

# 가우시안 프로세스를 이용한 실내 환경에서 소형무인기에 적합한 SLAM 시스템 개발

## Development of a SLAM System for Small UAVs in Indoor Environments using Gaussian Processes

전 영 산, 최 종 은, 이 정 옥\*  
(Young-San Jeon<sup>1</sup>, Jongeun Choi<sup>2</sup>, and Jeong Oog Lee<sup>1,\*</sup>)

<sup>1</sup>Aerospace Information Engineering, Konkuk University

<sup>2</sup>Mechanical Engineering, Michigan State University

**Abstract:** Localization of aerial vehicles and map building of flight environments are key technologies for the autonomous flight of small UAVs. In outdoor environments, an unmanned aircraft can easily use a GPS (Global Positioning System) for its localization with acceptable accuracy. However, as the GPS is not available for use in indoor environments, the development of a SLAM (Simultaneous Localization and Mapping) system that is suitable for small UAVs is therefore needed. In this paper, we suggest a vision-based SLAM system that uses vision sensors and an AHRS (Attitude Heading Reference System) sensor. Feature points in images captured from the vision sensor are obtained by using GPU (Graphics Process Unit) based SIFT (Scale-invariant Feature Transform) algorithm. Those feature points are then combined with attitude information obtained from the AHRS to estimate the position of the small UAV. Based on the location information and color distribution, a Gaussian process model is generated, which could be a map. The experimental results show that the position of a small unmanned aircraft is estimated properly and the map of the environment is constructed by using the proposed method. Finally, the reliability of the proposed method is verified by comparing the difference between the estimated values and the actual values.

**Keywords:** SIFT, small unmanned aircraft, SLAM, vision sensor, Gaussian process

### I. 서론

오늘날 무인기는 군사 정찰용으로 많이 개발되어 사용되고 있지만 민간부분에까지 그 활용범위를 넓혀나가고 그 종류도 다양해지고 있으며, 항공기술과 산업에서 점점 더 중요한 위치를 차지하고 있다. 특히, 크기가 작은 소형무인기(MAV: Micro Aerial Vehicle)는 실외뿐만 아니라 실내에서도 임무 수행이 가능하고, 비용대비 효율적이며 사람의 접근이 어려운 재난 환경에서 사고 희생자를 신속하게 수색하거나 사람의 개입 없이 재난 지역을 조사할 수 있는 등의 장점이 있어 국내외적으로 활발하게 연구 개발 되고 있다. 2011년 쓰나미가 발생했을 때 일본에서는 후쿠시마 원전발전소 안의 파괴상태를 파악하고 방사성 물질을 검출하고 감시 하는데 많은 무인기를 투입하기도 하였다.

무인기가 임무를 수행함에 있어서 가장 핵심이 되는 기술 중 하나는 비행체의 위치인식 및 비행환경에 대한 지도

작성이다. SLAM (Simultaneous Localization and Mapping)은 로봇과 무인운행체가 미지 환경에서 맵 생성과 위치인식을 동시에 수행하게 해주는 기술이다. 실외환경에서는 GPS (Global Positioning System)에 의해 비교적 정확한 비행체의 위치를 알아낼 수 있다. 그러나 실내 환경과 같이 GPS 수신에 불가능하고 장애물들이 비행체에 비교적 근접한 위치에 있는 환경에서는 더욱 정확한 위치 인식이 필요하다. 기존의 실내 환경을 위한 SLAM 기법들은 주로 고가의 레이저 스캔 센서(laser scan sensor)나 스테레오 카메라(stereo camera) 등의 센서를 사용하여 맵 생성과 자체 위치인식이 가능하게 하였다. 그러나 payload에 제약이 있는 소형무인기의 경우에는 이러한 무거운 센서들을 탑재하고 사용하는데 어려움이 있기 때문에 소형무인기에 탑재할 수 있는 저렴하고 가벼운 센서의 필요성이 대두되었다. 영상 장치는 최근 반도체 및 영상 기술의 눈부신 발전으로 매우 소형, 경량되면서 고화질 이미지 정보를 제공해 줄 수 있게 되었고, 가격도 저렴하다. 그래서 최근 들어 저가의 비전 정보와, MEMS 기술로 개발되는 오차가 크지만 저가인 관성 항법 장치 정보를 종합하여, 위치 인식의 정밀도를 개선하고자 하는 연구들이 진행 되고 있다[1,2].

