creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

조선대학교
CHOSUN UNIVERSITY

[UCI]I804:24011-200000267166

2019년 2월
석사학위 논문

무인 운반체의 항법을 위한 위치, 자세 및 지도 추정 방법

조선대학교 대학원
제어계측공학과
정 준 혁

조선대학교
CHOSUN UNIVERSITY

무인 운반체의 항법을 위한 위치, 자세 및 지도 추정 방법

Estimation of Position, Attitude, and Map for Navigation of Unmanned Vehicles

2019년 2월 25일

조선대학교 대학원

제어계측공학과

정 준 혁

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

무인 운반체의 항법을 위한 위치, 자세 및 지도 추정 방법

지도교수 고 낙 용

이 논문을 공학 석사학위신청 논문으로 제출함

2018년 10월

조선대학교 대학원

제어계측공학과

정 준 혁

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

정준혁의 석사학위논문을 인준함

위원장 조선대학교 교수 최한수 (인)

위 원 조선대학교 교수 이진이 (인)

위 원 조선대학교 교수 고낙용 (인)

2018년 11월

조선대학교 대학원

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

목차

ABSTRACT
제1장 서론 ····· 1
제2장 위치 및 자세 추정방법 ····· 4
제1절 각속도 편차 보정 방법을 사용한 EKF ····· 4
제2절 센서 복합 항법 ····· 7
제3장 지도 추정 방법 ····· 11
제1절 IEKF SLAM ····· 12
제2절 Graph-based SLAM ····· 15
제4장 실험 및 시뮬레이션 ····· 18
제1절 각속도 편차 보정 방법을 사용한 EKF ····· 18
1. 실험 환경 및 조건 ····· 18
2. 결과 ····· 20
제2절 센서 복합 항법 ····· 25
1. 실험 환경 및 조건 ····· 25
2. 결과 ····· 27
제3절 IEKF SLAM ····· 31
1. 시뮬레이션 조건 ····· 31
2. 결과 ····· 32
제4절 Graph-based SLAM ····· 34

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

1. 실험 환경 및 조건 ····· 34
2. 결과 ····· 35
제5장 결론 ····· 38
참고문헌 ····· 39
감사의 글 ····· 41

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

ABSTRACT

Estimation of Position, Attitude, and Map for Navigation of Unmanned Vehicles

Chung Jun Hyuk
Advisor : Prof. Ko, Nak Yong, Ph.D.
Department of Control and Instrumentation Eng.,
Graduate School of Chosun University

This study implements estimation of location and attitude of unmanned vehicles and builds map of the environment. Extended Kalman filter is used for estimation of location and attitude, and graph-based optimization is utilized for the map building.

The extended Kalman filter is applied using bias-calibrated angular rate. The method estimates bias in angular rate measured by an Attitude Heading Reference System(AHRS). Also, it fuses multiple sensor measurements for localization of an underwater vehicle. The sensors used for the fusion are Inertial Measurement Unit(IMU), Short Baseline(SBL), Doppler Velocity Log(DVL), and depth meter.

Two methods are implemented for map building : Invariant Extended Kalman filter(IEKF) SLAM and Graph-based SLAM. IEKF SLAM is an on-line SLAM which results in robuster performance than EKF SLAM. The IEKF SLAM estimates the location of a robot as well as the location of landmarks. The Graph-based SLAM is an off-line algorithm which is a optimization approach based on graph representation of constraints. These methods are verified using open measurement data set and test-tank experiments.

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

제1장 서론

자율 주행 로봇이 주변 환경을 인식하며 목적지까지 이동하는 기술은 매우 중요하다. 주변 환경을 인식하기 위해 그 지역의 map 정보가 필요하다. 또한 목적지까지 이동하기 위해 로봇의 위치 및 자세 정보가 필요하다. GPS(Global positioning system) 기술을 사용하면 로봇의 위치를 알 수 있다. 하지만 지상에서는 고층 빌딩이나 건물 안에서는 GPS를 사용하기 어려우며, 수중에서는 깊은 바다 속이나 해저 동굴에서 GPS를 사용하기 어려운 문제점이 있다. 이러한 경우 여러 센서를 사용하여 센서 측정값들을 융합하여 위치 및 자세를 추정한다[1~2].

위치 추정 및 자세 추정에 주로 사용되는 센서들은 다음과 같다. IMU(Inertial measurement unit) 센서는 가속도 센서와 자이로 센서가 내장된 센서로 x, y, z 축에 대한 가속도와 각속도를 측정하며 고가의 IMU 센서의 경우 x, y, z 축의 회전각 ϕ, θ, ψ도 측정한다. LRF(Laser range finder)는 일정 범위 내로 레이저를 발사하여 특징점의 2차원 위치를 측정한다. 음향 비콘(Acoustic beacon)은 로봇의 x, y, z 축에 대한 위치를 측정하는 센서로 LBL(Long baseline), SBL(Short baseline), USBL(Ultra short baseline) 등이 있다. DVL(Doppler velocity log) 센서는 수중에서 사용하는 센서로 x, y, z 축에 대한 선속도를 측정한다. DVL 센서는 초음파를 발사하여 해저면으로부터 반사되어 돌아온 정보로부터 선속도를 측정한다. 수심(Depth) 센서는 수중 로봇의 수심(z축 위치)을 측정한다[3].

센서에서 측정된 측정값들을 필터링 방법이나 최적화 방법에 적용하여 오차를 줄여 더 정확한 위치 및 자세를 추정할 수 있다. 필터링 및 최적화 방법은 칼만 필터(Kalman filter), 파티클 필터(Paticle filter), 상보 필터(Complementary filter) 등이 있다. 칼만 필터는 잡음이 포함되어 있는 선형 시스템의 상태 변수를 추적하는 재귀 필터이다. 비선형의 시스템의 경우 확장 칼만 필터(Extended Kalman fiter, EKF), 불변 확장 칼만 필터(Invariant EKF, IEKF), 무향 칼만 필터(Unscented Kalman filter, UKF), 칼만-부시 필터(The Kalman-Bucy filter) 방법 등을 사용하여 비선형 시스템을 선형 시스템에 비슷하게 변환하여 칼만 필터 방법에 적용한다. 칼만 필터는 추정 상태 변수(state)를 예측하는 예측 단계(Prediction)와 예측한 추정 상태 변수를 보정하는 보정 단계(Collection)로 이루어진다. 그림 (1)은 확장 칼만 필터 방법의 과

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

정을 그림으로 나타낸 것으로, 예측 단계에서는 프로세스 모델(process model)을 사용하여 예측 추정 상태 변수를 구하고 예측한 추정 상태 변수에 대한 오차 공분산(state error covariance)을 구한다. 보정 단계에서는 칼만 이득(Kalman gain)을 구하고 측정값과 측정 모델(measurement model)을 사용하여 측정 개선값(measurement innovation)을 구한다. 칼만 이득과 측정 개선값을 사용하여 예측한 추정 상태 변수를 보정하고 보정한 추정 상태 변수에 대한 오차 공분산을 구한다[4].

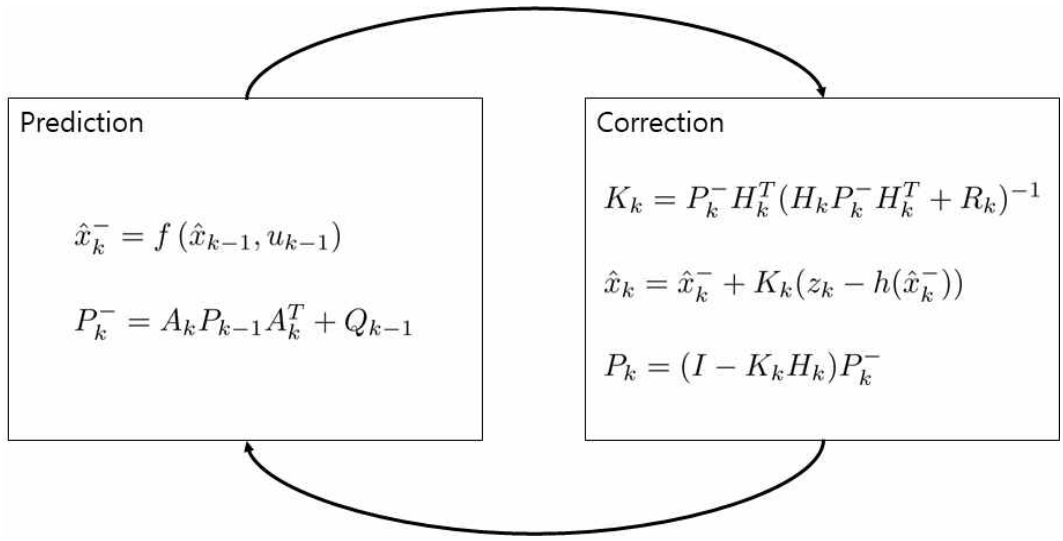

그림 1 확장 칼만 필터

Fig 1 Extended Kalman filter

본 논문에서는 무인 이동 로봇의 주행으로 얻은 센서 데이터를 필터링 방법 및 최적화 방법에 적용하여 로봇의 위치 및 자세를 추정하며, 지도를 작성하는 방법들을 구현한다. 위치 및 자세 추정 방법은 각속도 편차 보정 방법과 센서 복합 항법을 칼만 피터 방법 중 하나인 확장 칼만 필터 방법에 적용하여 구한다. 각속도 편차 보정 방법은 센서로 측정한 각속도 측정값을 가속도 측정값과 자기장 측정값을 사용하여 편차를 보정하여 확장 칼만 필터에 적용하여 무인 이동 로봇의 자세를 추정한다. 센서 복합 항법은 수중에서 사용하는 여러 센서 측정값들을 융합하여 확장 칼만 필터 방법에 적용

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

하며 기존의 방법들과 다르게 지구 자전에 의한 각속도 변화 및 센서 비작동시의 경우를 고려하여 위치 및 자세를 추정한다. 지도 작성은 지도를 작성함과 동시에 로봇의 위치를 추정하는 SLAM(Simultaneous localization and mapping)을 사용한다. 필터링 방법 중 하나인 불변 확장 칼만 필터를 사용한 SLAM(IEKF SLAM)과 스무딩(Smoothing) 방법 중 하나인 그래프 기반 SLAM(Graph-based SLAM)에 적용하여 지도를 작성하며 로봇의 위치를 추정한다. 불변 확장 칼만 필터를 사용한 SLAM은 온라인 SLAM(off-line SLAM)으로 확장 칼만 필터보다 비선형 시스템을 선형 시스템에 비슷하게 변환하는 방법으로 특정 조건에 만족하면 적용이 가능한 필터링 방법이다. 그래프 기반 SLAM은 오프라인 SLAM(off-line SLAM)으로 노드와 엣지를 생성하여 생성된 노드와 엣지를 최적화하는 방법이다[5].

