

토폴로지 기반 특징 기술을 위한 특징 검출 방법의 성능 분석

Performance Analysis of Feature Detection Methods for Topology-Based Feature Description

박 한 훈*, 문 광 석**
Han-hoon Park, Kwang-Seok Moon

요약

텍스처가 부족한 장면이나 카메라 포즈 변화가 클 경우, 기존의 텍스처 기반의 특징 추적 방법의 신뢰도는 크게 떨어진다. LLAH와 같은 특징 사이의 기하 정보를 활용하는 토폴로지 기반 특징 기술 방법이 좋은 대안이 될 수 있으나, 특징 검출 방법의 성능에 크게 영향을 받는다. 본 논문에서는 토폴로지 기반 특징 기술을 위한 효과적인 특징 검출 방법을 마련하기 위한 기초 연구로, OpenCV 라이브러리에서 제공되는 특징 검출 방법들의 반복성(repeatability) 분석을 통해 토폴로지 기반 특징 기술에의 적용 가능성을 살펴본다. 실험을 통해, FAST의 성능이 가장 우수함을 확인하였다.

ABSTRACT

When the scene has less texture or when camera pose largely changes, the existing texture-based feature tracking methods are not reliable. Topology-based feature description methods, which use the geometric relationship between features such as LLAH, is a good alternative. However, they require feature detection methods with high performance. As a basic study on developing an effective feature detection method for topology-based feature description, this paper aims at examining their applicability to topology-based feature description by analyzing the repeatability of several feature detection methods that are included in the OpenCV library. Experimental results show that FAST outperforms the others.

Keywords : *Topology-based Feature Description, Feature Detection with high Repeatability Fates, FAST, LLA*

1. 서론

특징(feature)은 영상 내에서 밝기의 변화가 주변에 비해 큰 차이를 가지는 점이나 영역을 의미하며, 특징 검출(detection)/기술(description)은 영상 정합, 영상 복원, 객체 인식/추적 등 다양한 컴퓨터 비전 분야에서 필수적인 과정이다. 지금까지 다양한 형태의 특징 검출/기술 방법이 제안되어 왔으며, 크게 Harris[1], FAST[2], ORB[3], BRISK[4] 등과 같이 코너를 검출/기술하는 방법과 SIFT[5], SURF[6] 등과 같이 영역을 검출/기술하는 방법으로 나눌 수 있다. 많은 특징 검출/기술 방법들이 OpenCV 라이브러리[7]에 포함되어 오픈소스로 제공되고 있으며, 정확성 및 속도 면에서 우수한 성능을 가진다.

그러나, 텍스처가 부족한 객체(예, 흑백으로 이루어진 텍스트 문서)의 경우 특징 주변의 밝기 변화를 활용하는 기존 특징 기술 방법의 성능은 크게 떨어진다[8]. 반면,

LLAH[9]와 같이 특징 사이의 기하 관계를 활용하는 토폴로지 기반 특징 기술 방법은 텍스트 문서[9], 랜덤 점 마커[10], 별자리[11] 등과 같이 텍스처가 부족한 객체에 효과적이다. 또한, 특징 사이의 기하 관계는 시점 변화에 의한 영향도 크지 않기 때문에, 텍스처는 풍부하지만 시점 변화가 큰 경우에도 효과적일 수 있다. 그럼에도 불구하고 토폴로지 기반 특징 기술 방법들의 활용 사례가 많지 않은 이유는 모든 특징이 매우 높은 반복성(repeatability)을 가지고 검출되는 것을 전제하기 때문이다. 무엇보다 개별적인 특징의 반복성뿐만 아니라 이웃 특징의 반복성이 함께 높아야 한다. 물론, 이웃 특징의 반복성이 충분하지 못한 것은 특징 기술 단계에서 이웃 특징의 집합에서 부분 집합만을 이용하여 기술함으로써[9], 어느 정도는 보완이 될 수 있지만 여전히 높은 반복성을 요구한다.

텍스처가 풍부한 객체에 대해 앞서 언급한 여러 특징 검출 방법들은 우수하지만 제약된 반복성을 가지기 때문에, 토폴로지 기반 특징 기술의 유용성은 크지 못하다[12]. 그러므로, 토폴로지 기반 특징 기술의 성능 향상을 위한 보다 효과적인 특징 검출 방법이 마련되어야 한다. 본 논문에서는 이러한 목적의 일환으로, 기존 특징 검출 방법들의 반복성을 분석하고, 토폴로지 기반 특징 기술에 가장 적합한 특징 검출 방법을 모색한다.