가우시안 프로세스(Gaussian Process) 기술은 날씨변화, 생물화학 등 자연 현상을 예측하고 추정하는 연구뿐만 아니라 로봇 분야 연구에서도 많이 활용되고 있다. 오늘날 스마트폰이나 로봇에서 Wi-Fi 신호를 송수신하고 Wi-Fi 신호

\* Corresponding Author

Manuscript received August 30, 2014 / revised September 15, 2014 / accepted September 29, 2014

전영산, 이정옥: 건국대학교 항공우주정보시스템공학과  
(ysjean0625@gmail.com/ljo7@konkuk.ac.kr)

최종은: Michigan State University Mechanical Engineering  
(jchoi@egr.msu.edu)

\* 이 논문은 2012학년도 건국대학교의 연구년교원 지원에 의하여 연구되었음.

강도의 크기를 특징으로 하여 SLAM 시스템을 구축하는 연구가 많이 진행되고 있다[3]. 하지만 Wi-Fi 신호는 불안정하기 때문에 Wi-Fi 신호 강도 특징을 가우시안 프로세스에 사용하는 방법은 로봇이나 무인기의 위치 추정을 지속적으로 수행하는데 어려움이 있다. Wi-Fi 신호 강도보다는 로봇 혹은 무인기에서 비전 센서로 촬영한 이미지의 특성에 따라 생성된 훈련 데이터를 기반으로 가우시안 프로세스를 이용하여 위치추정과 맵을 생성하는 것이 더욱 안정적이고 효율적이다[4,5].

본 논문에서는 실내 환경과 같이 GPS 사용이 제한된 환경에서 비전 센서와 AHRS 센서를 사용하여 소형무인기에 적합한 SLAM 시스템을 제안한다. 비전 센서로부터 획득한 영상정보에서 GPU 기반의 SIFT 알고리즘을 사용하여 특징점을 추출하고 AHRS로부터의 자세 정보를 결합하여 소형무인기의 위치를 추정한다. 추정된 위치 정보와 색상(color) 분포를 기반으로 가우시안 프로세스 모델을 생성하고 이를 통하여 맵을 생성한다. 제안한 시스템을 이용하여 무인기의 위치를 추정하고 맵을 구성하는 실험을 수행하고 실제 데이터와 비교 분석하여 시스템의 신뢰성을 검증하였다.

## II. 기본적인 이론과 알고리즘

### 1. SIFT 기반의 특징점 추출 및 매칭

이미지 매칭(matching)에는 원 이미지와 대상 이미지와의 픽셀 간 유사성 비교를 통한 매칭 외에 이미지에 대한 주된 특징이 되는 점들을 찾은 뒤 이 점들에 대하여 이 점들을 보다 식별이 용이하게 서술할 수 있는 서술 벡터(description vector)를 생성하고, 이 벡터들 간의 유사성을 측정하여 매칭을 하는 방법이 있다. 이러한 주된 특징이 되는 픽셀 혹은 지점들을 특징점(feature point) 혹은 키폰트(keypoint)라고 한다. SIFT (Scale Invariant Feature Transform)는 영상인식 기술 중 하나로 영상 피라미드를 만들어 특징점을 추출하여 크기 변화에 강인하고, 특징점들의 기준 방향을 추출하여 특징벡터를 생성하기 때문에 회전 변화에도 강인한 알고리즘이다[6]. 그림 1은 두 이미지에서 동일한 특징점을 매칭 하는 것을 보여주고 있다.

영상에서 회전, 스케일, 노이즈 등에 불변하는 특성을 가진 특징점을 추출하고 매칭(matching) 하는 기술은 물체 인식, 물체 검색, 물체 트래킹(tracking) 등을 하기 위해 매우 강력한 기술이다. SIFT 알고리즘은 영상에서 특징을 추출하는 알고리즘이다. 그러나 CPU 기반의 SIFT 알고리즘을 수




그림 1. 서로 다른 2개의 이미지에서 특징점 매칭.  
Fig. 1. Feature points matching in two different images.

