

퍼지 RANSAC을 이용한 강건한 인수 예측 (Robust Parameter Estimation using Fuzzy RANSAC)

이 중 재[†] 장 호 중^{**} 김 계 영^{***} 최 형 일^{****}
(Joong-Jae Lee) (Hyo-Jong Jang) (Gye-Young Kim) (Hyung-il Choi)

요 약 컴퓨터 비전 분야에서 다루는 많은 문제는 대부분 수학적 모델을 기반으로 하고 있으며 그 모델의 인수를 예측하는 방법을 사용하여 주어진 문제에 대한 최적의 해를 구한다. 그런데 입력 데이터 집합에 보통의 잡음에 비해 상대적으로 크기가 큰 이상치가 포함되어 있다면 이것은 부정확한 결과를 초래한다. 이러한 문제를 해결하기 위해 사용되는 대표적인 방법으로 강건한 예측기법인 RANSAC 알고리즘이 있다. 기존 RANSAC 알고리즘의 가장 큰 문제점은 이상치의 비율과 같은 데이터 분포에 대한 사전지식이 필요하다는 것이다. 본 논문에서는 이러한 문제점을 해결하기 위해 매 반복 수행시마다 퍼지분류 기법을 이용하여 전체 데이터를 좋은 샘플집합(good sample set)과 나쁜 샘플집합(bad sample set) 그리고 모호한 샘플집합(vague sample set)으로 분류한 뒤 좋은 샘플집합에서만 샘플링을 하나감으로써 이상치에 대한 제거율과 해의 정확도를 향상시키는 FRANSAC 알고리즘을 제안한다. 실험 결과에서는 제안한 알고리즘을 각각 선형회귀 문제와 호모그래피 계산 문제에 대해 적용했을 때의 성능을 보인다.

키워드 : 강건한 예측, RANSAC, FRANSAC(Fuzzy RANSAC), 이상치

Abstract Many problems in computer vision are mainly based on mathematical models. Their optimal solutions can be found by estimating the parameters of each model. However, provided an input data set is involved outliers which are relatively larger than normal noises, they lead to incorrect results. RANSAC is a representative robust algorithm which is used to resolve the problem. One major problem with RANSAC is that it needs priori knowledge(i.e. a percentage of outliers) of the distribution of data. To solve this problem, we propose a FRANSAC algorithm which improves the rejection rate of outliers and the accuracy of solutions. This is performed by categorizing all data into good sample set, bad sample set and vague sample set using a fuzzy classification at each iteration and sampling in only good sample set. In the experimental results, we show that the performance of the proposed algorithm when it is applied to the linear regression and the calculation of a homography.

Key words : Robust Estimation, RANSAC, FRANSAC(Fuzzy RANSAC), outlier

1. 서 론

컴퓨터 비전분야 또는 패턴인식 분야에서 다루고 있는 문제들은 대부분 수학적 모델을 기반으로 하며, 주어진 문제에 대한 해를 얻는 과정은 모델을 기술하는데 사용되는 인수(parameter)를 결정하는 방식으로 해석된

다. 그리고 이때 정확한 해는 주어진 입력 데이터에 대해서 최적화된 모델을 생성하는 시점에서 결정된다. 그런데 만약 입력 데이터에 잡음이 포함되어 있다면 최종적으로 결정된 해의 정확도는 감소한다. 물론 잡음이 전체 데이터에 비해서 크기가 작은 데이터인 경우에는 평균적으로 상쇄되어 큰 문제가 되지 않는다. 이에 비하여 대형오차(gross error), 즉 이상치(outlier)는 부정확한 모델인수를 결정하게 만들고, 그 결과 이상적인 해를 획득할 수 없다. 따라서 보다 정확한 모델인수를 예측하기 위해서는 이상치를 배제시키고 유효한 데이터만을 사용하여 모델인수를 결정해야 한다. 이러한 방법을 강건한 예측(robust estimation)이라고 한다. 대표적으로 사용되는 강건한 예측기법에는 LMedS(least median of square)와 M-estimator가 있다[1,2]. LMedS는 잔여오차 제곱값에 대한 중간(median)값을 최소로 만드는 경

· 이 논문은 2005년도 한국학술진흥재단의 지원에 의하여 연구되었음 (KRF-2005-005-D00198)

† 정 회 원 : 숭실대학교 정보미디어기술연구소 연구원

arbitlee@vision.ssu.ac.kr

** 학생회원 : 숭실대학교 컴퓨터학과

ozjhj@vision.ssu.ac.kr

*** 중신회원 : 숭실대학교 컴퓨터학부 교수

gykim@computing.ssu.ac.kr

**** 중신회원 : 숭실대학교 미디어학부 교수

hic@computing.ssu.ac.kr

논문접수 : 2005년 5월 19일

심사완료 : 2005년 12월 22일

우를 최적의 해로 판단하는 방법으로서 간단하면서도 사전지식을 필요로 하지 않는 장점이 있다. 그러나 중간값을 사용한다는 사실로부터 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[3]. 앞서 소개한 방법과 함께 컴퓨터 비전분야에서 많이 사용되는 강건한 예측기법으로 RANSAC(Random Sample Consensus)이 있다[4]. RANSAC은 Fischler와 Bolles에 의해 1981년에 제안된 강건한 예측방법으로 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 매 시점마다 최적의 n개의 해에 대한 순서리스트를 유지하는 방식을 사용한다[5]. 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 IMP-SAC이 있다[6]. 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) 분

포를 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 퍼지 RANSAC 알고리즘을 제안한다(이후로 퍼지 RANSAC은 FRANSAC으로 칭함). 제안하는 FRANSAC 알고리즘은 기존 방법의 문제점을 해결하기 위해서 매 반복 수행시마다 퍼지분류(fuzzy classification) 기법을 이용하여 전체 데이터를 좋은 샘플집합(good sample set)과 나쁜 샘플집합(bad sample set) 그리고 모호한 샘플집합(vague sample set)으로 분류한다. 그런 후에 좋은 샘플집합에서만 샘플링을 해나감으로써 이상치에 대한 제거율과 정확도를 향상 시킨다.

