3 (a)에서와 같이 기존의 결정 트리 방법으로는 참으로 판정이 일어나는 경우를 보여준다. 하지만 그림 3 (b)에서는 퍼지 판정 결과 루트노드에서의 판정은 임계값과 얼마 차이 나지 않아, 해당 노드는 두 경우로 분류된다. 그리고 리프노드에 할당된 가중치들을 합산한 결과, 참보다 거짓에 인식에 가까운 결과를 도출할 수 있다. 이는 첫 번째 상위노드의 결과에 따라 하위 노드에 상관없이 결과가 결정될 수 있음을 보여주는 예시이다.

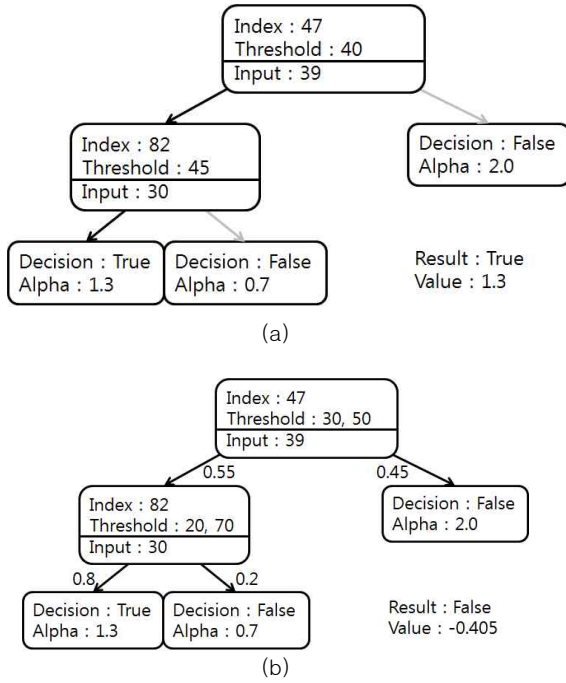


Fig. 3. Comparison between Decision Tree and Fuzzy Decision Tree.  
 (a) Decision Tree. (b) Fuzzy Decision Tree.

퍼지 결정 트리를 만들기 위해 본 논문에서는 그림 4과 같은 연관정 형태로 제안한다. 특히 연관정의 경우 두 개 이상의 임계값이 필요하게 된다. 이러한 두 임계값  $Th_1$ 과  $Th_2$  사이의 마진을 구하기 위해 수식 (1)과 수식 (2)를 통해 마진을 계산하게 된다.




Fig. 4. Example of Soft Decision.

$$Avg(i) = \frac{1}{N} \sum_{j=1}^N F(i, j) \quad (1)$$

수식 (1)에서  $Avg(i)$ 는  $i$ 번째의 특징에 대해 평균값을 계산하게 된다.  $N$ 은  $i$ 번째 특징을 나타내며  $N$ 은  $i$ 번째 긍정 데이터를 나타낸다.  $F(i, j)$ 는  $j$ 번째 데이터에서  $i$ 번째 특징값을 나타내며  $N$ 은 긍정 데이터의 개수를 나타낸다.

$$Th_2(i) = Th_1(i) + \frac{1}{N} \sum_{j=1}^N \sqrt{(Avg(i) - F(i, j))^2} \quad (2)$$

수식 (2)는 수식 (1)에서 구해진 평균  $Avg(i)$ 를 이용하여 분산을 산출 후, 이를 마진으로 이용하여 임계값 간의 차이를 나타낸다. 마진을 계산하기 위해 긍정데이터를 사용한 이유는 부정데이터의 경우 그림 5(b)과 같이 데이터가 한곳에 몰려있지 않고 여러 값에 펼쳐져 있는 형상으로 나타나게 된다. 반면에 긍정데이터의 경우 그림 5(a)와 같이 한곳으로 모이는 형상으로 나타나기 때문에, 부정데이터 보다는 긍정데이터가 의미 있는 데이터로 판단, 해당 마진을 계산하는데 사용되었다.