*부경대학교 ** 교신저자

투고 일자 : 2015.3.31 수정완료일자 : 2015.4.2

계재확정일자 : 2015.5.1

※ 이 논문은 2014년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업(NRF-2014R1A1A2059579).

II. 토폴로지 기반 특징 기술

토폴로지 기반 특징 기술에 대한 이해를 돕기 위해 LLAH에 대해 간략히 설명한다. 입력 영상에 대해 특징이 검출되어 있다고 가정하면, 검출된 각 특징에 대해 n 개의 이웃 특징들이 선택된다. 그리고 다시 n 개의 이웃 특징 중에서 m 개의 특징이 선택된다. 모든 조합의 개수는 ${}_nC_m$ 이 되고, 이는 특징 기술자의 개수가 된다. m 개의 특징으로부터 특징 기술자를 계산하기 위해 4(또는 5) 개의 특징이 선택되고, 이때 조합의 개수는 ${}_mC_4$ (또는 ${}_mC_5$)가 된다. 이는 특징 기술자의 차원(dimension)의 수가 된다. 4(또는 5) 개의 특징으로부터 두 개의 접한 삼각형의 면적 비(또는 삼각형 면적들의 교차 비(cross ratio))가 계산된다. 최종적으로, ${}_mC_4$ (또는 ${}_mC_5$)개의 면적 비(또는 교차 비)로 이루어진 특징 기술자는 해싱 함수에 의해 1 차원 인덱스로 변환되고, 각 특징은 이러한 1 차원 인덱스를 ${}_nC_m$ 개를 가진다[9]. 그러므로, 토폴로지 기반 특징 기술은 이웃한 특징들의 기하 관계를 기술하기 때문에 모든(최소 m 개 이상) 특징들의 높은 반복성이 전제된다.

III. 특징 검출 방법

본 논문에서는 특징 검출을 위해 OpenCV에서 제공되는 방법으로, Harris, FAST, ORB, BRISK, SIFT, SURF, STAR[13]를 사용한다. 이 장에서는 각 방법에 대해 간략하게 설명한다.

3.1. Harris

영상에서 코너를 찾는 대표적인 방법으로, 식 (1)을 이용하여 로컬 윈도우 내에서 x, y 방향으로의 변화가 큰 픽셀을 찾는다.

$$h = |M| - k * \text{trace}(M)^2 \tag{1}$$

$$\text{where } M = \begin{bmatrix} \sum_W I_x^2 & \sum_W I_x I_y \\ \sum_W I_x I_y & \sum_W I_y^2 \end{bmatrix} \tag{2}$$

여기서, k 는 경험에 의해 결정되는 상수, W 는 로컬 윈도우의 크기, I_x, I_y 는 영상의 x, y 방향으로의 1차 미분을 의미한다. h 가 일정한 값(> 0)보다 큰 픽셀이 코너로 검출된다. 검출된 코너는 영상의 affine 변화, 조명 변화에 어느 정도는 강인성을 가진다[1].

3.2. FAST

FAST는 고속 코너 검출에 초점을 두고, 어떤 픽셀 p 를 중심으로 하는 반지름 3인 원 상의 16개 픽셀 중에 p 의 값보다 일정한 값 이상 밝거나 어두운 픽셀들이 일정한 개수(9 ~ 16)

이상 연속되어 있으면 p 를 코너로 판단한다. 연속된 점들의 개수를 세는 속도를 향상시키기 위해 decision tree를 이용한다. FAST의 특성 상 검출된 코너들이 서로 인접하게 되는데, non-maximum suppression을 통해 코너성(cornerness)이 약한 코너는 제거할 수 있다[2].

3.3. ORB

기본적으로 FAST를 이용하여 코너를 특징으로 검출한다. 다만, 영상의 크기 변환에 대응하기 위해 영상 피라미드를 생성하여 각 단계에서 multi-scale 코너를 검출하고, 영상의 회전 변환에 대응하기 위해 각 코너를 중심으로 하는 로컬 윈도우 내에서 weighted intensity centroid를 계산하여 코너의 방향(orientation)을 함께 계산한다[3].