그림 1은 본 논문에서 제안하는 FRANSAC 알고리즘의 개요를 보여주고 있다. 그림 1에서 볼 수 있듯이 FRANSAC 알고리즘은 기본적으로 기존의 RANSAC 알고리즘의 구조를 따른다. 그러나 전체 데이터집합으로

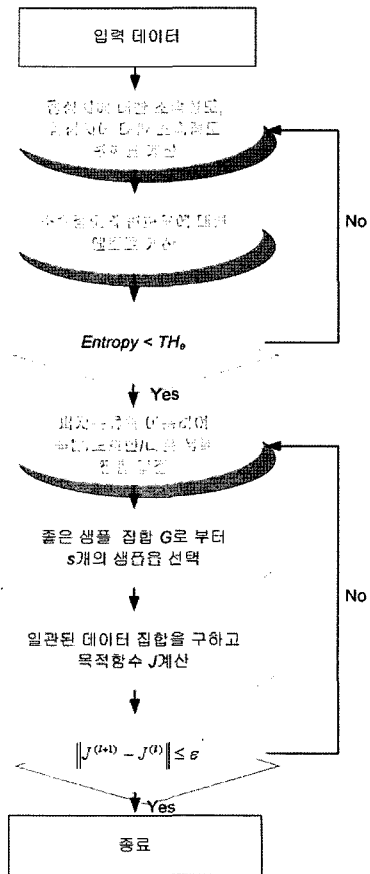


그림 1 FRANSAC 개요도

부터 샘플링을 수행하는 것이 아니라 퍼지분류를 이용하여 전체 데이터를 좋은 샘플집합, 나쁜 샘플집합, 모호한 샘플집합으로 분류한 뒤 좋은 샘플집합으로부터 샘플링을 수행한다. 이때 초기의 데이터 선정이 전체 결과에 큰 영향을 미치기 때문에 본 논문에서는 정확한 초기 데이터 선정을 위해서 엔트로피를 사용한다. 즉, 엔트로피가 높은 경우 데이터 간의 변별력이 낮아지고 반대의 경우에는 데이터 간의 변별력이 높아진다는 특성을 이용하여 초기의 데이터를 선정한다.

2장에서는 본 논문에서 제안한 FRANSAC 알고리즘에 대해서 기술하고 3장에서는 제안한 방법을 선형회귀 문제와 호모그래피 계산 문제에 적용하여 기존 방법과의 성능을 비교한 실험결과를 보인다. 마지막으로 4장에서는 본 논문의 결론을 맺는다.

2. FRANSAC 알고리즘

본 논문에서 제안한 FRANSAC 알고리즘은 기존의 RANSAC 알고리즘에 대해서 데이터의 모호성을 표현할 수 있는 퍼지이론을 접목한 것이다. 즉, 모든 데이터를 정상치(inlier) 또는 이상치의 두 종류로만 분류하는 대신 정상치와 이상치에 대한 0부터 1사이의 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 FRANSAC 알고리즘의 개요는 다음과 같다.

첫째, 퍼지 분류방법을 이용하여 전체데이터를 분류하여 샘플링을 수행한다[7]. 기존 방법이 수렴 시까지 매번 복원 랜덤 샘플링을 수행하는 방식 대신에 샘플링을 수행한 후 전체 데이터를 좋은 샘플집합, 나쁜 샘플집합, 모호한 샘플집합으로 분류하여 다음번 샘플링 시에는 전체 데이터에서 샘플링을 수행하지 않고 좋은 샘플

집합에 대해서만 랜덤 샘플링을 수행한다. 이렇게 함으로써 진동 문제를 해결함과 동시에 샘플링의 정확도를 향상시킨다. 그림 2는 퍼지 분류를 이용하여 데이터를 분류하는 방법을 보여주며 입력 값에 대한 퍼지화 및 소속함수의 정의, 퍼지 규칙의 정의, 퍼지 추론 단계로 구성됨을 알 수 있다.

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 부족한데 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 1은 FRANSAC 알고리즘에서 사용되는 용어의 정의를 보여준다.

2.1 입력에 대한 퍼지화 및 소속함수의 정의

앞서 언급했듯이, 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 계산된

표 1 FRANSAC에 사용되는 용어 정의

용어	의미
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

생성규칙




그림 2 퍼지 분류를 이용한 데이터 분류

다. 식 (1)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 (1)에서 r_i 는 i 번째 데이터에 대한 잔여오차를, r_{max} 는 잔여오차 중에서 최대값을 나타내며 정상치에 대한 소속정도는 0과 1사이의 값을 가진다.

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

식 (2)는 i 번째 데이터의 정상치에 대한 소속정도 변화율을 나타내며, 소속정도의 변화율은 현재 단계에서 계산된 소속정도와 이전 단계에서 계산된 소속정도의 차이로 정의한다. 따라서 소속정도의 변화율은 -1에서 1사이의 값을 가진다.

$$x_2^i = \Delta x_1^i = x_1^i(t) - x_1^i(t-1) \quad (2)$$

그리고 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”

그림 3은 각 입력에 대한 소속함수의 구성을 보여주고 있다. 그림 3의 (a)는 첫 번째 입력인 정상치에 대한 소속함수로서 소속정도가 작다, 중간, 크다는 세부분으로 구성된다. 그리고 그림 3의 (b)는 두 번째 입력인 정상치 소속정도의 변화율에 대한 소속함수를 나타내는데 소속정도의 변화율이 낮다, 중간, 높다는 구성된다.

2.2 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 때

문이다. 즉, 초기에 좋은 샘플집합으로 결정하는 데이터에 대한 판단 정확도가 전체 결과에 큰 영향을 미치기 된다. 본 논문에서는 초기 데이터에 대한 정확한 선정을 위해서 식 (3)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[8]. 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 변별력(discriminating power)이 낮아지며 반대의 경우에는 데이터 간의 변별력이 높아진다.

$$entropy(x) = - \sum_{i=1}^n p(x_i) \log(p(x_i)) \quad (3)$$

식 (3)에서 $p(x_i)$ 는 i 번째 샘플이 발생할 확률을 의미하고, 모집단의 엔트로피는 0과 1사이의 값을 가진다.

그림 4는 잔여오차 분포에 대한 엔트로피를 비교하였을 때 데이터 간의 변별력을 비교한 것이다. 그림 4에서 볼 수 있듯이 엔트로피가 높은 (a)의 경우에는 데이터의 분류가 쉽지 않은 반면에 엔트로피가 낮은 (b)의 경우에는 데이터의 분류가 용이하다.

본 논문에서는 이해를 돕기 위해 선형회귀(linear regression)에 대한 예제를 사용하기로 한다. 그림 5는 10개(8:정상치, 2:이상치)의 점으로 구성된 데이터에 대해서 이상적인 직선의 방정식을 찾기 위한 선형회귀 문제를 보여주고 있다. 선형회귀 문제를 해결하기 위해서는 임의의 두 점을 선택한 후 직선의 방정식을 구한 후 나머지 점들에 대한 잔여오차를 계산해서 그 총합을 최소로 하는 경우를 해로 결정한다[9].

