

PCA기반 검색 축소 기법을 이용한 SURF 매칭 속도 개선

김원규[†], 강동중^{**}

요 약

영상에서 임의의 점에 대한 고유한 특징을 계산하는 알고리즘은 파노라마 영상의 제작, 스테레오 영상의 획득, 물체 인식, 이미지 분석 등에 다양하게 사용되는 중요한 요소이다. 일반적으로 어떤 점의 특징은 스칼라 형태가 아닌 벡터형태로 나타나게 되는데, 무수히 많은 특징 점들을 서로 비교하는 작업은 매우 많은 계산량을 요구한다. 본 연구에서는 영상의 특징점 계산에 SURF(speeded up robust features)를 이용하였고, 이미지로부터 추출된 특징을 PCA(principal component analysis)기법을 이용하여 벡터의 차원을 축소하여 연결리스트 자료구조에 정렬한 다음 특징을 비교하는 기법을 제안한다. 제안된 특징의 비교 방법을 적용할 경우 기존 방법의 매칭 정확도는 유지한 상태에서 계산시간을 줄일 수 있는 것을 실험을 통하여 확인하였다.

Speed Improvement of SURF Matching Algorithm Using Reduction of Searching Range Based on PCA

Onecue Kim[†], Dong-Joong Kang^{**}

ABSTRACT

Extracting unique features from an image is a fundamental issue when making panorama images, acquiring stereo images, recognizing objects and analyzing images. Generally, the task to compare features to other images requires much computing time because some features are formed as a vector which has many elements. In this paper, we present a method that compares features after reducing the feature dimension extracted from an image using PCA(principal component analysis) and sorting the features in a linked list. SURF(speeded up robust features) is used to describe image features. When the dimension reduction method is applied, we can reduce the computing time without decreasing the matching accuracy. The proposed method is proved to be fast and robust in experiments.

Key words: SURF, feature registration, dimensionality reduction, PCA sorting

1. 서 론

최근 컴퓨터 성능의 향상과 카메라 가격의 하락으로 인해 영상처리와 관련된 다양한 프로그램들이 개발되고 있는 추세이다[1].

영상에서 임의의 점에 대한 고유한 특징을 계산하는 알고리즘은 파노라마 영상의 제작, 스테레오 영상에서의 3차원 정보 획득, 물체 인식, 이미지 분석 등에 다양하게 사용되는 핵심 기술이며, 이때 두 영상에서 동일한 특징이 검출되었는지를 판단하는 부분

※ 교신저자(Corresponding Author) : 강동중, 주소 : 부산광역시 금정구 장전동 산 30번지 기계관 3517호(609-735), 전화 : 051) 510-2163, FAX : 051) 514-1118, E-mail : dj kang@pusan.ac.kr

접수일 : 2013년 4월 2일, 수정일 : 2013년 5월 9일

완료일 : 2013년 5월 16일

[†] 정회원, 부산대학교 기계공학부
(E-mail : onecue@pusan.ac.kr)

^{**} 준회원, 부산대학교 기계공학부

※ 이 논문은 부산대학교 자유과제 학술연구비(2년)에 의하여 연구되었음.

에서 많은 계산량을 필요로 한다.

두 이미지에서 추출된 특징 셋을 탐색하고 매칭하는 알고리즘은 가장 단순하게는 유클리디안 거리(Euclidean distance) 또는 맨하탄 거리(Manhattan distance)를 모든 특징점들에 대해서 탐욕적 방법(Greedy algorithm)으로 비교하는 것이다. 하지만 특징점의 차원이 커지고 개수가 증가하게 되면 비교 연산의 횟수는 기하급수적으로 증가하는 문제가 발생하게 된다. 이런 문제를 해결하기 위하여 다양한 접근 방법들이 제안 되었는데 크게는 특징을 추출할 때 특징의 차원수를 줄이는 방법과 탐색 알고리즘을 적용하는 방법이다.

특징의 차원수를 줄이는 가장 대표적인 방법은 PCA-SIFT(Scale-invariant feature transform) [2]로써 SIFT(Scale-invariant Feature Transform)를 통하여 추출된 특징을 PCA(Principal component analysis)[3]기법을 이용하여 축소하는 방법이다. 또한 Valenzuela는 PCA를 이용하여 단순히 특징의 차원수를 줄이는 방법들에 대하여 연구하였다[4]. 하지만 이 방법을 사용하게 되면 계산 속도는 항상 시킬 수 있지만 특징 자체를 축소하기 때문에 특징 비교에서 정확도가 떨어지는 문제점이 발생한다.

탐색 알고리즘을 적용하는 경우에는 최단 이웃점 탐색(Nearest neighbor search)방법[5] 또는 KD Tree 탐색 방법[6]이 널리 사용하고 있다. 하지만 이 방법을 사용할 경우에는 비교되는 원소의 개수가 증가하게 되면 가지를 생성하는데 걸리는 시간이 많이 필요하다는 단점이 존재한다.

