



## 영상 기반 항법을 위한 가우시안 혼합 모델 기반 파티클 필터

홍경우<sup>1</sup>, 김성중<sup>2</sup>, 방효충<sup>3</sup>, 김진원<sup>4</sup>, 서일원<sup>5</sup>, 박장호<sup>6</sup>

### Particle Filters using Gaussian Mixture Models for Vision-Based Navigation

Kyungwoo Hong<sup>1</sup>, Sungjoong Kim<sup>2</sup>, Hyochoong Bang<sup>3</sup>, Jin-Won Kim<sup>4</sup>, Ilwon Seo<sup>5</sup>  
and Chang-Ho Pak<sup>6</sup>

Korea Advanced Institute of Science and Technology<sup>1,2,3</sup>, Poongsan R&D Institute<sup>4,5,6</sup>

#### ABSTRACT

Vision-based navigation of unmanned aerial vehicle is a significant technology that can reinforce the vulnerability of the widely used GPS/INS integrated navigation system. However, the existing image matching algorithms are not suitable for matching the aerial image with the database. For the reason, this paper proposes particle filters using Gaussian mixture models to deal with matching between aerial image and database for vision-based navigation. The particle filters estimate the position of the aircraft by comparing the correspondences of aerial image and database under the assumption of Gaussian mixture model. Finally, Monte Carlo simulation is presented to demonstrate performance of the proposed method.

#### 초 록

무인항공기의 영상 기반 항법은 널리 사용되는 GPS/INS 통합 항법 시스템의 취약점을 보강할 수 있는 중요한 기술로 이에 대한 연구가 활발히 이루어지고 있다. 하지만 일반적인 영상 대조 기법은 실제 항공기 비행 상황들을 적절하게 고려하기 힘들다는 단점이 있다. 따라서 본 논문에서는 영상 기반 항법을 위한 가우시안 혼합 모델 기반의 파티클 필터를 제안한다. 제안한 파티클 필터는 영상과 데이터베이스를 가우시안 혼합 모델로 가정하여 둘 간의 유사도를 이용하여 항체의 위치를 추정한다. 또한 몬테카를로 시뮬레이션을 통해 위치 추정 성능을 확인한다.

**Key Words** : Vision-Based Navigation(영상 기반 항법), Gaussian Mixture Model(가우시안 혼합 모델), Particle Filter(파티클 필터), Image Matching(영상 대조)

#### 1. 서 론

무인항공기의 항법시스템으로 널리 사용되는 GPS/INS(Global Positioning System/Inertial Navigation System) 통합 시스템은 매우 강력한 성능을 보장하지만, 관성항법장치의 오차 누적 문제와 GPS 재밍

(Jamming) 등으로 인해 취약점이 대두되고 있다. 이에 보조 항법 시스템에 대한 연구가 활발히 이루어지고 있다. 영상 기반 항법은 GPS 보조 항법 중 하나로 항공기에서 얻은 항공 영상과 데이터베이스와의 대조를 통해 위치를 추정하는 기법이다[1,2]. 영상으로부터 얻어지는 정보가 풍부하므로 데이터베이스

† Received : January 3, 2019 Revised : March 8, 2019 Accepted : March 26, 2019

<sup>1</sup> Graduate Student, <sup>2</sup> Graduate Student, <sup>3</sup> Professor, <sup>4</sup> Researcher, <sup>5</sup> Researcher, <sup>6</sup> Researcher

<sup>3</sup> Corresponding author, E-mail : hcbang@ascl.kaist.ac.kr, ORCID 0000-0001-6016-8102

© 2019 The Korean Society for Aeronautical and Space Sciences

와의 대조는 다양한 방법으로 진행되며, 템플릿 기반의 상호 정보(Mutual Information, MI) 대조[3], 템플릿 기반 교차 상관관계 대조[4,5] 및 도로 교차로 대조[6], SIFT 기반의 특징점 대조[7] 등 많은 연구가 진행되고 있다. 뿐만 아니라 [8,9]는 영상 대조 항법을 위한 비선형 필터링을 제안하였다.

대표적인 영상 대조 기법으로 템플릿 매칭과 특징점 기반 매칭이 있으며 템플릿 기반의 매칭의 경우 고도와 자세에 따른 정렬이 필요하다. 그러나 실제 비행 시 측정 오차로 인한 정렬 틀어짐은 불가피하며 정렬이 올바르지 못할 경우 구조적으로 올바른 해를 얻을 수 없다는 취약점이 있다. 반면에 특징점 기반 매칭으로 잘 알려진 SIFT와 SURF의 경우 고도와 자세에 강건한 결과를 주지만 데이터베이스 생성과 실제 비행과의 시간차가 날 경우 두 영상의 차이로 인해 동일한 특징점을 추출하지 못할 수 있다. 따라서 본 항공기 운용에 적합한 강건한 영상 대조 알고리즘이 필요하다.

한편, 인공지능 기술의 발달로 영상으로부터 의미론적인 물체를 구분, 더 나아가 영상에서 각 픽셀별 분류[10] 및 객체별 분류[11]가 가능해졌다. 이는 항공사진에도 활용될 수 있으며[12,13], 이를 활용하여 영상 대조 항법을 위한 특징들을 분류할 수 있다[14]. 이는 항공영상 내의 물체들을 의미론적 분류가 가능함을 암시하며, 이를 바탕으로 본 연구에서는 도심지 비행으로 특징을 건물로 한정하여 항공영상 내 건물들을 특징으로 구분한다고 가정한다.