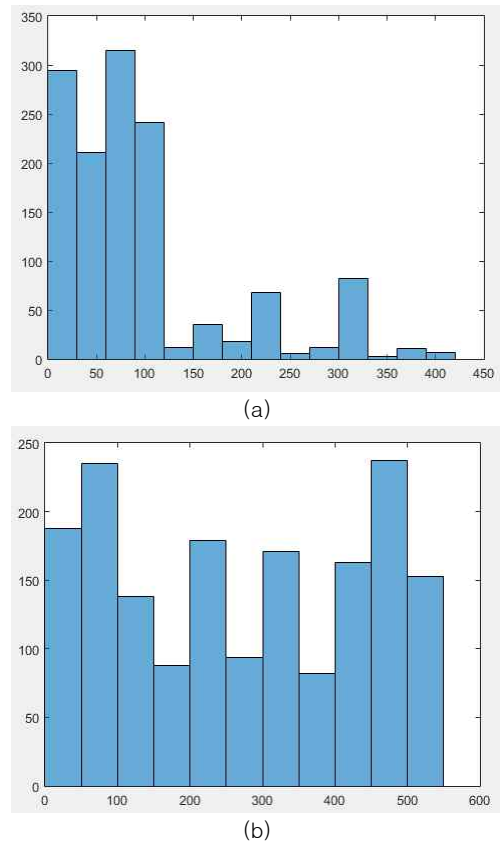


Fig. 5. Data Distribution.  
 (a) Positive data. (b) Negative data.

## 2. Ensemble of Fuzzy Decision Tree

기존의 결정 트리를 이용한 부스트 트리는 학습하는데 있어서 트리의 구성이 그림 6 (a)와 같이 자식 노드의 데이터의 개수가 부모 노드가 가지고 있는 데이터의 개수가 동일하기 때문에, 학습 시 데이터를 2 부류로 분류만 하면 된다. 하지만, 퍼지 결정 트리를 이용할 경우 그림 6 (b)와 같이 자식 노드가 가지고 있는 데이터의 개수 합이 부모가 가지고 있는 데이터의 개수 합보다 많게 되는 문제가 있다. 따라서, 본 논문에서는 이러한 문제를 해결하기 위해 그림 6 (c)에서와 같이 가중치 맵을 생성함으로써, 자식 노드에 포함된 각 데이터의 가중치를 할당할 수 있도록 하였다. 가중치 맵에서 어두운 부분일수록 1에 가깝게 할당되며, 하얀 부분일수록 0에 가깝게 할당하도록 하였다.

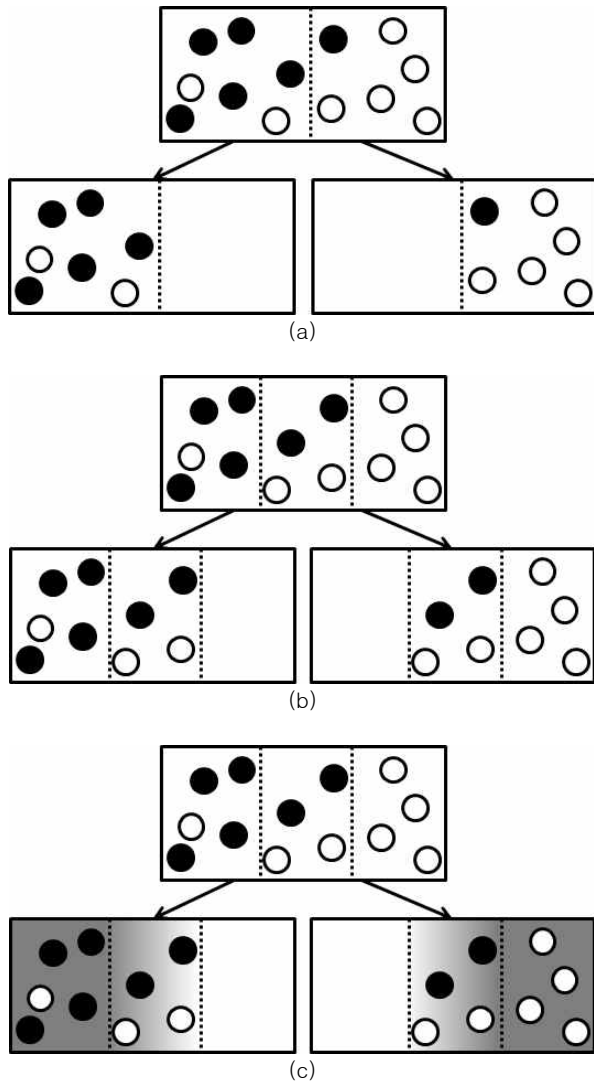


Fig. 6. Relationship between data and tree  
 (a) Decision Tree. (b) Fuzzy Decision Tree.  
 (c) Fuzzy Decision Tree with Weight Map.