3.4. BRISK

영상의 크기 변환에 대응하기 위해 보다 정교하게 생성된 scale space 상에서 non-maximum suppression을 수행하여 FAST 코너를 검출한다[4].

3.5. SIFT

영상에서 특징적인 영역을 찾는 대표적인 방법으로, 영상의 크기 변환에 대응하기 위해 scale space 상에서 영역의 세기가 극대인 점을 찾는다. 각 픽셀에서의 영역의 세기는 식 (3)의 Laplacian 값을 사용한다.

$$\nabla^2 I = \frac{\partial^2}{\partial x^2} I + \frac{\partial^2}{\partial y^2} I \tag{3}$$

그러나, 속도 향상을 위해 Laplacian 값을 직접 계산하지 않고, DoG(Difference of Gaussian)를 사용한다. DoG는 입력 영상의 Gaussian 피라미드를 생성한 후, 인접한 두 단계의 차(difference) 영상을 얻는 과정을 의미하며 이론적으로는 LoG(Laplacian of Gaussian) 필터를 적용한 것과 거의 동일한 결과를 갖는다[5].

3.6. SURF

SIFT와 유사하지만, 계산 효율성을 높여 속도가 크게 향상된 방법으로, scale space 상에서 식 (4)와 같이 근사화된 Hessian 행렬의 행렬식(determinant)을 계산하여 후보 영역을 찾는다.

$$d = D_{xx}D_{yy} - (0.9 * D_{xy})^2 \tag{4}$$

여기서, D_{xx}, D_{xy}, D_{yy} 는 입력 영상과 근사화된 LoG 필터인 box 필터와의 컨볼루션(convolution) 결과를 의미한다[6].

3.7. STAR

SURF에서처럼 근사화된 LoG 필터를 사용하지만, 보다 LoG 필터의 모양에 근접한 box 필터를 사용하여 후보 영역을 검출한다. 이후, scale space 상에서 non-maximum suppression을 수행하고, 최종적으로 식 (1)에서의 행렬식 값과 대각합의 비가 일정 값 이상인 영역을 찾는다[13].

IV. 특징 검출 방법의 반복성

4.1. 반복성 계산

특징의 반복성은 같은 특징이 서로 다른 영상에 걸쳐 반복해서 검출되는 빈도를 의미하며, 식 (5)와 같이 계산될 수 있다[14].

$$r = \frac{N_R}{\min(n_i, n_j)} * 100 \quad (5)$$

$$\text{where } R = \{(x_i, x_j) \mid \|Tx_i - x_j\| < \epsilon\} \quad (6)$$

여기서, N_R 은 집합 R 의 개수를 의미한다. x_i, x_j 는 i 번째 영상과 j 번째 영상에서 검출된 특징의 좌표, T 는 두 영상 사이의 변환을 의미한다. ϵ 은 0 ~ 1 사이의 값을 가지는 상수로, 본 논문에서는 0.15로 설정된다.

4.2. 기존 특징 검출 방법의 반복성

실험 영상은 특징 검출에 영향을 주는 다양한 조건을 포함하며, 미리 영상 간의 변환 행렬(T)이 주어진 영상을 사용했다[15] (그림 1 참조). 각 특징 검출 방법은 OpenCV 함수를 사용했으며, 문턱 값을 제외한 파라미터는 미리 정의된 값을 사용하였다. 단, FAST의 경우, non-maximum suppression을 수행하지 않도록 설정하였다. 문턱 값(ORB와 SIFT의 경우, 특징의 수를 문턱 값으로 설정했으며, 나머지 방법들은 특징의 세기(intensity or response)를 문턱 값으로 설정함)의 변화에 따라 특징의 수는 대략 500 ~ 2000 개의 범위를 가졌다.




그림 1. 실험 영상. 윗줄부터 Boat(in-plane rotation + scale 변화), Graffiti(시점 변화), Leuven(밝기 변화) 영상.

Fig.1. Images used in experiments. From top row, Boat, Graffiti, Leuven.