따라서 기존의 영상 대조 기법의 경우 항공기 운용에 적합하지 않으며, 인공지능 기술의 발달로 물체의 분류 및 인식의 정확도가 월등히 향상되었지만 이러한 인식 결과를 이용하여 항법을 위한 영상 대조를 수행한 연구가 부족한 상황이다. 이러한 이유에서, 본 연구에서는 영상 기반 항법을 위한 가우시안 혼합 모델 기반 파티클 필터를 제안한다. 먼저 항공영상의 특징들을 가우시안 혼합 모델로 간주하여 항공영상과 데이터베이스를 정량적으로 비교하는 방안을 제안하며, 항공기의 비행 조건을 고려하여 파티클 필터를 설계한다. 또한 본 파티클 필터의 우도함수를 데이터베이스와 항공영상의 두 가우시안 혼합 모델 간 유사도를 이용하여 정의한다. 마지막으로 몬테카를로 시뮬레이션을 수행하여 제안한 파티클 필터의 추정 성능을 검증한다.

본 논문의 구성은 다음과 같다. 2.1장에서는 시스템 모델과 측정치 모델을 보여준다. 2.2장에서는 베이저안 필터(Bayesian filter)에 대해 간략히 요약하고 파티클 필터에 대해 설명한다. 2.3장에서는 파티클 가중치 갱신에 사용되는 두 가우시안 혼합 모델간의 L2 거리에 대해 소개하고 우도함수를 정의한다. 2.4장에서는 시뮬레이션 환경을 나타내며 몬테카를로 시뮬레이션을 통해 제안한 파티클 필터의 성능을 확

인한다. 마지막으로 3장에 결론을 서술한다.

## II. 본 론

### 2.1 시스템 모델

본 연구에서 추정할 항체의 상태 벡터는  $X = [\phi, \lambda, h]^T$ 로 각각 위도, 경도, 고도 방향의 위치를 나타낸다. 시스템 모델은 다음과 같이 정의된다.

$$X_{k+1} = X_k + u_k + w_k \quad (1)$$

아래첨자  $k$ 은 이산 시간을 의미하며,  $u_k$ 는 위도, 경도, 고도 방향의 위치 증분 값을 의미한다. 또한 본 위치 증분 값은 INS로부터 획득 가능하다. 본 연구에서는 엄밀한 INS 모델을 사용하지 않지만, 독립적으로 고도 측정치를 얻을 수 있다면 식 (1)의 시스템 모델이 충분히 현실적이라고 알려져 있다[15].  $w_k \sim N(0, Q_k)$ 는 시스템 모델 오차를 의미하며, 가우시안으로 모델링하였다. 공분산  $Q_k$ 은 아래와 같다.

$$Q_k = \begin{bmatrix} \sigma_\phi^2 & 0 & 0 \\ 0 & \sigma_\lambda^2 & 0 \\ 0 & 0 & \sigma_h^2 \end{bmatrix} \quad (2)$$

$\sigma_\phi, \sigma_\lambda, \sigma_h$ 는 각각 위도, 경도, 고도 방향 위치 오차의 표준편차를 의미한다.

측정치는 크게 두 가지로 항공영상과 yaw 방향의 자세 각이 있다. 항공영상을 기존의 데이터베이스와 비교하기 위해서 yaw 방향의 정렬이 필요하며 yaw 방향의 자세 각은 INS로부터 획득 가능하다. 이산 시간  $k$  때의 yaw 방향 자세 각( $\psi_k$ )는 실제 자세 각( $\psi_{k,true}$ )에 대해서 영평균 가우시안 오차를 가진다.

$$\psi_k = \psi_{k,true} + \zeta_k \quad (3)$$

$$\zeta_k \sim N(0, \sigma_\psi^2) \quad (4)$$

$\sigma_\psi$ 는 yaw 자세 각 오차의 표준편차를 의미한다.

항공영상은 김발에 장착된 카메라가 직하방을 촬영하여 획득한다고 가정한다. 영상은 인공지능 기법을 통해 건물과 건물이 아닌 지형으로 분류되며, 이를 픽셀 단계에서의 확률 정보로 표현한다[14]. 이를 이용하여 항공영상에서의 건물을 가우시안 혼합 모델로 생성할 수 있으며, 가우시안 혼합 모델을 측정치로 사용함으로써 데이터베이스와 대조를 통해 위치를 추정할 수 있다.

Figure 1은 데이터베이스 내에서 비행체를 표시한 간단한 예로, 건물들의 확률 정보(빨간 점선)를 저장하고 있으며 카메라 영역(검은 점선) 내의 건물들(빨

간  $\times$  점)이 측정치로 얻어진다. 추가적으로 건물의 확률 분포는 다변수 정규분포로  $2 \times 1$  크기의 평균,  $[\mu_x, \mu_y]^T$ 와  $2 \times 2$  크기의 공분산 행렬,  $\Sigma$ 를 가진다. 아래첨자  $x, y$ 는 각각 영상 좌표계에서의 가로, 세로를 의미한다.

$$\Sigma = \begin{bmatrix} \Sigma_{xx} & \Sigma_{xy} \\ \Sigma_{yx} & \Sigma_{yy} \end{bmatrix} \quad (5)$$

그러나 본 연구에서는 계산의 편의를 위하여, 데이터베이스의 각 가우시안들은  $x, y$ 축으로 독립적이고 ( $\Sigma_{xy} = \Sigma_{yx} = 0$ ) 각 축의 표준편차가 동일( $\sqrt{\Sigma_{xx}} = \sqrt{\Sigma_{yy}}$ )하다고 가정한다.