본 논문의 구성은 다음과 같다. 2장에서는 각속도 편차 보정 방법을 사용한 확장 칼만 필터 방법을 사용하여 로봇의 자세를 추정하며 센서 복합 항법을 사용하여 로봇의 위치 및 자세를 추정한다. 3장에서는 불변 확장 칼만 필터 방법을 사용한 SLAM과 그래프 기반 SLAM을 사용하여 지도 작성 및 로봇의 위치를 추정한다. 4장에서는 2장과 3장에서 구현한 방법들을 각각의 실험 및 시뮬레이션을 통해 위치 및 자세 추정 방법과 지도 추정 방법들의 성능을 분석한다. 5장에서는 본 논문의 결론을 맺는다.

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

제2장 위치 및 자세 추정 방법

제1절 각속도 편차 보정 방법을 사용한 EKF

본 절은 각속도 편차 보정 방법을 사용한 확장 칼만 필터 방법(EKF bias calibrated angular rate, EKF BCAR)에 대해 서술한다[6]. 각속도 편차 보정 방법은 다음과 같이 구한다[7].

$$\hat{g}=\begin{bmatrix} a_{ax} \\ a_{ay} \\ a_{az} \end{bmatrix}-\begin{bmatrix} 0 & -\omega_{az} & \omega_{ay} \\ \omega_{az} & 0 & -\omega_{az} \\ -\omega_{ay} & \omega_{ax} & 0 \end{bmatrix}\begin{bmatrix} v_x \\ v_y \\ v_z \end{bmatrix}-\frac{1}{\Delta t}\left(\begin{bmatrix} v_x \\ v_y \\ v_z \end{bmatrix}_t-\begin{bmatrix} v_x \\ v_y \\ v_z \end{bmatrix}_{t-1}\right) \tag{2.1.1}$$

$$v_1=\frac{\hat{g}}{|\hat{g}|},\ \ v_{01}=[0\,0-1]^T \tag{2.1.2}$$

$$v_2=\frac{\hat{m}_a}{|\hat{m}_a|},\ \ v_{02}=[1\,0\,0]^T \tag{2.1.3}$$

$$\sigma=\sum_{i=1}^{n}k_i v_i\times\hat{R}^T v_{0i} \tag{2.1.4}$$

$$\dot{\hat{b}}=-k_b\hat{b}+k_b sat_{\triangle}(\hat{b})-k_I\sigma \tag{2.1.5}$$

$$|\hat{b}(0)|<\triangle,\ \ sat_{\triangle}(x):=x\min(1,\triangle/|x|),\ \ {}^{\forall}x\in\mathbb{R}^3$$

(k_p, k_I, k_i : positive gains, $\hat{R}(0)\in SO(3)$, $\triangle>|b|$, b : constant bias)

$$\omega=\overline{\omega}-\hat{b}+k_p\sigma \tag{2.1.6}$$

$$\omega=[p\quad q\quad r]^T$$

식 (2.1.1)은 중력 가속도 $\hat{g}$를 구하는 식으로 가속도 측정값 a에 선속도 측정값 v와 각속도 측정값 ω로부터 구한 회전속도와 선속도 측정값 v로부터 구한 선가속도를 빼주어 구한다. 식 (2.1.2)에서 v_1은 중력 가속도 $\hat{g}$를 표준화한 값이며, v_{01}은 기준 좌표계의 중력 가속도를 표준화한 값이다. 식 (2.1.3)에서 v_2은 자기장 측정값 $\hat{m}_a$를 표준화한 값이며, v_{02}은 기준 좌표계의 자기장을 표준화한 값이다. 식 (2.1.4)는

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

measured field(v_i)와 predicted field($\hat{R}^T v_{0i}$) 사이의 회전 방향과 회전각의 차이를 구하는 수식이다. 식 (2.1.2)에서 구한 v_{01}에 이전 시간에서 구한 자세 $[\phi\ \theta\ \psi]$로 구한 회전 행렬(Rotation matrix) $\hat{R}^T$를 곱하여 로봇 좌표계에서의 예측한 중력 가속도를 구하고 중력 가속도 측정값 v_1과 교차곱(cross product)을 하여 회전 방향과 회전각의 차이를 구한다. 식 (2.1.3)에서 구한 v_2, v_{02}를 앞서 설명한 방법을 사용하여 자기장으로부터 구한 회전 방향과 회전각의 차이를 구한다. 중력 가속도 및 자기장으로부터 구한 회전 방향과 회전각의 차이에 가중치를 곱하여 더해줌으로서 최종적인 회전 방향과 회전각의 차이를 구한다. 식 (2.1.4)에서 구한 값을 식 (2.1.5)에 적용하여 편차(bias)의 변화량 $\dot{\hat{b}}$를 구한다. $sat_{\triangle}(\hat{b})$는 반복되는 적분에 의해 $\hat{b}$ 값이 계속 증가하는 경우의 값을 △ 이하로 제한하기 위한 함수로, $|\hat{b}|$ 값이 △보다 클 경우 $sat_{\triangle}(\hat{b})=\triangle$가 된다. 식 (2.1.5)에서 구한 $\dot{\hat{b}}$를 적분하여 구한 $\hat{b}$와 식 (2.1.4)에서 구한 σ를 식 (2.1.6)에 사용하여 편차 보정된 각속도를 구한다. 여기서 $\overline{\omega}$는 측정된 각속도이다.

표 2.1.1은 편차 보정된 각속도를 사용한 EKF 알고리즘이다[6]. 입력 값으로 이전 시간에서의 자세 값 $\hat{X}_{k-1}$과 이전 시간에서의 자세 값에 대한 오차 공분산 P_{k-1}, 가속도 측정값 a, 자기장 측정값 m, 편차 보정된 각속도 ω를 사용한다. 1번 줄은 자세 값의 변화량을 구하는 식으로 각속도 편차 보정한 각속도와 이전 시간에서의 자세 값을 사용하여 구한다. 여기서 S는 sin, C는 cos, T는 tan를 의미한다. 2번 줄은 현재 시간에서의 예측한 자세 값을 구하는 식으로 1번 줄에서 구한 자세 변화량을 적분하여 구한다. 3번 줄은 프로세스 모델을 상태 변수로 편미분한 자코비안 행렬(Jacobian matrix)이다. 4번 줄은 예측한 자세 값에 대한 오차 공분산을 구하는 식이다. 여기서 Q는 프로세스 모델에 대한 오차 공분산(Process model error covariance)이다. 5번 줄은 칼만 이득을 구하는 식이다. 여기서 H는 측정 모델을 상태 변수로 편미분한 자코비안 행렬이며, R은 측정 모델에 대한 오차 공분산(Measurement model error covariance)이다. 6번 줄은 예측한 추정 상태 변수를 보정하는 식이다. 여기서 $\left(z_k - h\left(\hat{X}_k^-\right)\right)$는 측정 개선값으로 측정값 z_k와 예측한 측정값 $h\left(\hat{X}_k^-\right)$의 차이로 구한다. 측정값 z_k는 가속도 측정값 a와 자기장 측정값 m을 식 (2.1.8)에 적용하여 구한다.

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

여기서 ${}^{w}m$은 기준 좌표계에서의 자기장이므로 자기장 측정값 ${}^{v}m$에 회전 행렬 ${}^{w}_{v}R$을 곱하여 구한다. 7번 줄은 보정된 자세 값에 대한 오차 공분산을 구하는 식이다.

$$\begin{bmatrix} z_{k,\phi} \\ z_{k,\theta} \\ z_{k,\psi} \end{bmatrix} = \begin{bmatrix} atan2(-a_y, -a_z) \\ atan2(a_x, \sqrt{a_y^2 + a_z^2}) \\ atan2(-{}^{w}m_y, {}^{w}m_x) - \psi_0 \end{bmatrix} \tag{2.1.8}$$

$${}^{w}m = {}^{w}_{v}R\,{}^{v}m$$

표 2.1.1 각속도 편차 보정 방법을 사용한 확장 칼만 필터 알고리즘

Table 2.1.1 EKF algorithm using bias calibrated angular rate

EKF bias calibrated angular rate $(\hat{X}_{k-1}, P_{k-1}, \boldsymbol{a}, \boldsymbol{m}, \boldsymbol{\omega})$

1. $\dot{\phi} = p + q \cdot S(\hat{X}_{k-1,\phi})T(\hat{X}_{k-1,\theta}) + r \cdot C(\hat{X}_{k-1,\phi})T(\hat{X}_{k-1,\theta})$

   $\dot{\theta} = q \cdot C(\hat{X}_{k-1,\phi}) - r \cdot S(\hat{X}_{k-1,\phi})$

   $\dot{\psi} = q \cdot S(\hat{X}_{k-1,\phi})sec(\hat{X}_{k-1,\theta}) + r \cdot C(\hat{X}_{k-1,\phi})sec(\hat{X}_{k-1,\theta})$

2. $\hat{X}_k^- = \begin{bmatrix} \hat{X}_{k-1,\phi} + \dot{\phi}\Delta t \\ \hat{X}_{k-1,\theta} + \dot{\theta}\Delta t \\ \hat{X}_{k-1,\psi} + \dot{\psi}\Delta t \end{bmatrix}$

3. $A = \begin{bmatrix} \frac{\partial\dot{\phi}}{\partial\phi} & \frac{\partial\dot{\phi}}{\partial\theta} & \frac{\partial\dot{\phi}}{\partial\psi} \\ \frac{\partial\dot{\theta}}{\partial\phi} & \frac{\partial\dot{\theta}}{\partial\theta} & \frac{\partial\dot{\theta}}{\partial\psi} \\ \frac{\partial\dot{\psi}}{\partial\phi} & \frac{\partial\dot{\psi}}{\partial\phi} & \frac{\partial\dot{\psi}}{\partial\phi} \end{bmatrix}$