그림 5에서 볼 수 있듯이 이러한 선형회귀 문제에서 초기의 두 점을 선택하는 경우는 크게 3가지(정상치-정상치, 이상치-이상치, 정상치-이상치)로 나누어진다. 따라서 초기의 데이터를 정상치-정상치, 이상치-이상치와





그림 3 퍼지 소속함수



(a) 엔트로피가 높은 경우 (b) 엔트로피가 낮은 경우

그림 4 엔트로피에 따른 데이터의 변별력 비교

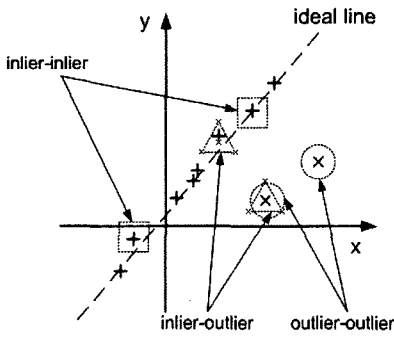



그림 5 선형회귀 문제

같이 데이터 사이의 변별력이 큰 경우로 선정하면 정확한 최종 결과를 얻을 수 있다. 이런 면에서 FRANSAC 알고리즘은 초기화단계에서 전체 데이터에 대한 정상치

의 소속정도와 변화율 값을 모두 0으로 초기화한 다음에 초기 데이터를 선정하게 되는데 이때 앞서 설명한 엔트로피를 이용한다.

그림 6은 선형회귀 문제에서 두 점을 샘플링하여 정상치의 소속정도와 변화율을 그래프로 나타낸 것이다. 그림 6에서 볼 수 있듯이 초기의 모든 데이터는 소속정도와 변화율이 모두 0으로 초기화되었기 때문에 원점에 몰려 있게 되는데 (b),(c),(d)에서 각각 초기 샘플링의 경우에 따라서 정상치의 소속정도가 변화한 결과를 볼 수 있다. 여기서 정상치의 소속정도에 대한 엔트로피를 계산하면 (b),(c)인 경우에는 낮은 엔트로피를, (d)인 경우에는 높은 엔트로피를 보인다. 결국 (b),(c)와 같이 데이터의 변별이 뚜렷한 경우에 대해서만 초기 데이터를 선정하게 되고 (d)와 같은 경우에는 샘플링을 재수행한다.



(a) 초기 데이터

(b) 이상치-이상치(샘플링)

(c) 정상치-정상치(샘플링)

(d) 정상치-이상치(샘플링)

그림 6 엔트로피에 따른 데이터 변별력 비교

이와 같이 본 논문에서는 잔여오차와 관련된 정상치의 소속정도에 대한 엔트로피를 이용하여 초기 데이터를 선정하는데 식 (4)와 같이 계산된 엔트로피 값이 임계값 TH_e 보다 작으면 초기 데이터로 선정하고 그렇지 않으면 샘플링을 재수행한다.

if $entropy(x_1) < TH_e$ **then** initialize data (4)
otherwise do resampling

2.3 퍼지규칙의 정의 및 퍼지추론

본 절에서는 퍼지분류에 사용되는 퍼지규칙의 정의와 생성된 퍼지규칙을 통하여 퍼지추론을 수행하는 방법에 대해서 설명한다. 퍼지 규칙은 식 (5)와 같이 퍼지 값으로 결합된 조건부와 결론부로 구성되며 각 규칙은 확신도(CF : Certainty Factor)를 가진다. 그런데 본 논문에서는 모든 규칙의 확신도를 1로 사용하기 때문에 퍼지 규칙을 표현하는 데에서 확신도는 생략하기로 한다.

규칙 i : 만약 x_1 이 A_i 이고 x_2 가 B_i 이면 Class는 C_i 이다 (CF _{i}) (5)

표 2는 제안한 방법에서 사용하는 퍼지규칙을 보여주고 있다. 표 2를 통해서 생성되는 전체 퍼지규칙의 수는 정상치에 대한 소속정도를 표현하는데 필요한 속성의 개수가 3개이고 소속정도의 변화율을 기술하는 속성이 5개이므로 총 15(=3× 5)개 이다.

표 2 FRANSAC 알고리즘에서 사용하는 퍼지규칙

No.	A	B	class(G/V/B)
1	Small	HighM	Vague
2	Small	MediumM	Vague
3	Small	Low	Bad
4	Small	MediumP	Vague
5	Small	HighP	Vague
6	Medium	HighM	Vague
7	Medium	MediumM	Vague
8	Medium	Low	Vague
9	Medium	MedimP	Vague
10	Medium	HighP	Vague
11	Large	HighM	Vague
12	Large	MediumM	Vague
13	Large	Low	Good
14	Large	MediumP	Vague
15	Large	HighP	Vague

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

[규칙1] IF Small(x_1) AND High(x_2) THEN Vague Set
 : "소속정도가 작고 소속정도의 변화율이 높으면 모호

한 샘플 집합의 원소이다"

[규칙3] IF Small(x_1) AND Low(x_2) THEN Bad Set
 : "소속정도가 작고 소속정도의 변화율이 낮으면 나쁜 샘플 집합의 원소이다"

[규칙13] IF Large(x_1) AND Low(x_2) THEN Bad Set
 : "소속정도가 크고 소속정도의 변화율이 낮으면 좋은 샘플 집합의 원소이다"

그림 7에서는 각 퍼지규칙에 대한 적용범위(coverage)를 가지적으로 보여준다. 전체 규칙 중에서 좋은 샘플 집합을 판별하는데 사용되는 규칙 13번, 나쁜 샘플 집합을 판별하는데 사용되는 3번 그리고 모호한 샘플 집합을 판별하는 여러 규칙 중에 하나인 1번 규칙을 그 예로 볼 수 있다.

