

## 스케일 불변 특징들의 분포를 이용한 장소의 모델링 및 인식

후 이\*, 신 범 주\*\*, 이 창 우\*\*\*

## Place Modeling and Recognition using Distribution of Scale Invariant Features

Yi Hu\*, Bum Joo Shin\*\*, Chang Woo Lee \*\*\*

### 요 약

본 논문에서 스케일 불변 특징 분포를 이용한 장소 모델링과 실제 입력되는 특징을 추출하여 데이터베이스에 저장된 장소모델을 비교하여 장소를 인식하는 방법을 제안한다. 제안된 방법에서 모든 장소는 각각 다른 장소와 확실히 구별되는 고유한 특징들의 분포로 표현 가능하다고 가정한다. 제안된 방법은 각 장소마다 전역정보를 사용하며, 하나의 장소는 하나의 장소모델로 표현된다. 따라서 장소의 인식을 위해 비교 대상이 되는 장소의 수가 증가하여도, 장소인식을 위한 시간의 복잡도가 기하급수적으로 증가하지 않는다는 장점을 가진다. 제안된 방법의 성능을 검증하기 위한 실험으로 인식에 사용된 특징의 수와 입력영상의 수를 변화시키며 실험을 수행하였고, 실험을 통해 기존의 방법보다 공간적, 시간적인 면에서 제안된 방법이 효율적임을 입증하였다. 제안된 방법은 로봇의 자율횡행, 시각장애인의 도움이 시스템, 웨어러블 컴퓨팅 분야 등, 다양한 분야에 활용도가 있으리라 기대한다.

### Abstract

In this paper, we propose a place modeling based on the distribution of scale-invariant features, and a place recognition method that recognizes places by comparing the place model in a database with the extracted features from input data. The proposed method is based on the assumption that every place can be represented by unique feature distributions that are distinguishable from others. The proposed method uses global information of each place where one place is represented by one distribution model. Therefore, the main contribution of the proposed method is that the time cost corresponding to the increase of the number of places grows linearly without increasing exponentially. For the performance evaluation of the proposed method, the different number of frames and the different number of features are used, respectively. Empirical results illustrate that our approach achieves better performance in space and time cost comparing to other approaches. We expect that the proposed method is applicable to many ubiquitous systems such as robot navigation, vision system for blind people, wearable computing, and so on.

▶ Keyword : 스케일 불변 특징(Scale-invariant Feature), 특징분포(Feature Distribution), 장소인식(Place Recognition)

\* 제1저자 : 후이 교신저자 : 이창우

\*\* 고려대학교 박사과정    \*\*\*부산대학교 교수    \*\*\*군산대학교 조교수

※ 이 논문은 2005년 정부(교육인적자원부)의 재원으로 한국학술진흥재단의 지원을 받아 수행된 연구임(KRF-2005-041-D00725)

## I. 서 론

멀지 않은 미래에는 사람의 힘으로 해결하는 대부분의 일을 로봇이 대신하게 될 것이라는 것은 자명한 사실로 받아들여지고 있다. 이러한 환경에서 자율로봇의 가장 기초적인 능력은 어디에 무엇이 있는지, 현재 자신이 위치한 곳은 어디 인지를 인식하는 것이다. 이러한 목적을 위해 로봇의 자율항해(Autonomous Navigation) 및 장소의 인식 영역에서 많은 연구가 수행되었다[1-5].