4. $P_k^- = P_{k-1} + \left(AP_{k-1} + P_{k-1}A^T + Q\right)\Delta t$

5. $K_k = P_k^- H^T \left(HP_k^- H^T + R\right)^{-1}$

6. $\hat{X}_k = \hat{X}_k^- + K_k\left(z_k - h\left(\hat{X}_k^-\right)\right)$

7. $P_k = P_k^- - K_k H P_k^-$

return $(\hat{X}_k, P_k)$

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

제2절 센서 복합 항법

본 절은 무인 수중 로봇의 다중 센서 복합 항법에 대해 서술한다[8~9]. 사용한 센서는 IMU, 음향 비콘(USBL, SBL), DVL, 수심 센서를 사용했다. IMU 센서는 로봇의 x, y, z축의 가속도 및 각속도를 측정하며 자세 정보를 측정한다. 음향 비콘은 로봇의 x, y, z축의 위치를 측정한다. DVL 센서는 로봇의 x, y, z축의 선속도를 측정한다. 수심 센서는 로봇의 수심을 측정한다. 자세 및 위치를 추정하기 위해 확장 칼만 필터 방법을 사용한다. 상태 변수는 식 (2.2.1)과 같다. X는 NED 좌표계에서의 위치 정보이며 $X = [x\ y\ z]^T$이다. q는 NED 좌표계에서의 쿼터니언이며 $q = [q_0\ q_x\ q_y\ q_z]^T$이다. V는 로봇 좌표계에서의 선속도이며 $V = [u\ v\ w]^T$이다. ω는 로봇 좌표계에서의 각속도이며 $\omega = [p\ q\ r]^T$이다. b_z는 수심의 편차이다.

$$\chi = [X\ q\ \ V\ \omega\ b_z]^T \tag{2.2.1}$$

표 2.2.1은 프로세스 모델이다. 위치는 이전 시간의 선속도에 시간 변화량 Δt를 곱하여 위치 변화량을 구한 후 이전 시간의 위치 정보에 더하여 현재 시간의 위치를 구한다. 선속도는 로봇 좌표계이므로 쿼터니언을 사용하여 NED 좌표계로 rotation 한 후에 사용한다. 쿼터니언은 이전 시간에서의 쿼터니언과 자세의 변화량 $q\{\omega(t_i)\Delta t\}$를 쿼터니언 곱($\otimes$)을 하여 현재 시간의 쿼터니언을 구한다. 여기서 $\omega(t_i)$는 센서에서 측정된 각속도를 의미하며 지구 자전에 의한 자세 변화량 ${}^N\omega$를 제거하고 사용한다. 선속도 및 각속도, 수심의 편차는 이전 시간에서의 값을 사용한다.

표 2.2.2는 측정 모델이다. 측정값 정보는 센서에서 측정된 위치(X), 자세(q), 선속도(V), 각속도(ω), 수심(z_p)이다. 위치 및 자세, 선속도, 각속도는 상태 변수와 같으므로 상태 변수와 같은 값을 사용한다. 수심은 z축 위치에 수심의 편차를 더하여 구한다. DVL 센서는 초음파를 발사하여 해저면에 반사되어 돌아오는 값을 사용하여 속도를 측정하는 원리(bottom lock)를 사용한다. 이로 인해 DVL 센서는 UUV가 해저면에 가까이 있어야만 속도를 측정할 수 있다는 단점이 있다. DVL의 출력값이 비정상적일 경우 측정 모델에서 선속도 측정값을 제외하고 사용한다. 마찬가지로 음향 비콘이나 IMU 센서의 출력값이 비정상적일 경우 해당하는 측정값을 제외하고 측정 모델을 적용

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

한다.

표 2.2.1 프로세스 모델

Table 2.2.1 Process model

Process model

$$\begin{bmatrix} x \\ y \\ z \end{bmatrix}_{t_{i+1}} = \begin{bmatrix} x \\ y \\ z \end{bmatrix}_{t_i} + \begin{bmatrix} q_0 \\ q_x \\ q_y \\ q_z \end{bmatrix}_{t_i} \otimes \begin{bmatrix} u \\ v \\ w \end{bmatrix}_{t_i} \otimes \begin{bmatrix} q_0 \\ q_x \\ q_y \\ q_z \end{bmatrix}_{t_i}^{-1} \triangle t$$

$$\begin{aligned} q(t_{i+1}) &= q(t_i) \otimes q\{\omega(t_i)\triangle t\} \\ &= q(t_i) \otimes \begin{bmatrix} \cos(\|\omega(t_i)\|\triangle t/2) \\ \frac{\omega(t_i)}{\|\omega(t_i)\|}\sin(\|\omega(t_i)\|\triangle t/2) \end{bmatrix} \end{aligned}$$

$$\mathbf{V}(t_{i+1}) = \mathbf{V}(t_i)$$

$$\omega(t_{i+1}) = \omega(t_i)$$

$$b_z(t_{i+1}) = b_z(t_i)$$

$$\text{where, } \omega(t_i) = \begin{bmatrix} p & q & r \end{bmatrix}^T$$

$$\omega(t_i) \Longleftarrow \omega(t_i) - q^* \otimes {}^N\omega \otimes q$$

$${}^N\omega = \frac{\pi}{12} \cdot \frac{1}{3600} \begin{pmatrix} \cos(\lambda) \\ 0 \\ \sin(\lambda) \end{pmatrix}$$: 지구 자전에 의한 자세 변화량

표 2.2.3은 센서 복합 항법을 확장 칼만 필터에 적용한 알고리즘이다. 입력 값으로 이전 시간에서의 추정 상태 변수 $\hat{\chi}(t_i)$와 이전 시간에서의 추정 상태 변수에 대한 오차 공분산 $P(t_i)$, 센서 측정값 $Y(t_{i+1})$를 사용한다. 1~3번 식은 확장 칼만 필터 방법의 예측 단계이며, 4~6번 식은 보정 단계이다. 1, 2번 식은 현재 시간에서의 추정 상

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

태 변수를 예측하는 식으로 프로세스 모델을 사용하여 구한다. 3번 식은 예측한 추정 상태 변수에 대한 오차 공분산을 구하는 식이다. 여기서 A는 프로세스 모델을 상태 변수로 편미분한 자코비안 행렬이며, Q는 프로세스 모델에 대한 오차 공분산이다. 4번 식은 칼만 이득을 구하는 식이다. 여기서 H는 측정 모델을 상태 변수로 편미분한 자코비안 행렬이며, R은 측정 모델에 대한 오차 공분산이다. 5번 식은 예측한 추정 상태 변수를 칼만 이득과 측정 개선값을 사용하여 보정하는 식이다. 여기서 측정 개선값은 측정값 Y와 측정 모델을 사용해 구한 예측한 측정값 $\bar{Y}$의 차이로 구한다. 6번 식은 보정된 추정 상태 변수에 대한 오차 공분산을 구하는 식이다.

표 2.2.2 측정 모델

Table 2.2.2 measurement model

Measurement model

$$Y = \begin{bmatrix} \mathbf{X} \\ q \\ \mathbf{V} \\ \omega \\ z_p \end{bmatrix} = \begin{bmatrix} I_3 & \mathbf{0}_{3\times4} & \mathbf{0}_{3\times3} & \mathbf{0}_{3\times3} & \mathbf{0}_{3\times1} \\ \mathbf{0}_{4\times3} & I_4 & \mathbf{0}_{4\times3} & \mathbf{0}_{4\times3} & \mathbf{0}_{4\times1} \\ \mathbf{0}_{3\times3} & \mathbf{0}_{3\times4} & I_3 & \mathbf{0}_{3\times3} & \mathbf{0}_{3\times1} \\ \mathbf{0}_{3\times3} & \mathbf{0}_{3\times4} & \mathbf{0}_{3\times3} & I_3 & \mathbf{0}_{3\times1} \\ \begin{bmatrix} 0 & 0 & 1 \end{bmatrix} & \mathbf{0}_{1\times4} & \mathbf{0}_{1\times3} & \mathbf{0}_{1\times3} & 1 \end{bmatrix} \begin{bmatrix} \mathbf{X} \\ q \\ \mathbf{V} \\ \omega \\ b_z \end{bmatrix}$$

Measurement model(DVL 비작동시)

$$Y = \begin{bmatrix} \mathbf{X} \\ q \\ \omega \\ z_p \end{bmatrix} = \begin{bmatrix} I_3 & \mathbf{0}_{3\times4} & \mathbf{0}_{3\times3} & \mathbf{0}_{3\times3} & \mathbf{0}_{3\times1} \\ \mathbf{0}_{4\times3} & I_4 & \mathbf{0}_{4\times3} & \mathbf{0}_{4\times3} & \mathbf{0}_{4\times1} \\ \mathbf{0}_{3\times3} & \mathbf{0}_{3\times4} & \mathbf{0}_{3\times3} & I_3 & \mathbf{0}_{3\times1} \\ \begin{bmatrix} 0 & 0 & 1 \end{bmatrix} & \mathbf{0}_{1\times4} & \mathbf{0}_{1\times3} & \mathbf{0}_{1\times3} & 1 \end{bmatrix} \begin{bmatrix} \mathbf{X} \\ q \\ \mathbf{V} \\ \omega \\ b_z \end{bmatrix}$$

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

표 2.2.3 확장 칼만 필터 알고리즘

Table 2.2.3 Algorithm of Extended Kalman filter

Input $(\hat{\chi}(t_i), P(t_i), Y(t_{i+1}))$

1. $$\begin{bmatrix} x \\ y \\ z \end{bmatrix}_{t_{i+1}} = \begin{bmatrix} x \\ y \\ z \end{bmatrix}_{t_i} + \begin{bmatrix} q_0 \\ q_x \\ q_y \\ q_z \end{bmatrix}_{t_i} \otimes \begin{bmatrix} u \\ v \\ w \end{bmatrix}_{t_i} \otimes \begin{bmatrix} q_0 \\ q_x \\ q_y \\ q_z \end{bmatrix}_{t_i}^{-1} \triangle t$$

$$q(t_{i+1}) = q(t_i) \otimes \begin{bmatrix} \cos(\|\omega(t_i)\|\triangle t/2) \\ \frac{\omega(t_i)}{\|\omega(t_i)\|}\sin(\|\omega(t_i)\|\triangle t/2) \end{bmatrix}$$

$$\mathbf{V}(t_{i+1}) = \mathbf{V}(t_i)$$

$$\omega(t_{i+1}) = \omega(t_i)$$

$$b_z(t_{i+1}) = b_z(t_i)$$

2. $\hat{\chi}^-(t_{i+1}) = [\ \mathbf{X}(t_{i+1}) \quad q(t_{i+1}) \quad \mathbf{V}(t_{i+1}) \quad \omega(t_{i+1}) \quad b_z(t_{i+1})\ ]^T$