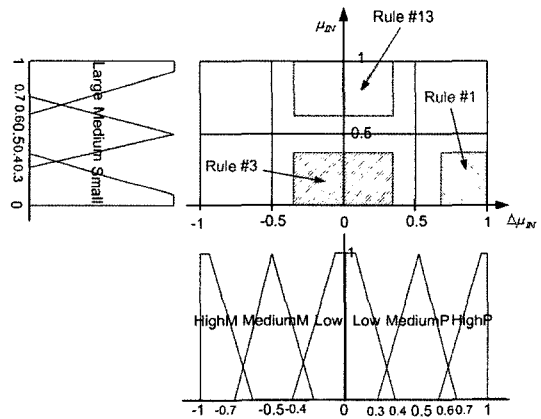


그림 7 각 규칙의 적용범위(coverage)에 대한 예

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

식 (8)은 입력벡터 x 에 대해서 i 번째 규칙의 지지도(degree of support)인 $w_i(x)$ 를 계산하는 방법을 보여주고 있다. 여기서 조건부의 만족도를 합성할 때 일반적으로 많이 사용되는 연산은 min 또는 product인데 본 논문에서는 식 (8)과 같이 min 연산을 사용한다.

$$w_i(x) = \min(u_A^i(x_1), u_B^i(x_2)) \quad (8)$$

이와 같이 입력벡터 x 에 대해서 모든 규칙의 지지도가 계산되면 계산된 지지도에 따라 최종적으로 규칙을 결정한다. 식 (9)는 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.

$$y^* = \arg \max_i (w_i(x)) \quad (9)$$

$$\text{where } w_i(x) = [w_1(x), w_2(x), \dots, w_n(x)]$$

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”

2.4 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[10]. 그리고 추가적인 분류척도로서 모호한 샘플집합에 대한 모호성을 사용한다.

식 (10)은 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 (10)으로부터 알 수 있는 것은 전체 데이터에 대한 응집도는 \emptyset 값에 반비례한다는 것이다. 식 (10)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.

$$\Phi = \sum_{i=1}^3 \sum_{j=1}^n \mu_{C_i}(x_j) \|x_j - v_i\|^2 \quad (10)$$

$$\text{where } v_1 = (0,1), v_2 = (0,0), v_3 = (1,0.5)$$

식 (11)은 분리성을 평가하는 척도로서 각 클래스 중심 간의 거리의 합으로 계산된다. 식 (11)에서 v_i 는 i 번째 클래스의 중심을 의미하며 m 은 퍼지정도를 나타내는 가중치를 나타낸다.

$$\Psi = \frac{1}{2} \sum_{i=1}^3 \sum_{j=1}^3 \|v_i - v_j\|^2 \quad (11)$$

$$v = \frac{1}{\sum_{i=1}^c (\mu_{ij})^m} \sum_{j=1}^n (\mu_{ij})^m x_j$$

식 (12)는 모호성을 평가하는 척도로서 v_2 는 모호한 샘플집합을 나타내는 클래스의 중심을 의미하고, 이 중심과 모호한 샘플집합에 속하는 데이터 x_j 의 거리와 소속정도의 곱에 대한 총합으로 계산된다.

$$\Omega = \sum_{x_j \in V} \mu_{C_1}(x_j) \|x_j - v_2\|^2 \quad (12)$$

식 (13)은 앞서 살펴본 응집성, 분리성, 모호성을 모두 고려했을 때 분류결과에 대한 정확도를 나타내는 목적함수 J 에 대한 정의이다. 식 (13)에서 α, β, γ 는 각각 응집성, 분리성, 그리고 모호성에 대한 가중치를 나타낸다. 식 (13)으로부터 분류결과에 대한 정확도는 응집성이 높을수록, 분리성이 클수록, 그리고 모호성이 작을수록 높아짐을 알 수 있다.

$$J = \alpha \sum_{i=1}^3 \sum_{j=1}^n \mu_{C_i}(x_j) \|x_j - v_i\|^2 - \beta \sum_{x_j \in V} \mu_{C_1}(x_j) \|x_j - v_2\|^2 + \frac{1}{2} \gamma \sum_{i=1}^3 \sum_{j=1}^3 \|v_i - v_j\|^2 \quad (13)$$

표 3은 지금까지 설명한 FRANSAC 알고리즘을 의 사코드로 나타낸 것이다.

3. 실험 및 결과

본 장에서는 본 논문에서 제안한 FRANSAC 알고리즘을 선형회귀 문제와 호모그래피 계산문제에 적용했을 때의 실험결과에 대해서 기술한다. 선형회귀 문제에 대한 실험에서는 FRANSAC 알고리즘을 적용한 데이터의 분류과정을 시각적으로 보이고 기존의 RANSAC 알고리즘과의 이상치 제거에 대한 정확도를 비교한다. 그리고 호모그래피 계산에 대한 실험에서는 이상치를 제거하지 않은 경우와 LMeds, RANSAC, RANSAC-f 그리고 FRANSAC을 이용하여 이상치를 제거한 경우에 대해 대칭형 변환오차(symmetric transfer error)를 계산하여 정확도를 비교한다.

3.1 선형회귀 문제에 대한 실험

본 논문에서는 이상치를 제거하는 정확도를 평가하는데 많이 사용되는 선형회귀 문제를 사용하여 기존의 방법과 제안하는 방법의 성능을 비교한다. 먼저 선형회귀 문제1에서는 기존방법과 제안하는 방법의 성능을 비교하기에 앞서 제안하는 FRANSAC 알고리즘을 사용하여 이상치를 검출하는 과정을 시각적으로 보여준다. 그림 8은 전체 10개의 점 중에 2개의 이상치, 즉 이상치 비율이 0.2인 데이터로 구성된 선형회귀문제 1을 보여준다.

그림 9는 반복횟수(iteration)에 따라서 랜덤하게 선택된 샘플 데이터와 이 데이터로부터 계산된 직선 방정식의 변화를 보여준다.

그림 9의 (a)는 퍼지분류를 수행하기 전에 초기 데이터를 선정하는 단계로서 본 실험에서 사용하는 임계값 0.7보다 작은 엔트로피를 보이고 있다. 그림 9의 (b), (c), (d), (f)에서는 좋은 데이터 집합으로부터 샘플 데이터를 선택한 후 퍼지분류를 수행한다. 이러한 반복 수행은 이상치와 정상치의 개수에 따라 종료하는 기존의

표 3 FRANSAC 알고리즘 의사코드(pseudo code)

```

FRANSAC 알고리즘
n = number of total samples
s = number of random samples
xi = i th data's membership for inlier
Δxi = i th data's rate of change of membership

I. Select initial good data
Initialize all xi and Δxi to 0
while
begin
for i=1 to n
begin
choose s samples from U
calculate xi
end
entropy(x) = - ∑i=1n p(xi) log(p(xi))
if entropy(x) < THe then
for i=1 to n
begin
if xi is Large then G := xi
end
end
end

II. Determine the consensus set of samples using fuzzy classification
while |J* - J*prev| > THJ
begin
J*prev = J*
for i=1 to n
begin
choose s samples from good set G
calculate xi and Δxi
determine good/vague/bad set using fuzzy classification
compute residual r
end
J* = α · compactness - β · isolation + γ · vagueness
end
    
```




그림 8 선형회귀 문제1

방법과는 달리 목적함수 J 의 변화량이 임계값 0.05보다 작을 때 종료한다.