장소인식을 위한 기존의 연구에서는 색상 정보[1]와 마커(Marker)[2]가 주로 사용되었다. 이 방법들의 단점은 색상 정보를 구별하기 위한 계산상 큰 부담을 감수해야 하고, 마커들을 사용할 경우는 모든 인식대상이 되는 장소에 사람들이 인위적으로 마커를 고정시켜야 하는 제약이 있다. 더 일반적인 방법들은 장면에서 획득 가능한 특징들에 기반하여 영상의 검색을 통한 장소의 인식이다[3-5]. 이 방법들은 영상 데이터베이스를 만들거나, 영상으로부터 추출된 특징들을 이용하여 장소들을 표현한다. 또한 인식을 위해 특징 정합 방법들을 사용하는 것과 이에 추가적으로 인간의 개입에 의한 보팅(Voting) 정보를 결합하여 조금 더 높은 정확성을 이루는 통계 방법[3-6]들이 있다. 장소의 인식을 위해 영상으로부터 추출된 특징들마다 라벨을 저장하기 위해 데이터베이스가 필요하다. 이와 같은 방법의 단점은 장소의 수가 증가 할수록 함께 데이터베이스의 크기가 커지며 데이터베이스에 저장된 특정 집합과 인식을 위한 입력간의 매칭에 소요되는 시간의 복잡도가 커진다. 또한, 장소의 모델화는 각 장소의 특징 집합과 각 장소마다 다른 특징분포를 모델링함으로써 이루어진다. 예를 들면, 장소 A는 장소 B 보다 많은 흰 점들을 포함하지만, 더 작은 수의 검은 선들을 포함한다. 그래서 만일 우리가 몇몇의 흰 점들이 관찰되면, 우리가 장소 A 안에 있을 확률이 더 높다는 것을 알 수 있다. 장소를 모델화할 때, 앞서 언급한 개념을 기초로 한다면 구분이 쉬운 주요특징의 추출이 보다 중요한 역할을 한다. 주요특징은 검출 시에 사용되는 많은 방법들 가운데 Harris 특징검출기(Interest Point Detector)[7]는 높은 반복성(Repeatability)을 나타내며, 안정적(Robust)이지만, 스케일(Scale)과 어파인 변환(Affine Transformation)[8]에 안정적이지 못하다. 중요특징의 스케일에 불변인 특성을 위해 스케일공간학설(Scale-space Theory)을 깊이 연구한 Lindeberg[9]의 연구와 기존의 스케일공간기반의 특징 검출기[10-12]가 제안되었다.

본 논문에서 제안한 방법은 주요특징(Interest Feature)

들의 분포를 사용하여 장소를 모델화하고, 장소의 인식을 위해 모델된 장소의 특징분포와 입력된 영상에서 추출된 특징들의 분포를 베이시안 인식기(Bayesian Classifier)[13]를 사용하여 인식하는 방법을 제안한다. 본 논문에서는 유동적인 환경에서 장소를 인식하기 때문에 스케일 불변성 특징 검출을 위해 Harris-Laplacian 특징검출기와 참고문헌 [12]에서 사용된 특징점 주변의 기울기의 방향의 크기에 대한 누적 히스토그램을 특징기술자로 활용하고, 추출된 특징들은 장소를 모델링하기 위해 사용된다. 2장에서는 본 논문에서 제안된 장소인식을 위한 장소 모델링과 장소모델을 이용한 장소인식에 대하여 설명하고, 3장에서는 다양한 환경과 변수에 따른 실험 결과에 대해 설명한다. 마지막으로 4장에서 결론 및 향후 연구방향에 대하여 설명한다.

## II. 제안된 방법

제안된 방법은 각각의 장소에는 서로 분리 가능한 고유한 특징들이 분포할 것이라고 가정하기 때문에 장소를 모델하기 위해 각 장소마다 고유한 특징들을 추출하고, 그 추출된 특징들의 분포를 이용한다. 이 방법은 문서를 분류하기 위해 단어들의 분포를 추정한 텍스트 분류 방법[14]에서 특징의 분포를 이용한 방법으로 변환한 것이다. 특징들의 분포를 모델링한다는 것은 실험의 대상이 되는 장소들에서 획득한 이미지들로부터 특징을 추출한 다음, 추출된 특징들의 히스토그램을 추정하는 것이다. 제안된 방법에서 히스토그램의 크기를 결정하기 위해 임의로 정의된  $k$ 개의 특징들을 선별한다. 실 장소로부터 획득된 영상에서 추출된 주요특징은  $k$ 개의 제한된 범주로 분류하고, 각 장소는 이 특징들이 얼마나 분포되어 있는지를 묘사하는 주요특징의 분포로 모델링한다. 특징에 대한 분포는 실험의 대상이 되는 각 장소로부터 획득된 학습데이터를 이용하여 생성한다. 인식단계에서는 실제 관측된 특징들이 장소모델에 일치할 확률을 계산하기 위해 베이시안 분류기를 사용한다. 제안된 방법은 그림 1에서 보듯이 이동형 컴퓨팅 환경에서 동적 입력영상 시퀀스로부터 특징을 추출한 후, 추출된 특징의 분포를 계산하여 사전에 구성된 장소모델과 분포의 유사도를 계산함으로써 현재 위치한 장소를 인식하는 방법을 제안한다.