각 데이터의 가중치 맵은 퍼지 결정을 이용하여 생성되며, 각 가중치는 수식 (3) 에서와 같이 각 자식 노드가 가지는 가중치 맵이 생성된다.

$$W_T(i, j) = \begin{cases} 0, & \text{if } F(i, j) < Th_1(i) \\ \frac{F(i, j) - Th_1(i)}{Th_2(i) - Th_1(i)}, & \text{if } Th_1(i) \leq F(i, j) \leq Th_2(i) \\ 1, & \text{Otherwise} \end{cases} \quad (3)$$

수식 (3)에서  $W_T(i, j)$ 는  $i$ 번째 특징에 대한  $j$ 번째 데이터의 가중치 맵을 나타낸다.  $Th_1(i)$ 와  $Th_2(i)$ 는 수식 (1)과 수식 (2)로 인해 연산된 임계값들이다. 수식 (2)에서도 설명되어 있지만, 일반적으로  $Th_2(i)$ 값은  $Th_1(i)$ 값보다 큰 값을 할당하게 된다. 이러한 특성을 이용하여  $Th_2(i)$ 보다 클 경우 1의 가중치 값을 할당하며,  $Th_1(i)$ 보다 작을 경우 0의 값을 할당한다.

다. 그 이외의 경우 0~1사이 값을 할당하게 된다.

퍼지 결정을 이용한 학습을 위해  $\alpha$ 값을 가중치맵과 데이터를 융합하여 생성하게 된다. 가중치 맵을 이용하여 수식 (4)에서와 같이 긍정 가중치 합과 수식 (5)에서와 같이 부정 가중치 합을 계산하고 이들을 이용하여 수식 (6)에서와 같이 새로운  $\alpha$  값을 생성하게 된다.

$$W_p(d) = \sum_{j_p=0}^{N_p} W_D(j_p) \times W_L(i_d, j_p) \quad (4)$$

$$W_n(d) = \sum_{j_n=0}^{N_n} W_D(j_n) \times W_L(i_d, j_n) \quad (5)$$

$$\alpha(d) = \frac{1}{2} \cdot \log\left(\frac{W_p(d)}{W_n(d)}\right) \quad (6)$$

수식 (4)와 (5)에서  $d$ 는 리프 노드를 나타내며  $i_d$ 는 해당 리프 노드의 특징 인덱스를 나타낸다. 퍼지 결정 트리를 생성하는 과정에서 사용할 특징은 고정되기 때문에, 생성과정에서 사용된 특징 인덱스이다.  $W_L(i_d, j)$ 는 수식(3)의 가중치맵을 이용한 리프가중치이다. 각 가중치맵은 노드마다 생성이 된다. 루트 노드로부터 리프 노드로 오면서 할당된  $W_T(i, j)$ 값들을 전부 곱한 값이  $W_L(i_d, j)$ 값으로 할당된다.  $W_D(j)$ 의 경우 각 데이터가 가지고 있는 가중치를 나타낸다. 이 가중치는 아다부스트 학습 시 사용되는 가중치와 동일한 가중치이다. 수식 (4)와 (5)에서 긍정 가중치와 부정 가중치의 결정 방법은 두 가중치를 계산 후 큰 값을 긍정 가중치로 할당하는 방식으로 사용하였다. 각 리프노드는 부정을 나타낼 수도 있고 긍정을 나타낼 수도 있다. 따라서 결정관계만 달라질 뿐,  $\alpha$ 값은 항상 1보다 큰 수가 유지되도록 하였다.

$\alpha$ 값이 퍼지 결정 트리에서 각 리프노드에 생성되면 학습의 마지막 단계인 업데이트를 수행하게 된다. 업데이트는 각 데이터가 해당 퍼지 결정 트리에 입력되어 나온 결과를 이용하여 해당 데이터의 가중치를 업데이트하게 된다. 수식 (7)은 업데이트에 대한 수식이다.

$$W_D(j) = \sum_d (-\alpha(d) \times W_L(i_d, j) \times M_d) \quad (7)$$

수식 (7)에서  $W_D(j)$ 는  $j$ 번째 데이터에 할당된 데이터 가중치이다.  $\alpha$ 값과  $W_L$ 값은 수식 (4)~(6)번에서 사용된 것과 동일하다.  $M_d$ 는 매칭 결과로서,  $j$ 번째 데이터와 해당 리프노드의 결정이 동일하면 1이며, 다르다면 -1로 할당한다. 예를 들어 긍정 데이터가 입력되고 리프 노드가 긍정데이터라고 결정이 되면 1로 할당하고, 그러지 않으면 -1로 할당한다. 이러한 방법을 이용해 각 데이터의 가중치를 업데이트 한다.