본 논문에서는 매칭 정확도는 유지한 상태에서 계산 시간을 줄일 수 있는 방법을 제안한다. 우선 이미지로부터 특징 생성은 SURF(Speeded Up Robust Feature)[7]를 이용하였고, 추출된 특징은 PCA기법을 이용하여 축소되어 연결리스트 자료구조에 정렬된다. 이때 축소된 특징은 차원을 축소하는 과정에서 많은 정보가 소실되기 때문에 단순히 비교의 범위를

정하기 위해서만 활용되고 실제 특징의 비교에서는 기존 SURF 특징을 그대로 사용하였다. 그리고 SURF 특징의 비교를 위해 사용된 탐색 알고리즘은 FANN(Fast Approximate Nearest Neighbor Search) [8]을 이용하였다.

2. 관련연구

2.1 SURF 특징

SURF는 그림 1에서 보여지는 것처럼 2D Haar wavelet[9]을 기반으로 하는 밝기의 기울기 정보를 이용하여 영상의 특징을 강인하게 표현할 수 있는 특징 검출 알고리즘으로써 Herbert Bay에 의해서 처음 소개되었다. SURF 알고리즘은 SIFT에서 가장 문제가 되었던 계산 속도를 개선하여 일반적인 SIFT알고리즘에 비해 수배 빠른 것으로 알려져 있고 특징의 회전, 크기 변화에 상관없이 특징을 검출할 수 있는 능력을 가지고 있다. 이미지에서 한 점의 SURF 특징은 64개의 원소를 가지는 vector형태로 표현되고 개별특징을 비교하는 작업은 많은 연산량을 필요로 한다.

SURF특징의 추출은 계산이 복잡하기 때문에 영상 전체 영역에 대하여 수행되는 것이 아니라 Hessian Detector(H)를 이용하여 특징이 잘 추출될 수 있는 영역에서만 SURF연산을 하는 것이 특징이다. 영상 I에서 임의의 점을 $\mathbf{x}=(x,y)^T$ 로 표현하고 헤시안 행렬은 x 위치에서 스케일 σ 로 표현되는 행렬 $\mathbf{H}(x,\sigma)$ 로 정의 된다.

$$\mathbf{H}(x,\sigma) = \begin{bmatrix} L_{xx}(x,\sigma) & L_{xy}(x,\sigma) \\ L_{yx}(x,\sigma) & L_{yy}(x,\sigma) \end{bmatrix} \tag{1}$$

이때 $L(x,\sigma)$ 는 2차 가우시안(Gaussian) 컨볼루션(convolution) 연산을 나타낸다.

그림 2는 SURF를 이용하여 특징을 검출했을 경우의 결과를 보여준다.

영상 A가 있다고 했을 때 여기서 추출된 특징들의 집합은 $S_a = \{s_1, s_2, \dots, s_N\}$, 영상B에서 추출된 특징들의 집합은 $S_b = \{s_1, s_2, \dots, s_M\}$ 라고 하자. 특징 s 는 64차원의 vector로 표시하고 두 집합에서 각 원소의 비교는 L1-norm을 이용한다.

$$\mathbf{s} = [f_1, f_2, \dots, f_{64}]^T \tag{2}$$

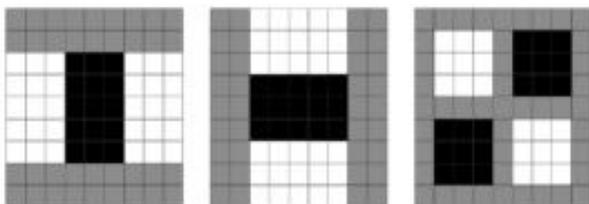


그림 1. 2D Haar wavelet



그림 2. SURF를 이용한 특징 검출

$$L1-norm = \sum_{i=1}^{64} |f_i^a - f_i^b| \tag{3}$$

두 영상에서 추출된 특징들의 비교횟수는 $O(NM)$ 이 되며 일반적으로 영상A을 영상B에서 찾고자 할 때 영상B에서 추출되는 특징의 개수가 상대적으로 커지게 되는데, 이때 어떤 기준에 따라 영상B의 특징들을 정렬하여 비교횟수를 줄이게 된다면 전체적인 알고리즘의 복잡도를 줄일 수 있다.

2.2 PCA를 이용한 SURF특징의 차원 축소

SURF를 이용해서 추출된 특징은 64차원의 vector 형태로 표현 되는데 정렬을 위해서는 아주 큰 데이터이다. 따라서 본 논문에서는 PCA를 이용하여 64차원의 특징을 2차원의 특징으로 축소하여 표현하고 그 특징을 정렬하여 두 벡터의 비교 범위를 제한한다.