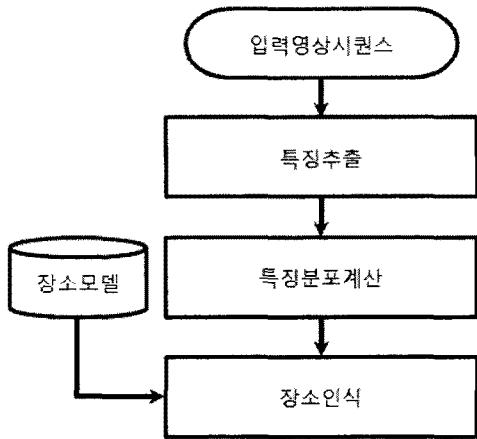


그림 1. 장소인식 흐름도

Fig 1. Flow Diagram of Place Recognition

## 2.1 장소 모델(Place Model)

인식의 대상이 되는 장소마다 고유한 특징을 가지고 모델링하기 위해 본 논문에서는 추출된 특징들을 이용하여 특징사전을 구성한다. 특징사전은 인식의 대상이 되는 장소에서 특정 특징이 얼마나 분포하고 있는지를 척도하기 위한 수단으로 사용된다. 사용될 특징의 수가 결정되면, 그 다음으로 모든 특징들이 특징사전의 인덱스로 레이블된다. 특징사전의 단어(Vocabulary) 수를 결정하기 위하여 제안된 방법에서는 K-means 군집화 알고리즘을 사용한다. 또한 군집간의 거리는 유clidean 거리(Euclidian Distance)로 척도한다. 알려진 바와 같이 K-means 군집화 알고리즘을 사용하기 위한 문제점은 적정한  $k$ 의 선택이 어렵다는 것이며, 또한 군집화 알고리즘이 수행되는 동안 각 군집의 최적 해를 찾는 것이 쉽지만은 않다. 군집화의 대상이 되는 특징들은 직접 인식의 대상이 되는 장소로부터 획득된 영상으로부터 추출된 것으로써, 방대한 양

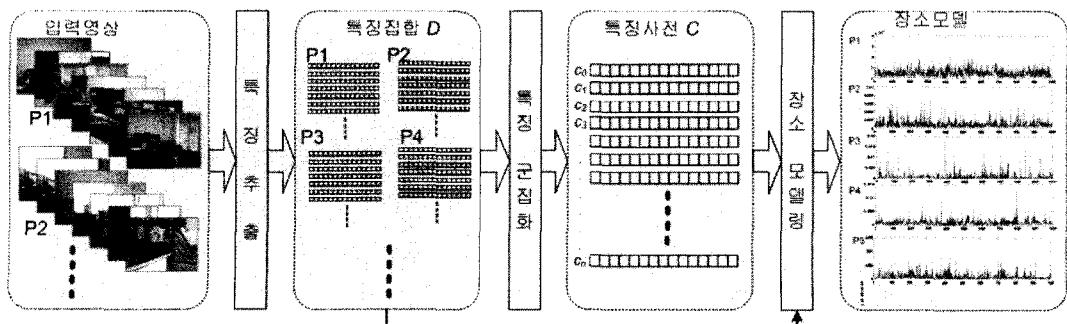
의 집합이다. 많은 양의 특징들을 수집하여 특징사전을 구성한 이유는 인식의 대상이 되는 장소들로부터 가능한 한 더 많은 특징을 추출하여 각 장소가 지니고 있는 고유한 특징들의 공간을 확장하려는 의도이다. 본 논문에서는 구성된 특징사전은 집합  $C = \{c_1, c_2, \dots, c_n\}$ 로서 나타낸다. 또한, 추출된 전체 특징 집합  $D$ 를 대상으로 장소를 모델링하기 위해 전체 특징 집합을 군집화 과정에서 선택한  $d$ 개의 특징으로 레이블링(Labeling)하여 각 장소를 모델링 한다. 전체 특징집합  $D$ 에  $c_j$ 로 레이블된  $h_j$ 개의 특징들이 있다고 가정하면, 각 장소모델의 히스토그램에서  $j$ 번째 빈은 아래 수식 (1)와 같다. 수식 (1)에서  $|D|$ 는 전체 특징집합의 특징들의 개수이며, 0의 계산 결과값을 피하기 위하여 간단한 스무딩을 수행한다.

$$P(c_j | \omega) = \frac{h_j + 1}{|D| + k} \quad \dots \dots \dots (1)$$

그림 2는 특징분포를 이용한 장소의 모델링과정을 보여준다. 그림 2의 오른쪽 모델은 설명한 과정과 같이 특정장소  $\omega$ 를  $k$  빈(Bin)의 특징 분포 히스토그램을 생성하고,  $k$ 를 1000으로 설정했을 때 실험의 대상이 된 장소의 모델에 대한 예를 나타낸 것이다.

