

퍼지 분류기법을 이용한 강건한 카메라 동작 추정

이 중재[†] · 김 계영^{‡‡} · 최형일^{***}

요약

본 논문에서는 두 영상간의 대응관계로부터 퍼지 분류기법을 이용한 강건한 카메라 동작 추정 방법을 제안한다. 제안한 방법에서는 이상치가 존재할 때 정확한 카메라 동작을 추정하기 위하여 대표적인 강건 예측기법인 RANSAC 알고리즘을 사용한다. 그런데 RANSAC은 사전에 결정되는 이상치의 비율에 따라 정확도가 좌우되는 샘플링 문제점을 가지고 있다. 이러한 문제점을 개선하기 위해 샘플링 시에 퍼지 분류기법을 이용하여 전체 샘플을 좋은, 모호한, 나쁜 샘플로 분류한다. 그런 후에 좋은 데이터에 대해서만 샘플링을 수행함으로써 이상치 제거에 대한 정확도를 향상시킨다. 실험에서는 호모그래피 계산에 대한 성능을 비교함으로써 제안한 방법의 우수함을 보인다.

키워드 : 카메라 동작, 호모그래피, 퍼지 분류, RANSAC, 이상치

Robust Estimation of Camera Motion using Fuzzy Classification Method

Joong-Jae Lee[†] · Gye-Young Kim^{‡‡} · Hyung-il Choi^{***}

ABSTRACT

In this paper, we propose a method for robustly estimating camera motion using fuzzy classification from the correspondences between two images. We use a RANSAC(Random Sample Consensus) algorithm to obtain accurate camera motion estimates in the presence of outliers. The drawback of RANSAC is that its performance depends on a prior knowledge of the outlier ratio. To resolve this problem, the proposed method classifies samples into three classes(good sample set, bad sample set and vague sample set) using fuzzy classification. It then improves classification accuracy omitting outliers by iteratively sampling in only good sample set. The experimental results show that the proposed approach is very effective for computing a homography.

Key Words : Camera Motion, Homography, Fuzzy Classification, Ransac, Outlier

1. 서론

컴퓨터 비전분야에서 활발히 연구되고 있는 분야로서 증강현실, 3차원 복원, 자가 위치 추정, 영상기반 랜더링 등이 있다. 이러한 연구 분야의 공통점을 살펴보면 정확한 카메라 동작 계산이 요구되는 것이다. 카메라 동작을 계산하기 위해서는 3차원 실세계 좌표공간을 표현할 수 있는 카메라 모델이 필요한데 그동안 다양한 방법들이 소개되었다[1]. 그 가운데 호모그래피는 인접한 두 영상에서 평면구조상에 존재하는 특징점들의 대응관계로부터 카메라의 동작을 기술할 수 있는 모델이다. 이 모델은 비교적 단순하고 카메라의 이동량이 작고 평면구조를 포함하면서 거리가 멀다는 조건을 만족하는 경우에 실제 영상을 훌륭하게 근사화할 수 있는

장점이 있기 때문에 3차원 구조복원, 영상정렬, 영상모자이 등에 많이 사용되고 있다[2]. 호모그래피를 이용하여 정확한 카메라 동작을 계산하기 위해서는 영상간의 정확한 대응관계를 선택하는 것이 선행되어야 한다. 그 이유는 카메라 인수를 계산하는데 대응관계가 입력으로 사용되기 때문이다. 다시 말해서, 입력으로 선택된 대응관계 중에서 부정확한 경우가 포함된다면 그 결과는 신뢰성이 떨어진다. 따라서 정확한 카메라 동작 계산을 위해서 잡음, 특히 이상치를 제거할 수 있는 강건한 예측(robust estimation)기법이 많이 사용된다. 여기서 강건한 예측이란 정확한 모델인수를 예측하기 위해서 이상치를 배제시키고 유효한 데이터만을 사용하여 모델인수를 결정하는 방법을 말한다. 대표적으로 사용되는 강건한 예측기법에는 LMedS(least median of square)와 M-estimator가 있다[3,4]. LMedS는 잔여오차 제곱값에 대한 중간(median)값을 최소로 만드는 경우를 최적의 해로 판단하는 방법으로서 간단하면서도 사전지식을 필요로 하지 않는 장점이 있다. 그러나 중간값을 사용한다는 사실로부터

* 본 연구는 숭실대학교 교내연구비 지원으로 이루어졌다.

† 정회원: 한국과학기술연구원 지능로봇연구센터(박사후연구원)

‡‡ 종신회원: 숭실대학교 컴퓨터학부(조교수)

*** 종신회원: 숭실대학교 미디어학부 교수

논문접수: 2006년 9월 1일, 심사완료: 2006년 10월 25일

이상치의 비율이 50%를 넘는 경우에는 중간값을 이상치로 오인식 하는 문제점이 있다. 반면에 M-estimator는 통계적 효율성이 높으나 데이터가 적절하게 초기화 되지 않으면 처리할 수 있는 이상치의 비율이 많이 낮아진다[5]. 앞서 소개한 방법과 함께 카메라 동작 계산에서 이상치를 제거하는 방법으로 가장 많이 사용되는 강건한 예측기법으로 RANSAC(Random Sample Consensus)이 있다[6]. RANSAC은 전체 데이터 중에서 모델 인수를 결정하는데 필요한 최소의 데이터를 랜덤하게 샘플링하면서 반복적으로 해를 계산함으로써 최적의 해를 찾는다. 이 방법은 전통적인 데이터 스무딩(smoothing) 기법과는 반대의 개념을 가진다. 즉, 대부분의 방법들이 초기의 해를 획득하기 위해서 가능한 많은 데이터를 사용하고 그 결과로부터 비유효한 데이터를 제거한다. 반면에 이 방법은 가능한 적은 양의 초기 데이터를 사용해서 일관된 데이터의 집합(consensus set)을 확장시켜가는 방식을 사용한다. 그런데 이러한 RANSAC에는 다음과 같은 문제점이 있다.