PCA는 훈련집합을 이용하여 특징 추출에 사용할 변환 행렬 U 를 추정한다. 훈련집합을 $S = \{s_1, s_2, \dots, s_D\}$ 이라고 표기하고 특징 추출 함수를 $e(s; U)$ 를 [수식 4]와 같이 쓸 수 있다. 원신호 s 와 축소된 특징 벡터 x 가 각각 D 와 d 차원이라면 U 는 $d \times D$ 차원의 행렬이 된다.

$$x = e(s; U) = Us \tag{4}$$

PCA는 신호 S 를 보다 낮은 차원의 특징 벡터 $X = \{x_1, x_2, \dots, x_d\}$ 로 변환하는 것이 목적이므로 $d < D$ 이다. 차원이 줄어들면 당연히 정보 손실이 일어나게 된다. 따라서 PCA의 목적은 정보 손실을 최소화하며 D 차원을 d 차원으로 변환하는 변환행렬 U 를 결정하는 것이다.

PCA를 이용하여 변환 행렬을 구하는 알고리즘은

표 1. PCA 변환 알고리즘

입력 : 훈련집합 S , 축소 차원 d 출력 : 변환행렬 U , 평균벡터 \bar{s}
1. $\bar{s} = \frac{1}{N} \sum_{i=1}^N s_i$ 2. For($i=1$ to N) $s'_i = s_i - \bar{s}$ 3. $s'_i, 1 \leq i \leq N$ 의 공분산 행렬 Σ 를 구한다. 4. Σ 의 고유 벡터와 고유 값을 구한다. 5. 고유 값 기준으로 가장 큰 d 개의 고유 벡터들을 u_1, u_2, \dots, u_d 를 선정한다. 6. 변환 행렬 U 를 만든다. 7. Return U, \bar{s}

다음과 같다.

PCA 알고리즘의 입력으로 모델 영상, 실험 영상에서 각각 추출된 특징집합 S_m, S_t 와 축소할 차원 d 를 입력하면 변환행렬 U 를 구할 수 있다. 수식 5, 6과 같이 구해진 U 를 특징집합의 각 원소들에 적용해 주면 특징들이 d 차원으로 축소되어 표현된다.

$$X_m = U_m \cdot S_m \tag{5}$$

$$X_t = U_m \cdot S_t \tag{6}$$

2.3 PCA-SIFT

회전, 크기, 조명의 변화에 강인하게 특징을 추출하는 방법으로 SURF와 더불어 SIFT는 다양한 영상 처리 분야에서 활용되어온 방법이다. SIFT 알고리즘은 특징이 잘 나타날 수 있는 관심 영역을 탐지하는 단계와 관심 영역을 잘 표현하기 위하여 특징 벡터로 표현하는 2 단계로 구성되어있다. PCA-SIFT는 SIFT 알고리즘의 가장 큰 단점으로 지적되어온 계산량을 줄이기 위하여 Yan Ke에 의해서 제안된 방법이다. SIFT의 특징 기술자(feature descriptor)는 128차원의 특징 벡터로 표현되기 때문에 특징들을 서로 비교할 때 많은 연산량을 요구하게 된다. 하지만 특징을 추출 할 때 PCA 기법을 이용하여 특징을 20차원으로 축소하게 되면 특징의 비교에 필요한 시간을 대략 1/4로 줄일 수 있다.

특징 기술자를 생성하는 과정은 우선 특징 후보 영역 주위의 41×41 의 작은 패치(Patch)들로 나누고 그 영역의 기울기 이미지(gradient image)를 가장 잘 표현하기 위한 고유공간(eigenspace)을 PCA를 이용하여 미리 계산한다. 그리고 그 영역의 기울기 영상



그림 3. 시스템 순서도

을 미리 계산된 고유공간에 사영하여 축소된 PCA-SIFT 특징 기술자를 생성한다.

PCA-SIFT와 본 논문에서 제안하는 방법의 차이점은 PCA-SIFT에서는 특징 자체를 축소하였기 때문에 SIFT가 가지는 고유한 특징이 사라질 수 있다. 반면, 우리가 제안하는 방법에서는 SURF의 특징은 그대로 유지한 상태에서 SURF의 특징들을 PCA로 축소된 값들을 검색범위를 줄이는 과정에서만 사용하고 실제 특징의 비교에서는 원본 SURF를 사용하기 때문에 SURF특징의 고유한 성질을 보존 할 수 있다는 장점이 있다.

3. 차원 축소를 통한 SURF의 계산시간 단축

본 연구에서는 두 영상에서 SURF특징을 추출하고 모델 영상에서 추출된 특징들과 실험영상에서 추출된 특징들을 PCA를 통하여 축소된 특징을 비교하여 매칭률이 가장 높은 특징점을 찾는다. 그리고 두 매칭점 사이의 호모그래피 H 를 구하는 작업을 RANSAC(RANdom SAmples Consensus)[10] 알고리즘을 이용하여 수행하고 모델영상이 실험영상에 어떻게 사영되는지를 시뮬레이션한다, 이 때 두 영상의 특징점을 PCA로 차원 축소하여 정렬하고 일정 범위 안에 있는 특징들만 비교함으로써 비교 시간이 단축 된다는 것을 실험으로 확인한다. 전체적인 시스템의 작동 순서는 그림 3과 같다.

