

논문 2011-48SC-1-8

# 이동로봇을 위한 $H_\infty$ 필터 기반의 강인한 동시 위치인식 및 지도작성 구현 기술

( $H_\infty$  Filter Based Robust Simultaneous Localization and Mapping for Mobile Robots)

전 서 현\*, 이 건 용\*\*, 도 낙 주\*\*\*

(Seo-Hyun Jeon, Keonyong Lee, and Nakju Lett Doh)

## 요 약

이동로봇의 동시 위치인식 및 지도작성(Simultaneous Localization And Mapping, SLAM)에서 가장 기본이 되는 알고리즘은 확장 칼만 필터 SLAM(Extended Kalman Filter SLAM, EKF-SLAM)이다. 하지만 칼만 필터를 사용할 때, 시스템 설계자는 외부 입력에 대한 시스템적 특성과 외부 노이즈의 확률적 모델을 알고 있어야 하나, 실제 환경에서는 이를 정확히 파악할 수 없는 한계가 있다. 이에, 칼만 필터를 불확실성이 심한 실제 환경에 적용할 경우 내부 변수의 변화에 민감하게 반응하거나, 필터의 수학적 일관성이 지켜지지 않거나 또는 부정확한 상태 변수값을 추정하기도 한다. 이에 비해  $H_\infty$  필터는 외부 모델에 대한 상세한 정보가 없을지라도 강인하게 상태를 예측할 수 있다는 장점을 가지고 있다. 본 논문에서는 이러한  $H_\infty$  필터의 특성이 이동로봇의 SLAM 알고리즘의 성능 향상에 도움이 될 것이라는 아이디어에 착안하여  $H_\infty$  필터에 기반한 SLAM 알고리즘을 제안하고 이를 모의 실험에 적용해 보았다. 이를 통해 불확실성이 큰 환경에서는 제안된 알고리즘이 기존의 EKF-SLAM에 비해 다소 우수한 예측 성능을 보임을 확인할 수 있었다.

## Abstract

The most basic algorithm in SLAM(Simultaneous Localization And Mapping) technique of mobile robots is EKF(Extended Kalman Filter) SLAM. However, it requires prior information of characteristics of the system and the noise model which cannot be estimated in accurate. By this limit, Kalman Filter shows the following behaviors in a highly uncertain environment: becomes too sensitive to internal parameters, mathematical consistency is not kept, or yields a wrong estimation result. In contrast,  $H_\infty$  filter does not requires a prior information in detail. Thus, based on a idea that  $H_\infty$  filter based SLAM will be more robust than the EKF-SLAM, we propose a framework of  $H_\infty$  filter based SLAM and show that suggested algorithm shows slightly better result than the EKF-SLAM in a highly uncertain environment.

**Keywords:**  $H_\infty$  filter, Kalman Filter, EKF-SLAM, mobile robot

## I. 서 론

SLAM(Simultaneous Localization And Mapping)은 이동로봇이 주어진 공간을 주행하면서 탑재된 센서의 데이터를 이용하여 스스로 지도를 생성함과 동시에 그 생성된 지도 내에서 자신의 위치를 추정 해내는 연구 분야이다. SLAM 내에서는 지도작성과 위치인식이 상호 영향을 미치는 특성으로 인해 상태 변수의 값 뿐만 아니라, 상태 변수의 불확실성이 함께 고려되어야 하며,

\* 정회원-주저자, 한국전자통신연구원 (ETRI)

\*\* 정회원-공동저자, \*\*\* 정회원-교신저자, 고려대학교 전기전자전파공학과 (Korea University)

※ 본 연구는 산학협동 재단 학술 연구 사업, 한국산업 기술진흥원 융복합형로봇전문인력양성사업 및 국방 무인화기술 특화연구센터의 지원을 받아 수행되었습니다.