첫째, 기존의 RANSAC 알고리즘은 확률통계 이론에 기초하여 수렴 시 까지 매번 복원 랜덤 샘플링을 수행한다. 그러므로 사전에 정확한 이상치의 비율을 알지 못하면 샘플링 시에 진동과 같은 문제점이 발생하면서 최적의 해를 결정할 수 없게 된다. 이러한 문제점이 발생하는 근본적인 원인은 현재시점의 해를 결정할 때 이전 시점에서 결정된 해에 대한 정보를 사용할 수 없다는 것이다. RANSAC-f는 이 문제점을 해결하기 위해서 매시점마다 최적의 n개의 해에 대한 순서리스트를 유지하는 방식을 사용한다[7]. 매시점마다 새롭게 해를 결정하는 것이 아니라 각시점마다 유지되는 리스트로부터 최상의 해를 평균해서 생성되는 새로운 해가 더 최적의 해가 될 수 있는지를 결정한다. 이런 방식을 사용하여 최종적으로 가장 최적의 해를 도출해 낸다. 또 다른 방법으로는 중요도 샘플링 기법을 RANSAC에 적용한 IMPSAC이 있다[8]. 이 방법에서는 랜덤하게 샘플링을 수행하는 RANSAC과는 달리 중요도가 높은 샘플을 샘플링함으로써 해의 정확도를 높인다.

둘째, 기존 방법에서는 정상치와 이상치를 분류하기 위해서 하드분할(hard partitioning)을 사용한다. 이것은 데이터에 따라서 정상치와 이상치로 구별하기가 모호한 데이터까지도 어느 한쪽의 집합으로 소속시킴으로써 수렴의 정확도를 감소시키는 문제점이 있다. 그리고 이때 정상치와 이상치를 판단하기 위해 사용하는 임계값 결정 역시 잔여오차(residual)의 분포가 카이제곱(χ^2) 분포를 따른다는 가정을 만족해야 한다.

따라서 본 논문에서는 통계이론을 기반으로 하는 기존의 RANSAC 알고리즘이 수렴 시 까지 매번 복원 랜덤 샘플링을 수행하기 때문에 모집단의 분포에 따라서 민감한 결과를 보이는 문제점을 보완한 방법을 제안한다. 제안하는 방법은 기존 방법의 문제점을 해결하기 위해서 매 반복 수행시마다 페지분류기법을 적용하여 전체 샘플을 좋은 샘플집합과 나쁜 샘플집합 그리고 모호한 샘플집합으로 분류한다. 그런 후에 좋은 샘플집합에서만 샘플링을 해나감으로써 이상치

제거율에 대한 정확도를 향상 시킨다. 그 결과 효과적으로 이상치를 제거할 수 있으므로 보다 정확한 카메라 동작 계산이 가능하다.

2장에서는 호모그래피를 이용한 카메라 동작 추정 방법에 대해서 소개하고 3장에서는 본 논문에서 제안한 페지분류기법을 이용한 이상치 제거 방법에 대해서 기술한다. 4장에서는 호모그래피 계산 문제에 대한 기존 방법과의 성능을 비교한 실험결과를 보인다. 마지막으로 5장에서는 본 논문의 결론을 맺는다.

2. 호모그래피를 이용한 카메라 동작 추정

카메라 동작을 기술할 수 있는 많은 모델이 존재하지만 본 논문에서는 3차원 평면 구조 추적을 이용한 이웃하는 영상 간의 호모그래피 계산 방법을 사용한다. 호모그래피는 두 영상 간의 일대일 매핑으로서 8개의 인수로 정의된다. 그리고 비교적 간단한 모델이기 때문에 카메라의 이동량이 작고 평면구조를 포함하면서 거리가 멀다는 조건을 만족하는 경우에 실제 영상을 훌륭하게 근사화할 수 있다. (그림 1)에서는 3차원 평면구조로부터 유도되는 호모그래피에 대한 개념을 보여주고 있다. 즉, 동일한 3차원 평면상의 점들에 대해 2차원 영상에 원근 투영된 점들 간의 대응관계로부터 이웃하는 영상 간의 호모그래피를 계산할 수 있으며, 이 결과로부터 어떠한 카메라 동작이 발생했는지를 알아낼 수 있다.

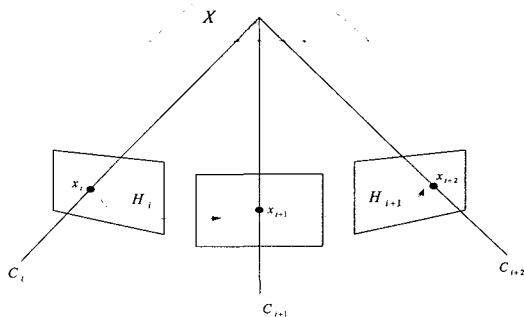
이러한 호모그래피의 계산은 이웃하는 영상에서 획득된 네 쌍의 점들에 대한 대응관계로부터 직접 선형 변환인 DLT(Direct Linear Transformation) 알고리즘에 의해서 수행되는데 그 과정은 다음과 같다.

첫 번째 영상에 대한 동차좌표를 $x = (x, y, w)^T$, 그리고 이 좌표에 대응하는 두 번째 영상에 대한 동차좌표를 $x' = (x', y', w')^T$ 라 하고 두 좌표간의 대응관계를 $x \leftrightarrow x'$ 라 할 때 식 (1)과 같은 관계식을 만족하면 두 영상 사이에는 호모그래피 H 가 존재한다.

$$x' = Hx$$

$$\begin{bmatrix} x' \\ y' \\ w' \end{bmatrix} = \begin{bmatrix} h_1 & h_2 & h_3 \\ h_4 & h_5 & h_6 \\ h_7 & h_8 & h_9 \end{bmatrix} \begin{bmatrix} x \\ y \\ w \end{bmatrix} \quad (1)$$