3.1 축소된 특징의 정렬 및 비교

모델 영상의 특징을 실험영상의 특징과 비교할 때 많은 연산량을 요구하게 되는데, 앞 절의 PCA를 통하여 축소된 실험 영상의 특징을 연결리스트(linked list) 자료구조에 정렬하고 제한된 범위의 특징들만을 모델 특징과 비교하면 전체적인 계산시간을 줄일 수 있다. 이때 실험 영상의 특징은 PCA 차원 축소로 감소된 차원의 벡터중 하나의 값을 키로 이용하여

크기로 정렬된 특징을 가지고 있으므로 모델 특징의 키 값으로 실험영상의 특징 값의 일정부분을 인덱싱 하는 것이 가능하다. 축소된 특징의 비교는 마할라노비스 거리(mahalanobis distance)를 사용하였으며 임계값(Th)을 조절하면 실험 영상 특징의 몇 %를 탐색할지를 결정 할 수 있다. 임계값은 실험을 통하여 결정되었으며 탐색 범위는 100%, 15%, 7%로 정의하였다. 모델 영상의 특징이 M 개, 실험 영상의 특징이 T 개라면 상대적으로 T 의 숫자가 커지게 된다. 따라서 그림 4와 같이 비교 대상이 되는 실험영상의 특징들 중에서 모델 영상의 특징과 유사한 값들만을 비교하면 비교횟수를 줄일 수 있다.

PCA를 통하여 차원을 축소하면 특징의 고유한 성질을 완벽하게 표현 할 수 없게 된다. 따라서 단순히 축소된 데이터를 비교한다는 것은 정확도에서 많은 문제를 야기하기 때문에 본 연구에서는 PCA를 통하여 축소된 특징(X_m, X_t)은 비교를 위한 범위를 결정하는데 사용되며 실제적인 비교는 축소되기 전의 데이터(S_m, S_t)를 사용하였다.

연결리스트 자료구조는 일반 배열에 비하여 데이터의 삽입과 삭제가 용이하기 때문에 본 연구에서와

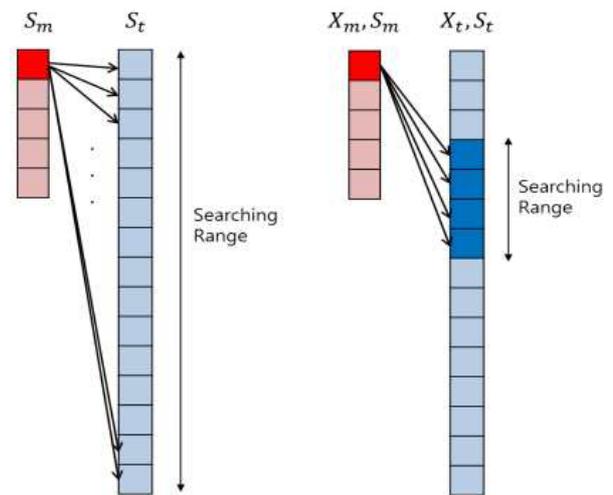


그림 4. 기존 방법(좌), 제안된 방법(우)

같이 자료의 삽입이 많이 발생하는 경우에 적합한 자료구조이다.

이렇게 줄여진 탐색 범위 안에서 최종적으로 FANN알고리즘을 이용하여 두 영상의 매칭점을 계산한다. 정렬 및 비교 알고리즘은 표 2에 나타나있다.

표 2. 정렬 및 비교 알고리즘

```

입력 : 특징 집합  $S_m, S_t$ , 축소된 특징 집합  $X_m, X_t$ , 비교 범위 임계값 Th
출력 : 매칭 결과 Match

1.  $M = \{X_m, S_m\}, T = \{X_t, S_t\}$ 
2. Build L
3. Sort L by the first element of  $X_t$ 
4. for(i=1;i<m;i++){
5.   for(j=1;j<t;j++){
6.     if(dist( $X_m^i, X_t^j$ ) < Th){
7.       Append  $S_m^i$  to  $L^i$ 
8.     }
9.   }
10. }
11. for(i=1;i<m;i++){
12.   if(FANN( $S_m^i, L^i$ )){
13.     Insert  $S_m^i, \overline{S_t^i}$  into Match
14.   }
15. }
16. return Match
    
```

3.2 RANSAC을 이용한 외란 제거

RANSAC은 거짓정보를 포함하는 일련의 데이터 집합으로부터 수학적 모델의 인자들을 반복적인 작업으로 예측하는 기법이다. 기본 가정은 데이터 셋이 참 정보를 포함하고 있다는 것에서 시작한다. 즉, 데이터의 일부 셋이 수학적 모델 인자들로 표현 가능하며, 해당 모델에 맞지 않는 거짓정보들이 있다는 것이다. 이것에 더하여, 데이터는 노이즈로 판명 날 수도 있다. 예를 들어 거짓데이터는 외란의 극값이나 데이터의 잘못된 측정, 혹은 데이터의 해석에 대한 잘못된 가정으로부터 도출될 수 있다. RANSAC은 또한 주어진 (대체로 적은 수의) 참값 들의 집합에서 최적이거나 데이터에 딱 맞는 모델의 인자들을 예측하는 방법이 있다는 것을 가정한다.