행하여 서로 다른 2장의 이미지에서 같은 위치의 특징점을 찾는 작업은 그 처리시간이 10~15초 정도 걸리는데, 이는 비행체에서 실시간으로 전송하는 영상들을 분석하여 처리하기는 한계가 있다. GPU(Graphics Processing Unit) 기반의 SIFT 알고리즘은 속도 면에서 10배 정도의 성능 향상을 보인다.

### 2. Visual Landmark 추출 및 위치계산

촬영한 이미지로부터 실내 환경의 Visual Landmark를 추출하기 위하여, projection geometry를 이용하여 SIFT 알고리즘에 의해 식별된 특징점의 3차원 위치 정보를 계산에 의해 획득한다. 그림 2는 특징점( $P_F$ )의 projection( $P_P$ )을 보여준다. 세 개의 서로 다른 좌표계, 전역 좌표계  $(x, y, z)$ , 카메라 좌표계  $(n_x, n_y, n_z)$ , 그리고 projection plane coordinate  $(\vec{P}_x, \vec{P}_y)$ 를 사용하였다.  $P_F$ 와  $R$ 은 전역 좌표계로 나타내어질 수 있다. 반면에  $P_P$ 는 projection plane coordinate로 나타내어진다. 단위벡터  $\vec{n}_x$ 는 투영면(projection plane)에 법선인 카메라 방향이다.  $R$ 은 카메라 위치이고,  $f$ 는 카메라의 초점 거리이다.

Triangle proportionality를 사용하면, 식 (1)과 같이 쉽게  $P_P$ 를 도출해낼 수 있다.

$$P_p(x_p, y_p) = \frac{f}{n_x \cdot RP_F} (-\vec{n}_y \cdot \vec{RP}_F, \vec{n}_z \cdot \vec{RP}_F) \quad (1)$$

식 (1)을 통해  $x_p$ 와  $y_p$ 에 대한 2개의 방정식을 유도할 수 있다. 그러나 특징점  $P_F(x_F, y_F, z_F)$ 의 위치를 계산하기 위해서는 3개의 독립된 방정식이 필요하다. 이는 그림 3에서와 같이, 서로 다른 위치에서 촬영한 2개의 이미지로부터 동일한 위치에 있는 특징점을 사용하여 획득할 수 있다[7].




그림 2. 특징점 ( $P_F$ )의 projection.

Fig. 2. Projection of the feature points ( $P_F$ ).




그림 3. 동일한 특징점을 공유하는 서로 다른 두 이미지.  
Fig. 3. Two different images having the same feature point.

AHRS 센서의 roll, pitch, yaw 등의 항공기 자세 변화와 원점으로부터의 병진운동을 반영한 식 (2)와 (3)을 이용하여 무인기의 위치를 추정한다.  $\psi, \theta$ , 그리고  $\phi$  는 각각 yaw, pitch, roll 각이다.  $(X, Y, Z)$ 은 카메라 좌표계에서의 위치를  $(x, y, z)$ 은 전역 좌표계에서의 위치를 나타낸다.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} \cos\psi\cos\theta & \cos\psi\sin\theta\sin\phi + \sin\psi\cos\phi \\ -\sin\psi\cos\theta & -\sin\psi\sin\theta\sin\phi + \cos\psi\cos\phi \\ \sin\theta & -\sin\phi\cos\theta \end{bmatrix} \begin{bmatrix} x \\ y \\ z \end{bmatrix} \quad (2)$$

$$\begin{aligned} X_F &= (x_F - x_R)(\cos\psi\cos\theta) \\ &\quad + (y_F - y_R)(\cos\psi\sin\theta\sin\phi + \sin\psi\cos\phi) \\ &\quad - (z_F - z_R)(\cos\psi\sin\theta\cos\phi + \sin\psi\sin\phi) \\ Y_F &= -(x_F - x_R)(\sin\psi\cos\theta) \\ &\quad - (y_F - y_R)(\sin\psi\sin\theta\sin\phi + \cos\psi\cos\phi) \\ &\quad + (z_F - z_R)(\sin\psi\sin\theta\cos\phi + \cos\psi\sin\phi) \\ Z_F &= (x_F - x_R)(\sin\theta) - (y_F - y_R)(\sin\phi\cos\theta) \\ &\quad - (z_F - z_R)(\cos\theta\cos\phi) \end{aligned} \quad (3)$$