식 (1)로부터 좌표 x' 는 호모그래피 H 에 의한 x 좌표의 사상(mapping)이라는 것을 알 수 있다. 또한 여기서 사용하는 좌표들이 동차좌표이기 때문에 각 영상의 대응하는 좌표들에 대해서 호모그래피는 카메라의 중심을 통과하는 광선(ray)에 대한 간단한 선형 변환으로 정의된다. 그러므로 호모그래피 H 를 계산하는 방법은 정의상 x' 와 Hx 이 같은 방향을 가리키는 광선 상의 좌표라는 성질을 이용한다. 즉, 식 (2)와 같이 x' 와 Hx 에 대한 외적의 값이 0이 되고 이 관계



(그림 1) 평면구조부터 유도되는 호모그래피

식을 이용하면 호모그래피 H 를 쉽게 구할 수 있다. 식 (2)에서 h_i 는 호모그래피 행렬 H 에 대한 i 번째 행벡터를 의미한다.

$$\mathbf{x}' \times H\mathbf{x} = 0$$

$$\mathbf{x}' \times H\mathbf{x} = \begin{pmatrix} y' h_3^T \mathbf{x} - w' h_2^T \mathbf{x} \\ w' h_1^T \mathbf{x} - x' h_3^T \mathbf{x} \\ x' h_2^T \mathbf{x} - y' h_1^T \mathbf{x} \end{pmatrix} = 0 \quad h = \begin{pmatrix} h_1 \\ h_2 \\ h_3 \end{pmatrix} \quad (2)$$

식 (2)로부터 호모그래피 H 를 계산하는 과정은 다음과 같다.

$$\begin{bmatrix} 0^T & -w' \mathbf{x}^T & y' \mathbf{x}^T \\ w' \mathbf{x}^T & 0^T & -x' \mathbf{x}^T \\ -y' \mathbf{x}^T & x' \mathbf{x}^T & 0^T \end{bmatrix} \begin{pmatrix} h_1 \\ h_2 \\ h_3 \end{pmatrix} = 0 \quad (3)$$

식 (2)는 식 (3)과 같이 정리할 수 있으며, 다시 식 (3)은 식 (4)와 같이 표현될 수 있다. 그런데 식 (4)에서 3개의 방정식이 만들어지지만 이 중에서 두 개의 방정식만이 선형독립 관계를 만족하기 때문에 세 번째 방정식은 생략이 가능하다.

$$\begin{bmatrix} 0^T & -w' \mathbf{x}^T & y' \mathbf{x}^T \\ w' \mathbf{x}^T & 0^T & -x' \mathbf{x}^T \end{bmatrix} \begin{pmatrix} h_1 \\ h_2 \\ h_3 \end{pmatrix} = 0 \quad (4)$$

마지막으로 식 (4)는 식(5)와 같이 표현될 수 있으며, 식 (5)에서 A 는 2×9 행렬을 나타낸다. 식 (5)에서 호모그래피를 기술하는 행렬의 원소가 9개로 구성되어 있지만 동차 좌표를 사용하기 때문에 크기(scale)에 대해서는 고려하지 않아도 된다.

$$A\mathbf{h} = 0 \quad (5)$$

따라서 호모그래피를 계산하는 과정에서는 실제로 8개의 원소만을 결정하면 되므로 앞서 언급한바와 같이 이웃하는 두 영상으로부터 네 쌍의 대응관계가 주어지면 호모그래피를 결정할 수 있다. 즉, 동일직선(collinear)상에 존재하지 않는 네 점의 대응관계로부터 식 (5)와 같은 방정식이 성립하

고 이 방정식의 해 \mathbf{h} 는 8×9 크기인 A 행렬의 널 공간(null-space)이다. 그리고 이 해는 SVD (Singular Value Decomposition) 방법에 의해서 구할 수 있다[9].

3. 퍼지분류 기법을 이용한 이상치 분류

카메라 동작을 계산할 때 그 결과는 입력으로 사용하는 대응관계의 정확도에 따라 좌우된다. 즉 대응관계 중에 이상치가 포함되어 있으면 정확한 카메라 동작을 계산할 수 없다. 따라서 카메라 동작 계산 시에 이상치를 제거하고 정상치(inlier)만을 사용하는 것이 매우 중요하다. 본 논문에서는 이런 측면에서 보다 정확하게 이상치를 제거하기 위해 기존의 RANSAC 알고리즘에 퍼지분류 기법을 접목한 방법을 제안한다. 즉, 모든 데이터를 정상치 또는 이상치의 이진 데이터로만 분류하는 대신 정상치와 이상치에 대한 0부터 1 사이의 소속정도를 가지는 퍼지집합으로 표현한다. 구체적으로 본 논문에서는 데이터가 어느 정도 정상치에 소속되는지를 나타내는 소속정도와 정상치에 대한 소속정도의 변화율을 퍼지화하여 데이터 분류에 사용한다.

본 논문에서 제안한 방법의 개요는 다음과 같다.

첫째, 퍼지 분류방법을 이용하여 전체데이터를 분류하여 샘플링을 수행한다[10]. 기존 방법의 수렴 시까지 매번 복원 랜덤 샘플링을 수행하는 방식 대신에 샘플링을 수행한 후 전체 데이터를 좋은 샘플집합, 나쁜 샘플집합, 모호한 샘플집합으로 분류한다. 그리고 다음번 샘플링 시에는 전체 데이터에서 샘플링을 수행하지 않고 좋은 샘플 집합에 대해서만 랜덤 샘플링을 수행한다. 이렇게 함으로써 진동 문제를 해결함과 동시에 샘플링의 정확도를 향상시킨다.

둘째, 수렴여부에 대한 판단 기준의 수치적 확신도에 대한 설명을 제공한다. 기존 방법에서는 미리 정의된 임계값 범위 내에 있으면 정상치로 그렇지 않으면 이상치로 분류하여 정상치에 대한 개수를 통해 수렴여부를 결정한다. 따라서 정상치로 분류된 데이터가 얼마나 정확한 데이터인지에 대한 설명이 부족하다. 이러한 점을 보완하기 위해서 좋은 샘플집합, 나쁜 샘플집합, 모호한 샘플집합에 대한 응집성(coherency), 분리성(isolation), 모호성(vagueness)과 같은 분류 척도를 제공함으로써 분류 결과를 평가 할 수 있도록 한다.