RANSAC의 의사 코드는 다음과 같다.

표 3. RANSAC 알고리즘

```

입력 : 관측 데이터  $S = \{s_1, s_2, \dots, s_N\}$ , 임계값 T
출력 : 참값 셋  $t = \{t_1, t_2, \dots, t_n\}$ , 예측 모델 M

1. 임의로 관측데이터에서 N개의 서브데이터를 선택한다.
2. 이 데이터를 이용하여 모델을 예측한다.
3. 예측한 모델을 이용하여 관측 데이터의 정확도를 검증한다.
4. 정확도가 임계값 이상이면, 모델을 확정하고 알고리즘을 종료한다.
5. 모델이 좋지 않으면 1~4과정을 반복한다.
    
```

3.3 호모그래피

평면 호모그래피(planar homography)는 하나의 평면을 다른 평면으로 옮기는 투영 변환을 의미한다. 이러한 변환은 실제 평면 위의 점 p_a 와 영상면에 매핑된 점 p_b 를 각각 동차 좌표계로 표현하는 행렬의 곱셈으로 간단히 나타낼 수 있다.

$$p_a = \begin{bmatrix} x_a \\ y_a \\ 1 \end{bmatrix}, p_b = \begin{bmatrix} w'x_b \\ w'y_b \\ w' \end{bmatrix} \tag{7}$$

$$H_{ab} = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{bmatrix} \tag{8}$$

$$p_b = H_{ab} \cdot p_a \tag{9}$$

이때 H_{ab} 는 변환행렬을 나타내며 w' 는 스케일 팩터를 의미한다.

호모그래피 행렬은 두 영상간에 대응되는 4개의 점을 구하면 간단한 선형방정식으로 구할 수 있다. 하지만 정확도를 높이기 위하여 대응점의 개수를 늘려서 과적합 문제로 만들고, 최소 제곱 오차를 가지는 해를 선정하는 것이 일반적인 방법이다. 하지만 너무 많은 점들을 입력으로 넣게 된다면 오차가 증가하는 문제가 발생하게 되는데 이런 문제를 해결하기 위해서는 RANSAC기법을 이용하여 샘플링 집합에서 외란 데이터(outliers)를 제거한 집합만을 이용하여 호모그래피를 구한다.

4. 실험

모델 영상과 실험 영상에서 각각 SURF 특징을



그림 5. 모델 영상

추출하고 실험 영상의 검색 범위를 100%, 15%, 7%로 줄여가면서 특징의 비교 시간을 기록하였다. 또한 매칭이 완료된 특징점들 중에서 매칭이 정확하게 이루어진 좋은 특징점의 개수를 비교하여 알고리즘의 정확도를 판단하였다.

모델 영상은 300(W) × 300(H) 크기의 알파벳 A 영상이며, 실험 영상은 2560(W) × 1920(H) 크기의 카메라 입력 영상이다. 특징 개수는 Hessian 임계값을 100, 200, 400, 1000, 5000으로 조절하며 수량을 정하였고, 검색범위는 특징의 차원 축소로 얻어진 값의 오차 범위를 조절하여 결정하였다.

표 4와 그림 6에서 확인 할 수 있듯이 탐색 범위를 줄이게 되면 전체적인 탐색 시간에 비례하여 계산 시간이 줄어드는 것을 확인 할 수 있다. 표 5와 그림 7에서 검색 범위를 15%까지 줄였을 경우에 매칭 정확도가 높은 좋은 특징의 개수가 100% 검색했을 때와 거의 비슷한 것을 관찰할 수 있다. 이것은 PCA를 이용하여 검색 범위를 15%까지 줄이더라도 정확도의 차이는 크게 안 나지만 그 이하로 줄일 경우에는 원본 데이터와 매칭 성능의 차이를 보인다는 것을 나타낸다. 본 논문에서는 검색 범위를 15%로 제한하기 위하여 PCA 기법이 적용 되었는데 이 때의 계산 시간은 그림 8과 같이 특징의 개수가 증가 하더라도 크게 변화가 없는 것을 확인 할 수 있다.

그림 9에서 PCA를 이용하여 탐색 범위를 15%로 축소한 알고리즘과 100%를 탐색한 알고리즘의 계산 시간을 비교한 결과를 확인 할 수 있는데 특징의 개수가 아주 작을 때에는 성능이 더 안 좋거나 유사하지만, 특징의 개수가 증가하면 성능이 가파르게 향상되는 것을 확인 할 수 있다.