접수일자: 2010년7월30일, 수정완료일: 2011년1월14일

이에 대한 최초의 해결책은 확장 칼만 필터(Extended Kalman Filter, EKF) 기반의 SLAM(EKF-SLAM)을 통해 제시되었다.<sup>[1~2]</sup>

그러나 EKF-SLAM은 비선형 시스템을 선형화 시키는 과정에서 '선형화 오차'가 존재하고, 시스템 노이즈 모델이 가우시안(Gaussian)이어야 하나 실제로는 그렇지 않음으로 인한 불일치가 있으며, 상태 변수의 공분산 행렬(covariance matrix)의 부정확한 모델링에 의해 내부 변수에 민감하게 반응하거나, 수학적 일관성이 깨지거나 혹은 잘못된 예측결과를 도출하기도 하는 문제를 가지고 있다.<sup>[3]</sup>

이러한 EKF-SLAM의 단점 중 하나인 선형화 오차를 해결하기 위해 Unscented Kalman Filter SLAM (UKF-SLAM)<sup>[4]</sup>이 제안되었으나, 눈에 띄는 성능향상을 가져오지는 못했고, SLAM 문제에서는 선형화 오차 그 자체보다는 선형화 오차가 시스템의 관측도(observability)에 문제를 야기 시킴이 더 근본적인 원인이 추가로 발견되었다.<sup>[5]</sup>

또한 EKF-SLAM의 단점을 보완하기 위해, 다수의 EKF-SLAM을 동시에 구현하되 상태 변수의 독립성 가정을 통해 실시간 구현을 가능케 한 FastSLAM<sup>[6]</sup>이 제안되기도 하였고, 이의 성능이 EKF-SLAM에 비해 탁월하다는 것은 여러 논문을 통해 검증 되어왔다.<sup>[2,7]</sup>

본 논문에서는 상기 연구들과 맥락을 같이 하여, EKF-SLAM의 단점들을 보완하기 위해  $H_\infty$  필터 기반의 SLAM( $H_\infty$ -SLAM)을 제안 한다. 본 접근법의 기본 접근 철학은  $H_\infty$  필터<sup>[10~12]</sup>는 칼만 필터와 달리 오차 모델에 대한 상세한 정보 보다는 오차 노름(norm)의 크기의 상한선 정보만 있다면 그 범위 안에서는 강인한 성능을 보이기 때문에, 불확실성이 존재하는 실제 환경에서는  $H_\infty$ -SLAM이 기존의 EKF-SLAM에 비해 다소 우수한 성능을 보일 것이라는 가정이다.

이를 위해 본 논문에서는  $H_\infty$ -SLAM을 제안하고, SLAM 과정 중에 발생하는 오차들 중에서 바퀴를 통해 들어오는 오차는 EKF-SLAM이 가정하는 수학적 모델과 상이함을 보인다. 이 후 다양한 바퀴 오차의 값에 대해  $H_\infty$ -SLAM의 성능과 EKF-SLAM의 성능을 모의

실험을 통해 비교 검증한다. 그 결과, 바퀴 오차와 같이 모델링되지 않거나 예측할 수 없는 환경의 변화가 있는 경우에는 제안된  $H_\infty$ -SLAM이 기존의 EKF-SLAM에 비해 우수한 성능을 보임이 확인되었다.

본 논문의 구성은 다음과 같다. 우선  $H_\infty$ -SLAM의 알고리즘에 대한 내용이 II장에 제안되어 있고, 실험을 위한 수학적 모델링이 III장에 기술되어 있다. 이를 이용한 실험 및 결과에 대한 분석은 IV장에 기술되어 있고, 이후 결론 및 향후 연구 방향이 V장에 서술되어 있다.

## II. $H_\infty$ -SLAM 알고리즘

$H_\infty$ -SLAM 알고리즘은 EKF-SLAM 알고리즘과 큰 틀에서는 동일하다고 볼 수 있다. 먼저 각 필터가 적용되기 전에 이루어지는 시스템 선형화 과정이 동일하고, 로봇의 운동 모델에 의한 로봇 상태 예측 과정이 동일하다. 하지만 필터가 적용이 되는 업데이트 과정에서는 두 알고리즘이 차이를 보인다. 따라서 본 논문에서는 EKF-SLAM 알고리즘과 차이를 보이는  $H_\infty$ -SLAM 알고리즘의 특성을 설명함으로써, 전체 알고리즘을 구체화하려고 한다.