그림 10은 선형회귀 문제 1에 대한 결과를 도식적으로 보여준다. 그림 10에서 x축은 이상치에 대한 소속정도의 변화율을 나타내고 y축은 이상치에 대한 소속정도를 나타낸다. 그림 10의 (a)는 초기 데이터를 선정하기 위한 단계로서 소속정도의 엔트로피에 따라 퍼지분류를 시작할 여부를 결정한다. 그림 10의 (b), (c), (d), (e), (f)는 차례대로 퍼지분류를 수행해 나가는 과정을 시각적으로 보여주고 있으며 반복횟수가 증가함에 따라 소속정도의 변화율이 0으로 수렴해 가는 것을 볼 수 있다. 여기서 기존의 RANSAC 알고리즘과의 차이점은 반복 수행시 전체 데이터에서 샘플 데이터를 선택하는 것이 아니라 퍼지분류에 의해 좋은 집합으로 분류된 데이터로부터 샘플링을 수행한다는 점이다.

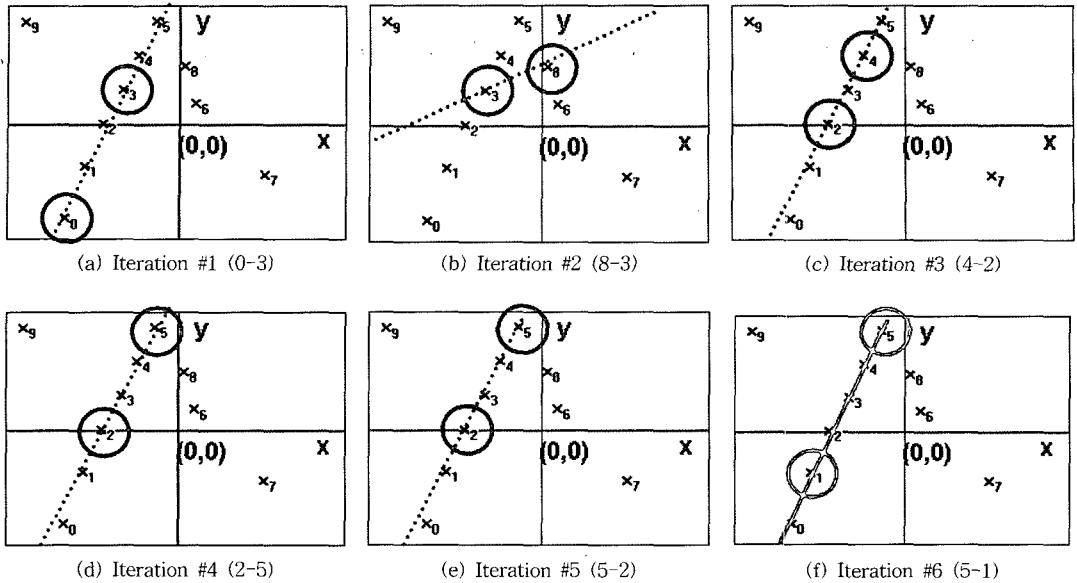


그림 9 반복 횟수에 따른 직선의 방정식

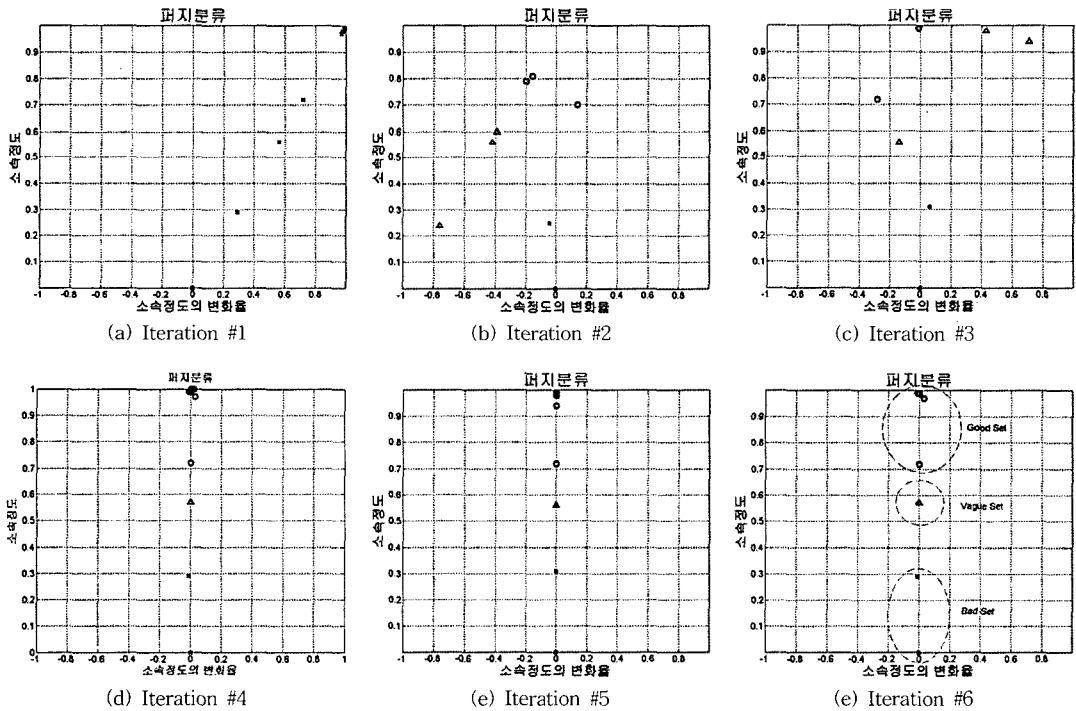


그림 10 퍼지 분류에 의한 데이터 분류

표 4는 선형회귀 문제1에 대해 반복횟수에 따라 산출되는 실험결과를 정리한 것이다. 표 4에서 주목할 점은 최종적인 데이터의 분류에서 1개의 모호한 데이터가 존재한다는 것이다. 이것은 그림 8에서 볼 수 있듯이 6번 데이터가 정상치 또는 이상치로 분류해 내기가 어렵기

때문에 모호한 데이터로 분류한 것이다. 만약 이 데이터가 정상치였는데 이상치로 오분류한다면 최종적으로 산출되는 직선의 방정식에 나쁜 영향을 주게 되므로 이 데이터를 모호한 데이터로 분류함으로써 발생할 수 있는 오류를 줄일 수 있다. 그림 11은 표 4에서 산출된