측정치 모델은 아래와 같다.

$$Z_k = M_k \times \{h(X_k) + v_k\} \quad (6)$$

$$M_k = \begin{bmatrix} \cos(\psi_k) & \sin(\psi_k) & 0 \\ -\sin(\psi_k) & \cos(\psi_k) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (7)$$

데이터베이스에는 위경도 위치에 따른 건물들의 가우시안 혼합 모델이 저장되어 있으며,  $h(X_k)$ 는 해당 위치( $X_k$ )에서의 건물들의 확률 분포 정보 즉 가우시안 혼합 모델 정보를 의미한다. 이는 Fig. 1의 카메라 영역(검은 점선) 내의 건물 확률 분포(빨간 점선)와 같다. 만약  $X_k$  위치에서  $B$ 개의 건물이 측정되며  $i$ 번째 건물의 확률 분포는 평균  $\mu^i$ 와 공분산  $\Sigma^i$ 를 따른다고 할 때, 가우시안 혼합 모델은 아래와 같다.

$$\sum_{i=1}^B \alpha_i N(\mu^i, \Sigma^i) \quad (8)$$

$$N(\mu^i, \Sigma^i) = \frac{e^{-\frac{1}{2}(x-\mu^i)^T(\Sigma^i)^{-1}(x-\mu^i)}}{\sqrt{|2\pi\Sigma^i|}} \quad (9)$$

$\alpha_i$ 는 각 건물들의 혼합 비율을 의미하며 모든 건물이 건물의 중심에서의 확률이 1이 되도록 설정하였다( $\alpha_i = \sqrt{|2\pi\Sigma^i|}$ ). 다변수 정규분포가 각 축에 독립적이고 각축의 표준편차가 동일하다는 가정에 때문에 공분산 값을 대표하여  $\Sigma_{xx}$  값만을 사용할 수 있다. 따라서 식 (8)의 확률 분포는  $\mu_x, \mu_y, \Sigma_{xx}$  세 변수로 표현 가능하며,  $h(X_k)$ 는 앞선 세 변수만을 출력한다.

$$h(X_k) = \begin{bmatrix} \mu_x^1 & \dots & \mu_x^i & \dots & \mu_x^B \\ \mu_y^1 & \dots & \mu_y^i & \dots & \mu_y^B \\ \Sigma_{xx}^1 & \dots & \Sigma_{xx}^i & \dots & \Sigma_{xx}^B \end{bmatrix} \quad (10)$$

$v_k$ 는 항공영상에서 가우시안 혼합 모델을 생성하는 과정에서 발생하는 오차로 3개의 열과 해당 지역의 가우시안들의 개수만큼의 행을 가지며 가우시안으로 모델링하였다,  $v_k \sim N(0, R_k)$ . 공분산  $R_k$ 는 아래와 같다.

$$R_k = \begin{bmatrix} \sigma_{\mu_x}^2 & 0 & 0 \\ 0 & \sigma_{\mu_y}^2 & 0 \\ 0 & 0 & \sigma_{\Sigma_{xx}}^2 \end{bmatrix} \quad (11)$$

$\sigma_{\mu_x}, \sigma_{\mu_y}, \sigma_{\Sigma_{xx}}$ 는 각각 영상 좌표계 상 가로, 세로 방향 오차와 가우시안 분포 분산 오차의 표준편차를 의미한다.  $M_k$ 는 데이터베이스와의 정렬을 위한 회전행렬을 의미한다. 최종적으로 측정치 모델을 이용하여 생성된 측정치는 Fig. 2와 같으며 Fig. 3은 이를 3차원으로 보여준다. 명확한 이해를 위해 Fig. 2는 Fig. 1의  $h(X_k)$  분포에 측정치 오차를 추가하지 않은 결과이며, 시뮬레이션에서는 측정치 오차를 추가하여 수행하였다.

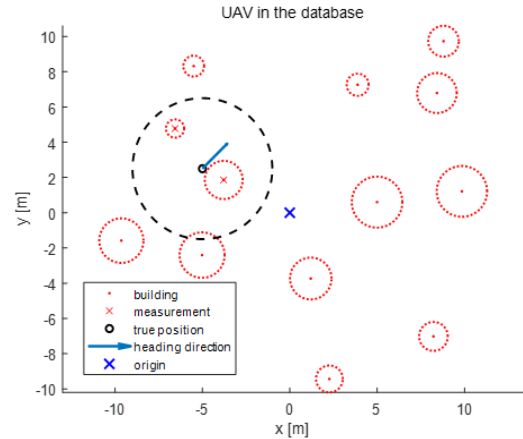


Fig. 1. An example of database and an aircraft




Fig. 2. Measurements(Gaussian mixtures) generated by the measurement model

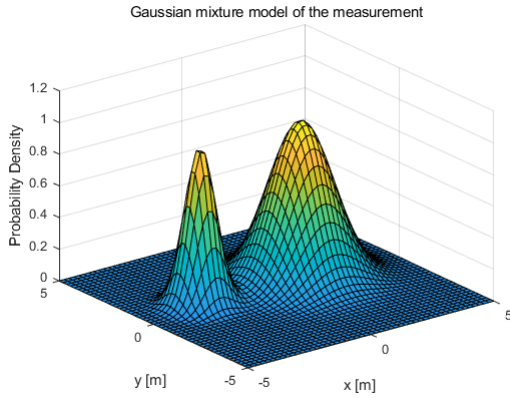


Fig. 3. 3D graph of gaussian mixtures of the measurement generated by the measurement model