### 3. 가우시안 프로세스 모델

가우시안 프로세스는 수집된 랜덤 분포의 데이터 집합  $D(y, X)$ 로부터 훈련을 통하여 가우시안 분포를 가지는 모델을 생성하고 새로운 변수  $X_*$ 의 입력값으로부터 이에 대응하는 출력값을 예측하고 추정 하는 방법이다. 가우시안 프로세스는 평균 함수  $m(x)$ 와 공분산 함수(covariance function) (식 (4))로 완전히 명세될 수 있으며, 그러므로 식 5와 같이 가우시안 프로세스를 나타낸다[8].

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (4)$$

$$f(x) \sim N(m(x), k(x, x')) \quad (5)$$

Covariance (또는 Kernel) 함수는 가우시안 프로세스의 특성을 제어하는데, 출력값을 정확하게 추정 및 예측하기 위해서는 훈련 데이터의 분포 특성에 따라 최적화된 공분산 함수가 필요하다. 대표적으로 많이 사용되는 것 중의 하나는 SE (Squared Exponential) covariance function이다(식 (6)).

$$k_y(x_p, x_q) = \sigma_f^2 \exp\left(-\frac{1}{2l^2}(x_p - x_q)^2\right) + \sigma_n^2 \delta_{pq} \quad (6)$$

SE는 무한히 미분가능하며 방정식을 smooth 하게 하는 특징이 있다. 식 (6)에서  $l, \sigma_f^2, \sigma_n^2$ 은 hyperparameter이며 각각 length-scale, signal variance, noise variance를 나타낸다. Hyperparameter의 값 변화에 따라 가우시안 프로세스 모델의 posterior function이 영향을 받으며 따라서 예측 정확도를 높이기 위해서는 훈련 데이터에 대한 최적의 hyperparameter를 계산하는 것이 중요하다.

## III. SLAM 시스템

### 1. SLAM 시스템 구성

SIFT 알고리즘과 가우시안 프로세스 모델을 이용한 SLAM 시스템은 그림 4와 같다.

시스템의 주된 센서는 전방에 설치된 비전 센서와

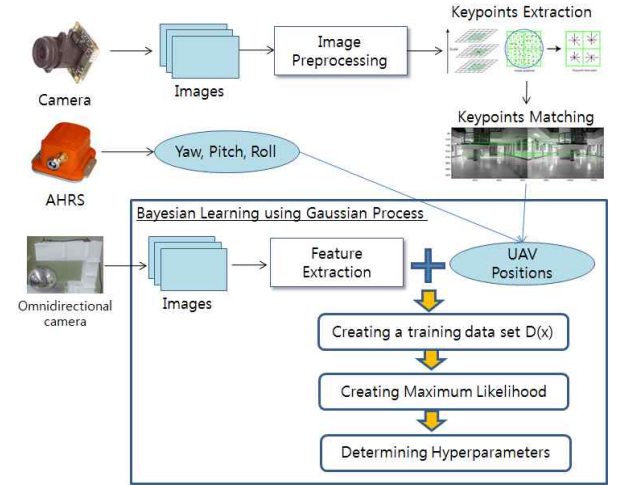


그림 4. SLAM 시스템.

Fig. 4. SLAM system.

AHRS 센서 그리고 무인기 상단에 설치된 전방위 카메라 (omnidirectional camera)이다. 비전 센서로부터 획득한 이미지에 대해 전처리과정을 거쳐 SIFT 알고리즘을 이용하여 특징점을 추출하고 그림 3에서와 같이 연속된 이미지에서 특징점 매칭을 수행한다. 이렇게 매칭된 특징점 정보와 AHRS 센서로부터의 자세 정보(yaw, pitch, roll)를 결합하고 식 (3)을 이용하여 무인기의 위치를 계산한다. 이미지는 렌즈 특성 및 카메라 특징에 따라 방사 왜곡과 접선 왜곡이 발생하기 때문에 이미지 전처리 과정에서는 이미지 왜곡 보정 도구를 사용하여 이미지를 보정함으로써 렌즈 및 이미지 왜곡 오차를 최소화한다.