<표 1>은 제안한 방법에서 사용하는 용어의 정의를 보여준다.

<표 1> 제안한 방법에서 사용하는 용어 정의

용 어	의 미
정상치	잔여오차가 작은 데이터
이상치	잔여오차가 큰 데이터
좋은 샘플 집합	정상치에 대한 소속정도가 크고 소속정도의 변화율이 거의 없는 데이터 집합
나쁜 샘플 집합	이상치에 대한 소속정도가 크고 소속정도의 변화율이 거의 없는 데이터 집합
모호한 샘플 집합	소속정도에 관계없이 소속정도의 변화율이 큰 데이터의 집합

3.1 입력에 대한 퍼지화 및 소속함수의 정의

퍼지 분류에 대한 입력으로는 각각 정상치에 대한 소속정도와 이 소속정도의 변화율을 나타내는 벡터 $x = [x_1, x_2]$ 를 사용한다. 이때 정상치에 대한 소속정도는 데이터에 대한 잔여오차를 통해 계산된다. 여기서 각 입력에 대한 언어적 표현은 다음과 같다.

- 입력1(x_1): “정상치에 대한 소속정도가 작다/중간/크다”
- 입력2(x_2): “정상치에 대한 소속정도의 변화율이 낮다/중간/높다”

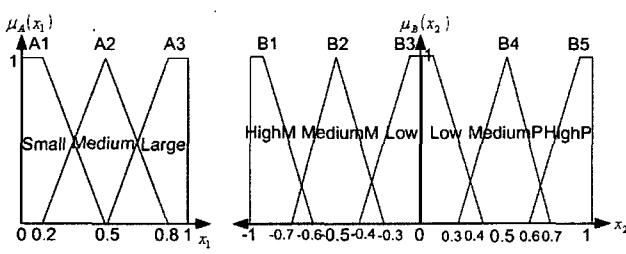
식 (6)은 i 번째 데이터의 정상치에 대한 소속정도를 나타내는데, 여기서 소속정도는 잔여오차의 제곱에 반비례함을 알 수 있다. 즉, 잔여오차가 크면 정상치에 대한 소속정도가 감소하고 반대의 경우에는 소속정도가 증가한다. 식 (6)에서 r_i 는 i 번째 데이터에 대한 잔여오차를, r_{\max} 는 잔여오차 중에서 최대값을 나타내며 정상치에 대한 소속정도는 0과 1사이의 값을 가진다.

$$x_1^i = D(r) = 1 - \left(\frac{r_i}{r_{\max}} \right)^2 \quad (6)$$

식 (7)은 i 번째 데이터의 정상치에 대한 소속정도 변화율을 나타내며, 소속정도의 변화율은 현재 단계에서 계산된 소속정도와 이전 단계에서 계산된 소속정도의 차이로 정의 한다. 따라서 소속정도의 변화율은 -1에서 1사이의 값을 가진다.

$$x_2^i = \Delta x_1^i = x_1^i(t) - x_1^i(t-1) \quad (7)$$

(그림 2)는 각 입력에 대한 소속함수를 보여준다. (그림 2)의 (a)는 첫 번째 입력인 정상치에 대한 소속함수로서 “소속정도가 작다, 중간, 크다”的 세부분으로 구성된다. 그리고 (그림 2)의 (b)는 두 번째 입력인 정상치 소속정도의 변화율에 대한 소속함수를 나타내는데 “소속정도의 변화율이 낮다, 중간, 높다”로 구성된다.



(a) 정상치 소속정도 (b) 정상치 소속정도의 변화율

(그림 2) 퍼지 소속함수

3.2 엔트로피를 이용한 초기 데이터 선정

퍼지 분류 방법을 이용하여 전체 데이터를 정확하게 좋은 샘플집합, 나쁜 샘플집합, 모호한 샘플집합으로 분류하기 위해서는 초기 데이터 선정이 중요하다. 이것은 반복적으로 퍼지 분류가 수행될 때 전체 데이터에서 랜덤 샘플링을 수행하는 것이 아니라 좋은 샘플 집합으로 분류된 데이터 집합에서만 랜덤 샘플링을 수행하기 때문이다. 즉, 초기에 좋은 샘플집합으로 결정하는 데이터에 대한 판단 정확도가 전체 결과에 큰 영향을 미치게 된다. 본 논문에서는 초기 데이터에 대한 정확한 선정을 위해서 식 (8)과 같이 특징 값들의 비균일도 또는 무질서도를 측정하는데 사용되는 엔트로피(entropy)를 사용한다. 엔트로피는 통계학이나 코딩이론에서 널리 사용되는 개념으로 전체 데이터에 대한 확률 분포와 불확실성(uncertainty)을 나타낸다[11]. 즉, 모집단이 균일한 분포를 이루는 경우에는 높은 값의 엔트로피를 가지며, 비균일한 분포를 이루는 경우에는 낮은 값의 엔트로피를 가진다. 다시 말해서, 엔트로피가 높은 경우에는 데이터 간의 변별력이 낮아지며 반대의 경우에는 데이터 간의 변별력이 높아진다.

$$\text{entropy}(x) = - \sum_{i=1}^n p(x_i) \log(p(x_i)) \quad (8)$$

식 (8)에서 $p(x_i)$ 는 i 번째 샘플이 발생할 확률을 의미하고, 모집단의 엔트로피는 0과 1사이의 값을 가진다.