측정치 모델의 비선형성이 강하기 때문에 선형 필터나 EKF와 같은 선형근사 필터는 높은 정확도를 얻기 힘들며, 이에 파티클 필터를 사용하여 항체의 위치를 추정한다.

## 2.2 파티클 필터

본 장에서는 베이지안 필터에 대해 소개하며 다음으로 파티클 필터 SISR 알고리즘에 대해 소개한다.

### 2.2.1 베이지안 필터(Bayesian Filter)

이산 시간  $k$ 때의 상태변수를  $x_k$ , 측정치를  $z_k$ , 시스템 전이(System transition) 함수를  $f_k$ , 측정치 함수를  $h_k$ 라 할 때 시스템 모델과 측정치 모델은 아래와 같다.

$$x_{k+1} = f_k(x_k, w_k) \quad (12)$$

$$z_k = h_k(x_k, v_k) \quad (13)$$

베이지안 필터를 통해 현재까지의 측정치 정보로 현재 상태 변수의 확률 분포를 계산할 수 있으며 이를 사후 확률 분포라 한다. 이는  $p(x_k|Z_k)$ 로 표기하며,  $Z_k = \{z_1, z_2, \dots, z_k\}$ 를 의미한다.

베이지안 필터는 상태 예측(Prediction) 과정과 측정치 갱신(Update) 과정으로 구성되어 있다. 상태 예측 과정에서는 Chapman-Kolmogorov 식[16]을 이용하여 이전 시간까지의 측정치 정보로부터 현재 시간의 상태를 예측한다.

$$p(x_k|Z_{k-1}) = \int p(x_k|x_{k-1})p(x_{k-1}|Z_{k-1})dx_{k-1} \quad (14)$$

상태 예측 과정에서 얻어진 사전 확률 분포와 현재 시간의 측정치를 이용하여 사후 확률 분포를 구할 수 있다.

$$p(x_k|Z_k) = \frac{g(z_k|x_k)p(x_k|Z_{k-1})}{p(z_k|Z_{k-1})} \quad (15)$$

$$p(z_k|Z_{k-1}) = \int g(z_k|x_k)p(x_k|Z_{k-1})dx_k \quad (16)$$

$g(z_k|x_k)$ 은 측정치 우도(Likelihood)로 현재 상태에서 얻을 수 있는 측정치의 확률 분포를 의미한다. 따라서 상태 예측 과정과 측정치 갱신 과정을 재귀적으로 반복하여 현재 상태를 추정한다.

그러나 식 (10)의 적분항 계산이 실제 구현에 많은 어려움이 있으며 파티클 또는 격자로 근사하여 계산되며 이를 각각 파티클 필터, 포인트 매스 필터(Point Mass Filter)라 한다.

### 2.2.2 파티클 필터 SISR 알고리즘

파티클 필터는 가중치 있는 파티클들로 베이지안 필터를 근사한 필터로, 충분한 파티클이 확보된다면 비선형이 심한 상황에서도 높은 성능을 보여준다. 각각의 파티클은 항체와 동일한 상태변수와 파티클마다 가중치를 가지고 있으며,  $\{x_k^i, \omega_k^i\}_{i=1}^N$ 로 표기한다.  $N$ 은 전체 파티클 개수를 의미한다. 베이지안 필터와 유사하게 파티클 전파와 측정치 갱신 두 과정으로 구성되어 있으며, 각 과정은 아래와 같이 수행된다 [17].

$$x_k^i \sim p(x_k|x_{k-1}) \quad (17)$$

$$\tilde{\omega}_k^i = \omega_{k-1}^i \times g(z_k|x_k^i) \quad (18)$$

$\tilde{\omega}_k^i$ 는 표준화되기 전 가중치를 의미하며 전체 합이 1이 되도록 표준화해야 한다.  $g(z_k|x_k)$ 는 앞서 언급했듯이, 측정치 우도함수이다.

파티클 전파와 측정치 갱신 과정을 반복 시, 소수의 파티클들이 가중치를 독점하여 필터의 성능을 저하시키는 파티클 퇴화(Degeneracy)문제가 발생한다. 퇴화 여부는 유효 샘플 크기(Effective sample size)를 이용하며, 유효 샘플 크기가 일정 임계값 이하가 되면 파티클이 퇴화되었다고 판단한다. 본 연구에서는 전체 파티클 개수의  $\frac{2}{3}$  값을 임계값으로 사용하였다. 유효 샘플 크기의 추정치는 아래와 같다.

$$\hat{N}_{eff} = \frac{1}{\sum_{i=1}^N (\omega_k^i)^2} \quad (19)$$

파티클 퇴화 문제를 해결하기 위해서 가중치가 큰 파티클들은 가중치가 작은 여러 파티클들로 나누어 주고 가중치가 너무 작은 파티클들은 소거하여 전체 파티클들의 분포를 유지시키며 파티클의 가중치를

고르게 분포해야 한다. 본 과정을 파티클 재추출(Resampling)라 하며, 측정치 갱신 과정 후 파티클 퇴화문제가 발생할 시 파티클을 재추출하는 알고리즘을 SISR(Sequential Importance Sampling with Resampling) 알고리즘이라 한다.