그림 9에서 확인 할 수 있듯이 본 연구에서 제안한

표 4. 특징 개수에 따른 탐색 시간 (Millisecond)

특징점 개수(개)		검색 범위		
모델 영상	실험 영상	7%	15%	100%
339	779	1.7	2.4	16
485	2505	3.5	6.3	42
542	4638	5.1	11.0	73
562	7263	9.0	17.0	111
579	10488	14	26.0	161

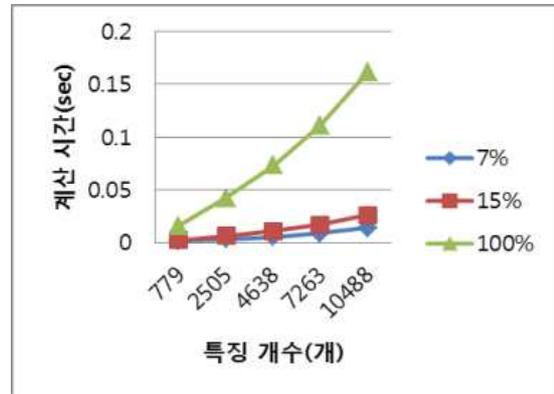


그림 6. 특징 개수와 탐색 범위에 따른 계산 시간

표 5. 탐지된 좋은 특징의 개수 (개)

특징점 개수(개)		검색 범위		
모델 영상	실험 영상	7%	15%	100%
339	779	43	94	101
485	2505	71	153	161
542	4638	85	168	184
562	7263	97	201	213
579	10488	107	215	231

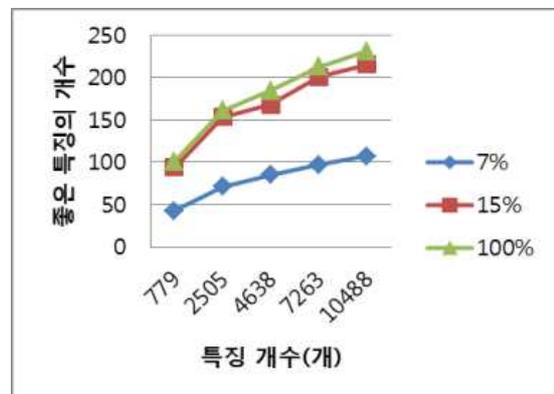


그림 7. 특징 개수와 탐색 범위에 따른 좋은 특징의 개수

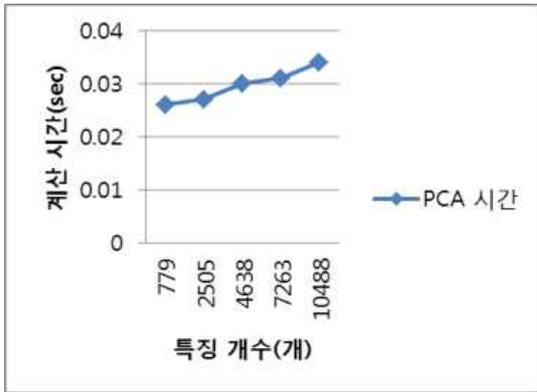


그림 8. 특징 개수에 따른 PCA계산 시간



그림 9. 기존 방법과 제안한 방법의 계산시간 비교

방법을 적용하여 모델 영상을 실험 영상에서 탐지하였다. 특징 매칭을 수행할 경우에 SURF알고리즘의 특징인 크기, 방향의 변화에 강인하게 물체를 탐지

할 수 있으며 계산 시간을 단축 할 수 있었다.

Inria Dataset을 이용하여 PCA-SIFT와 본 논문에서 제안한 방법의 좋은 특징 개수와 매칭률을 비교하였고 그림 11과 그림 12를 통하여 그 결과를 확인할 수 있다. Inria Dataset에서는 두 영상의 변환 행렬을 제공 하는데 이 자료를 기준으로 매칭률을 검증하였다. 표 6에서 확인할 수 있듯이, 전체적으로 PCA-SIFT에서는 좋은 특징의 개수가 비교적 많이 검출되었지만 매칭률에서는 본 논문에서 제안한 방법이 더 좋은 결과를 보였다. 조명의 변화와 크기 및 회전 변화에는 본 논문에서 제안한 방법이 더 효과적인 반면 뷰포인트의 변화에는 PCA-SIFT가 더 뛰어난 성능을 보이는 것으로 나타났다. 이 결과는 Juan에 의해서 수행된 SIFT, PCA-SIFT와 SURF특징의 비교실험에서 나타난 결과와 유사한 것을 확인할 수 있다[11].

5. 결 론

본 논문에서는 컴퓨터 비전과 영상처리 알고리즘에서 폭넓게 사용되고 있는 특징의 비교 성능을 개선하기 위한 방법을 연구하였다.