3. $P^-(t_{i+1}) = AP(t_i)A^T + Q$

4. $K = P^-(t_{i+1})H^T\{HP^-(t_{i+1})H^T + R\}^{-1}$

5. $\hat{\chi}(t_{i+1}) = \hat{\chi}^-(t_{i+1}) + K\{Y(t_{i+1}) - Y^-(t_{i+1})\}$

6. $P(t_{i+1}) = (I - KH)P^-(t_{i+1})$

return $(\hat{\chi}(t_{i+1}), P(t_{i+1})))$

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

제3장 지도 추정 방법

본 장은 지도 추정 방법에 대해 서술한다. 무인 이동체가 목적지까지 이동하기 위해서는 주변 환경에 대한 지도 정보가 필요하다. 주변 환경에 대한 지도 정보가 없을 경우 사전 탐사를 통하여 지도 정보를 구하며 목적지로 이동해야 한다. 지도 정보를 구하며 목적지를 이동하면 무인 이동체의 위치 정보도 동시에 구하게 된다. 위치 추정 및 지도 작성을 동시에 하는 것을 SLAM이라고 한다. SLAM은 스무딩 방법과 필터링 방법으로 구분된다. 스무딩 방법은 모든 측정 데이터를 얻은 후 지도 작성 및 위치 추정을 하는 방법으로 그래프 SLAM(Graph SLAM), 그래프 기반 SLAM 등이 있다. 필터링 방법은 실시간으로 데이터를 측정하며 현재의 위치를 추정하며 지도를 작성하는 방법으로 확장 칼만 필터 SLAM, 무향 칼만 필터 SLAM(UKF SLAM), 불변 확장 칼만 필터 SLAM 등이 있다.

표 3 SLAM 방법 비교

Table 3 Comparison of SLAM

Smoothing 방법	Filtering 방법
Off-line SLAM Full SLAM	On-line SLAM Incremental SLAM
모든 측정 데이터 적용	현재 측정 데이터 적용
모든 위치 추정	현재의 위치와 지도 작성
수렴할 때까지 수행	한번 수행
Graph SLAM Graph-based SLAM	EKF SLAM UKF SLAM IEKF SLAM
$p(x_{1:T}, m \mid z_{1:T}, u_{1:T}, x_0)$	$p(x_t, m \mid z_t, u_t, x_{t-1})$

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

제1절 IEKF SLAM

본 절은 필터링 방법 중 하나인 불변 확장 칼만 필터 방법을 사용한 SLAM을 이차원 환경에서 구현한다[10]. 불변 확장 칼만 필터 방법은 확장 칼만 필터 방법의 상태 변수 오차를 개선하여 적용한 방법으로, 확장 칼만 필터 방법보다 비선형 시스템을 선형 시스템에 비슷하게 변환하는 방법이다. 불변 확장 칼만 필터 방법은 쿼터니언을 사용한 자세 추정의 경우, 쿼터니언의 단일 정규화(unit norm)를 보장하며, 수렴하는 상태 변수 공간의 영역이 커지는 장점이 있다. 불변 확장 칼만 필터 방법은 General Lie group을 사용하는 방법과 Matrix Lie group을 사용하는 방법이 있다[11]. 본 논문에서는 Matrix Lie group을 사용한 불변 확장 칼만 필터 방법을 사용한다[12].

$$X = (\theta, x^T, (p^1)^T, \cdots, (p^k)^T) \longrightarrow \left(\begin{array}{c|c} R(\theta) & x \;\; p^1 \cdots p^n \\ \hline 0_{1,2} & \\ \vdots & I_{K+1} \\ 0_{1,2} & \end{array}\right) \tag{3.1.1}$$

식 (3.1.1)와 같이 상태 변수를 Matrix Lie group으로 변환하여 특정 조건에 만족하면 불변 확장 칼만 필터 방법을 적용할 수 있다. 확장 칼만 필터 SLAM에서 F_k, G_k, H_k 행렬은 프로세서 모델 및 측정 모델을 편미분하여 자코비안 행렬로 사용한다. 반면에, 불변 확장 칼만 필터 SLAM에서 F_k, G_k, H_k 행렬은 Matrix Lie group을 사용하여 구한 오차 시스템을 선형화하여 구한다.

표 3.1.2는 불변 확장 칼만 필터 SLAM 알고리즘이다. 입력 값으로 이전 시간에서의 추정 상태 변수 $\hat{X}_{k-1}$와 이전 시간에서의 추정 상태 변수에 대한 오차 공분산 P_{k-1}, 측정값 Y_k, 이동체의 자세 변화량 w_k, 로봇 좌표계에서의 이동체의 이동거리 변화량 v_k를 사용한다. 추정 상태 변수는 이동체의 자세 θ와 이동체의 xy 위치 x, 각각의 특징점의 xy좌표계 위치 p를 사용한다. 측정값은 로봇 좌표계에서의 각각의 특징점의 xy 위치를 사용한다. 불변 확장 칼만 필터 방법은 확장 칼만 필터 방법과 같이 예측 단계와 보정 단계로 이루어진다. 예측 단계에서는 예측한 추정 상태 변수 $\hat{X}_{k|k-1}$와 예측한 추정 상태 변수에 대한 오차 공분산 $P_{k|k-1}$를 구한다. 예측한 이동체의 자세 $\hat{\theta}_{k|k-1}$은 이전 시간에서의 이동체의 자세 $\hat{\theta}_{k-1}$에 이동체의 자세 변화량 w_k을 더하여

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

구한다. 예측한 이동체의 xy 위치 $\hat{x}_{k|k-1}$은 이전 시간에서의 이동체의 xy 위치 $\hat{x}_{k-1}$에 이동체의 이동거리 변화량 v_k를 더하여 구한다. 예측한 특징점의 xy 위치 $\hat{p}_{k|k-1}$은 이전 시간에서의 각각의 특징점의 xy 위치를 사용한다. 예측한 추정 상태 변수에 대한 오차 공분산 $P_{k|k-1}$은 이전 시간에서의 추정 상태 변수에 대한 오차 공분산 P_{k-1}와 프로세스 모델에 대한 오차 공분산 Q_k, 표 3.1.1에서 구한 F_k, G_k 행렬을 사용하여 구한다. 보정 단계에서는 칼만 이득을 사용하여 예측 단계에서 구한 예측한 추정 상태 변수를 보정한다.

표 3.1.1 불변 확장 칼만 필터 SLAM 알고리즘

Table 3.1.1 SLAM algorithm using Invariant EKF

EKF SLAM	IEKF SLAM
$F_k = \frac{\partial f}{\partial x}$	$F_k = I_{2n+3}$
$G_k = \frac{\partial f}{\partial w}$	$G_k = \begin{pmatrix} 1 & 0_{1,2} & 0_{1,2n} \\ -J\hat{x}_{k-1} & R(\hat{\theta}_{k-1}) & 0_{2,2n} \\ -J\hat{P}^1_{k-1} & 0_2 & 0_{2,2n} \\ \vdots & \vdots & \vdots \\ -J\hat{P}^n_{k-1} & 0_2 & 0_{2,2n} \end{pmatrix}$
$H_k = \frac{\partial h}{\partial x}$	$H_k = \begin{pmatrix} \nabla\tilde{h}^1 \cdot R(\hat{\theta}_{k\|k-1})^T \begin{pmatrix} 0_{2,1} & -I_2 & I_2 & 0_{2,2(n-1)} \end{pmatrix} \\ \nabla\tilde{h}^2 \cdot R(\hat{\theta}_{k\|k-1})^T \begin{pmatrix} 0_{2,1} & -I_2 & 0_{2,2} & I_2 & 0_{2,2(n-1)} \end{pmatrix} \\ \vdots \\ \nabla\tilde{h}^n \cdot R(\hat{\theta}_{k\|k-1})^T \begin{pmatrix} 0_{2,1} & -I_2 & 0_{2,2(n-1)} & I_2 \end{pmatrix} \end{pmatrix}$

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

표 3.1.2 Invariant EKF SLAM 알고리즘

Table 3.1.2 SLAM algorithm using Invariant EKF

Invariant EKF SLAM$(\hat{X}_{k-1}, P_{k-1}, Y_k, w_k, v_k)$

state : $X = (\theta, x^T, (p^1)^T, \cdots, (p^n)^T)$
measurement : $Y = ((p^1)^T, \cdots, (p^n)^T)$

Prediction

$$\hat{\theta}_{k|k-1} = \hat{\theta}_{k-1} + w_k$$
$$\hat{x}_{k|k-1} = \hat{x}_{k-1} + R(\hat{\theta}_{k-1})v_k$$
$$\hat{p}^j_{k|k-1} = \hat{p}^j_{k-1} \qquad 1 \le j \le n$$
$$P_{k|k-1} = F_k P_{k-1} F_k^T + G_k Q_k G_k^T$$