파티클 필터 SISR 알고리즘은 아래와 같다.

---

Algorithm 1: SISR algorithm

---

Input:  $\{x_{k-1}^i, \omega_{k-1}^i\}_{i=1}^N, z_k$

output:  $\hat{x}_k, \hat{P}_k$

For  $i = 1:N$

Draw  $x_k^i \sim p(x_k | x_{k-1})$

Update  $\tilde{\omega}_k^i = \omega_{k-1}^i \times g(z_k | x_k^i)$

For  $i = 1:N$

Normalize  $\omega_k^i = \tilde{\omega}_k^i / \sum_{j=1}^N \tilde{\omega}_k^j$

If degeneracy problem occurs

$\{x_k^i, \omega_k^i\}_{i=1}^N = \text{Resampling}\{x_k^i, \omega_k^i\}_{i=1}^N$

Compute  $\hat{x}_k = \sum_{i=1}^N \omega_k^i \times x_k^i$

Compute  $\hat{P}_k = \sum_{i=1}^N \omega_k^i \times (x_k^i - \hat{x}_k)$

---

## 2.3 가우시안 혼합 모델의 L2 거리

두 가우시안 혼합 모델을  $P$ 와  $Q$ 라 할 때  $P$ 와  $Q$  간의 L2 거리는 아래와 같다.

$$L_2(P, Q) = \int (p(x) - q(x))^2 dx \quad (20)$$

$p(x)$ 와  $q(x)$ 는 두 가우시안 혼합 모델의 확률 밀도 함수(Probability density function)를 의미한다. 이는 전체 면적에 대해서 두 모델 차의 제곱 성분을 적분한 값으로 두 모델이 동일할 경우 작은 값을 가지며, 두 모델의 차이가 심할 경우 큰 값을 가진다.

한편, 파티클 필터의 가중치 계산에 사용되는 우도 함수는 현재 상태에서 얻을 수 있는 측정치의 확률로 실제 항체가 얻는 측정치와 파티클이 얻는 측정치, 두 측정치 간의 유사 정도로 정의할 수 있다. 따라서 두 측정치가 유사할 경우, 파티클의 가중치를 높게 하며 유사하지 않을 경우, 가중치를 낮게 함으로 항체 위치를 추정할 수 있다. 즉, 본 문제에서는 항체에서 얻는 항공사진의 가우시안 혼합 모델과 각 파티클이 측정치 모델로부터 획득하는 가우시안 혼합 모델 간의 유사함을 수치화할 수 있어야 한다. 이러한 이유에서 두 가우시안 혼합 모델간의 L2 거리를 이용하여 우도 함수를 정의하고 파티클 필터를 수행한다.

$P$ 와  $Q$ 가 가우시안 혼합 모델이므로 각각  $p_i$ 와  $q_j$ 를 확률밀도함수로 가지는 정규분포들을  $\alpha_i$ 와  $\beta_j$ 의 혼합비율로 혼합한 것으로 볼 수 있다. 따라서  $P$ 와  $Q$ 의 L2 거리는 아래와 같다.

$$L_2(P, Q) = \int \left( \sum_{i=1}^M \alpha_i p_i(x) - \sum_{j=1}^L \beta_j q_j(x) \right)^2 dx \quad (21)$$

식 (21)를 계산하기 위해서는 두 정규분포의 곱을 적분해야하며, 본 적분 과정은 식 (22)과 같이 해석해가 존재한다[18]. 이는 두 가우시안 혼합 모델의 비교를 매우 빠르게 수행할 수 있도록 한다.

$$\begin{aligned} \int \phi(x | \mu_1, \Sigma_1) \phi(x | \mu_2, \Sigma_2) dx \\ = \phi(0 | \mu_1 - \mu_2, \Sigma_1 + \Sigma_2) \end{aligned} \quad (22)$$

따라서 모든 적분 계산 소거 시, 두 가우시안 혼합 모델간의 L2 거리는 0에서의 정규분포 값들의 합으로 표현된다.

$$\begin{aligned} L_2(P, Q) = & \sum_i^M \sum_j^M \alpha_i \alpha_j \phi(0 | \mu_i^p - \mu_j^p, \Sigma_i^p + \Sigma_j^p) \\ & - 2 \sum_i^M \sum_j^L \alpha_i \beta_j \phi(0 | \mu_i^p - \mu_j^q, \Sigma_i^p + \Sigma_j^q) \\ & + \sum_j^L \sum_j^L \beta_j \beta_j \phi(0 | \mu_j^q - \mu_j^q, \Sigma_j^q + \Sigma_j^q) \end{aligned} \quad (23)$$

$p_i$ 와  $q_j$  각각의 평균과 분산을 위첨자  $p$ 와  $q$  그리고 아래첨자  $i$ 와  $j$ 로 표시하였다.