표 4 선형회귀 문제1에 대한 결과

반복횟수	sample	이상치비율			entropy	분류평가				식상치(일정치)
		ϵ	γ	θ		음성성	양성성	명료성	J	
1	0-3	0	0	0	0.6712	-1	-1	-1	-1	$y = 2.43 * x + 164.57$
2	8-3	5	3	2	0.7290	0.735	1.061	0.445	0.747	$y = 0.41 * x + 57.93$
3	4-2	5	3	2	0.6712	1.616	1.026	1.235	1.292	$y = 2.12 * x + 153.73$
4	2-5	6	1	2	0.6247	0.654	0.641	0.565	0.620	$y = 2.10 * x + 152.20$
5	5-2	6	1	2	0.6247	0.654	0.641	0.565	0.620	$y = 2.10 * x + 152.20$
6	5-1	6	1	2	0.6712	0.650	0.680	0.567	0.632	$y = 2.21 * x + 154.60$




그림 11 선형회귀 문제 1에 대한 결과 그래프

분류평가에 대한 결과를 시각적으로 보여준다.

그림 12는 전체 20개의 점에 대해서 0.2의 이상치 비율을 갖는 선형회귀 문제2를 보여준다.

선형회귀 문제2에서는 기존의 RANSAC 알고리즘과 본 논문에서 제안한 FRANSAC 알고리즘에 대한 이상치 검출의 정확도를 비교한다. 앞서 언급했듯이 RANSAC 알고리즘은 통계이론을 기반으로 하기 때문에 데이터의 분포에 민감하다는 단점을 가지고 있다. 대표적인 예로서 이상치와 정상치를 판별하기 위해 사용되는 임계값을 결정할 때 주어진 데이터에 대한 측정오차의 분포가 평균이 0이고 분산이 σ 인 정규분포를 따르고 이러한 오차의 제곱에 대한 분포가 카이제곱(χ^2)분포를 따른다는 가정이 필요하다. 그런데 만약 주어진 데이터의 분포가




그림 12 선형회귀 문제2


이 가정을 만족하지 않는다면 부정확한 임계값이 결정되고 그 결과 이상치와 정상치에 대한 오검출이 발생하게 된다.

표 5에서는 선형회귀 문제2에 대해 RANSAC 알고리즘과 FRANSAC 알고리즘을 적용했을 때의 실험결과를 보여준다. 표 5에서는 실제로 이상치 비율이 0.2인 데이터에 대해서 이상치 비율이 0.1부터 0.4까지 차별로 변경해가면서 RANSAC 알고리즘을 적용한 결과를 볼 수 있는데 이상치의 비율이 정확하지 않은 0.3, 0.4인 경우에는 오검출을, 0.1인 경우에는 수렴하지 못하고 진동하는 결과를 보인다. 이에 반해서 이상치 비율이 0.2인 경우와 FRANSAC 방법을 적용한 경우에는 정확하게 이상치를 검출하였음을 알 수 있다. 그리고 FRANSAC 방법을 적용한 경우에 9번 데이터는 모호한 데이터로 분류되는데 이것은 그림 12에서 볼 수 있듯이 이상치와 정상치로 분류하기에 모호한 위치에 존재하기 때문이다.


선형회귀 문제2에 대한 결과비교를 통해서 알 수 있는 사실은 기존의 RANSAC 알고리즘을 적용하여 정확한 이상치 검출결과를 얻기 위해서는 전체 데이터에 대한 이상치 비율을 사전에 정확히 알고 있어야 한다는 것이다. 이에 비해서 FRANSAC 알고리즘은 이상치 비율을 필요로 하지 않으면서 이상치를 검출할 수 있음을 알 수 있다. 그림 13에서는 선형회귀 문제2에 대한 최종

표 5 선형회귀 문제2에 대한 결과


방법	잔여오차	직선의 방정식	정상치	이상치	수렴
RANSAC($\epsilon=0.1$)	1240.99	$y = -0.55 * x + 17.73$	1,2,3,4,6,7,8,9,11, 13,14,15,16,17,18,19	0,5,10,12,17	×
RANSAC($\epsilon=0.2$)	728.00	$y = 0.75 * x + 12.00$	0,1,2,3,4,5,8,9,10, 12,13,15,16,17,18,19	6,7,11,14	○
RANSAC($\epsilon=0.3$)	810.25	$y = 0.64 * x - 16.47$	0,1,2,3,4,5,8,9,10, 12,15,16,17,18,19	6,7,11,13,14	○
RANSAC($\epsilon=0.4$)	817.32	$y = 0.62 * x + -16.83$	0,1,2,3,4,5,8,9,10, 15,17,18,19	6,7,11,12,13,14,16	○
FRANSAC	733.76	$y = 0.81 * x + 4.08$	0,1,2,3,4,5,8,10,12,13,15,16,17,18,19	6 7 11 14	○




(a) RANSAC($\epsilon=0.1$)




(b) RANSAC($\epsilon=0.2$)



(c) RANSAC($\epsilon=0.3$)



(d) RANSAC($\epsilon=0.4$)



(e) FRANSAC

그림 13 선형회귀 문제2에 대한 직선의 방정식

적인 직선의 방정식을 보여주고 있다.

4.2 호모그래피 계산 문제에 대한 실험

본 절에서는 FRANSAC 알고리즘을 호모그래피(homography) 계산 실험에 적용한 결과를 기술한다. 호모그래피 계산은 실감 있는 증강현실을 구현하기 위해서 실사영상에 자연스럽게 가상객체를 정렬하는데 필수적인 정확한 카메라 동작 추출과 관련이 있다. 구체적으로 말해서, 호모그래피 계산에 입력으로 사용되는 이웃하는 두 영상으로부터 추출된 특징점간의 대응관계로부터 카메라의 동작정보를 획득하는 것이다. 그런데 이때 대응관계 중에 포함되어 있을 이상치를 적절하게 제거할 수 있어야만 보다 정확한 카메라 동작을 계산할 수 있다. 따라서 본 논문에서는 두 영상간의 대응관계 중에서 이상치를 제거하는 문제에 대해서 기존에 많이 사용되는 RANSAC 알고리즘과 본 논문에서 제안한 FRANSAC 알고리즘을 적용했을 때의 실험결과를 보

인다.