## 2.2 특징 추출(Feature Extraction)

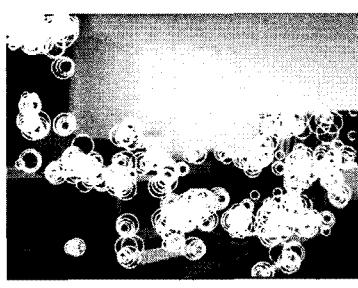
각각의 장소를 구별하기 위한 주요특징들은 코너(Corner)처럼 높은 반복성과 풍부한 주변정보, 등과 같은 중요한 특징을 포함한다. 이와 같은 특징은 정합이나, 인식과정에서 그 유용성이 입증되었으며, 특히, 스케일링(Scaling), 회전(Rotation), 부분적인 조명변화, 등과 같은 영상의 변환에 대한 강건성을 가진다[15-16]. 제안된 방법에서 Harris-Laplacian 검출기를 이용하여 특징을 추출하고, 특징을 표현하기위해 SIFT[12]에

그림 2. 장소모델링 순서도  
Fig 2. Flow Diagram of Place Modeling

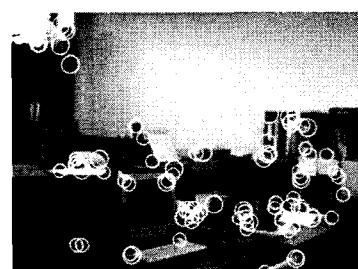
서 사용한 방법과 같은 특징기술자(Feature Descriptor)를 사용한다. 먼저, Harris-Laplacian 특징검출을 위해 다음의 세 단계를 거친다. 첫째, 스케일 불변성을 위한 스케일 공간의 구성을 다른 레벨(Level)의 가우시안 커널(Gaussian Kernel,  $\sigma_n = s^{n^*} \sigma_0$ )을 적용하여 구성한다. 여기서  $\sigma_0$ 는 입력영상을 스무딩하기 위한 초기값이고,  $s$ 는 스케일 공간의 인접 레벨들 사이의 스케일 요소(Factor)이다. 제안된 연구에서는  $s=1.4$ 를 사용한다 [12]. 둘째, 스케일 공간에서 각 영상에 대해 Harris 검출기[7]을 사용하여 특징 후보점(Candidate points)들을 검출한다. 셋째, 특징 후보점을 중에 특징점의 선별은 인접 스케일에서 정규화된  $LoG$ (Laplacian of Gaussian)값이 최대인 특징 후보점을 특징점으로 선택한다.

$$LoG_{norm}(x, y, \sigma_n) = \sigma_n^{-2} \cdot |I_{xx}(x, y, \sigma_n) + I_{yy}(x, y, \sigma_n)| \dots (2)$$

수식 (2)에서  $LoG_{norm}$ 는 정규화된  $LoG$ 함수이며,  $I_{xx}$ 와  $I_{yy}$ 는 밝기 영상의 2차 미분 값,  $on$ 은 n번째 스케일공간에서의 영상이다. 그림 3 (a)는 해리스 코너검출기를 사용하여 스케일 공간에서 특징점들을 검출한 결과이고, (b)는  $LoG$  필터링을 거친 후의 결과이다. 그림 3에서 원의 중심은 특징점의 위치를 표현하고, 반지름의 크기는 스케일공간에서의 스케일 요소를 의미한다.



(a)



(b)



(c)

그림 3. 스케일 공간에서의 특징 검출 결과  
Fig 3. Result of Feature Extraction in Scale-space

특징 검출 후, 각 특징의 비교를 위해 SIFT 기술자[12]와 같은 방법을 이용하여 검출된 특징점은 128차원 벡터로 표현한다. 이 방법은 명암(Intensity)을 그대로 기술자로 사용한 방법[6] 보다 유용하며, 스케일, 조명, 회전에 강건한 것으로 알려져 있다. 그림 3 (c)에서는 특징기술자에 대한 예이다. 그림 3 (c)에서 빨간색 화살표는 SIFT 기술자의 방법과 같이 특징점 주변의 16x16영영에 대해 영상의 밝기값의 기울기에 대한 누적히스토그램이다.