L2 거리의 경우, 두 가우시안 혼합 모델이 유사할 수록 작은 값을 가지고 반대로 유사하지 않을수록 큰 값을 가지므로 우도 함수와 반대되는 개념이며, 우도 함수로 사용하기 위해 역수를 취한다. 또한 L2 거리 변화에 따른 가중치 변화량을 증가시키기 위해 L2 거리의 제곱 값을 사용한다. 최종적인 파티클 필터의 우도 함수는 아래와 같이 정의하였다.

$$g(z_k | x_k^i) = \frac{1}{L_2(P, Q)^{20} + \gamma} \quad (24)$$

$\gamma$ 는 아주 작은 값으로 L2거리에 직접적인 영향을 주지 않지만 L2 거리가 0일 때 우도 함수 값이 발산하는 것을 막아준다.

## 2.4 시뮬레이션

본 장에서는 시뮬레이션을 통하여 가우시안 혼합 모델을 이용한 파티클 필터의 성능을 검증한다. 먼저 시뮬레이션 환경에 대해 설명하고 가우시안 분포가 밀집한 지역과 그렇지 않은 지역에서 파티클 필터 성능을 보여준다.

### 2.4.1 시뮬레이션 환경

항체는 시뮬레이션 상에서 도심지 위를 비행하며 위치를 추정한다. 도심지 정보는 오픈플랫폼 지도, Vworld에서 제공하는 GIS(Geographic Information System) 정보를 이용하였다(Fig. 4). 이후 각 건물들의 중심 좌표와 건물 꼭짓점들의 공분산 값을 계산하여 가우시안 혼합 모델로 변환한다. 항체는 본 가우시안 혼합 모델을 데이터베이스로 보유하며, 각 파티클의 상태 벡터에 따른 측정치를 생성할 수 있다. 먼저 건물 밀집도가 낮은 지역의 결과를 분석하며 상대적으로 밀집도가 높은 지역에서의 100회 몬테카를로 시뮬레이션 수행 결과를 보여준다.

몬테카를로 시뮬레이션 결과는 위도, 경도, 고도 별 평균 제곱근 오차(Root mean square error)를 평균 공분산 값을 계산하여 평가한다. 이산시간  $k$ 개의 평균 제곱근 오차,  $RMSE_k$ 와 평균 공분산 값,  $COV_k$ 은 아래와 같다.

$$RMSE_k = \sqrt{\frac{1}{N_M} \sum_{m=1}^{N_M} \|\hat{x}_k^m - x_k\|^2} \quad (25)$$

$$COV_k = \frac{1}{N_M} \sum_{m=1}^{N_M} \sqrt{\hat{P}_k^m} \quad (26)$$

$N_M$ 는 몬테카를로 시뮬레이션 횟수를 의미하며  $\hat{x}_k^m, \hat{P}_k^m$ 는  $m$ 번째 몬테카를로 시뮬레이션의 이산 시간  $k$  때의 추정치와 추정 공분산을 의미한다.




Fig. 4. V-world GIS data(red: building, blue: road)




Fig. 5. The database formed by Gaussian mixtures and the flight trajectory

Table 1. Conditions of simulation

Parameters	Values
Initial Position (Latitude, Longitude)	(36.3550°, 127.3562°) (35.2435°, 127.8710°)
Height & Velocity	100m & 10m/s
Flight Condition	Steady flight at constant attitude, height, and velocity
Duration	100sec
Initial Error	(27m, 28m, 28m)
Filter Update Rate	1Hz
Process Noise ( $\sigma_\phi, \sigma_\lambda, \sigma_h$ )	(4m, 4m, 4m)
Image Measurement Noise ( $\sigma_{\mu_x}, \sigma_{\mu_y}, \sigma_{\Sigma_{xx}}$ )	(5m, 5m, 4m)
Yaw Measurement Noise ( $\sigma_\psi$ )	0.5°
Number of Particles	1,000
Standard Deviation of Initial Particles	(30m, 30m, 30m)
Number of Monte Carlo Simulation	100
Angular Field of View	53.26°

카메라의 AFOV(Angular Field Of View)는 가로 53.26° 가정하였으며 가로 세로 비율을 1.5:1로 가정하였다. 비행 조건 및 필터에 관련된 자세한 시뮬레이션 조건은 Table 1에서 보여준다.

### 2.4.2 시뮬레이션 결과

먼저 측정된 건물의 개수에 따른 성능을 비교하기 위해 건물 밀집도가 낮은 지형에서 시뮬레이션을 수행한다. 본 시뮬레이션 비행 상의 건물들을 Fig. 5에서 보여주며, 화살표로 표시된 비행궤적과 해당 시점의 영상 화면을 점선 사각형으로 함께 보여준다. 각 영상 화면은 비행시간 12, 18, 58초 때의 화면으로, 측정치가 없는 구간, 하나의 건물만 측정되는 구간,

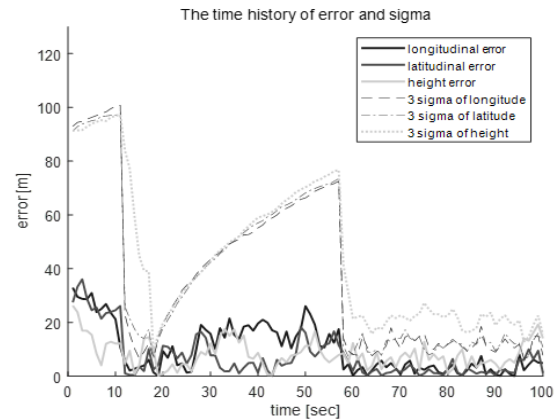
**Table 2. Estimation results by the number of measurements**