### 1. 시스템 초기화

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

$$Y_k = C_k X_k + v_k \quad (2)$$

$$z_k = L_k X_k \quad (3)$$

$$Q_k = E(w_k w_k^T) \quad (4)$$

$$R_k = E(v_k v_k^T) \quad (5)$$

$$E(w_k v_j^T) = 0 \quad (6)$$

식 (1)에서  $X_k$ 는 로봇의 좌표  $[x(k) y(k) \theta(k)]^T$ 와 등록된 랜드 마크 정보를 나타내는 상태 행렬이며,  $u_k$ 은 로봇의 제어입력으로서 각각 상태 변환 행렬  $A_k$ 와 제어 입력 변환 행렬  $B_k$ 를 가진다. 로봇의 상태 행렬에는 공분산 행렬이  $Q_k$ 인 상태 노이즈  $w_k$ 가 더해진다. 식 (2)에서  $Y_k$ 는 로봇이 측정된 센서 데이터이며  $C_k$ 는 센서 변환 행렬이다. 그리고 측정 노이즈에 해당하는  $v_k$

본 연구결과는 2009년 2월에 처음 발표되었으며<sup>[8]</sup>, 이후 2009년 10월 유사한 연구결과가 일본의 Kanazawa University팀에 의해 발표되었으므로<sup>[9]</sup>, 두 그룹에 의해 유사한 연구가 독립적으로 병행된 것으로 판단된다.

는 공분산 행렬  $R_k$ 를 갖는다. 식 (3)에서  $L_k$ 는 사용자가 정의하는 가중 행렬이며,  $X_k$ 의 요소 중 신뢰도가 높은 요소에 가중치를 줄 때 사용된다.

### 2. $H_\infty$ 필터의 비용 함수

$H_\infty$  필터를 다른 필터와 크게 구분 짓는 특징 중의 하나는 비용함수(cost function)가 있다는 것이다. 비용 함수에 대한 내용은 Shen<sup>[12]</sup>이 정리하였으며, 그 결과는 다음과 같다.

$$J = \frac{\sum_{k=0}^{N-1} \|z_k - \hat{z}_k\|_{S_k}^2}{\|X_0 - \hat{X}_0\|_{P_0}^2 + \sum_{k=0}^{N-1} (\|w_k\|_{Q_k}^2 + \|v_k\|_{R_k}^2)} < \frac{1}{\gamma} \quad (7)$$

여기서  $P_0$ ,  $Q_k$ ,  $R_k$ 와  $S_k$ 는 대칭행렬(symmetric matrix)로서 양의 정부호(positive definite)이며 상황에 따라 사용자가 지정한다.

$\hat{z}_k$ 에 대한 예측은 비용함수  $J$ 가 최소화 되도록 해야 한다. 이것은 단순히 비용함수의 분자에 있는  $(z_k - \hat{z}_k)$  값만 줄여서 되는 것이 아니고,  $w_k$ 와  $v_k$ 에도 영향을 받는다. 따라서 매 단계  $k$ 에서  $(z_k - \hat{z}_k)$ 의 값에 따라  $w_k$ 와  $v_k$ 를 조절하여 최소의 비용  $J$ 를 얻을 수 있다.

식 (7)의 부등호 식과 같이 비용함수  $J$ 는 사용자가 지정한  $\gamma$ 의 역수값으로 최대값을 제한할 수 있다. 이렇게 비용함수를 제한함으로써, 예측 오차를 제한할 수 있다.