PCA알고리즘을 사용하여 특징의 차원 수를 축소하고 연결리스트 자료구조에 정렬하여 탐색 범위를 줄이는 기법을 제안하고 실험을 통하여 그 성능을 검증하였다. 제안된 기법을 이용할 경우 파노라마 영



그림 10. 실험 영상에서 모델 이미지 탐지 결과

표 6. PCA-SIFT와 제안된 방법의 비교 결과

	PCA-SIFT		제안된 방법	
	좋은 특징(개)	정확도(%)	좋은 특징(개)	정확도(%)
선명도 변화	78	95%	37	96%
조명 변화	120	64%	110	92%
뷰포인트 변화	334	75%	105	69%
크기 및 회전 변화	713	45%	150	53%

상의 제작, 스테레오영상의 획득, 물체인식, 이미지 분석 등에서 전체적인 알고리즘의 성능을 향상시킬 수 있을 것으로 기대 된다.

다음 연구로는 제안된 기법을 SIFT, FAST, ORB, STAR 등과 같은 다른 특징 검출 알고리즘에 적용하여 성능을 검증할 계획이다.

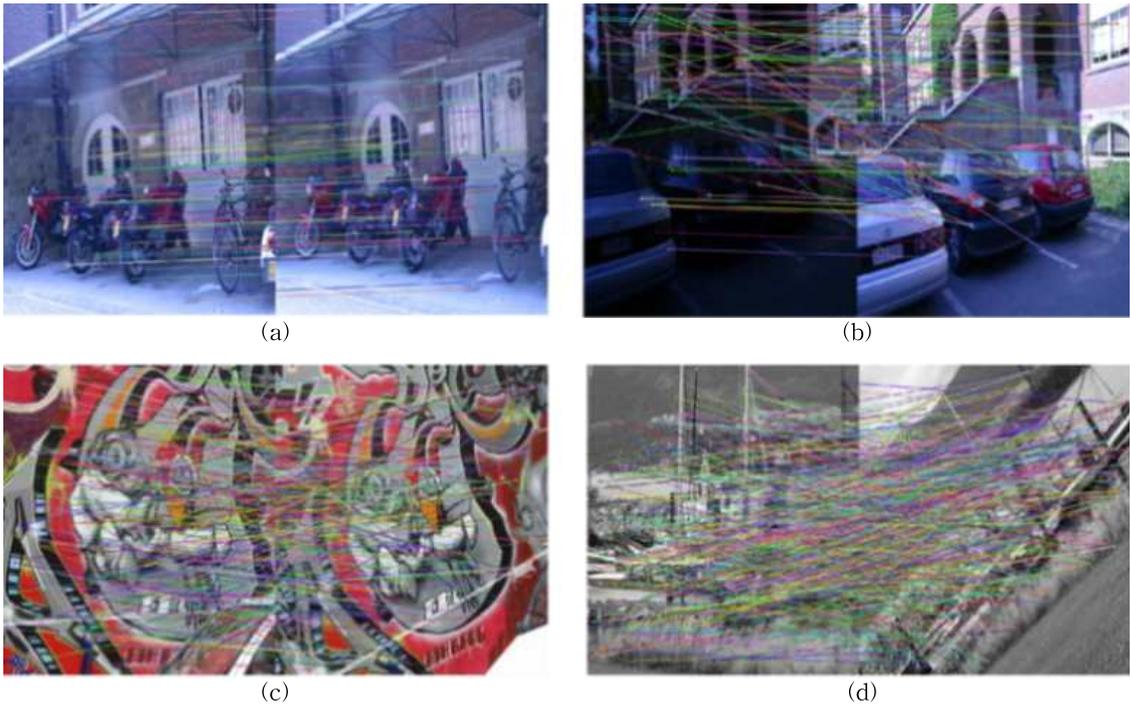


그림 11. Inria Dataset을 이용한 PCA-SIFT 매칭률 비교. (a) 선명도 변화. (b) 조명의 변화. (c) 뷰포인트의 변화. (d) 크기 및 회전 변화