Correction

$$z_k = Y_k - \begin{pmatrix} \tilde{h}\left[R(\hat{\theta}_{k|k-1})^T(\hat{p}^1_{k|k-1} - \hat{x}_{k|k-1})\right] \\ \vdots \\ \tilde{h}\left[R(\hat{\theta}_{k|k-1})^T(\hat{p}^n_{k|k-1} - \hat{x}_{k|k-1})\right] \end{pmatrix}$$
$$K_k = P_{k|k-1}H_k^T(H_k P_{k|k-1} H_k^T + R_k)^{-1}$$
$$P_k = (I - K_k H_k)P_{k|k-1}$$
$$\hat{X}_k = \varphi(K_k z_k, \hat{X}_{k|k-1})$$

$$\varphi\left(\begin{pmatrix} \delta\theta \\ \delta x \\ \delta p^1 \\ \vdots \\ \delta p^n \end{pmatrix}, \begin{pmatrix} \hat{\theta} \\ \hat{x} \\ \hat{p}^1 \\ \vdots \\ \hat{p}^n \end{pmatrix}\right) = \begin{pmatrix} \hat{\theta} + \delta\theta \\ R(\delta\theta)\hat{x} + B(\delta\theta)\delta x \\ R(\delta\theta)\hat{p}^1 + B(\delta\theta)\delta p^1 \\ \vdots \\ B(\delta\theta)\hat{p}^n + B(\delta\theta)\delta p^n \end{pmatrix}, \quad B(\alpha) = \begin{pmatrix} \frac{\sin(\alpha)}{\alpha} & -\frac{\cos(\alpha)}{\alpha} \\ -\frac{\cos(\alpha)}{\alpha} & \frac{\sin(\alpha)}{\alpha} \end{pmatrix}$$

return $(\hat{X}_k, P_k)$

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

z_k은 측정 개선값으로 측정값 Y_k와 예측한 측정값의 차이를 의미한다. 예측한 측정값은 각각의 특징점의 예측한 위치 $\hat{p}^j_{k|k-1}$와 이동체의 예측한 위치 $\hat{x}_{k|k-1}$의 차이를 로봇 좌표계로 변환하여 구한다. 이 때 사용하는 회전 행렬은 예측한 이동체의 자세 $\hat{\theta}_{k|k-1}$를 사용하여 구한다. 칼만 이득 K_k는 추정 상태 변수와 측정값의 교차 공분산(cross-covariance) $P_{XY}=P_{k|k-1}H_k^T$와 측정값의 오차 공분산 $P_{YY}=H_kP_{k|k-1}H_k^T+R_k$를 연산하여 구한다. 여기서 R_k는 측정 모델에 대한 오차 공분산이다. 칼만 이득 K_k와 측정 개선값 z_k, 예측한 추정 상태 변수 $\hat{X}_{k|k-1}$를 $\varphi(\alpha,\beta)$에 대입하여 보정된 추정 상태 변수 $\hat{X}_k$를 구하고, 보정된 추정 상태 변수에 대한 오차 공분산 P_k를 구한다.

제2절 Graph-based SLAM

본 절은 스무딩 방법 중 하나인 그래프 기반 SLAM 구현에 대해 서술한다[13~14]. 그래프 기반 SLAM은 그래프 구성(graph construction)과 그래프 최적화(graph optimization) 과정으로 구성된다. 그래프 구성 과정은 노드(node)들과 엣지(edge)를 구성하는 과정이다. 노드는 이동체의 위치 정보, 자세 정보를 의미하고, 엣지는 센서 정보로 얻어진 노드들 간의 관계를 의미한다. 그래프 최적화 과정은 노드들과 엣지들의 최적화를 수행하는 과정이다.

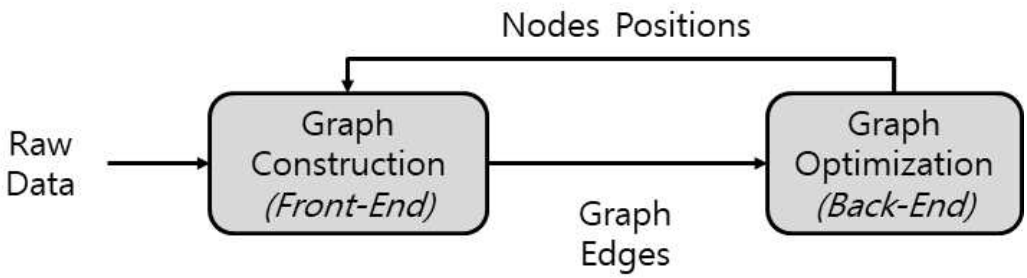

그림 3.2.1 그래프 기반 SLAM

Fig 3.2.1 Graph-based SLAM

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

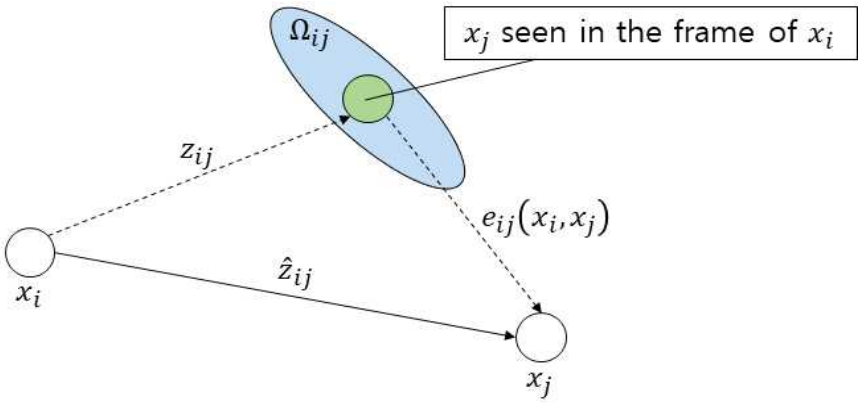

그림 3.2.2 그래프 최적화

Fig 3.2.2 Graph optimization

그림 3.2.2은 그래프 최적화를 그림으로 표현한 것이다. x_i, x_j는 i, j번째 노드를 의미한다. z_{ij}는 노드 x_i에서 바라본 노드 x_j에 대한 측정값이다. $\hat{z}_{ij}$는 예측한 노드 x_i에서 바라본 예측한 노드 x_j에 대한 예측한 측정값이다. Ω_{ij}는 z_{ij}의 정보 행렬(information matrix)이다. e_{ij}는 노드 x_i, x_j의 오차 함수(error function)이다. 오차 함수는 식 (3.2.1)과 같이 측정값 z_{ij}와 예측한 측정값 $\hat{z}_{ij}$의 차이이다.

$$e_{ij}(x_i, x_j) = z_{ij} - \hat{z}_{ij}(x_i, x_j) \tag{3.2.1}$$

최적화는 식 (3.2.2) ~ (3.2.5)와 같다. 노드들의 집합 x에 관한 확률밀도함수(probability density function, pdf)를 구하여 모든 확률밀도함수들을 전부 곱하여 가장 큰 값이 되는 x^*를 구한다. 식 (3.2.3)에 negative log를 취한 후 상수 부분을 제외하여 식 (3.2.4)와 같이 negative log likelihood $F(x)$를 구한다. negative log를 취했으므로 $F(x)$가 가장 작아지는 x^*를 구한다.

$$pdf(x) = |2\pi\Sigma|^{-1/2} e^{-e^T \Omega e/2} \tag{3.2.2}$$

$$x^* = \text{maximize}\left(\prod |2\pi\Sigma|^{-1/2} e^{e^T \Omega e/2}\right) \tag{3.2.3}$$

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

$$F(x) = \sum_{\langle i,j \rangle \in C} e_{ij}^T \Omega_{ij} e_{ij} \tag{3.2.4}$$

$$x^* = \operatorname{argmin} F(x) \tag{3.2.5}$$

노드들의 집합 x를 최신화하기 위해 $\triangle x$를 구한다. $\triangle x$를 구하기 위해 $F(x)$에 $x+\triangle x$를 적용하여 구한다. 테일러 급수 전개를 사용하여 2차식까지 전개하여 식 (3.2.6)과 같은 결과 식을 구한다. $F(x+\triangle x)$가 최소가 되는 $\triangle x$ 값을 구하기 위하여 $F(x+\triangle x)$를 $\triangle x$에 대해 미분하여 0이 되는 값을 구한다. 식 (3.2.6)의 맨 마지막 식을 미분하여 0이 되는 식을 구하면 식 (3.2.7)과 같은 선형 시스템이 구해진다. 이 선형 시스템을 풀어서 $\triangle x$를 구하여 x를 최신화한다. 여기서 H는 확률 정보 행렬(probabilistic information matrix)를 의미하며 b는 계수 벡터(coefficient vector)를 의미한다.

$$\begin{aligned} F(\check{x}+\triangle x) &= \sum_{<i,j> \in C} F_{ij}(\check{x}+\triangle x) \\ &\simeq \sum_{<i,j> \in C} c_{ij} + 2b_{ij}\triangle x + \triangle x^T H_{ij} \triangle x \\ &= c + 2b\triangle x + \triangle x^T H \triangle x \end{aligned} \tag{3.2.6}$$

$$x^* = \operatorname{argmin} F(x) \tag{3.2.7}$$

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

제4장 실험 및 시뮬레이션

제1절 각속도 편차 보정 방법을 사용한 EKF

1. 실험 환경 및 조건

본 실험에서 사용한 센서는 FOG(Fiber obtic gyro) 센서와 AHRS(Attitude and heading reference system) 센서, DVL 센서이다. FOG 센서는 빛을 이용한 자이로 센서로 기준값으로 사용할 자세 정보를 획득하기 위하여 사용되었고, AHRS 센서는 가속도, 각속도, 자기장 벡터 측정값을 획득하기 위하여 사용되었고, DVL 센서는 속도 측정값을 획득하기 위하여 사용되었다. 그림 4.1.1은 실험에서 사용된 AHRS 센서와 FOG 센서, DVL 센서를 장착한 수중로봇이다. 그림 4.1.2는 실험에서 사용된 수조이다. 그림 4.1.3은 로봇의 주행 경로이다. 2.95m × 2.85m 범위에서 시계반향으로 1회, 반시계방향 1회를 왕복하는 주행으로 총 14번 왕복하였으며 사람이 직접 컨트롤러를 사용하여 주행하였다.