### 2.3 특징 분포 모델을 사용한 장소 인식

인식 단계에서는 인식의 대상이 되는 장소를 이동하는 카메라로부터 실시간 입력영상을 획득한다. 획득된 영상마다 특징을 검출하고, 검출된 특징은 미리 구성된 특징사전을 이용하여 레이블링한다. 추출된 특징을  $X$ 로 표현할 때, Naive Bayesian 분류기[13]에 의해 특정 장소  $\omega$ 일 확률은 베이시안 규칙에 의해 식 (3)와 같이 표현된다.

$$P(\omega | X) = \frac{P(X | \omega) \cdot P(\omega)}{P(X)} \dots (3)$$

여기서, 각각의 장소의 사전확률이 동일하다는 가정 하에 사전확률을  $\alpha$ 항, 즉 정규화 상수로 취급할 수 있다. 또한, 관측된 데이터가 독립이라는 Naive Bayesian 분류기의 가정에 따라 식 (4)과 같이 다시 쓸 수 있다.

$$P(\omega | X) = \alpha \cdot \prod_{j=1}^{|X|} P(x_j | \omega) \dots (4)$$

식 (4)에서 특징 집합  $X$ 의 크기를  $|X|$ 로 표시한다. 특징들  $X$ 는 특징들의 확률 분포를 히스토그램으로 표시한다. 계산의 편의를 위해 수식 (5)에서와 같이 특징  $X$ 를 특징사전의 대표특징인  $C = \{c_1, c_2, \dots, c_k\}$ 로 바꾸어 기술한다.

$$P(\omega | X) = \alpha \cdot \prod_{j=1}^k P(c_j | \omega)^{N(j)} \quad \dots \dots \dots (5)$$

수식 (5)는  $P(\omega | X)$ 에 logarithm을 취하여 수식 (6)처럼 전개할 수 있다.  $N(j)$ 는  $c_j$ 로 레이블 된 특징의 수를 의미한다.

$$\log P(\omega | X) = \log \alpha + \sum_{j=1}^k N_j \cdot \log P(c_j | \omega) \quad \dots \dots \dots (6)$$

장소인식의 결과는 아래 수식 (7)에서와 같이 미리 모델링된 모든 장소를 대상으로 사후확률을 계산하여 최고의 사후확률을 보이는 장소로 인식한다.

$$\text{Classify}(X) = \arg \max_i \{\log P(\omega = \omega_i | X)\} \quad \dots \dots \dots (7)$$

### III. 실험결과

제안된 방법의 성능을 평가하기 위해 학습과 실험에 사용된 데이터 집합은 건물의 1개 층을 대상으로 하였다. 1개 층을 아래 그림 4와 같이 11개의 장소로 분리하여 인식과정을 수행하였다. 장소의 모델링을 위해 필요한 학습데이터는 삼성 노트북 센스 P28모델에 장착된 Logitech PC카메라로부터 20초에서 1분간 촬영한 비디오 클립으로부터 추출한 12760 프레임의 영상에서 추출한 특징들을 대상으로 장소를 모델링하였다. 그림 4은 실험의 대상이 되는 장소들로부터 추출된 학습데이터의 예이다.

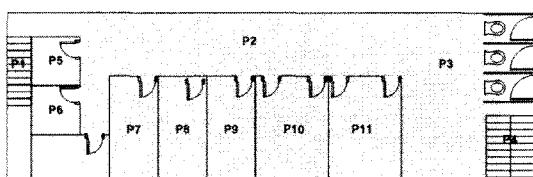


그림 4. 실험환경의 개요  
Fig 4. Overview of Experimental Environment

학습 데이터로부터 특징들을 추출하고, 추출된 특징들의 집합으로부터 대표특징을 선별하기 위한 군집화 작업은 Pentium IV 3GHz, 1GHz 메모리를 가진 데스크탑 시스템에서 30시간 정도가 소요되었고, 각 프레임들의 크기는 320\*240이다. 제안된 방법에서 적정한 군집의 수를 결정하기 위해 군집화 알고리즘의 종료조건을 단순 반복회수 200으로 설정하였고, k의 값은 실험적으로 1000으로 설정하였다. 그 이유는 실험에 의해 1000개 이상(1100, 1200)으로 군집화를 수행하여 제안된 방법의 성능을 평가하였을 때, 성능 향상이 무시할 수준이었기 때문이다.