무인기가 이동하면 전방위 카메라로 획득한 이미지에서 주변 환경에 대한 색상 정보는 거리 변화에 따라 다르게 분포된다. 이러한 색상 분포와 무인기 위치 정보를 훈련 데이터로 하여 가우시안 프로세스 모델을 생성하고 맵을 구축하게 된다. 무인기 위치 추정 과정에서 파악된 주변 환경은 일정한 간격의 그리드 형태로 표현이 되며 맵 해상도는 그리드 간격의 크기이다. 해상도가 높으면(그리드 간격의 크기가 작으면) 더 많은 그리드 포인트가 생성되어 맵 정확도가 향상되지만 계산 시간을 많이 필요로 한다.

### 2. 훈련 데이터 특징 추출

RGB 이미지에서 모든 픽셀에 대해 색상 분포를 계산하여 공분산 함수를 계산하기에는 시간이 많이 소요되기 때문에 계산량을 줄이고 속도를 향상하기 위해서 본 논문에서는 주성분 분석 (또는 PCA: Principal Component Analysis) 기법을 사용한다. 주성분 분석은 데이터 성분 중에서 주성분이 되는 부분 집합으로부터 전체 데이터 집합을 분석하는 기법이다. 이러한 방법은 고차원의 데이터 집합을 저차원의 데이터 집합으로 차원을 줄여서 데이터를 분석함으로써 시간을 적게 소모 하면서 계산 속도를 향상 시키는 장점이 있다.

이미지는 서로 다른 방향과 스케일에 적용된 필터 응답으로 표현된다. 전방위 카메라로 획득한 RGB 이미지를 두 부분으로 분할한다. 분할된 이미지에 대해 DTCWT (Dual-Tree Complex Wavelet Transform) 기법[9]을 6 방향과 5개

스케일에 적용하여 서브밴드를 구성한다. 각 서브밴드는 이미지 상단과 하단에 대한 2개의 평균 필터 응답으로 표현된다. 여기에 green, red, blue 평균값이 추가되어  $5 \times 6 \times 2 + 3 = 63$  차원이 된다. 따라서 각 RGB 이미지는 126 차원으로 표현된다. 주성분 벡터를 계산하는 과정은 다음과 같다. 우선, 126차원의 데이터에 대하여 126개의 고유벡터(eigenvector)와 고유값(eigenvalue)을 계산한다. 다음에 고유값을 크기순으로 정렬한 후 처음 8개의 고유벡터를 선택한다. 최종 데이터 집합은 원 데이터 집합보다 적은 차원을 가지게 된다. 8 차원으로 압축된 훈련 데이터에 대해 각 차원의 색상 분포에 대한 공분산 함수의 hyperparameter를 계산하고 가우시안 프로세스 모델을 구축하였다.

3. 가우시안 프로세스 기반 Bayesian Inference

훈련 데이터는 가우시안 잡음  $\epsilon$ 를 가진 선형적 분포를 가진다고 가정하면 prior function은  $y = f(x) + \epsilon$ 이다. Marginal likelihood는 함수 값의 Marginalization을 나타내며 식 (7)과 같다. 식 (7)의 편미분을 통해 얻어진 maximum marginal likelihood에 의해 hyperparameter를 설정한다. Hyperparameter는 공분산 함수의 계수가 되고 공분산 함수와 평균으로부터 가우시안 프로세스 모델을 구축하게 된다.

$$\log p(y|X) = -\frac{1}{2}y^T(K + \delta_n^2 I)^{-1}y - \frac{1}{2}\log|K + \delta_n^2 I| - \frac{n}{2}\log 2\pi \quad (7)$$

Bayesian linear model에서 추론은 Bayes의 이론에 따라 식 (8)과 같이 계산된 posterior distribution에 기반한다.

$$\begin{aligned} \text{posterior} &= \frac{\text{likelihood} \times \text{prior}}{\text{marginal likelihood}} \\ &= p(f|y, X) = \frac{p(y|X, f)p(f)}{p(y|X)} \end{aligned} \quad (8)$$

맵이 생성된 후 무인기의 특정 위치를 식별하기 위해서는 현 위치에서 전방위 카메라로 획득한 이미지의 색상 분포로부터 공분산 함수를 계산한다. 이를 맵을 구성하는 모든 그리드 포인트에 대해 미리 계산되어 저장된 공분산 함수와 비교하여 비용 함수(cost function)를 계산하고 최소값을 가지는 그리드 포인트를 선택하여 무인기의 위치를 결정하게 된다.