Time interval [sec]		0~11	12~18	19~57	58~
The number of measurements		0	1	0	>10
average of error [m]	$\phi$	26.8	2.9	7.8	2.8
	$\lambda$	25.7	3.6	14.1	2.9
	$h$	14.7	8.2	7.7	7.2
average of 3-sigma [m]	$\phi$	97	12	51	12
	$\lambda$	95	17	51	12
	$h$	94	50	53	21


다수의 건물이 측정되는 구간들의 경계를 의미한다. 각 구간별 측정치와 평균 오차, 평균 공분산을 Table 2에서 보여준다.

먼저, 시작부터 11초의 경우 얻어지는 측정치가 없기 때문에 평균 오차는 초기 오차와 비슷한 수준으로 나오며, 평균 공분산의 경우 초기 파티클 분포의 분산보다 큰 값을 알 수 있다. 이후 Fig. 5에서 확인 할 수 있듯이, 하나의 건물이 측정치로 얻어져 18초까지 평균 오차와, 평균 공분산을 현저하게 낮추는 것을 확인할 수 있다. 그러나 고도의 경우, 평균 오차 및 공분산 측면에서 위경도 방향의 결과보다 좋지 못한 결과를 얻었다. 19초에서 57초까지는 다시 측정치가 없는 구간으로 평균 오차도 증가했으며 평균 공분산이 급격하게 증가하였다. 다음으로 비행 종료까지 다수의 건물들이 측정되었으므로, 평균 오차 및 공분산 모든 부분에서 우수한 결과를 보임을 확인할 수 있다. 본 결과를 통하여 다수의 건물이 관측될 경우 가장 우수한 성능을 얻는 것을 알 수 있다. 또한 하나의 건물 측정치만으로도 위경도 방향 약 5m의 위치 오차보이며, 수렴성이 존재함을 확인할 수 있다.

Figure 7은 시간에 따른 오차 및 공분산 결과를 보여준다. 앞서 분석했듯이 12초에 하나의 건물로 인해 오차와 공분산을 두드러지게 수렴시켰으며, 이후 측




**Fig. 7. Time history of RMSE and standard deviation of error for the flight trajectory of Fig. 5**



**Fig. 8. Time history of RMSE and standard deviation of error for the flight trajectory of Fig. 6**

정치의 부재로 인해 오차와 공분산이 증가함을 확인할 수 있다. 마지막으로 다수의 건물이 밀집한 지역으로 진입하여 오차 및 공분산 측면에서 우수한 성능을 보여준다.

Figure 8은 Fig. 6 지형의 필터 추정 결과, 즉 시간에 따른 평균 제곱근 오차 및 공분산 그래프를 보여



**Fig. 6. The database formed by Gaussian mixtures and the flight trajectory**

준다. Fig. 6에서 알 수 있듯이, 다수의 반복적인 건물 패턴을 가지고 있지만, 그럼에도 불구하고 계속해서 좋은 항법 성능을 보여주고 있다. 건물 밀집도가 높으므로 각 방향의 오차 및 공분산 모두 초기 10초 내외로 빠르게 수렴하는 것을 확인할 수 있다. 이후 꾸준한 건물 측정치로 인해 오차 및 공분산 측면에서 안정적인 항법을 수행한다. 위도 및 경도 방향의 오차는 약 5m 정도로 비슷한 수준을 보이지만, 고도 방향 오차의 경우 그보다 약간 높은 10m 내의 오차를 보여준다.

본 실험결과를 통해 제안한 가우시안 혼합 모델을 이용한 파티클 필터가 항체의 위치를 충분히 추정하는 것을 확인할 수 있다. 영상으로부터 얻어진 측정치의 오차( $\sigma_{\mu_x}, \sigma_{\mu_y}, \sigma_{\Sigma_{xx}}$ )와 yaw 각의 오차( $\sigma_{\psi}$ )가 존재하는 상황에서도 초기오차를 위경도의 경우 5m 이내, 고도의 경우 10m 이내로 수렴시켰으며, 이를 바탕으로 실제 비행체 운용 상황에서도 우수한 추정 성능을 보여줄 것으로 기대된다. 그러나 본 연구는 도심지 위 비행으로 국한되어 건물 측정치가 없는 지역에서는 항법을 할 수 없다는 단점이 있다. 그러나 건물 이외의 영상으로 얻을 수 있는 정보를 추가, 즉 측정치로 사용할 특징 물체 또는 지형을 추가할 수 있다. 따라서 측정치 확장이 이루어진다면 본 결과보다 더욱 강건하고 높은 성능을 보여줄 것으로 기대된다.

### III. 결 론

본 논문은 비행 상황에 더욱 적합하고 측정치 오차에 강건한 영상 대조를 위한 파티클 필터를 제안하였다. 의미론적 인식 및 분류된 항공 영상과 데이터베이스 정보를 가우시안 혼합 모델로 가정하여 정량적 비교 방안을 제안하였다. 또한 가우시안 혼합 모델 간의 L2 거리로 파티클 필터의 우도함수를 설계함으로써 항체의 위치를 추정한다. 결과로는, 건물 밀집도와 관련하여 성능을 분석하였으며, 몬테카를로 시뮬레이션을 통하여 전반적인 필터 성능을 검증하였다. 건물 측정치가 많을 경우 그렇지 않은 지형보다 우수한 성능을 보였지만, 하나의 건물 측정치로도 필터 수렴성 및 준수한 성능을 확인하였다. 마지막으로, 몬테카를로 시뮬레이션을 통하여 오차 및 공분산 측면에서 높은 성능을 확인하였다.