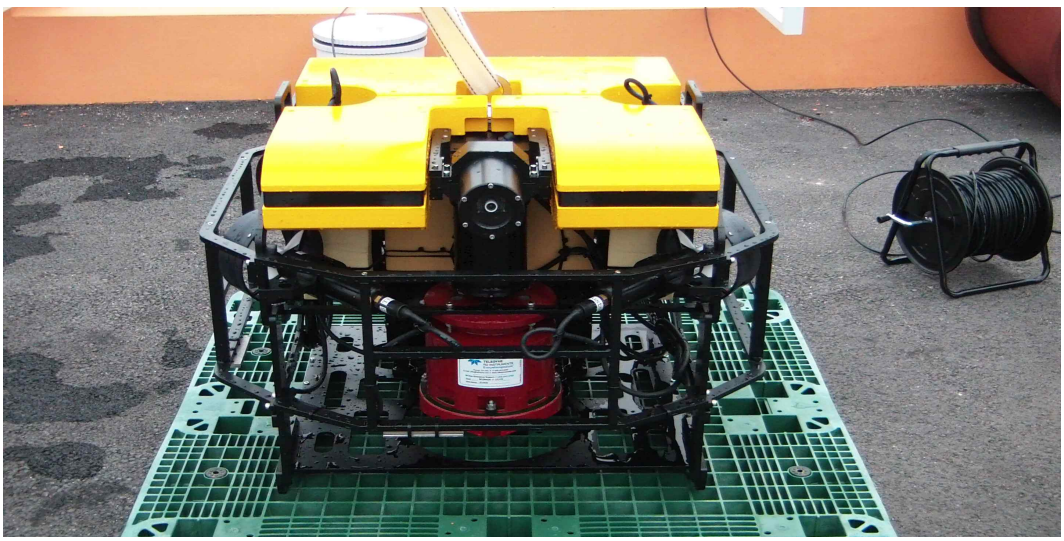

그림 4.1.1 실험에서 사용된 수중로봇

Fig 4.1.1 Underwater vehicle for experiment

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

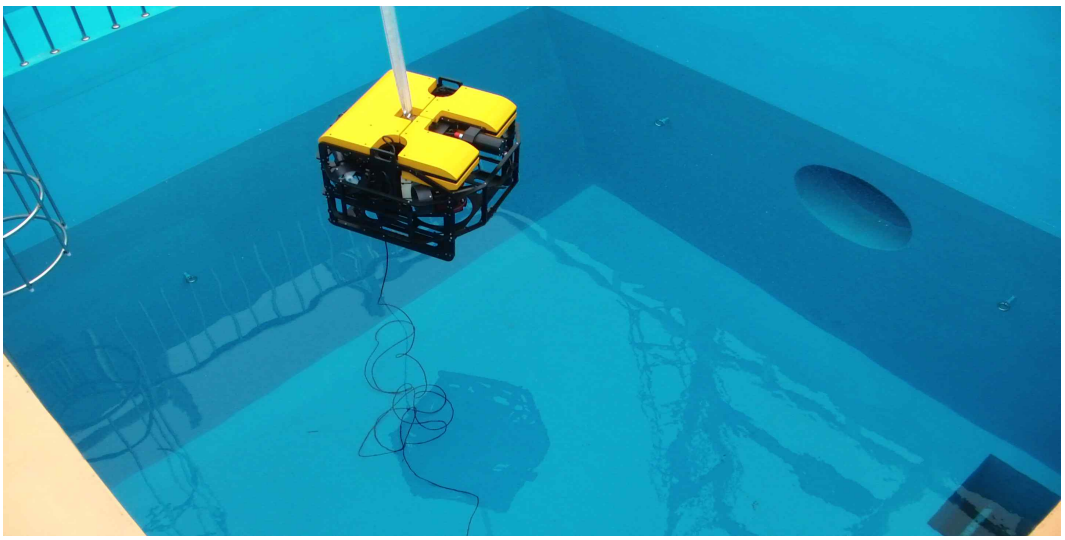

그림 4.1.2 실험에서 사용된 수조

Fig 4.1.2 Test tank for experiment

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

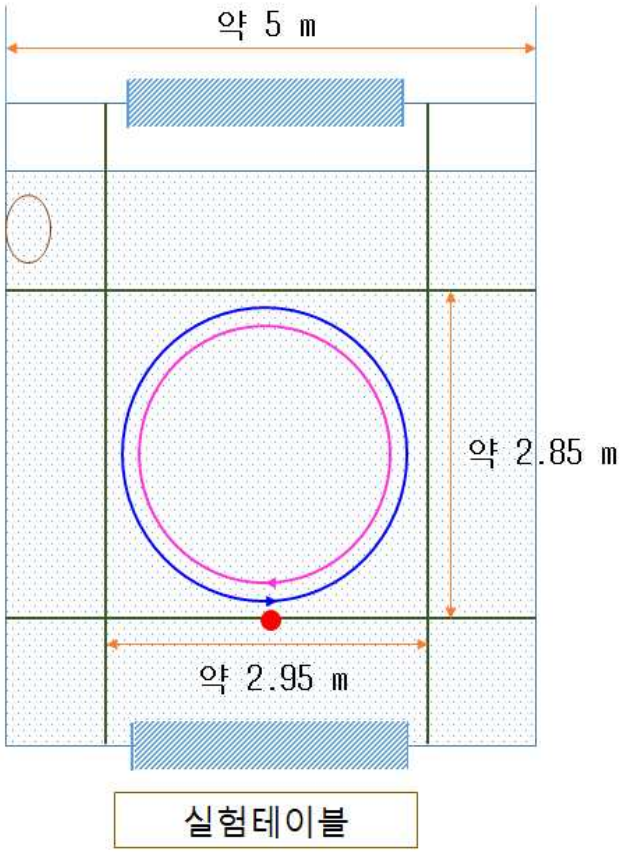

그림 4.1.3 로봇의 주행 경로

Fig 4.1.3 Vehicle motion trajectory

2. 결과

그림 4.1.4부터 4.1.6은 FOG 센서에서 측정된 자세 정보를 기준으로 확장 칼만 필터 방법과 각속도 편차 보정한 확장 칼만 필터 방법의 roll, pitch, yaw 오차를 비교한 그래프이다. (a) 그래프는 전체 시간에 대한 오차 그래프이며, (b) 그래프는 자세한 비교를 위해 시간 축을 1000초에서 1500초까지 확대하여 표시하였다. 그림 4.1.4는 roll 오차를 비교한 그래프로, 각속도 편차 보정한 확장 칼만 필터의 오차가 더 작게 나왔다. 그림 4.1.5는 pitch 오차를 비교한 그래프로, 각속도 편차 보정한 확장 칼만 필터의 오차가 더 작게 나왔다. 그림 4.1.6은 yaw 오차를 비교한 그래프로, 각속도 편차 보정한 확장 칼만 필터의 오차가 더 작게 나왔다.

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

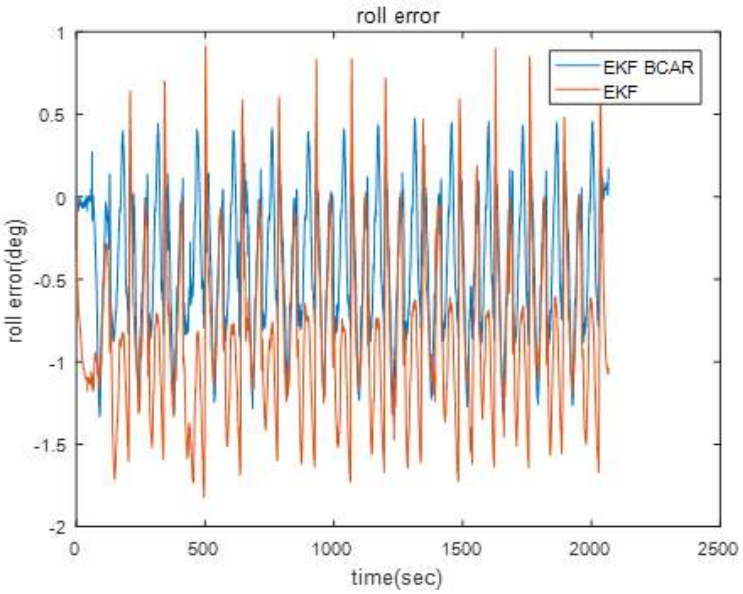

(a)

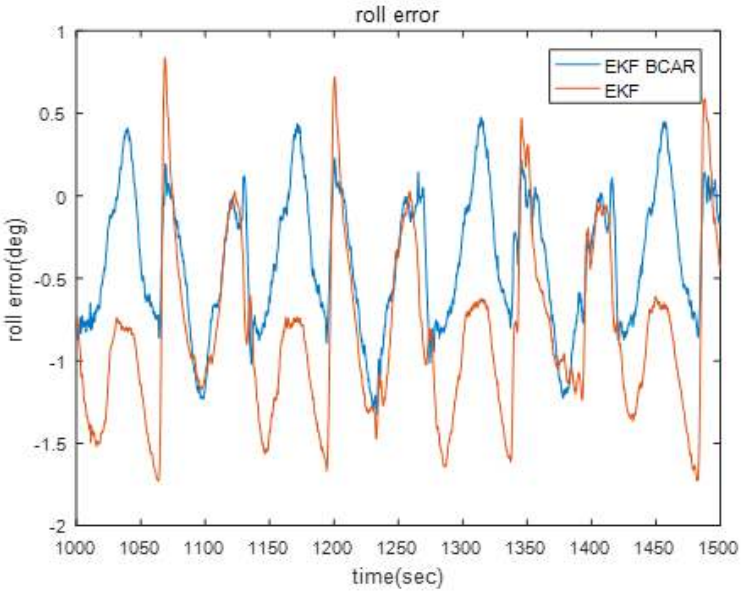

(b)

그림 4.1.4 확장 칼만 필터방법과 각속도 편차 보정한 확장 칼만 필터 방법의 roll 오차 비교

Fig 4.1.4 Comparison of roll error between EKF and EKF BCAR

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

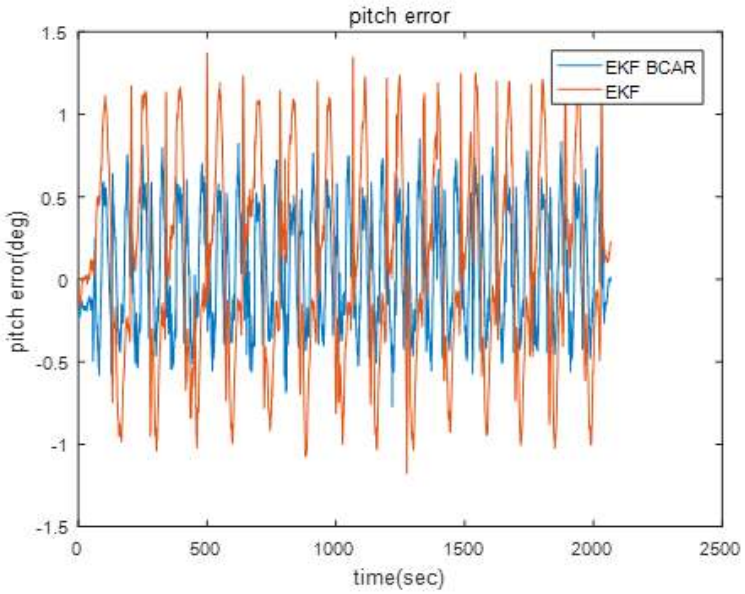

(a)