그림 2는 각 특징 검출 방법에 대해 다른 문턱 값을 사용하여 계산된 반복성을 평균한 결과이다. 실험 결과, 영상의 기하 변환에 대해서는 Harris와 FAST의 반복성이 가장 좋았으며, 밝기 변화에 대해서는 FAST와 SURF의 반복성이

높았다. 기하 변환의 경우 scale space 상에서 non-maximum suppression의 수행이 반복성을 낮추는 원인으로 분석된다. FAST의 경우에도 non-maximum suppression을 수행하도록 설정할 경우(공간 제약으로 실험 결과는 생략), 반복성이 20 ~ 30% 정도 하락한다. 그러나, non-maximum suppression을 수행하지 않으면 매우 밀집된 혹은 중첩된 영역에서 다수의 특징이 검출되고, 이러한 특징에 의해 반복성이 크게 증가되는 것이다(Harris, FAST, ORB의 결과가 이에 해당함). 즉, 식 (5)는 밀집된 특징으로 인한 반복성 향상 효과를 구별할 수 없기 때문에, non-maximum suppression을 수행하지 않았을 때의 높은 반복성은 항상 신뢰할 수 없다.

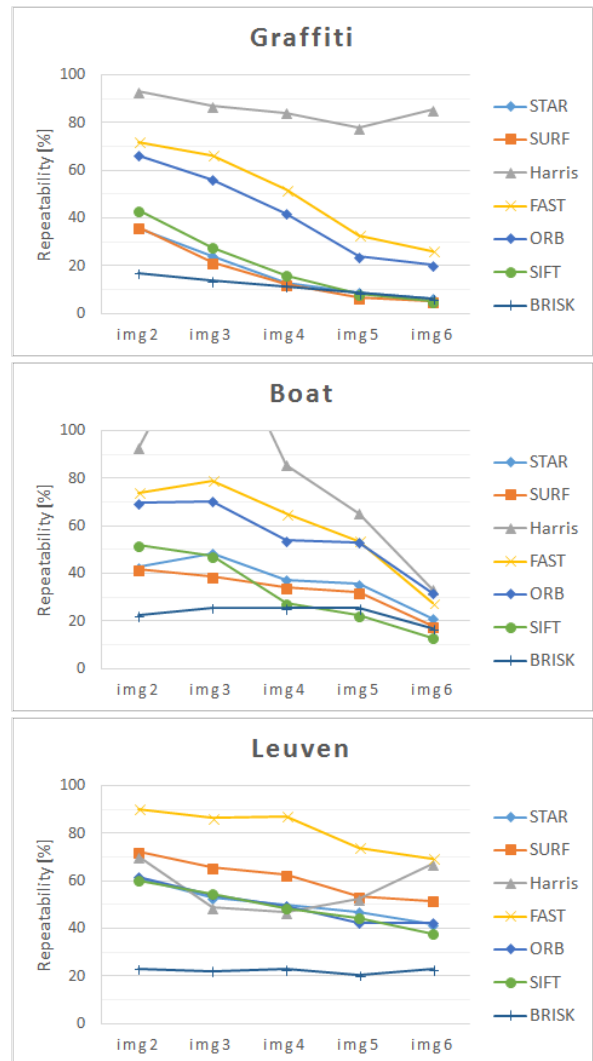


그림 2. 기존 특징 검출 방법들의 반복성.
Fig.2. Repeatability of the existing feature detection methods.

4.3. 토폴로지 기반 특징 기술을 위한 기존 특징 검출 방법의 반복성

II장에서 언급한 대로, 토폴로지 기반 특징 기술 방법은 개별적인 특징의 반복성뿐만 아니라 이웃 특징의 반복성이

함께 높아야 한다. 또한 4.2절에서 언급한 대로, Harris나 FAST의 경우 검출된 특징들이 매우 인접하게 분포하기 때문에 토폴로지 기반 특징 기술에 적합하지 못하다[12](사실, non-maximum suppression을 수행하는 방법들도 토폴로지 기반 특징 기술에 적합할 만큼 특징 사이의 거리가 충분히 크지 않다). 반면, Harris나 FAST를 사용하지 않으면 특징의 반복성이 좋지 못하다.