본 연구는 도심지 비행을 가정하여 건물 정보만을 측정치로 활용하였다. 즉, 실제 비행에 적용하기엔 한계가 있으며 영상으로부터 추가적인 측정치를 추출하고 데이터베이스를 생성하여 전체 항법 시스템을 설계하는 과정이 필요하다. 하지만 시뮬레이션을 통한 수렴성 확인과 오차 결과를 바탕으로 제안한 기법을 실제 무인기에 적용 가능할 것으로 판단되며

추가적인 보장을 통해 더욱 높은 성능을 보여줄 것으로 기대된다.

### 후 기

본 논문은 풍산-KAIST 미래기술연구센터에서 시행 중인 “상용기반 보조센서에 의한 복합항법 시스템 개발” 과제의 지원으로 수행되었으며, 지원에 감사드립니다.

### References

- 1) Brown, A., Bockius, B., Johnson, B., Holland, H., and Wetlesen, D., “Flight test results of a video-aided GPS/inertial navigation system,” *Proceedings of the 2007 ION GNSS Conference*, pp.1111~1117.
- 2) Wu, A. D., “Vision-based navigation and mapping for flight in GPS-denied environments,” PhD Thesis, Georgia Institute of Technology, 2010.
- 3) Yol, A., Delabarre, B., Dame, A., Dartois, J. E., and Marchand, E., “Vision-based absolute localization for unmanned aerial vehicles,” *Intelligent Robots and Systems (IROS 2014), 2014 IEEE/RSJ International Conference on*, IEEE, 2014, pp.3429~3434.
- 4) Conte, G., and Doherty, P., “An integrated UAV navigation system based on aerial image matching,” *Aerospace Conference, 2008 IEEE IEEE*, 2008, pp.1~10.
- 5) Conte, G., and Doherty, P., “Vision-based unmanned aerial vehicle navigation using geo-referenced information,” *EURASIP Journal on Advances in Signal Processing*, 2009, 10.
- 6) Dumble, S. J., and Gibbens, P. W., “Airborne vision-aided navigation using road intersection features,” *Journal of Intelligent & Robotic Systems*, Vol. 78, No. 2, May 2015, pp.185~204.
- 7) Koch, T., Zhuo, X., Reinartz, P., and Fraundorfer, F., “A NEW PARADIGM FOR MATCHING UAV-AND AERIAL IMAGES,” *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, Vol. 3, No. 3, July 2016, pp.83~90
- 8) Stepanov, O. A., and Toropov, A. B., “Nonlinear filtering for map-aided navigation. Part 1. An overview of algorithms,” *Gyroscopy and Navigation*, Vol. 6, No. 4, October 2015, pp.324~337.
- 9) Stepanov, O. A., and Toropov, A. B., “Nonlinear filtering for map-aided navigation Part



2. Trends in the algorithm development," *Gyroscopy and Navigation*, Vol. 7, No. 1, January 2016, pp.82~89.

10) Garcia-Garcia, A., Orts-Escolano, S., Oprea, S., Villena-Martinez, V., and Garcia-Rodriguez, J., "A review on deep learning techniques applied to semantic segmentation," *arXiv preprint arXiv:1704.06857*.

11) He, K., Gkioxari, G., Dollár, P., and Girshick, R., "Mask r-cnn," In *Computer Vision (ICCV), 2017 IEEE International Conference on*, IEEE, 2017 pp.2980~2988.

12) Sofman, B., Bagnell, J., Stentz, A., and Vandapel, N., "Terrain classification from aerial data to support ground vehicle navigation," *Robotics Institute, Carnegie Mellon University, Pittsburgh, PA, Tech. Rep. CMURI-TR-05-39*.

13) Montoya-Zegarra, J. A., Wegner, J. D., Ladický, L., and Schindler, K., "Semantic segmentation of aerial images in urban areas with class-specific higher-order cliques," *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 2, No. 3, March 2015,

pp.127~133.

14) Hong, K. W., Kim, S. J., and Bang, H. C., "Aerial Image Segmentation and Template Matching for Vision-aided UAV Navigation," *Proceeding of The Korean Society for Aeronautical and Space Sciences Fall Conference*, November 2018, pp.599~600.

15) Rogers, R. M., "Applied mathematics in integrated navigation systems," *American Institute of Aeronautics and Astronautics*, 2007.

16) Papoulis, A., and Pillai, S. U., "Probability, random variables, and stochastic processes," *Tata McGraw-Hill Education*, 2002.

17) Arulampalam, M. S., Maskell, S., Gordon, N., and Clapp, T., "A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking," *IEEE Transactions on signal processing*, Vol. 50, No. 2, February 2002, pp.174~188.

18) Jian, B., and Vemuri, B. C., "Robust point set registration using gaussian mixture models," *IEEE transactions on pattern analysis and machine intelligence*, Vol. 33, No. 8, August 2011, pp.1633~1645.