### III. Experimental Results

본 알고리즘에 대한 개발 및 실험하기 위한 컴퓨터 환경으로는 Intel(R) CoreTM i7-4790 3.60 Ghz CPU와 8GByte 메모리를 사용하였다. 운영체제는 Windows 8 Enterprise K 64bit OS를 사용하였으며, 개발 툴은 Visual Studio 2013의 MFC 환경과 OpenCV 2.4.13 라이브러리를 사용하였다. 실험 데이터로는 직접 수집한 실내 환경 영상으로, 학습용으로는 316장을, 실험용으로는 학습용과 중복되지 않는 316장의 영상을 준비하였다. 그림 7의 (a)는 학습으로 사용된 데이터를 나타내며, 그림 7의 (b)는 실험으로 사용된 데이터를 나타낸다.




Fig. 7. Image Database. (a) Train Database. (b) Test Database.

그림 8은 입력된 영상에서 슈퍼픽셀을 추출한 결과이다. 슈퍼픽셀의 경우 [4]에서 사용된 알고리즘과 동일한 알고리즘을 사용하였다. 그림 8의 왼쪽 영상은 원본 영상을 나타내며, 오른쪽 영상은 왼쪽 영상으로부터 추출된 슈퍼픽셀 세그멘테이션 결과를 나타낸다.




Fig. 8. Examples of Super-Pixel.

각 슈퍼픽셀은 Table 1과 같은 특징들로 구성된다. 슈퍼픽셀은 픽셀들의 군집화 된 결과이기 때문에, 일반 픽셀과 달리 그에 맞는 특징들로 구성되어 있다.

Table 1. Feature of each Super-pixel

Feature	Index
Region size rate in an image	Location
Average of X Position in a Super-pixel	Location
Average of Y Position in a Super-pixel	Location
Average value of RGB	Color
Average value of HSI	Color
Difference of RGB Average value between an image and a Super-pixel	Color
Difference of HSI Average value between an image and a Super-pixel	Color
The number of Edge pixel	Edge
Average of Edge pixel	Edge
Maximum bin value from the Gradient in Edge pixel	Edge

학습하기 위해 별도의 부정 데이터베이스가 존재 하지 않는 이유는 영상 자체를 인식하는 것이 아닌 슈퍼픽셀에 대해 인식을 시도하기 때문이다. 본 논문에서 슈퍼픽셀이 인식하는 대상은 벽, 천장, 바닥, 그리고 클러터로 구분된다. 이러한 특성을 이용하여 천장에 대해 학습할 경우, 벽, 바닥 등 천장의 대상이 되지 않는 슈퍼픽셀들이 부정 데이터로 포함되기 때문에 하나의 영상 데이터베이스만으로도 학습이 가능한 것이다.

슈퍼픽셀을 이용하여 인식한 결과를 그림 9에서 보여준다. 그림 9에서 (a)는 원본 영상을 나타내며, 그림 9의 (b)는 기존 방법의 결과를 나타낸다. 그리고 그림 9의 (c)는 제안한 방법을 적용한 실험 결과를 나타낸다. 그림 9의 (b)에서 보듯이 기존의 방법에서는 창의 발의 경우 오른쪽 벽으로 인식 못하며, 중앙 벽 부분도 제대로 인식 못하는 결과를 가져왔다. 제안하는 방법은 이러한 문제점을 개선되는 강점을 보였으나, 천장 인식에서는 다소 아쉬운 인식 결과를 보였다.




Fig. 9. Indoor Space Recognition (a) Original Image. (b) Traditional Method. (c) Proposed Method.

그림 10에서는 다른 관점에서의 비교 결과이다. 그림 10의 (a)는 원본 영상이며 (b)는 사용자가 원하는 영상 인식 결과이다. 그림 10의 (c)는 기존 방법으로 한 결과이며, 그림 10의 (d)는 제안한 방법의 결과이다. 그림 10의 (b)와 검출된 인식 결과가 같을 경우 그림 10의 (c)와 그림 10의 (d)와 같이 검정

색으로 표시하였으며, 다른 경우 흰색으로 표시하였다.




Fig. 10. Indoor Space Recognition with difference between recognition and ground truth.  
 (a) Original image. (b) Ground truth.  
 (c) Traditional Method. (d) Proposed Method.

Table 2~4는 테스트 데이터베이스의 인식률에 대해 나타낸다. 인식률은 True Positive Rate(TPR), True Negative Rate(TNR), False Positive Rate(FPR), False Negative Rate(FNR)로 4가지로 구분하였다.