IV. 실험 및 분석

1. 실험 환경

실험은 그림 5와 같이  $4m \times 4m$  실내 환경에서 수행되었으며 위치를 미리 알고 있는 64개 지점에서 비전 센서로부터 이미지를 획득하고 제안된 방법에 의하여 위치를 계산한 후 이를 미리 알고 있는 참값과 비교하여 분석하였다. 카메라는 그림 5에서와 같은 방향으로 진행하였다.

카메라 방향에 영향을 받지 않기 위해서 전방위 카메라가 필요하지만 고가의 센서이기 때문에 그림 6과 같이 시중에서 쉽게 구할 수 있는 크리스마스 장식 볼과 웹캠을 이용하여 전방위 카메라를 대신하였다. 장식 볼에 비친 주변 환경을 웹캠으로 촬영하여 영상을 획득하였다.




그림 5. 실험 환경과 카메라 진행방향.  
Fig. 5. Experimental environment and camera movement.




그림 6. 전방위 카메라 구성과 획득된 이미지.  
Fig. 6. Construction of an omnidirectional camera.

2. 실험 결과 분석

실험은 세 단계, 무인기 위치 추정 단계, 맵 생성 단계, 그리고 맵 정확도 측정 단계로 진행되었다. 첫 번째 단계에서는 미리 정한 64개 지점에서 촬영한 연속된 2개의 서로 다른 이미지에서 SIFT 알고리즘을 사용하여, 특징점을 추출하고 매칭하였다. 이를 AHRS 센서 정보와 결합하여 무인기의 위치를 추정하였다. 무인기 위치 추정과 동시에 전방위 카메라로부터 RGB 이미지를 획득하여 색상 분포를 계산한다. 그림 7은 여러번 실험을 통하여 얻어진 데이터의 평균을 구하여 실제 위치와 계산에 의해 구해진 위치와의 차이를 보여준다.

두 번째 단계는 64개 지점에서 전방위 카메라로부터 획득한 이미지 색상 분석을 토대로 생성된 8차원의 64개 데이터 집합과 첫 번째 단계에서 무인기가 이동하면서 측정된 각 지점의 위치값을 결합하여 훈련 데이터를 생성하고 가우시안 프로세스 모델을 구축하여 맵을 생성하였다. 맵을 구성하는 그리드 간격은 0.1m로 하였으며, 따라서  $4m \times 4m$  실험 환경에 대해 총  $41 \times 41 = 1681$ 개의 그리드 포인트를 사용하였다. 맵 생성은 위치를 미리 알고 있는 64개 훈련 데이터를 사용하여 1681개 각 그리드 포인트에 대한 공분산 함수를 계산하는 것을 의미한다.

세 번째 단계에서는 그림 8의 왼쪽 그림과 같이 임의의 47개 테스트 위치를 정하고 각 위치에서 테스트 RGB 이미지를 획득하여 두 번째 단계에서와 같은 방법으로 공분산




그림 7. 실제 위치와 계산에 의해 구해진 위치와의 차이.  
Fig. 7. Difference between actual and calculated locations.

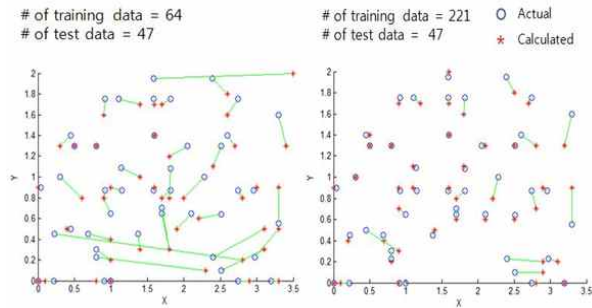


그림 8. 맵 정확도 테스트 결과.

Fig. 8. The results of map accuracy testing.