본 논문에서는 잔여오차와 관련된 정상치의 소속정도에 대한 엔트로피를 이용하여 초기 데이터를 선정하는데, 식 (9)와 같이 엔트로피 값이 임계값 TH_e 보다 작으면 초기 데이터로 선정하고 그렇지 않으면 샘플링을 재수행한다.

$$\begin{aligned} & \text{if } \text{entropy}(x_1) < TH_e \text{ then initialize data} \\ & \text{otherwise do resampling} \end{aligned} \quad (9)$$

3.3 퍼지규칙의 정의 및 퍼지추론

본 절에서는 퍼지분류에 사용되는 퍼지규칙의 정의와 생성된 퍼지규칙을 통하여 퍼지추론을 수행하는 방법에 대해서 기술한다. 퍼지 규칙은 식 (10)과 같이 퍼지 값으로 결합된 조건부와 결론부로 구성되며 각 규칙은 확신도(CF : Certainty Factor)를 가진다. 그런데 본 논문에서는 모든 규칙의 확신도를 1로 사용하기 때문에 퍼지규칙을 표현하는데에서 확신도는 생략하기로 한다.

$$R_i : \underline{\text{If } x_1 \text{ is } A_{il} \text{ and } x_2 \text{ is } B_{in} \text{ Then } y \text{ is } C_i (CF_i)} \quad (10)$$

식 (11)은 제안한 방법에서 사용하는 총 15개의 전체 퍼지규칙을 보여준다.

- R1 : If x_1 is Small and x_2 is HighM Then y is Vague
R2 : If x_1 is Small and x_2 is MediumM Then y is Vague
R3 : If x_1 is Small and x_2 is Low Then y is Bad
R4 : If x_1 is Small and x_2 is MediumP Then y is Vague
R5 : If x_1 is Small and x_2 is HighP Then y is Vague
R6 : If x_1 is Medium and x_2 is HighM Then y is Vague
R7 : If x_1 is Medium and x_2 is MediumM Then y is Vague
R8 : If x_1 is Medium and x_2 is Low Then y is Vague
R9 : If x_1 is Medium and x_2 is MediumP Then y is Vague
R10 : If x_1 is Medium and x_2 is HighP Then y is Vague
R11 : If x_1 is Large and x_2 is HighM Then y is Vague
R12 : If x_1 is Large and x_2 is MediumM Then y is Vague
R13 : If x_1 is Large and x_2 is Low Then y is Good
R14 : If x_1 is Large and x_2 is MediumP Then y is Vague
R15 : If x_1 is Large and x_2 is HighP Then y is Vague
(11)

다음은 15개의 퍼지규칙 중에서 대표적인 3개의 규칙에 대한 정의와 각 규칙이 가지고 있는 의미에 대한 설명이다.

- [R1] If x_1 is Small and x_2 is HighM Then y is Vague:
“소속정도가 작고 소속정도의 변화율이 높으면 모호한 샘플집합의 원소이다”
[R3] If x_1 is Small and x_2 is Low Then y is Bad:
“소속정도가 작고 소속정도의 변화율이 낮으면 나쁜 샘플집합의 원소이다”
[R13] If x_1 is Large and x_2 is Low Then y is Good:
“소속정도가 크고 소속정도의 변화율이 낮으면 좋은 샘플집합의 원소이다”

이와 같이 퍼지규칙이 생성되면 생성된 여러 규칙으로부터 결론을 도출해 내기 위한 추론과정이 필요하다. 퍼지추론 과정은 입력 데이터에 대한 퍼지 소속 함수의 소속정도에 따라 min-max 퍼지연산을 적용하여 퍼지규칙에 대한 추론을 수행하게 된다.

식 (12)는 입력벡터 x 에 대해서 i 번째 규칙의 지지도(degree of support)인 $w_i(x)$ 를 계산하는 방법을 보여준다. 여기서 조건부의 만족도를 합성할 때 일반적으로 많이 사용되는 연산은 min 또는 product인데 본 논문에서는 식 (12)와 같이 min 연산을 사용한다.

$$w_i(x) = \min(u_A^i(x_1), u_B^i(x_2)) \quad (12)$$

이와 같이 입력벡터 x 에 대해서 모든 규칙의 지지도가 계산되면 계산된 지지도에 따라 최종적으로 규칙을 결정한다. 식 (13)은 최대 지지도를 가지는 규칙에 따라 해당하는 클래스를 결정하는 방법을 보여준다. 즉, 모든 규칙의 지지도 중에서 가장 큰 값을 갖는 규칙을 찾아서 그 규칙의 결론부에 해당하는 클래스가 퍼지추론의 최종결과가 된다.

$$y^* = \arg \max_i (w_i(x)) \\ \text{where } w_i(x) = [w_1(x), w_2(x), \dots, w_n(x)] \quad (13)$$

위와 같은 방법을 통해서 입력벡터 x 에 대한 퍼지추론의 결과는 다음과 같이 표현된다.

- 출력(y^*): “입력 데이터 x 는 좋은/모호한/나쁜 샘플 집합에 속한다”

3.4 퍼지 분류 평가척도

본 논문에서는 전체 데이터를 퍼지분류한 결과가 얼마나 정확한지를 평가하기 위해서 응집성(compactness), 분리성(isolation), 모호성(vagueness)과 같은 분류척도를 사용한다. 여기서 응집성과 분리성은 정확한 클러스터링 결과를 얻기 위하여 Wang이 제안한 목적함수에서 사용하는 척도를 사용한다[12]. 그리고 추가적인 분류척도로서 모호한 샘플집합에 대한 모호성을 사용한다.