### 3. 업데이트 과정

$$S_k = L_k^T P_k L_k \quad (8)$$

$$\bar{S}_k = L_k^T S_k L_k \quad (9)$$

$$H_k = P_k (I - \gamma \bar{S}_k P_k + C_k^T R_k^{-1} C_k P_k)^{-1} C_k^T R_k^{-1} \quad (10)$$

$$\hat{X}_{k+1} = A_k \hat{X}_k + A_k H_k (Y_k - C_k \hat{X}_k) \quad (11)$$

$$P_{k+1} = A_k P_k (I - \gamma \bar{S}_k P_k + C_k^T R_k^{-1} C_k P_k) A_k^T + Q_k \quad (12)$$

$S_k$ 는  $\hat{z}_k$ 의 공분산 행렬이며 식 (8)과 같이 계산된다.  $\gamma$ 는 식 (10)과 (12)에서와 같이, SLAM과정 중 업데이

트 단계에서  $-\gamma \bar{S}_k P_k$ 의 형태로 추가되는데, 이 부분이 바로 EKF와 다른 부분이다. 위의 결과는 제어이득  $H_k$ 와  $\hat{X}_k$ 의 공분산 행렬  $P_k$ 의 업데이트 과정에서 사용자가 지정한 경계값  $\gamma$ 이 작용한다는 것을 보여준다.

## III. 실험을 위한 수학적 모델링

### 1. 이동로봇의 수학적 모델링

본 알고리즘을 시험하기 위해 그림 1과 같은 디퍼렌셜 드라이브 로봇의 모델을 사용 하였다. 로봇의 상태는 식 (13)과 같이 좌표  $X_k$ 와 입력  $u_k$ 로 나타낸다.

$$X_k = \begin{bmatrix} x(k) \\ y(k) \\ \theta(k) \end{bmatrix}, u_k = \begin{bmatrix} w_R(k) \\ w_L(k) \end{bmatrix} \quad (13)$$

랜드 마크 정보가 등록되기 이전의  $X_k$ 는 각 로봇 중심의 절대 좌표인  $x(k)$ ,  $y(k)$ 와 로봇의 방향을 나타내는  $\theta(k)$ 로 정의된다. 로봇의 입력  $u_k$ 는 로봇의 양 바퀴에 장착된 모터의 각속도값인  $w_R(k)$ ,  $w_L(k)$ 으로 주어진다. 이는 바퀴의 반지름  $r_R$ 과  $r_L$ 에 곱해져 식 (14)과 같이 각 바퀴의 속도가 된다. 이렇게 입력을 각속도와 반지름으로 세분화하는 이유는 모터의 제어 입력에 적용되는 오차와 반지름에 적용되는 오차의 영향을 독립적으로 분석하기 위함이다.

$$\begin{aligned} v_R(k) &= r_R(k) \times w_{R,cmd}(k) \\ v_L(k) &= r_L(k) \times w_{L,cmd}(k) \end{aligned} \quad (14)$$

따라서 로봇의 전체 이동속도  $V_k$ 와 방향 각속도  $\psi_k$ 는 주어진 양쪽 바퀴 B에 대해 다음의 식 (15)과 같이 표현될 수 있다.




그림 1. 디퍼렌셜 드라이브 로봇 및 관련변수  
Fig. 1. Differential-drive robot and related variable.

$$V_k = \frac{v_R(k) + v_L(k)}{2}$$

$$\psi(k) = \frac{v_R(k) - v_L(k)}{B} \quad (15)$$

## 2. 관측의 수학적 모델링

랜드 마크의 위치를 측정하기 위한 센서는 로봇의 중심에 탑재되어 있으며, 이 센서는 랜드 마크까지의 거리  $d_m(k)$ 와 각도  $\phi_m(k)$ 를 측정한다고 가정한다.

$$Y_k = \begin{bmatrix} d_m(k) \\ \phi_m(k) \end{bmatrix} \quad (16)$$

측정데이터  $Y_k$ 는 로봇의 센서로부터 랜드 마크까지의 거리  $d_m$ 과 각도  $\psi_m$ 으로 구성된  $2 \times n$ 행렬이며, 로봇의 제어 스텝  $k$ 에서 관측된 랜드 마크의 개수  $n$ 만큼의 열로 구성된다.