따라서, 토폴로지 기반 특징 기술에 적합하도록 검출된 특징 사이의 거리가 일정 이상 되도록 하고, 반복성을 향상시키기 위해, 특징을 선별하는 것을 고려해 볼 수 있다. [12]에서는 특징의 세기가 특징의 반복성에 비례한다고 가정하고, 일정한 수(max_n)의 큰 세기를 가지는 특징 순으로 선별하되, 더 큰 세기를 가지는 특징이 일정 거리(min_d) 이내에 있다면 제외시켰다. 그러나, 앞서 실험을 통해 특징의 세기와 반복성은 항상 비례하지 않음을 짐작할 수 있다. 즉, 그림 3에서 보는 것처럼, 큰 문턱 값을 사용해서 세기가 큰 특징만을 검출하더라도 반복성 향상은 크지 않으며, 작은 문턱 값을 사용하여 세기가 낮은 특징들을 포함하더라도 반복성에는 큰 차이가 없다. 이는 세기가 낮은 특징들도 높은 반복성을 가질 수 있다는 것을 의미한다. 그러므로, 특징의 세기를 기준으로 특징을 선별할 경우, 그림 4에서 보는 것처럼, 각 특징의 세기는 시점이나 조명 변화에 따라 달라지기 때문에 반복성이 크게 저하될 수도 있다. 또한, 특징 수를 min_n 으로 제한하는 것은 반복성이 높지만 세기가 낮은 특징들이 제거될 수 있다. 실제 [12]의 방법을 사용할 경우 그림 5에서 보는 것처럼 반복성은 크게 저하되었다.




그림 4. 특징 세기에 기반한 선별의 영향. f_1 이 가장 큰 세기를 가지기 때문에, f_2 와 f_3 는 제거된다. 반면, f_2 가 가장 큰 세기를 가지기 때문에, f_1 과 f_4 가 제거되어 f_1 의 반복성은 유지되지 못한다.

Fig.4. Effect of selecting features using their intensity.

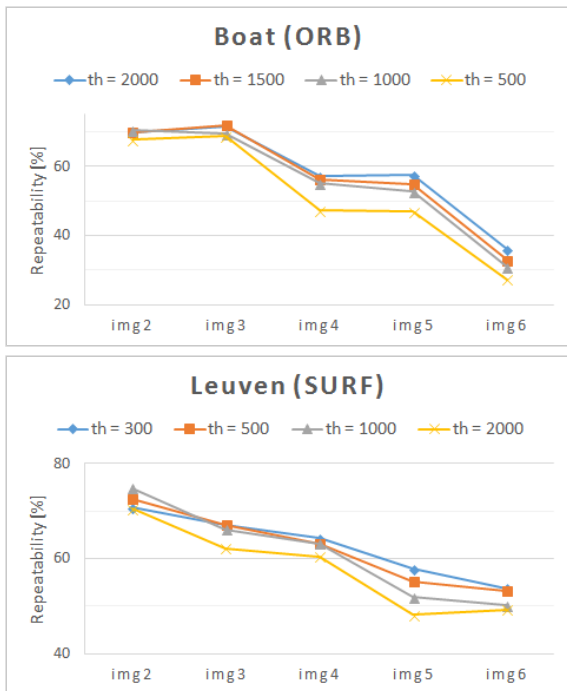


그림 3. 문턱 값에 따른 ORB와 SURF 특징의 반복성.
Fig.3. Repeatability of ORB and SURF features detected with different thresholds.




그림 5. [12]에서 제안된 방법에 의해 선별된 특징의 반복성($max_n = 200, min_d = 10$).

Fig.5. Repeatability of features selected by using the method proposed in [12].




그림 6. 본 논문에서 제안된 M1 방법에 의해 선별된 특징의 반복성.

Fig.6. Repeatability of features selected by using the M1 method proposed in this paper.

그러므로, 본 논문에서는 완화된 기준을 적용하여 특징을 선별한다. 첫 번째 방법(M1)으로, min_n 을 설정하지 않고 낮은 세기를 가진 특징들도 모두 선별될 수 있도록 한다. 두 번째 방법(M2)으로, 우선 특징의 세기 대신 특징 사이의 거리가 일정 이상 되도록 하는 데 초점을 둔다. 즉, 거리가 10([12]의 결과로부터 설정)보다 작은 이웃 특징의 개수가 5(LLAH의 성능 고려)보다 작은 특징은 제거한다. 그러나, 특징의 세기가 전혀 고려되지 않기 때문에, 작은 min_d 값(= 5)을 가지는 M1 방법을 선행한다.