식 (14)는 좋은 샘플집합, 나쁜 샘플집합 그리고 모호한 샘플집합으로 분류된 데이터에 대한 응집성을 평가하는 척도이다. 구체적으로 살펴보면, 각 클래스에 속하는 데이터와 클래스 중심까지의 거리와 소속정도를 나타내는 가중치 곱의 총합으로 응집성을 계산한다. 식 (14)로부터 알 수 있는 것은 전체 데이터에 대한 응집도는 Φ 값에 반비례한다는 것이다. 식 (14)에서 x_j 는 j 번째 데이터를, $\mu_{C_i}(x_j)$ 는 x_j 의 i 번째 클래스에 대한 소속정도를 나타낸다. 여기서 v_i 는 i 번째 클래스의 중심을 의미하고 v_1, v_2, v_3 는 순서대로 좋은, 모호한, 그리고 나쁜 클래스의 중심을 나타낸다.

$$\Phi = \sum_{i=1}^3 \sum_{j=1}^n \mu_{C_i}(x_j) \|x_j - v_i\|^2 \\ \text{where } v_1 = (0, 1), v_2 = (0, 0), v_3 = (1, 0.5) \quad (14)$$

식 (15)는 분리성을 평가하는 척도로서 각 클래스 중심간의 거리의 합으로 계산된다. 식 (15)에서 v_i 는 i 번째 클래스의 중심을 의미하며 m 은 퍼지정도를 나타내는 가중치를 나타낸다.

$$\Psi = \frac{1}{2} \sum_{i=1}^3 \sum_{j=1}^3 \|v_i - v_j\|^2 \\ v = \frac{1}{\sum_{i=1}^c (\mu_{ij})^m} \sum_{j=1}^n (\mu_{ij})^m x_j \quad (15)$$

식 (16)은 모호성을 평가하는 척도로서 v_2 는 모호한 샘플집합을 나타내는 클래스의 중심을 의미하고, 이 중심과 모호한 샘플집합에 속하는 데이터 x_j 의 거리와 소속정도의 합에 대한 총합으로 계산된다.

$$\Omega = \sum_{x_j \in V} \mu_{C_1}(x_j) \|x_j - v_2\|^2 \quad (16)$$

식 (17)은 앞서 살펴본 응집성, 분리성, 모호성을 모두 고려했을 때 분류결과에 대한 정확도를 나타내는 목적함수 J 에 대한 정의이다. 식 (17)에서 α, β, γ 는 각각 응집성, 분리성, 그리고 모호성에 대한 가중치를 나타낸다. 식 (17)로부터 분류결과에 대한 정확도는 응집성이 높을수록, 분리성이 클수록, 그리고 모호성이 작을수록 높아짐을 알 수 있다.

$$J = \alpha \sum_{i=1}^3 \sum_{j=1}^n \mu_{C_i}(x_j) \|x_j - v_i\|^2 - \beta \sum_{x_j \in V} \mu_{C_1}(x_j) \|x_j - v_2\|^2 + \frac{1}{2} \gamma \sum_{i=1}^3 \sum_{j=1}^3 \|v_i - v_j\|^2 \quad (17)$$

4. 실험 및 결과

본 장에서는 제안한 방법을 호모그래피 계산문제에 적용했을 때의 실험결과에 대해서 기술한다. 실험에서 사용하는

입력영상은 실외에서 SONY사의 DCR-PC5로 촬영한 후 320×240 으로 정규화한 칼라 영상이다. 본 논문에서는 이성치를 제거하지 않은 경우와 LMeds, RANSAC, RANSAC-f 그리고 FRANSAC을 이용하여 제안한 방법의 성능을 비교하였다.

(그림 3)은 실험에서 사용한 입력영상을 보여준다. 입력영상은 실외 공간 중에서 평면구조를 포함하고 있는 장면을 촬영하였으며 카메라의 위치는 우에서 좌로 이동하면서 왼쪽에서 오른쪽으로 회전(pan right)하는 영상이다.

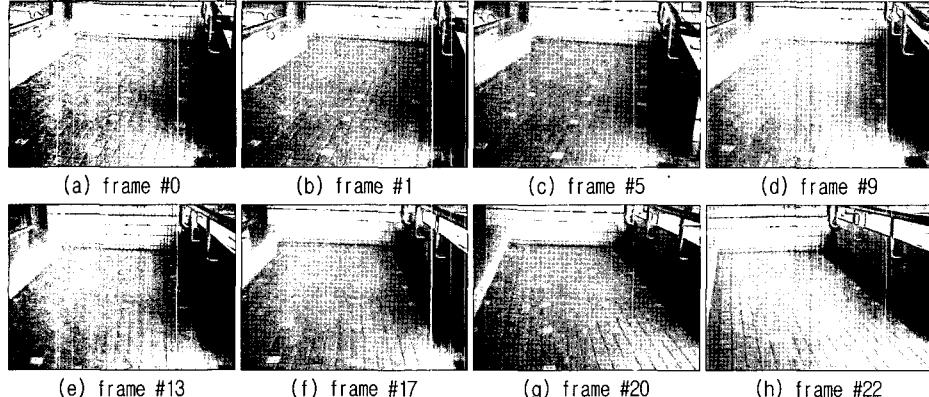
(그림 4)는 입력영상에 대해 KLT-Tracker를 사용하여 코너점에 해당하는 특징점을 추출한 결과를 보여준다[13]. 그리고 카메라 동작을 계산하기 위해서 사용되는 후보 특징점은 추출된 100개의 특징점 중에서 (그림 4)의 (a)에 표시된 영역 내에 존재하는 18개의 특징점을 사용한다. 그리고 이 특징점 중에는 4개의 이상치가 포함되어 있다.

본 논문에서는 추출된 카메라 동작의 정확도를 평가하기 위해서 식 (18)과 같은 대칭형 변환 오차(symmetric transfer error)를 사용한다[1].

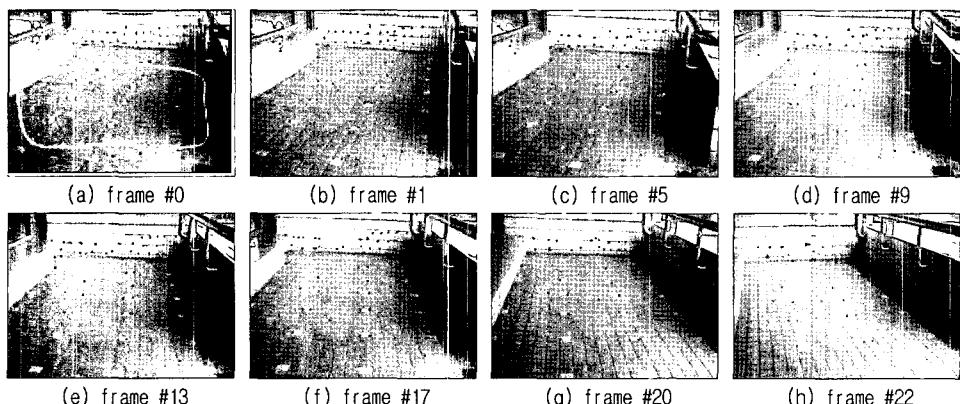
$$\sum_i [d(x_i, H^{-1}x'_i)^2 + d(x'_i, Hx_i)^2] \quad (18)$$