## 3. 바퀴 오차의 수학적 모델링

로봇 바퀴의 반지름  $r(k)$ 는 다음의 식 (17)과 같이 표현된다.

$$r(k) = (r_0 + \alpha) + \epsilon(k) \quad (17)$$

실제 로봇 바퀴의 반지름  $r_0$ 에 영향을 주는 오차에는  $\alpha$ 와  $\epsilon(k)$ 가 있다.  $\alpha$ 는 바퀴의 오랜 사용으로 인한 노후 또는 사이즈 측정시 발생하는 오차를 의미하고,  $\epsilon(k)$ 는 노면의 요철에 따른 가우시안 랜덤 노이즈를 의미한다. 실제로 이와 같지만, SLAM 알고리즘에서는 이 두 오차값이 정확하게 고려되지 않는다. 먼저, 측정 오차에 해당하는  $\alpha$ 값은 알고리즘 안에서 이용되지 않고 가우시안 노이즈에 해당하는  $\epsilon(k)$  값은 그 공분산 행렬값이 실제로는 노면의 환경에 따라 변하게 되지만, 알고리즘 안에서는 고정된 값으로 적용이 된다.

따라서 이 두 오차는 예측할 수 없는 환경의 변화가 있는 경우, EKF-SLAM과 같이 모델링 정보를 필요로 하는 알고리즘과 제안된  $H_\infty$ -SLAM과 같이 상세 정보를 필요로 하지 않은 알고리즘 사이의 성능 차이를 보이게 하는 중요한 매개 변수로 작용하게 된다.

## IV. 모의실험

### 1. 실험 환경

$H_\infty$ -SLAM의 강인성을 보이기 위하여 아래 그림 2




그림 2. 로봇의 주행 경로 및 랜드 마크의 위치  
Fig. 2. Simulation path and Landmark location.

와 같은 환경에서 MATLAB 기반의 모의실험을 수행하였다.

로봇은 그림 2의 경로를 따라 주행하면서 점으로 표시된 랜드 마크를 인식하여 자신의 위치를 예측하게 된다. 시작점은  $(2m, 2m)$ 이며, 주어진 경로를 2회 왕복 회전한다. 그리고 식 (17)에서 모델링된 로봇 바퀴값에 영향을 주는  $\alpha$ 와  $\epsilon(k)$ 값이 작은 경우와 큰 경우를 나누어서 실험을 하였다.

가중치 행렬은 식 (18)에서와 같이  $H_\infty$  필터의 예측 결과가 더 좋아질 수 있도록 조절할 수 있는데, 본 실험에서는 다음과 같이 3가지 경우를 반영하였다.

$$L_{k1} = \begin{pmatrix} 100 \\ 010 \\ 001 \end{pmatrix} = I, \quad L_{k2} = \begin{pmatrix} 100 \\ 010 \\ 0010 \end{pmatrix}, \quad L_{k3} = \begin{pmatrix} 1000 \\ 0100 \\ 001 \end{pmatrix} \quad (18)$$

$L_{k1}$ 은 로봇의 상태  $x_k = [x, y, \theta]^T$ 에 골고루 가중치를 둔 행렬이고,  $L_{k2}$ 는  $\theta$ 에 가중치를 둔 행렬이다. 즉, '거리 데이터'보다 '방향 데이터'에 더 큰 비중을 둔 행렬에 해당한다. 또한 '방향 데이터'보다 '거리 데이터'에 비중을 둔  $L_{k3}$ 의 경우도 실험해 보았다.

식 (7)의 비용함수는 아래의 식 (19)와 같이 간단히 표현 될 수 있고, 실험을 위해 그 값을  $10^3$ 보다 작은 값, 즉  $\gamma > 10^{-3}$ 으로 제한하였다.