그림 5. 실험의 대상이 되는 장소영상의 예  
Fig 5. Examples of Place Images

또한, 제안된 방법에서 특징추출을 위한 코너점들을 찾기 위해 OpenCV 라이브러리에서 cvGoodFeatureToTrack() 함수를 사용하였다. 인식 단계에서 PC 카메라가 장착된 노트북을 실험자가 보행으로 설정된 장소를 이동하면서 수행하였다.

그림 5는 실험의 대상이 되는 전체 11장소 중 일부에서 촬영한 영상으로 인식의 대상이 되는 장소의 예를 보여준다.

일반적으로 베이시안 분류기의 성능은 관측데이터의 크기가 사후확률의 결과에 영향을 미친다. 즉, 한 장소에서 관측된 데이터의 수가 많으면 많을수록 결과의 신뢰성이 향상된다. 실험을 통하여 동일한 장소의 인식에서 관측된 영상의 수를 증가시켜가면서 실험한 결과 그 신뢰도와 정확성이 향상됨을 확인하였다. 그림 6은 동일한 6개의 장소에서 인식에 사용된 프레임 수를 증가시켜가면서 실험한 결과이다. 신뢰도와 정확도의 향상을 가시화하기 위해 수치는 확대 스케일링하였지만, 결과는 다르지 않다.

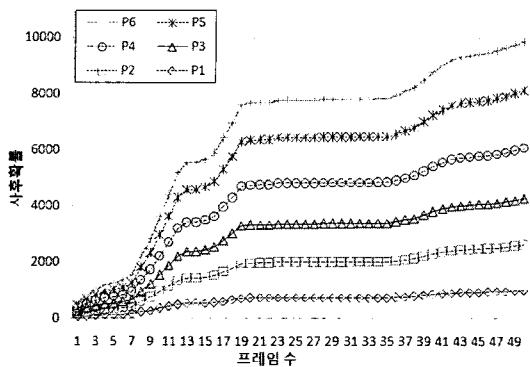


그림 6. 인식에 사용된 프레임 수에 따른 베이시안 분류기의 사후확률들의 예

Fig 6. Examples of Posterior Probabilities according to the Number of Frames

표 1에서는 그림 6에서 설명한 것과 같이 사용된 프레임 수를 1, 5, 10, 15프레임(표1에서 행)으로 증가시켜가며 장소 P1에서 P11까지 실제 인식의 대상이 되는 장소의 인식률을 나타낸다. 실험은 11개의 장소에 대하여 수행하였고, 한 프레임의 입력을 대상으로 인식 성능을 평가했을 시, 여러 프레임을 대상으로 평가했을 때 보다 비교적 낮은 인식률을 보인다.

표 1. 사용된 영상의 수에 따른 인식률(%).

Table 1. Recognition Accuracy According to the Number of Frames

장소 \	1	5	10	15
P1	97.4	99.3	99.3	100.0
P2	58.3	67.2	85.0	85.0
P3	99.0	95.3	100.0	100.0
P4	75.0	87.7	100.0	100.0
P5	75.0	91.7	100.0	100.0
P6	70.6	89.8	100.0	100.0
P7	77.2	92.7	93.5	99.8
P8	81.7	88.8	99.0	100.0
P9	84.5	97.3	99.2	100.0
P10	79.9	86.2	100.0	100.0
P11	83.5	96.3	100.0	100.0
평균	80.19	90.21	97.82	98.62

표 1에서 보듯이 15프레임 정도를 사용했을 때 비교적 신뢰성있는 인식 결과를 보장할 수 있었다. 다만 인식에 소요되는 시간이 지연된다는 단점이 존재한다. 장소 P2(그림 5의 4열)의 경우에는 정확성은 15 프레임을 사용했을 때도 그 정확도가 향상되지 않았는데, 그 이유는 P2의 장소가 복도환경이고, 거의 특징점을 추출하기 힘든 벽면이거나, 바닥면이기 때문인 것으로 분석된다.