Table 2. Comparison of Ceil Recognition

	Boosted Tree	Fuzzy Boosted Tree
TPR	85.07%	91.39%
FPR	14.93%	8.61%
TNR	81.53%	73.05%
FNR	18.47%	26.95%

Table 3. Comparison of Floor Recognition

	Boosted Tree	Fuzzy Boosted Tree
TPR	81.66%	90.67%
FPR	18.34%	9.33%
TNR	88.79%	78.57%
FNR	11.21%	21.43%

Table 4. Comparison of Wall Recognition

	Boosted Tree	Fuzzy Boosted Tree
TPR	76.52%	81.38%
FPR	23.48%	18.62%
TNR	26.94%	17.24%
FNR	73.06%	82.76%

실험 결과, Table 2~4에서 보듯이 긍정 분류에서는 기존의 방법에 비해 개선되었음을 보였다. 하지만, 부정 분류에 대해서는 Table 2와 Table 3에서와 같이 오류율이 증가하였음을 확인할 수 있었다. 하지만, 부정 분류의 오차는 여러 분류기들을 융합하면서 오차를 줄일 수 있었다. 그 결과, 최종 인식률에서는 기존의 방법은 59.63% 수준이었지만, 제안하는 방법으로는

73.23%의 인식률을 보였다. 최종 인식 방법으로는 인식기의 긍정 분류 중 가장 큰 값을 선택하는 방식을 사용하였다.

## IV. Conclusions

본 논문은 학습기를 이용한 실내 공간 검출에 대해 연구하였다. 기존의 학습기인 부스트 트리 방법은 결정 트리의 방식으로 인하여 트리의 결과 값이 큰 오차가 발생하는 경우가 존재한다. 이러한 오류를 줄이고자 본 논문에서는 퍼지 결정 트리를 이용한 퍼지 부스트 트리 방법을 제안하였다. 실험 결과에서는 제안하는 방법이 기존의 방법보다 더 좋은 결과를 보이는 것을 확인하였다. 이러한 결과를 이용하여 소실점, 지향성 지도 등 기존의 연구와 융합하면 더 좋은 실내 공간 검출에 대해서 추후 연구가 필요하다고 생각한다.

## REFERENCES

- [1] H. Jung, Y. Choi and S. Lee, "Changes in the Fourth Industrial Revolution and Health Industry Paradigm", KHIDI Brief, Vol. 215, May 2016.
- [2] F. Meneguzzi, B. Kannan, K. Sycara, C. Gnegy, E. Glasgow, P. Yordanov and B. Dias, "Predictive indoor navigation using commercial smart-phones," Proceedings of the 28th Annual ACM Symposium on Applied Computing ACM, March 2013.
- [3] S. Siltanen, "Diminished reality for augmented reality interior design," The Visual Computer, pp. 1-16, November 2015.
- [4] D. Hoiem, A. Efros and M. Hebert, "Recovering surface layout from an image," International Journal of Computer Vision, Vol. 75, No. 1, pp. 151-172, February 2007.
- [5] D. Lee, M. Hebert and T. Kanade, "Geometric reasoning for single image structure recovery," Computer Vision and Pattern Recognition, June 2009.
- [6] A. Gupta, M. Hebert, T. Kanade and D. Blei, "Estimating spatial layout of rooms using volumetric reasoning about objects and surfaces," Advances in neural information processing systems, December 2010.
- [7] S. Ramalingam, J. Pillai, A. Jain and Y. Taguchi,

“Manhattan junction catalogue for spatial reasoning of indoor scenes,” Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, December 2013.

- [8] G. Ratsch, T. Onoda and K. Muller, “Soft margins for AdaBoost,” Machine learning, Vol. 42, No. 3, pp. 287–320, March 2001.

## Authors



Kisang Kim received the B.S., in Computer Science and M.S. in School of Media from Korea University, Korea, in 2007 and 2009, respectively

Mr. Kim had work at the Daemyung Enterprise (2009~2012) and KETI (2014). Currently, he attends several projects developing vision systems. He is currently a Ph.D. candidate student at Computer Vision Laboratory in the School of Media from Soongsil University



Hyung-II Choi received the B.A. (1979) in Electronic Engineering from Yonsei University and both his M.S. (1983) and Ph.D. (1987) in EECS from the University of Michigan

Prof. Choi teaches computer vision and pattern recognition. His research focuses on computer vision, pattern recognition, fuzzy inference system, and artificial intelligence. His published works deal with the smart device interface, user interaction system, vehicle security system and helping system for blind people.