$$J < \frac{1}{\gamma} \quad (19)$$

### 2. $H_\infty$ -SLAM 실험 결과

그림 3, 5는 바퀴 오차가 작은 경우, 큰 경우 각각에

대해서 로봇의 위치에 대한 RMSE(Root Mean Square Error)값을 그래프로 나타낸 결과이고, 그림 4, 6은 EKF-SLAM의 RMSE값을 기준으로  $H_{\infty}$ -SLAM의 RMSE값을 비교한 결과이다. 각 데이터는 10번의 실험을 통해 측정된 결과의 평균값이 이용되었고, x축은 주행거리, y축은 RMSE를 나타낸다. 주행거리는 전체 약 112m이다. 그래프에서 실선은 EKF-SLAM의 결과를, 작은 점선은  $H_{\infty}$ -SLAM 중  $L_{k1}$ 을, 직선과 점으로 이루어진 선은  $L_{k2}$ , 큰 점선은  $L_{k3}$ 을 나타낸다.

그림 3, 4의 결과를 보면, 바퀴 오차가 작은 경우에는  $H_{\infty}$ -SLAM중  $L_{k3}$  행렬을 사용한 경우가 가장 좋은 결과를 얻었다. 하지만 다른 가중치 행렬을 갖는  $H_{\infty}$ -SLAM은 EKF-SLAM과 거의 비슷한 성능을 보였다. 결국 바퀴 오차가 작은 경우에는 EKF-SLAM과  $H_{\infty}$ -SLAM이 큰 차이가 없다고 볼 수 있다. 반면, 바퀴 오차가 큰 경우에는 그림 5, 6의 결과와 같이 모든 가중치 행렬의  $H_{\infty}$ -SLAM이 EKF-SLAM의 결과보다 더 좋음을 볼 수 있다. 즉, 모델링 되지 않거나 예측할 수 없




그림 3. RMSE 결과(바퀴 오차가 작은 경우)  
Fig. 3. RMSE result(small wheel noise).




그림 4. RMSE 결과 비교(바퀴 오차가 작은 경우)  
Fig. 4. RMSE result comparison(small wheel noise).




그림 5. RMSE 결과(바퀴 오차가 큰 경우)  
Fig. 5. RMSE result(large wheel noise).




그림 6. RMSE 결과 비교(바퀴 오차가 큰 경우)  
Fig. 6. RMSE result comparison(large wheel noise).

는 애러가 포함된 경우에는  $H_{\infty}$  필터를 통한 예측이 칼만 필터를 통한 예측보다 더 정확함을 알 수 있다.

## V. 결 론

본 논문에서는 불확실성이 큰 환경에서, 이동 로봇의 SLAM의 성능을 향상시킬 수 있는 방법에 대한 연구를 진행하였다. 먼저, 기존에 사용되고 있던 EKF-SLAM의 단점을 제시하였고, 그 단점을 보완할 수 있는  $H_{\infty}$  필터에 기반한 SLAM 알고리즘( $H_{\infty}$ -SLAM)을 제안하였다. 그리고 SLAM 과정에서 발생하는 바퀴 오차를 수학적으로 모델링 하였고, 물리적 의미를 제시하였다. 그 모델링 정보를 이용하여 바퀴 오차가 존재하는 경우와 그렇지 않은 경우에 대한 EKF-SLAM 알고리즘 성능과  $H_{\infty}$ -SLAM 알고리즘 성능을 비교하였고, 그 결과 바퀴 오차값이 큰 경우에는  $H_{\infty}$ -SLAM이 기존의 EKF-SLAM에 비해 우수한 성능을 보이는 것을 확인할 수 있었다. 이를 통해, 예측할 수 없는 환경의 변화

가 있는 경우에는 제안된  $H_\infty$ -SLAM이 기존의 EKF-SLAM에 비해 더 정확한 예측을 할 수 있다는 본 논문의 주장을 증명할 수 있었다.

그러나 본 논문에서는  $H_\infty$ -SLAM이 더 정확할 수 있음에 대한 결과론적 내용을 제시하였을 뿐,  $H_\infty$  필터 알고리즘에서 사용된 가중치와 비용함수  $J$  등의 핵심 매개 변수가 결과에 미치는 영향에 대한 분석은 이루어지지 않았다. 따라서 향후 연구를 통해 각 매개 변수에 대한 구체적 분석이 수행되어야 할 것으로 판단된다.