그림 14는 실험에서 사용한 입력영상을 보여준다. 입력영상은 실외공간 중에서 평면구조를 포함하고 있는 장면을 촬영하였으며 카메라의 위치는 위에서 좌로 이동하면서 왼쪽에서 오른쪽으로 회전(pan right)하는 영상이다.

그림 15는 입력영상으로부터 코너점을 검출하는데 사용되는 KLT-Tracker를 사용하여 특징점을 추출한 결과를 보여준다[11]. 그리고 카메라 동작을 측정하기 위해서 사용되는 후보 특징점은 추출된 100개의 특징점 중에서 그림 15의 (a)에 표시된 영역 내에 존재하는 18개의 특징점을 사용한다. 그리고 이 특징점 내에는 4개의 이상치가 포함되어 있다.

본 논문에서는 추출된 카메라 동작의 정확도를 평가하기 위해서 식 (14)와 같은 대칭형 변환 오차(symmetrical transfer error)를 사용한다[12].




그림 14 입력영상




그림 15 특징점 추출

$$\sum_i [d(x_i, H^{-1}x'_i)^2 + d(x'_i, Hx_i)^2] \quad (14)$$

$$x'_i = Hx_i$$

식 (14)에서 x_i, x'_i 는 각각 첫 번째 영상과 두 번째 영상에 대한 i 번째 점을 나타내며 H 는 두 점들의 대응 관계로부터 계산된 호모그래피를 나타낸다. 그리고 d 는 두 점 사이의 유클리디언(Euclidean) 거리함수이며 $d(x_i, H^{-1}x'_i)^2$ 는 첫 번째 영상에서 두 번째 영상으로의 전방향(forward) 변환 오차를 나타내고 $d(x'_i, Hx_i)^2$ 는 두 번째 영상으로부터 첫 번째 영상으로의 역방향(backward) 오차이다. 최종적으로 이 두 오차의 합을 대칭변환 오차라고 한다. 따라서 카메라 동작 계산 결과의 정확도는 대칭변환 오차에 반비례한다.

표 6에서는 각 방법에 따른 입력영상에 대한 대칭변

환 오차를 보여준다. 그리고 표 6에서 NOP는 강건한 예측 알고리즘을 사용하지 않는 즉, 이상치를 제거하지 않은 경우를 의미한다. 표 6에서 주목할 점은 정확한 이상치 비율을 적용한 RANSAC 알고리즘의 오차가 RANSAC-f와 FRANSAC에 비해 크다는 사실이다. 이것은 앞서 지적 했듯이 측정오차의 분포가 정규분포를 따른다는 가정을 만족하지 않으면 부정확한 임계값이

표 6 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
FRANSAC	1939.267	74.587

결정되고 그에 따라 이상치를 오검출하게 되는 문제점이 원인이다.

본 논문에서는 측정오차가 정규분포를 따르는지에 대한 여부를 알아보기 위해 표 7에 있는 데이터에 대해서 정규성 검정을 수행하였다. 그 결과 “ p 값이 0.001이면서 유의수준 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 16에서는 연속된 프레임에 대한 대칭변환 오차를 보여준다. 그림 16에서 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 FRANSAC과 RANSAC-f과 다른 방법에 비해서 비교적 작은 오차를 보인다.




그림 16 대칭 변환 오차(symmetric transfer error)

그림 17에서는 측정오차가 추출된 호모그래피를 통하여 계산된 Panning, Tilting, Swing 각도 변화에 어떤 영향을 미치는지를 보여주고 있다. 그리고 그림 17의 (d)에서는 비교적 다른 각도에 비해 각도변화가 상당히 큰 Panning 각도에 대한 누적 각도를 보여준다. 그림으로부터 계산된 카메라 동작 결과가 정확하지 않으면 프레임이 증가함에 따라서 누적 각도의 차이가 커짐을 알 수 있다.

본 논문에서는 프레임 수가 증가할수록 누적된 Panning 각도의 차이가 증가하는 결과가 가상객체를 정렬할 때 정렬오차에 어떤 영향을 주는지를 그림 18에서 시각적으로 보여주고 있다. 그림 18의 (a), (c)는 기존의 방법을 이용하여 획득한 카메라 동작정보를 통해 가상객체를 정렬한 결과이고 (b), (d)는 본 논문에서 제안한 방법을 통해 계산한 카메라 동작정보를 이용하여 가상객체를 정렬한 결과이다. 그림 18을 통해서 부정확한 카메라 동작정보를 이용하여 가상객체를 정렬하였을 때는 실세계 영상과는 부조화된 합성영상이 생성됨을 볼 수 있다. 반면에 정확한 카메라 동작정보를 이용하여 가상객체를 정렬하면 자연스러운 합성영상이 생성됨을 알 수 있다.

5. 결론

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 FRANSAC 알고리즘을 제안하였다. 구체적으로 제안한 알고리즘은 기존의 알고리즘이 모집단의 크기, 샘플의 크기, 이상치의 비율 등에 따라서 수행결과가 영향을 받기 때문에 이 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 향상시키고 이에 따라 정확한 모델인수를 결정할 수 있었다. 그리고 기존의 방법에서는 미리 정의된 임계값 범위 내에 있으면 정상치로 그렇지 않으면 이상치로 분류하여 정상치에 대한 개수만으로 수렴여부를 결정하는 반면에 정상치로 분류된 데이터가 얼마나 정확한 데이터인지에 대한 수치적 확신도 즉, 좋은 샘플집합, 나쁜 샘플집합, 모호한 샘플집합에 대한 응집성, 분리성, 모호성과 같은 분류 척도를 제공한다.

참고 문헌

[1] P.J. Rousseeuw, A.M. Leroy, "Robust Regression and Outlier Detection," Wiley, 1987.
 [2] P.J. Huber, "Robust Statistics," John Wiley, New York, 1981.
 [3] Charles V. Stewart, "Robust parameter estimation