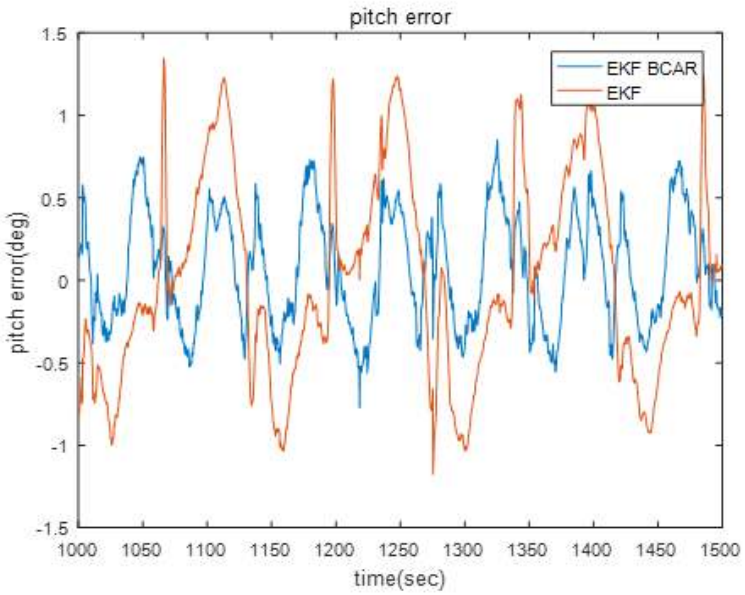

(b)

그림 4.1.5 확장 칼만 필터 방법과 각속도 편차 보정한 확장 칼만 필터 방법의 pitch 오차 비교

Fig 4.1.5 Comparison of pitch error between EKF and EKF BCAR

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

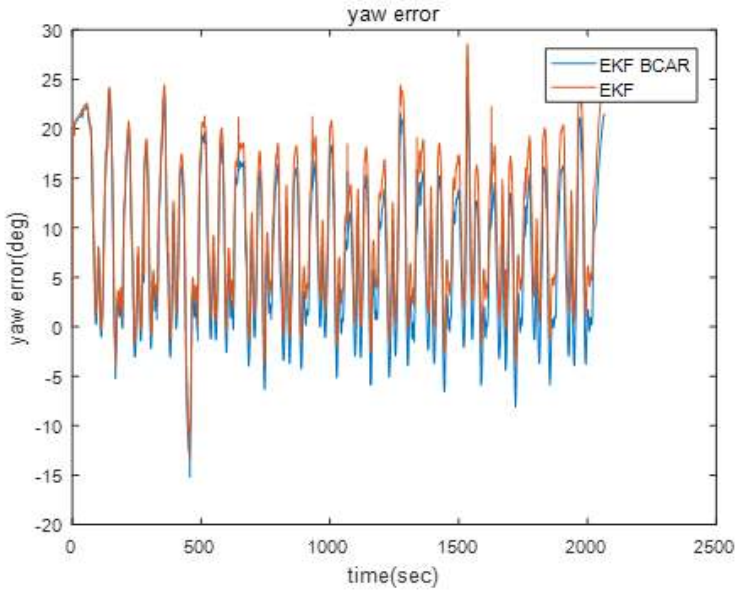

(a)

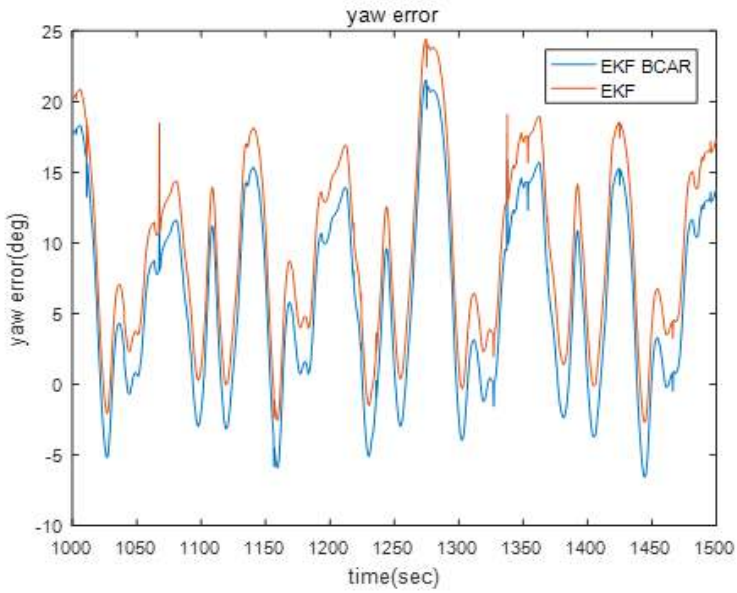

(b)

그림 4.1.6 확장 칼만 필터 방법과 각속도 편차 보정한 확장 칼만 필터 방법의 yaw 오차 비교

Fig 4.1.6 Comparison of yaw error between EKF and EKF BCAR

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

표 4.1.1은 FOG 센서를 기준으로 확장 칼만 필터 방법과 각속도 편차 보정한 확장 칼만 필터 방법의 오차를 여러 방법으로 비교한 결과이다. 오차 평균 결과는 roll, pitch, yaw의 결과 값이 기존의 확장 칼만 필터 방법의 결과 값보다 각속도 편차 보정한 확장 칼만 필터 방법의 결과 값이 더 작게 나왔다. 표준편차는 roll, pitch의 결과 값은 각속도 편차 보정한 확장 칼만 필터 방법이 더 작게 나왔지만 yaw의 값은 기존 확장 칼만 필터 방법이 더 작게 나왔다. 오차 peak to peak는 roll, pitch, yaw의 결과가 각속도 편차 보정한 확장 칼만 필터 방법의 결과 값이 더 작게 나왔다. 오차 최대값은 roll, pitch, yaw의 결과가 각속도 편차 보정한 확장 칼만 필터 방법의의 결과 값이 더 작게 나왔다. 표준편차의 yaw를 제외한 나머지 오차 분석 결과가 각속도 편차 보정한 확장 칼만 필터 방법이 오차가 작게 나온 결과를 확인할 수 있다.

표 4.1.1 확장 칼만 필터 방법과 각속도 편차 보정한 확장 칼만 필터 방법의 자세 추정 오차 비교

Table 4.1.1 Comparison of attitude estimation error between EKF and EKF BCAR

	기존의 확장 칼만 필터 방법			각속도 편차 보정된 확장 칼만 필터 방법		
	roll	pitch	yaw	roll	pitch	yaw
오차 평균(deg)	-0.8339	0.0817	9.9004	-0.3757	0.0628	7.2368
표준 편차(deg)	0.4929	0.6118	7.3607	0.4122	0.3414	7.6220
오차 peak to peak(deg)	2.7376	2.5530	42.0301	1.8298	1.6247	40.5297
오차 최대값(deg)	-1.8226	1.3744	28.6216	-1.3514	0.8525	25.2989

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

제2절 센서 복합 항법

1. 실험 환경 및 조건

본 실험은 포항 수중건설로봇복합실증센터 수조에서 실험했다. 여러 센서를 장착한 수중 로봇을 사각형 모양의 인공 수조에서 사람이 직접 컨트롤러를 사용하여 주행하여 데이터를 얻었다. 그림 4.2.1의 수중 로봇을 그림 4.2.2의 수조에서 실험을 하였다. 사용한 센서는 IMU 센서, DVL 센서, SBL 센서, 수심 센서이다. IMU 센서는 Advanced Navigation 사의 Spatial FOG를 사용했으며, DVL 센서는 Teledyne RD 사의 Navigator DVL을 사용했다. 실험은 사각형 모양으로 주행했으며, 반시계방향으로 주행 후 반대로 돌아 시계방향으로 주행하여 원점으로 돌아왔다. 측정한 데이터는 칼만 필터를 적용하여 필터링하여 사용했다. 오차를 줄이기 위해 이상점(outlier)을 제거하였다.