또한, 제안된 방법의 성능 평가를 위해 인식에 사용되는 특징의 수를 증가시켜가면서 실험하였다. 표 2는 인식에 사용된 특징의 수에 대한 인식률을 보인다. 실험에 의한 결과로 각 장소마다 300개의 특징을 사용하여 인식하였을 때와 그 이상의 특징을 사용하였을 경우의 인식률이 유사한 인식 결과를 보였다. 제안된 방법은 참고문헌 [6, 17]과 비슷하거나 더 좋은 성능을 보인다. 그러나 제약이 되는 특징의 수를 연속적인 입력으로부터 획득하기 위해서는 150개의 특징은 약 1초, 300개의 특징을 사용하였을 경우 약 2.34초가 소요되었다. 즉, 그림 7에서처럼 인식을 위해 필요한 특징의 수를 많이 사용할수록 정확도는 높일 수 있지만, 그 소요시간은 증가한다.

표 2. 사용된 특징의 수에 따른 인식률(%).  
Table 2. Recognition Accuracy According to the Number of Features

	50	100	150	200	250	300	350
P1	99.1	100	100	100	100	100	100
P2	78.2	86.7	90.5	93.8	95.4	100	100
P3	98.3	100	100	100	100	100	100
P4	95.1	90.9	93.3	100	100	100	100
P5	92.1	94.9	98.3	100	100	100	100
P6	88.3	91.2	94.9	96.8	99.3	99.6	99.6
P7	87.7	88.0	88.1	88.5	95.6	97.2	97.2
P8	89.4	94.5	95.0	95.4	98.0	98.1	98.9
P9	78.1	82.9	93.9	98.0	98.0	98.5	98.7
P10	87.3	93.2	94.9	96.8	99.3	99.6	99.6
P11	91.1	98.9	99.9	100	100	100	100
평균	89.52	92.84	95.35	97.21	98.69	99.36	99.45

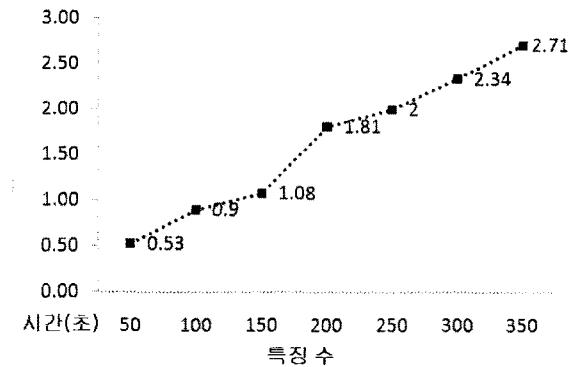


그림 7. 사용된 특징 개수에 따른 인식시간  
Fig 7. Time Cost for Recognition using Different Number of Features.

#### IV. 결론 및 향후과제

본 논문에서는 각 장소가 보유한 고유한 특징의 모델링을 통한 장소인식 방법을 제안하였다. 제안된 방법에서 장소의 인식은 이동형 컴퓨팅 환경에서 카메라로부터 입력되는 영상에서 특징을 추출하고, 이 특징의 분포와 학습에 의해 정의된 장소들의 모델들 간의 베이시안 분류기의 유사도 측도에 의해 이루어졌다. 제안된 연구의 장점은, 첫째, 기존 연구의 단점인 장소의 수가 증가함에 따라 데이터베이스의 크기가 커지는 공간적인 복잡도를 최소화 하였으며, 둘째, 장소인식에 소요되는 시간의 복잡도는 인식대상이 되는 장소의 수에 따라 선형적으로 증가한다는 것이다. 이를 입증하기 위해 실험결과에서는 사용된 특징의 수와 인식에 사용되는 프레임 수를 변경하면서 제안된 방법의 성능을 평가하였고, 그 효율성을 입증하였다. 제안된 방법에서 영상의 시퀀스를 인식의 대상으로 할 때, 즉 많은 수의 프레임을 사용하여 인식을 수행하였을 때, 그만큼 시간상의 효율성이 떨어짐을 확인하였다. 또한, 다수의 프레임을 사용할 경우, 장소간의 전환 시에 인식의 결과가 다소 부정확해짐을 확인하였다. 따라서 향후 연구방향은 장기판측을 통한 장소 인식에 대한 성능개선과 장소의 모델링 단계에서, 방과 방은 복도에 의해 의존관계를 가지고 있으며, 각종은 계단, 건물과 건물은 도로라는 장소에 의해 서로 의존적이라는 장소의 위상정보를 삽입하여 인식의 정확도를 높이는 방향으로 연구를 진행할 것이다.