우선, 각 특징 선별 방법의 처리 시간은 선별 후의 특징 수에 비례하기 때문에, 일반적으로, M1 방법은 [12]의 방법보다 선별 후에 많은 특징이 발생하므로, 선별 과정에 걸리는 시간이 길지만, M2 방법은 M1 방법보다는 항상 선별

과정에 걸리는 시간이 짧지만, 영상에 따라 선별 후의 특징 수가 크게 달라지기 때문에 [12]의 방법에 비해 선별 시간이 증가하기도 감소하기도 했다.

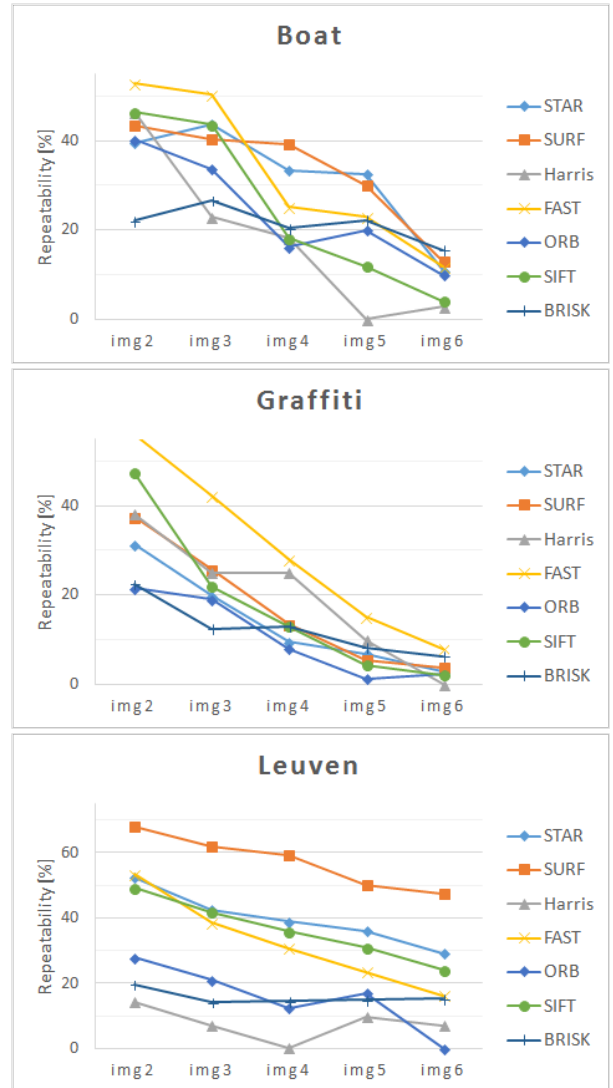


그림 7. 본 논문에서 제안된 M2 방법에 의해 선별된 특징의 반복성.

Fig.7. Repeatability of features selected by using the M2 method proposed in this paper.

표 1. 각 특징 검출 방법의 처리 시간(단위: [ms])

Table 1. Processing time of feature detection methods

Harris	Fast	ORB	BRISK	SIFT	SURF	STAR
17	1	7	190	160	40	18

그림 6에서 보는 것처럼, M1 방법을 사용함으로써 Boat 영상에 대해 7%, Graffiti 영상에 대해 2%, Leuven 영상에 대해 10% 정도의 반복성이 향상되었고, M2 방법을 사용함으로써 Boat 영상에 대해 16%, Graffiti 영상에 대해 4%,

Leuven 영상에 대해 13% 정도의 반복성이 향상되었다. 이는 모든 특징 검출 방법에 대한 평균적인 수치로, SURF, SIFT, STAR와 같은 방법의 반복성 향상이 상대적으로 뚜렷했다. M1 방법에 비해 M2 방법의 성능이 더 좋았으며, 기하 변환에 대해서는 FAST가, 밝기 변화에 대해서는 SURF가 가장 높은 반복성을 가졌다. 그러나, 표 1에서 보는 것처럼 검출 방법에 따라 처리 시간(i7 3.4GHz CPU, 8GB RAM을 가진 PC에서 측정)이 현저히 차이가 나며 FAST의 검출 시간이 월등히 작았다. 결과적으로 토폴로지 기반 특징 기술을 위해서는 FAST(정확히 말하면, non-maximum suppression을 수행하지 않은 FAST)가 가장 적합한 방법으로 판단된다.