### 참고 문헌

- [1] H. Durrant-Whyte and T. Bailey, "Simultaneous Localization and Mapping: Part I," *IEEE Robotics and Automation Magazine*, vol. 13, no. 2, pp. 99 - 110, 2006.
- [2] T. Bailey and H. Durrant-Whyte, "Simultaneous Localization and Mapping(SLAM): Part II," *IEEE Robotics and Automation Magazine*, vol. 13, no. 3, pp. 108 - 117, 2006.
- [3] Guoquan P. Huang, Anastasios I. Mourikis and Stergios I. Roumeliotis, "Observability-based Rules for Designing Consistent EKF SLAM Estimators," *The International Journal of Robotics Research*, Vol. 29, no. 5, pp. 502-528, 2010.
- [4] S. Julier, J. Uhlmann, and H. F. Durrant-Whyte, "A new method for the nonlinear transformation of means and covariances in filters and estimators," *IEEE Transactions on Automatic Control*, vol. 45, no. 3, pp. 477 - 482, 2000.
- [5] Guoquan P. Huang, Anastasios I. Mourikis and Stergios I. Roumeliotis, "On the Complexity and Consistency of UKF-based SLAM," *IEEE International Conference on Robotics and Automation*, pp. 4401-4408, 2009.
- [6] M. Montemerlo, S. Thrun, D. Koller, and B. Wegbreit, "Fast-SLAM: A factored solution to the simultaneous localization and mapping problem," *AAAI National Conference on Artificial Intelligence*, pp. 593-598, 2002.
- [7] M. Montemerlo, S. Thrun, D. Koller, and B. Wegbreit, "Fast-SLAM 2.0: An improved particle filtering algorithm for simultaneous localization and mapping that provably converges," *International Joint Conference on Artificial Intelligence*, pp. 1151-1156, 2003.
- [8] 전서현, 도낙주, "Robust Data Estimation for Simultaneous Localization and Mapping : a hybrid approach of  $H_\infty$  and Extended Kalman Filter," 고려대학교 대학원 학위논문, 2009년 02월.
- [9] Hamzah Ahmad and Toru Namerikawa, " $H_\infty$  filtering convergence and it's application to SLAM," *ICROS-SICE International Joint Conference*, pp. 2875-2880, 2009.
- [10] T. Basar and P. Bernhard,  *$H_\infty$ -Optimal Control and Related Minimax Design Problems: a dynamic game approach 2nd ed.*, Birkhauser, 1995.
- [11] Dan Simon, *Optimal State Estimation*, WILEY, pp. 333-391, 2006.
- [12] X. Shen and L. Deng, "Game Theory Approach to discrete  $H_\infty$  Filter Design," *IEEE Transactions on Signal Processing*, vol. 45, no. 4, pp. 1092 - 1095, 1997.
- [13] Y. S. Hung and F. Yang, "Robust  $H_\infty$  filtering with error variance constraints for discrete time-varying systems with uncertainty," *Automatica*, vol 39, no. 7, pp. 1185-1194, 2003.

### 저자 소개



전 서 현(정회원)-주저자  
2007년 고려대학교 전기전자전파  
공학부 학사 졸업.  
2009년 고려대학교 전기전자전파  
공학부 석사 졸업.  
2011년 현재 ETRI 근무.  
<주관심분야 : 이동로봇, 자율주  
행, 자동차>



이 건 용(정회원)-공동저자  
2009년 고려대학교 전기전자전파  
공학부 학사 졸업.  
2011년 현재 고려대학교 전기  
전자전파공학부  
석박사통합과정 재학.  
<주관심분야 : 이동로봇, SLAM>



도 낙 주(정회원)-교신저자  
1998년 포항공과대학교  
기계공학과 학사 졸업.  
2000년 포항공과대학교  
기계공학과 석사 졸업.  
2005년 포항공과대학교  
기계공학과 박사 졸업.

2011년 현재 고려대학교 전기전자전파공학과  
조교수.  
<주관심분야 : 이동로봇, 3D 지도작성, SLAM>