표 7 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

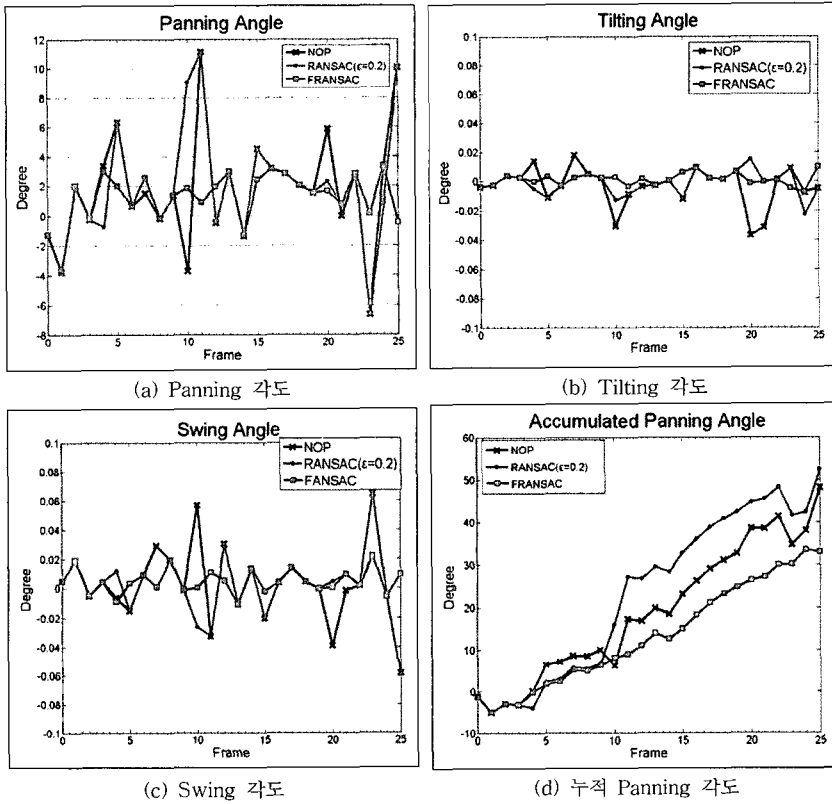


그림 17 프레임별 각도변화

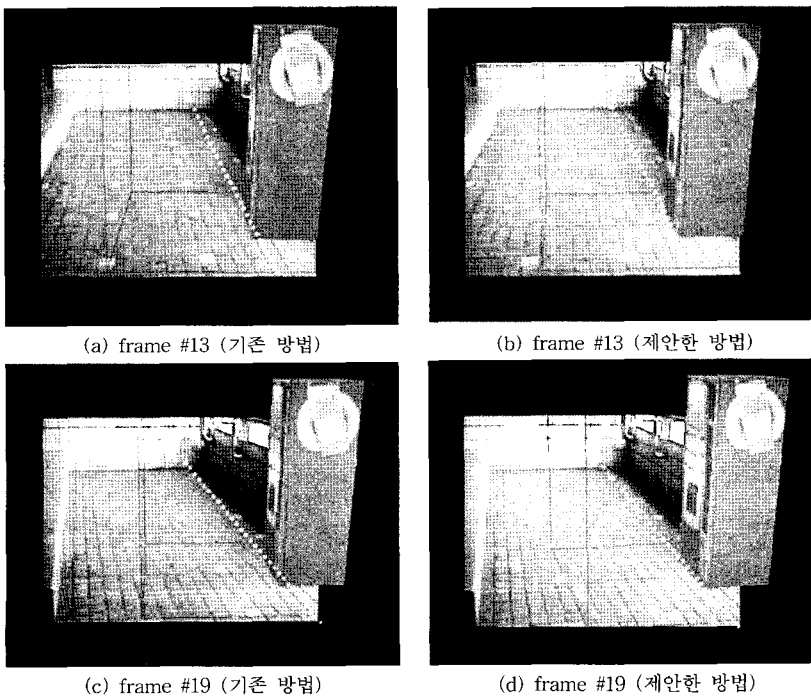


그림 18 가상객체 정렬 오류 비교

in Computer Vision," SIAM Review, vol.41, No.3, pp.513-537, 1999.

[4] 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.

[5] 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.

[6] PHS Torr and C. Davidson, "IMPSAC: Synthesis of Importance Sampling and Random Sample Consensus," IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol.25, No.3, pp. 354-364, 2003.

[7] Valenzuela-Rendon M., "The Fuzzy Classifier System : a Classifier System for Continuously Varying Variables," International Conference on Genetic Algorithms, pp.346-353, 1991.

[8] Danna H. Ballard, Christopher M. Brown, "Computer Vision," Prentice-Hall, 1982.

[9] G. Qian and H. R. Kunsch, "On model selection in robust linear regression," Technical Report 80, Seminar Fur Statistik, Eidgenossische Technische Hochschule (ETH), Zurich, Switzerland, Nov. 1996.

[10] H. Wang, C. Wang, G. Wu, "Bi-criteria Fuzzy C-Means Analysis," Fuzzy Sets and Systems, vol.64, pp.311-319, 1994.

[11] C. Tomasi, T. Kanade, "Detection and tracking of point features," CMU Technical Report, CMU-CS-91-132, April, 1991.

[12] Hartley, R. I, Zisserman, A, "Multiple View Geometry in Computer Vision," Cambridge University Press, 2000.



이 중 재

1999년 2월 숭실대학교 전자계산학과 졸업(공학사). 2001년 2월 숭실대학교 대학원 컴퓨터학과 졸업(공학석사). 2005년 2월 숭실대학교 대학원 컴퓨터학과 졸업(공학박사). 2005년 9월~현재 숭실대학교 정보미디어기술연구소(연구교수). 관

심분야는 컴퓨터 비전, 증강현실, 3차원 복원, 의료영상처리 등임



장 효 중

2001년 2월 숭실대학교 컴퓨터학부 졸업(공학사). 2003년 2월 숭실대학교 대학원 컴퓨터학과 졸업(공학석사). 2003년 3월~현재 숭실대학교 대학원 컴퓨터학과 박사과정. 관심분야는 음성 처리, 컴퓨터 비전, 영상처리, 패턴인식, 영상검색, 증

강현실 등임



김 계 영

1990년 2월 숭실대학교 전자계산학과 졸업(공학사). 1992년 2월 숭실대학교대학원 컴퓨터학과 졸업(공학석사). 1996년 2월 숭실대학교대학원 컴퓨터학과 졸업(공학박사). 1996년 3월~1997년 11월 한국 전자통신연구원(Post Doc.). 1997년 12월

~2001년 2월 한국전력공사 전력연구원(선임연구원). 2001년 3월~현재 숭실대학교 컴퓨터학부(조교수). 관심분야는 컴퓨터비전, 형태인식, 생체인식, 증강현실, 영상 및 신호처리 등임



최 형 일

1979년 2월 연세대학교 전자공학과 졸업(공학사). 1982년 6월 미시간대학교 전산공학과 졸업(공학석사). 1987년 6월 미시간대학교 전산공학과 졸업(공학박사). 1987년 9월~현재 숭실대학교 미디어학부 교수. 관심분야는 컴퓨터비전, 패턴인식, 퍼

지이론, 비디오검색, 인터페이스 에이전트 등