V. 결론

본 논문에서는 토폴로지 기반 특징 기술에 적합한 특징 검출 방법을 마련하기 위한 기초 연구로서, 특징 사이의 거리를 일정 이상 되도록 했을 때 OpenCV 라이브러리에서 제공되는 기존의 특징 검출 방법들의 반복성을 분석하고, 반복성 향상을 위한 특징 선별 방법을 제안하였다. 실험을 통해, FAST 방법이 가장 높은 반복성을 가짐을 알 수 있었다. 그러나, FAST 방법의 반복성 역시 토폴로지 기반 특징 기술에 바로 적용할 수 있을 정도로 높지는 않았다. 향후, 이를 보다 향상시키기 위한 방법이나 특징 기술 단계에서 낮은 반복성을 보충하기 위한 방법에 대한 추가 연구가 수행되어야 할 것이다.

참고 문헌

[1] C. Harris and M. Stephens, "A combined corner and edge detector," Proc. of the 4th Alvey Vision Conf., pp. 147-151, 1988.

[2] E. Rosten and T. Drummond, "Fusing points and lines for high performance tracking," Proc. of ICCV, pp. 1508-1511, 2005.

[3] E. Rublee, V. Rabaud, K. Konolige, G. R. Bradski, "ORB: An efficient alternative to SIFT or SURF," Proc. of ICCV, pp. 2564-2571, 2011.

[4] S. Leutenegger, M. Chli, and R. Siegwart, "BRISK: Binary robust invariant scalable keypoints," Proc. of ICCV, pp. 2548-2555, 2011.

[5] D. G. Lowe, "Distinctive image features from scale-invariant keypoints", IJCV, vol. 60, no. 2, pp. 91-110, 2004.

[6] H. Bay, T. Tuytelaars, L. V. Gool, "SURF: Speeded up robust features," Proc. of ECCV, pp. 404-417, 2006.

[7] OpenCV, <http://opencv.org/>

[8] H.-S. Ryu, H. Park, "A system for supporting paper-based augmented reality," MTAP, 2015. (online

published)

[9] T. Nakai, K. Kise, and M. Iwamura, "Use of affine invariants in locally likely arrangement hashing for camera-based document image retrieval," Proc. DAS, pp. 541-552, 2006.

[10] H. Uchiyama and H. Saito, "Random dot markers," Proc. of VR, pp.35-38, 2011.

[11] B.-K. Seo, H. Uchiyama, and J.-I. Park, "stAR: Visualizing constellations with star retrieval," Proc. of SIGGRAPH ASIA, article no. 53, 2011.

[12] H. Uchiyama and E. Marchand, "Toward augmenting everything: Detecting and tracking geometrical features on planar objects," Proc. of ISMAR, pp. 17-25, 2011.

[13] M. Agrawal, K. Konolige, and M. R. Blas, "CenSurE: Center surround extremas for realtime feature detection and matching," Proc. of ECCV, pp. 102-115, 2008.

[14] Schmid, R. Mohr, and C. Bauckhage, "Evaluation of interest point detectors," IJCV, vol. 37, no. 2, pp. 151-172, 2000.

[15] <http://www.robots.ox.ac.uk/~vgg/research/affine/index.html>



박한훈 (Han-hoon Park)

正會員

2000년 한양대학교 전자통신전파공학사

2002년 한양대학교 전자통신전파공학석사

2007년 한양대학교 전자통신전파공학박사

2008년 ~ 2011년 NHK방송기술연구소 박사후연구원

2012년 ~ 현재 부경대학교 전자공학과 부교수

※주관심분야 : 3차원 영상처리, 증강현실, HCI



문광석 (Kwang-Seok Moon)

正會員

1979년 2월 경북대학교 전자공학사

1981년 2월 경북대학교 전자공학석사

1989년 2월 경북대학교 전자공학박사

1988년 일본 동경대학교 학부연구원

1997년 8월 ~ 1998년 7월 미국 Jackson State University

객원교수

1990년 3월 ~ 현재 부경대학교 전자공학과 교수

※주관심분야 : 영상신호처리, 적응신호처리 등