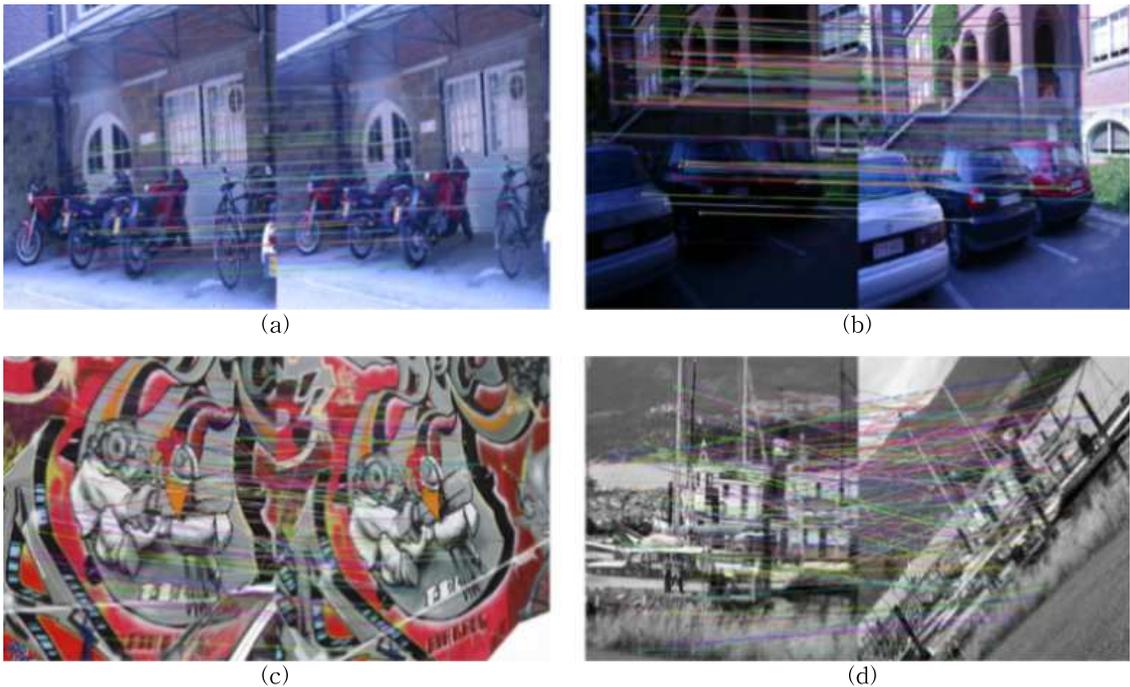


그림 12. Inria Dataset을 이용한 제안된 방법의 매칭률 비교. (a) 선명도 변화. (b) 조명의 변화. (c) 뷰포인트의 변화. (d) 크기 및 회전 변화

참 고 문 헌

[1] 라연, 신성식, 박현주, 권오봉, “SURF와 멀티밴드 블렌딩에 기반한 파노라마 스티칭”, 멀티미디어학회논문지, 제 14권, 제 2호, 201-209, 2011

[2] Y. Ke, and R. Sukthankar, “PCA-SIFT: A More Distinctive Representation for Local Image Descriptors”, *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Vol. 2, 506-513, 2004

[3] S. Wold, K. Esbensen, and Paul Geladi, “Principal Component Analysis”, *Chemometrics and Intelligent Laboratory Systems 2.1*, Vol. 2, No. 1, 37-52, 1987

[4] Valenzuela, R. E. González, W. Schwartz, and H. Pedrini, “Dimensionality Reduction Through PCA over SIFT and SURF Descriptors”, Vol. 1, 58-63, 2012

[5] P.M. Vaidya, “AnO (n logn) Algorithm for the All-Nearest-Neighbors Problem”, *Discrete & Computational Geometry 4.1*, Vol. 4, No. 1, 101-115, 1989

[6] A.W. Moore, *An Introductory Tutorial on Kd-trees*, Extract from Ph.D. Thesis, University of Cambridge, 1991

[7] H. Bay, T. Tuytelaars, and L. Van Gool. “Surf: Speeded up Robust Features.” *Computer Vision - ECCV*, 404- 417. 2006

[8] M. Marius, and David G. Lowe. “Fast Approximate Nearest Neighbors with Automatic Algorithm Configuration”, *International Conference on Computer Vision Theory and Applications*, Vol.1, 331-340, 2009

[9] A. Graps, “An Introduction to Wavelets.” *Computational Science & Engineering IEEE*, Vol. 2, No. 2, 50-61, 1995

[10] M. A. Fischler and R. C. Bolles, “Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography”, *Communications of the ACM*, Vol. 24, No. 6, 381-395, 1981

[11] L. Juan, and O. Gwun., “A Comparison of Sift, Pca-Sift and Surf”, *International Journal of Image Processing (IJIP)*, Vol. 3, No. 4, 143-152, 2009

[12] 오일석, “패턴인식”, 교보문고, 서울, 2008

[13] 개리 로스트 브라드스키, 에이드리안 켈러, “Learning OpenCV 제대로 배우기,” 한빛미디어, 서울, 2009



김 원 규

2000년 3월~2007년 2월 동명대학교 컴퓨터공학과 학사
 2000년 3월~현재 부산대학교 기계공학부 석·박사 통합과정
 관심 분야 : 컴퓨터 비전, SLAM, 스테레오 비전, 3차원 복원



강 동 중

1988년 2월 부산대 기계공학부 학사
 1990년 2월 KAIST 기계공학과 석사
 1999년 2월 KAIST 대학원 자동차 및 설계공학과 박사
 1990년~1992년 현대전자 연구원
 1997년~1999년 삼성종합기술원 신호처리연구실 선임 연구원
 2004년 Cornell Univ. 연구원
 2000년~2005년 동명대 메카트로닉스공학과 조교수
 2006년~현재 부산대 기계공학부 부교수
 관심 분야 : 컴퓨터 비전, 이동로봇, 공장에서의 영상검사 시스템 개발