#### 참고문헌

- [1] Ulrich, I., Nourbakhsh, I. : Appearance-based place recognition for topological localization. In: IEEE International Conference on Robotics and Automation. Vol.2, pp. 1023 - 1029, 2000.
- [2] Briggs, A., Scharschtein, D., and Abbott, S.: Reliable mobile robot navigation from unreliable visual cues, in Fourth International Workshop on Algorithmic Foundations of Robotics, WAFR, 2000.
- [3] Dudek, G., and Jugessur, D.: Robust place recognition using local appearance based methods. In: IEEE International Conference on Robotics and Automation, San Francisco, CA, USA, April, pp. 1030 - 1035, 2000.
- [4] Lowe, D., Se, S., D. and Little, J.: Mobile robot localization and mapping with uncertainty using scale-invariant visual landmarks. In: International Journal of Robotics Research, Vol.21, No. 8, pp. 735 - 758, 2002.
- [5] Davision, A. J., Reid, I. D., Molton, N. D., and Stasse, O., "MonoSLAM: Real-time single camera SLAM," IEEE Trans. PAMI, vol. 29, no. 6, pp. 1052-1067, 2007.
- [6] Mikolajczyk, K., and Schmid, C.: A performance evaluation of local descriptors. In: International Conference on Computer Vision and Pattern Recognition (CVPR), Vol. 2, pp. 257 - 263, 2003.
- [7] Harris, C., Stephens, M.: A combined corner and edge detector. In: Proceedings of the Fourth Alvey Vision Conference, pp. 147 - 151, 1988.
- [8] Schmid, C., Mohr, R., Bauckhage, C.: Evaluation of interest point detectors. In: International Journal of Computer Vision Vol. 37, No. 2, pp. 151 - 172, 2000.
- [9] Lindeberg, T.: Scale-space theory: A basic tool for analysing structures at different scales. In: Journal of applied statistics, Vol 21 , No. 2, pp. 225 - 270, 1994.
- [10] Lindeberg, T.: Feature detection with automatic scale selection. In: International Journal of

Computer Vision, Vol. 30, No. 2, pp. 77 - 116, 1998.

- [11] Mikolajczyk, K. and Schmid, C.: An affine invariant interest point detector. In: European Conference on Computer Vision, Copenhagen, pp. 128 - 142, 2002.
- [12] Lowe, D.: Distinctive Image Features from Scale-Invariant Keypoints. In: International Journal of Computer Vision Vol. 60, No. 2, pp. 91 - 110, 2004.
- [13] Lewis, D. D.: Naive (Bayes) at forty: The independence assumption in information retrieval. In: Proceedings of the 10th European Conference on Machine Learning, Chemnitz, Germany, pp. 4 - 15, 1998.
- [14] McCallum, A. and Nigam, K.: A comparison of event models for naive bayes text classification. In Proceedings of AAAI-98 Workshop on Learning for Text Categorization, Madison, Wisconsin, pp. 137 - 142, 1998.
- [15] Lowe, D.: Object Recognition from Local Scale-Invariant Features. In: Proceedings of the International Conference on Computer Vision, Corfu, Greece, pp. 1150 - 1157, 1999.
- [16] Lowe, D., Little, J.: Vision-based Mapping with Backward Correction. In: Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2002.
- [17] Ledwich, L. and Williams, S.: Reduced SIFT features for image retrieval and indoor localization. In: Australian Conference on Robotics and Automation (ACRA), 2004.

### 저자 소개



후 이

2005년 중국 난카이대학 (이학사)  
2007년 군산대학교 컴퓨터정보과학과  
(이학석사)  
2007년~현재 : 고려대학교 박사과정  
관심분야 : 영상처리, 패턴인식, 컴퓨  
터비전



신 범 주

1998년 경북대학교 컴퓨터공학과  
(공학박사)  
1987년~2002년 한국전자통신연구원  
책임연구원  
2002년~2006년 밀양대학교 컴퓨터  
공학부 교수  
2006년~현재 : 부산대학교 바이오메  
디컬공학과 교수  
관심분야 : 시스템소프트웨어



이 창 우

1996년 경일대학교 컴퓨터공학과(공  
학사)  
1998년 경북대학교 컴퓨터공학과 (공  
학석사)  
1998년~2001년 포항1대학 전임강사  
2004년 경북대학교 컴퓨터공학과(공  
학박사)  
2004년~현재 : 군산대학교 조교수  
관심분야 : 텔레매틱스, 패턴인식, 캠  
퓨터비전