$$x'_i = Hx_i$$

식 (18)에서 x_i, x'_i 는 각각 첫 번째 영상과 두 번째 영상에 대한 i 번째 점을 나타내며 H 는 두 점들의 대응관계로부터



(그림 3) 입력영상



(그림 4) 특징점 추출

터 계산된 호모그래피를 나타낸다. 그리고 d 는 두 점 사이의 유로리디언(Euclidean) 거리함수이며 $d(x_i, H^{-1}x'_i)^2$ 는 첫 번째 영상에서 두 번째 영상으로의 전방향 변환 오차를 나타내고 $d(x'_i, Hx_i)^2$ 는 두 번째 영상으로부터 첫 번째 영상으로의 역방향 오차이다. 최종적으로 이 두 오차의 합을 대칭변환 오차라고 한다. 따라서 카메라 동작 계산 결과의 정확도는 대칭변환 오차에 반비례한다.

<표 2>에서는 각 방법에 따른 입력영상에 대한 대칭변환 오차를 보여준다. 그리고 <표 2>에서 NOP는 강건한 예측 알고리즘을 사용하지 않는 즉, 이상치를 제거하지 않은 경우를 의미한다. <표 2>에서 주목할 점은 정확한 이상치 비율을 적용한 RANSAC 알고리즘의 오차가 RANSAC-f와 제안한 방법에 비해 크다는 사실이다. 이것은 앞서 지적 했듯이 측정오차의 분포가 정규분포를 따른다는 가정을 만족하지 않으면 부정확한 임계값이 결정되고 그에 따라 이상치를 오검출하게 되는 문제점에 원인이 있다.

본 논문에서는 측정오차가 정규분포를 따르는지에 대한 여부를 알아보기 위해 <표 3>에 있는 데이터에 대해서 정규성 검정을 수행하였다. 그 결과 “ p 값이 0.001이면서 유의 수준 1%로 자료가 정규분포에 적합하다는 귀무가설을 기각한다”는 사실을 알 수 있었다. 결국 자료의 분포가 정규분포를 만족하지 않는다는 이 사실로부터 RANSAC 알고리즘의 결과가 부정확했음을 알 수 있다.

(그림 5)에서는 연속된 프레임에 대한 대칭변환 오차를 보여준다. (그림 5)에서 볼 수 있듯이 NOP인 경우에는 특히 4, 7, 10, 20, 25 프레임에서 오차가 상당히 크게 나타나고 있다. 이것은 카메라의 동작이 크게 일어나는 경우로서 본 논문에서 제안한 방법과 RANSAC-f과 다른 방법에 비해서 비교적 작은 오차를 보인다.

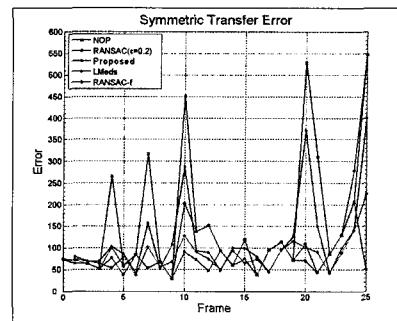
(그림 6)에서는 측정오차가 호모그래피를 통하여 계산된 Panning, Tilting, Swing 각도 변화에 어떤 영향을 미치는지를 보여주고 있다. 그리고 (그림 6)의 (d)에서는 비교적 다른 각도에 비해 각도변화가 상당히 큰 Panning 각도에 대한

<표 2> 호모그래피 계산 시에 발생하는 대칭변환 오차

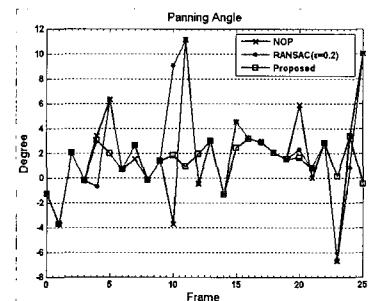
방법	전체오차	평균오차
NOP	4223.985	162.461
LMeds	3096.642	119.102
RANSAC($\epsilon=0.2$)	2927.862	112.610
RANSAC-f	2177.675	83.757
제안한 방법	1939.267	74.587

<표 3> 1, 2 프레임 간의 대응관계로부터 계산된 데이터에 대한 오차

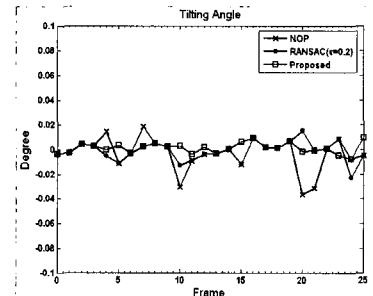
번호	0	1	2	3	4	5	6	7	8
오차	0.36	8.66	0.18	0.13	0.28	0.37	0.17	39.57	5.62
번호	9	10	11	12	13	14	15	16	17
오차	0.95	0	0.27	0	17.69	0.12	0	0.1	0



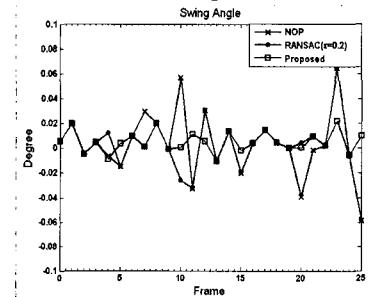
(그림 5) 대칭 변환 오차
(symmetric transfer error)



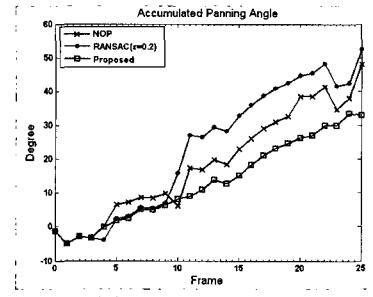
(a) Panning 각도



(b) Tilting 각도



(c) Swing 각도



(그림 6) 프레임별 각도변화

누적 각도를 보여준다. 그림으로부터 계산된 카메라 동작 결과가 정확하지 않으면 프레임이 증가함에 따라서 누적 각도의 차이가 커짐을 알 수 있다.