함수를 계산한다. 이를 1681개 각 그리드 포인트에 대한 공분산 함수와 비교하여 최소값을 가지는 그리드 포인트를 선택한다. 그림 8은 이와 같은 방식으로 테스트 위치를 계산하는 작업을 여러번 반복 수행한 후 평균값을 구하고 이를 참값과 비교한 결과를 보여준다.

동일한 과정의 실험을 미리 정한 지점 수를 221개로 증가하여 수행한 결과를 그림 8의 오른쪽 그래프에서 보여준다.

### V. 결론

본 논문에서는 비전 센서로부터 얻은 영상 정보로부터 SIFT 알고리즘과 AHRS 센서 데이터를 사용하여 무인기 위치를 비교적 정확하게 추적할 수 있었다. 무인기 위치정보와 전방위 카메라로부터 획득한 이미지의 색상 분포 특징을 결합하여 생성된 가우시안 프로세스 모델로부터 신뢰할 만한 수준의 맵이 생성되는 것을 확인할 수 있었다.

그림 8에서와 같이 훈련 데이터의 수가 많은 경우 맵 정확도가 향상되는 것을 알 수 있었다. 그러나 훈련 데이터의 수가 증가할수록 계산 시간도 늘어나는 단점이 있다. 추후 연구에서는 전체 영역을 분할하여 분할된 각 영역에 대한 서브맵을 작성하고 이들을 결합하여 전체 맵을 생성하는 방법에 대한 연구를 수행할 예정이다. 이를 통하여 맵 정확도는 향상되고 계산시간은 단축하는 효과를 기대할 수 있다.

### REFERENCES

- [1] T. T. Nwe, T. Htike, K. M. Mon, Dr.Z. M. Naing, and Dr.Y. M. Myint, "Application of an inertial navigation system to the quad-rotor UAV using MEMS sensors," *Proc. of World Academy of Science, Engineering and Technology*, Aug. 2008.
- [2] E. Altuğ, J. P. Ostrowski, and R. Mahony, "Control of a quadrotor helicopter using visual feedback," *Proc. of the 2002 IEEE Conference on Robotics & Automation*, 2002.
- [3] J. Huang, D. Millman, M. Quigley, and D. Stavens, "Efficient, generalized indoor WiFi GraphSLAM," *Proc. of 2011 IEEE International Conference on Robotics and Automation*, pp. 1038-1043, May 2011.
- [4] A. Brooks, A. Makarenko, and B. Upcroft, "Gaussian process models for indoor and outdoor sensor-centric ro-

bot localization," *IEEE Trans. on Robotics*, vol. 24, no. 6, pp. 1341-1351, Dec. 2008.

- [5] Y. Xu and J. Choi, "Adaptive sampling for learning gaussian process using mobile sensor networks," *Sensors*, vol. 11, no. 3, pp. 3051-3066, 2011.
- [6] C. Han, C. Oh, and B. Choi, "Distinctive image features from scale-invariant keypoints," *International Journal of Computer Vision*, vol. 60, no. 2, pp. 91-110, 2004.
- [7] J. O. Lee, T. S. Kang, K. H. Lee, S. G. Im, and J. K. Park, "Vision-based indoor localization for unmanned aerial vehicles," *Journal of Aerospace Engineering*, vol. 24, no. 3, pp. 373-377, 2011.
- [8] C. E. Rasmussen and C. K. I. Williams, *Gaussian Processes for Machine Learning*, the MIT Press, 2006.
- [9] I. W. Selesnick, R. G. Baraniuk, and N. C. Kingsbury, "The dual-tree complex wavelet transform," *IEEE Signal Processing Magazine*, vol. 22, no. 6, pp. 123-151, 2005.



전 영산

2010년 연변과학기술대 재료기계자동화공학과 졸업. 2012년 건국대학교 석사. 관심분야는 제어공학, 무인비행기.



최 종은

1998년 연세대 기계공학과 졸업. 2002년 University of California at Berkeley 석사. 2006년 동 대학 박사. 2008년~현재 Michigan State University Mechanical Engineering 교수. 관심분야는 시스템과 제어, Bayesian approaches.



이 정욱

1992년 고려대 컴퓨터학과 졸업. 1994년 동 대학원 석사. 2001년 동 대학 박사. 2006년~현재 건국대학교 항공우주정보시스템공학과 교수. 관심분야는 인공지능, 무인비행기, 자율비행.