5. 결 론

본 논문에서는 정확한 카메라 동작을 추정하기 위해 사용되는 강건한 예측기법인 RANSAC 알고리즘의 샘플링 문제를 해결하기 위해 퍼지분류 기법을 적용하였다. 구체적으로 기존의 알고리즘은 모집단의 크기, 샘플의 크기, 이상치의 비율 등에 따라서 수행결과가 영향을 받는다. 이러한 문제를 해결하기 위해서 매 반복 수행시마다 퍼지분류 기법을 이용하여 전체 데이터를 좋은 샘플집합과 나쁜 샘플집합 그리고 모호한 샘플집합으로 분류한 뒤 좋은 샘플집합에서만 샘플링을 해나감으로써 이상치에 대한 제거율을 향상시킨다. 제안한 방법을 호모그래피 계산에 적용한 결과 보다 정확한 카메라 동작을 추정할 수 있었다. 그리고 기존의 방법에서는 미리 정의된 임계값 범위 내에 있으면 정상치로 그렇지 않으면 이상치로 분류하여 정상치에 대한 개수만으로 수렴여부를 결정한다. 반면에 제안한 방법에서는 정상치로 분류된 데이터가 얼마나 정확한 데이터인지에 대한 수치적 확신도 즉, 좋은 샘플집합, 나쁜 샘플집합, 모호한 샘플집합에 대한 응집성, 분리성, 모호성과 같은 분류 척도를 제공한다.

참 고 문 현

- [1] Hartley, R. I, Zisserman, A, "Multiple View Geometry in Computer Vision," Cambridge University Press, 2000.
- [2] Simon J.D. Prince, Ke Xu, Adrian David Cheok, "Augmented Reality Camera Tracking with Homographies," IEEE Computer Graphics and Applications, Vol.22, No.6, pp.39-45, 2002.
- [3] P.J. Rousseeuw, A.M. Leroy, "Robust Regression and Outlier Detection," Wiley, 1987.
- [4] P.J. Huber, "Robust Statistics," John Wiley, New York, 1981.
- [5] Charles V. Stewart, "Robust parameter estimation in Computer Vision," SIAM Review, vol.41, No.3, pp.513-537, 1999.
- [6] M.A. Fischler and R.C. Bolles, "Random Sample Consensus : A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography," Communications to the ACM, Vol.24, Issue.6, pp.381-395, 1981.
- [7] A. J. Lacey and N. Pinitkaran and N. A. Thacker, "An Evaluation of the Performance of RANSAC Algorithms for Stereo Camera Calibration," Proceeding of British Machine Vision Conference, pp.646-655, 2000.
- [8] PHS Torr and C. Davidson, "IMPSAC: Synthesis of Importance Sampling and Random Sample Consensus," IEEE Transaction on Pattern Analysis and Machine Intelligence.
- [9] Emanuele Trucco, Alessandro Verri, "Introductory Techniques for 3D Computer Vision," Prentice-Hall, 1998.

- [10] Valenzuela-Rendon M., "The Fuzzy Classifier System : a Classifier System for Continuously Varying Variables," International Conference on Genetic Algorithms, pp.346-353, 1991.
- [11] Danna H. Ballard, Christopher M. Brown, "Computer Vision," Prentice-Hall, 1982, Vol.25, No.3, pp. 354-364, 2003.
- [12] H. Wang, C. Wang, G. Wu, "Bi-criteria Fuzzy C-Means Analysis," Fuzzy Sets and Systems, vol.64, pp.311-319, 1994.
- [13] C. Tomasi, T. Kanade, "Detection and tracking of point features," CMU Technical Report, CMU-CS-91-132, April, 1991.



이 종 재

e-mail : arbitlee@kist.re.kr
 1999년 2월 숭실대학교 전자계산학과 졸업
 (공학사)
 2001년 2월 숭실대학교 대학원 컴퓨터학과
 졸업(공학석사)
 2005년 2월 숭실대학교 대학원 컴퓨터학과
 졸업(공학박사)

2005년 9월~2006년 5월 숭실대학교 정보미디어기술연구소(연구교수)
 2006년 6월~현재 한국과학기술연구원 지능로봇연구센터(박사후연구원)
 관심분야: 컴퓨터 비전, 로봇비전, 증강현실, 3차원 복원 등임



김 계 영

email : gykim@computing.ssu.ac.kr
 1990년 2월 숭실대학교 전자계산학과 졸업
 (공학사)
 1992년 2월 숭실대학교 대학원 컴퓨터학과
 졸업(공학석사)
 1996년 2월 숭실대학교 대학원 컴퓨터학과
 졸업(공학박사)
 1996년 3월~1997년 11월 한국전자통신연구원 (박사후연구원)
 1997년 12월~2001년 2월 한국전력공사 전력연구원(선임 연구원)
 2001년 3월~현재 숭실대학교 컴퓨터학부(조교수)
 관심분야: 컴퓨터비전, 형태인식, 생체인식, 증강현실, 영상 및
 신호처리 등임



최 형 일

email : hic@computing.ssu.ac.kr
 1979년 2월 연세대학교 전자공학과 졸업
 (공학사)
 1982년 6월 미시간대학교 전산공학과
 졸업(공학석사)
 1987년 6월 미시간대학교 전산공학과
 졸업(공학박사)
 1987년 9월~현재 숭실대학교 미디어학부 교수.
 관심분야: 컴퓨터비전, 패턴인식, 퍼지이론, 비디오검색,
 인터페이스 애플리케이션 등