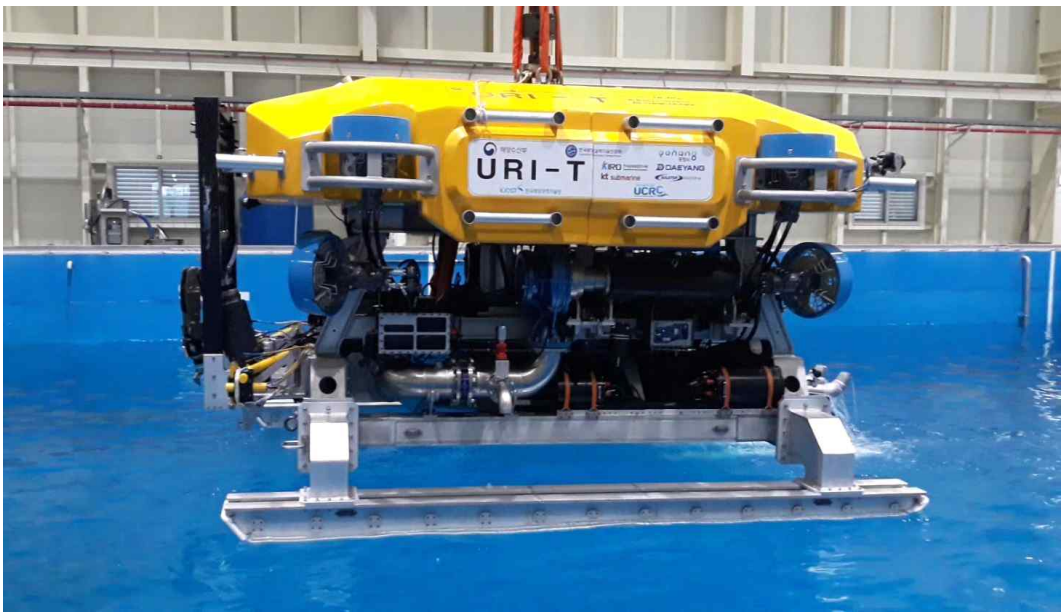

그림 4.2.1 실험에서 사용된 수중로봇

Fig 4.2.1 Underwater vehicle for experiment

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

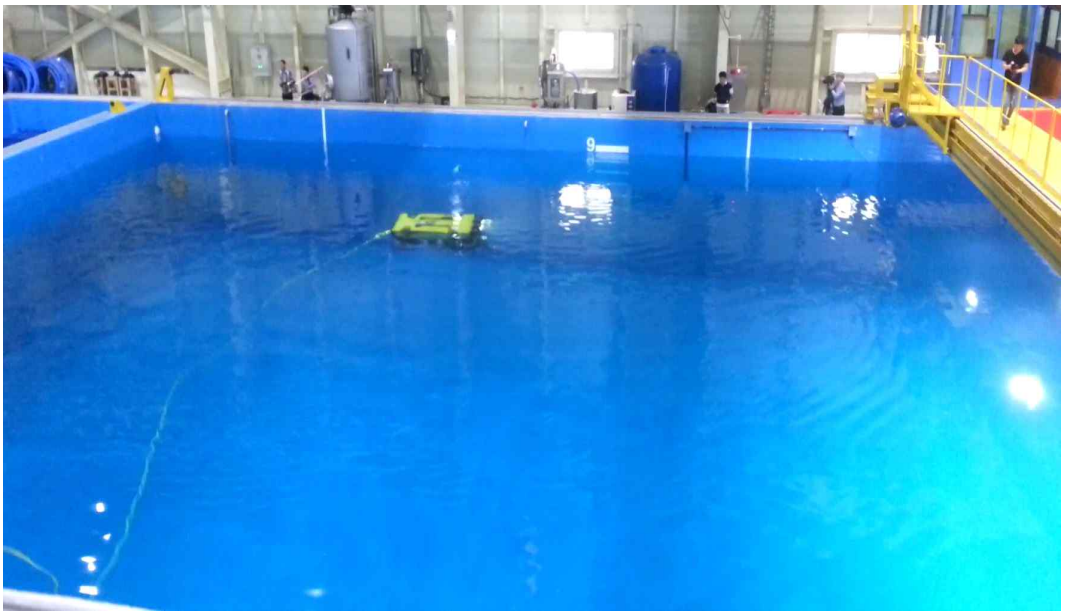

그림 4.2.2 실험에서 사용된 수조

Fig 4.2.2 Test tank for experiment

(a) IMU 센서

(b) DVL 센서

그림 4.2.3 실험에서 사용된 센서

Fig 4.2.3 Sensor for experiment

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

2. 결과

그림 4.2.4에서 (a)는 위치 추정 결과이며, (b)는 위치 오차 공분산이다. 위치 추정 결과 그래프에서 적색 그래프는 센서 측정값을 칼만 필터에 적용한 결과이며 청색 그래프는 위치 추정 결과이다. (a)의 적색 그래프에서 약 (-10, -15)의 값을 향하는 값들은 SBL 센서 출력값이 비정상적인 값을 의미한다. 위치 추정 결과 그래프에서는 이상점을 제거함으로서 매우 안정적이 결과를 보인다. 위치 오차 공분산 그래프는 0에 가까운 값에 수렴하는 것을 확인할 수 있다. 그림 4.2.5는 자세 추정 결과이며, (a)는 roll, (b)는 pitch, (c)는 yaw이다. 센서 출력값과 자세 추정 결과가 비슷한 결과를 보인다. 그림 4.2.6은 선속도 추정 결과이다. 순서대로 x, y, z이며 추정 결과가 센서 출력값과 비슷한 결과를 보인다. 그림 4.2.7는 각속도 추정 결과이다. 순서대로 x, y, z이며 추정 결과가 센서 출력값과 비슷한 결과를 보인다. 그림 4.2.8는 수심의 편차를 추정 결과이다. 수심의 편차가 1보다 작으며 0에 가까운 결과를 보인다.

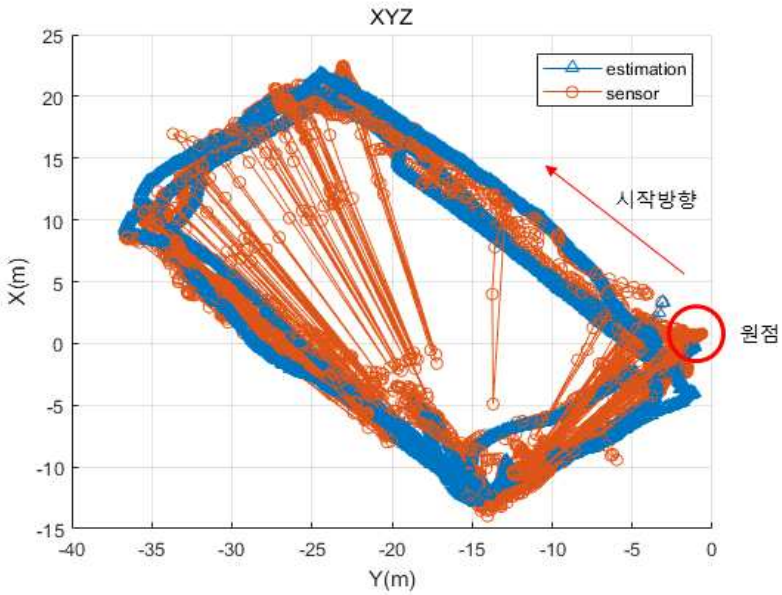

(a)

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

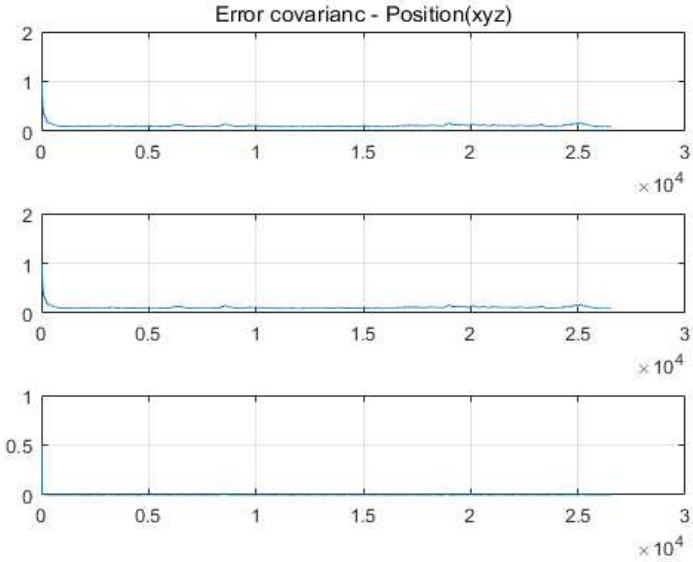

(b)

그림 4.2.4 위치 추정 결과 및 위치 오차 공분산

Fig 4.2.4 Position estimation & error covariance

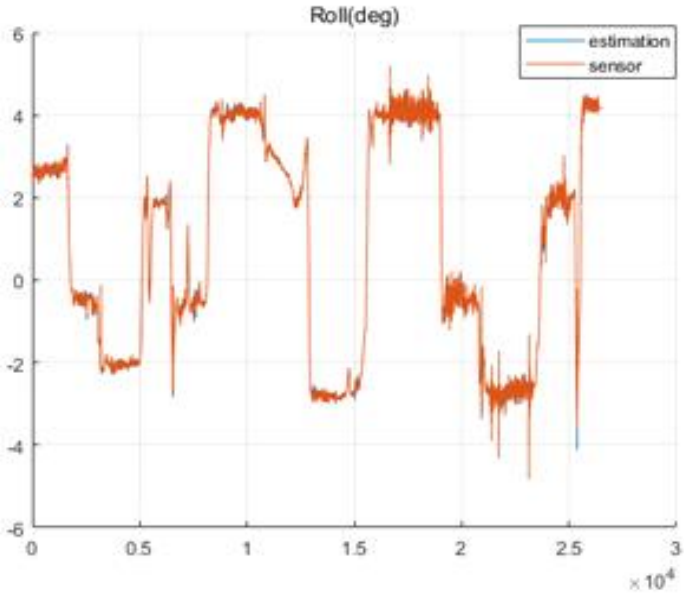

(a)

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

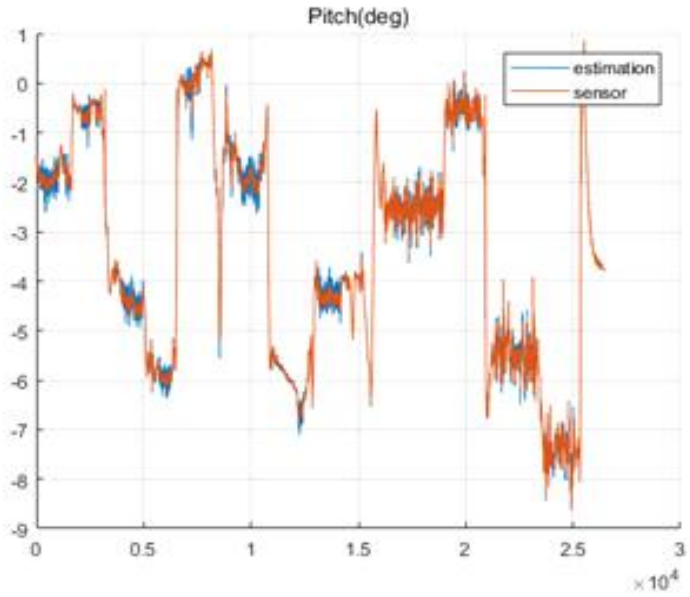

(b)

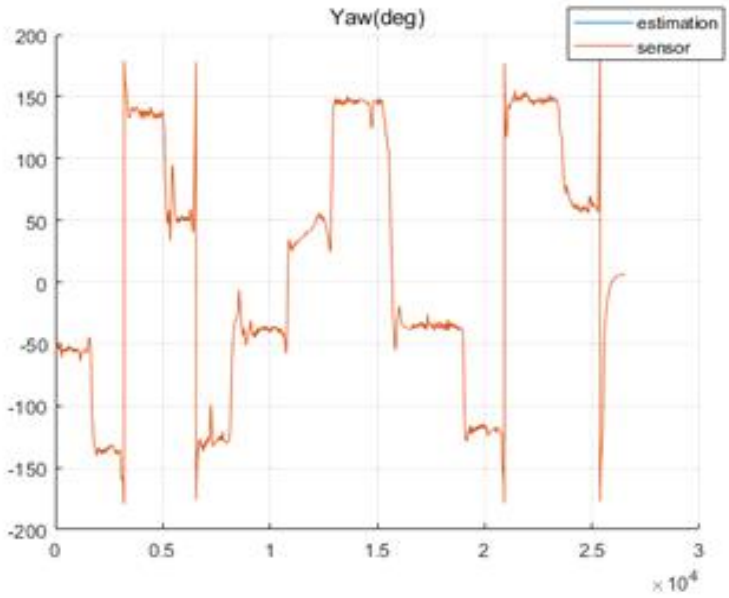

(c)

그림 4.2.5 자세 추정 결과

Fig 4.2.5 Attitude estimation

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

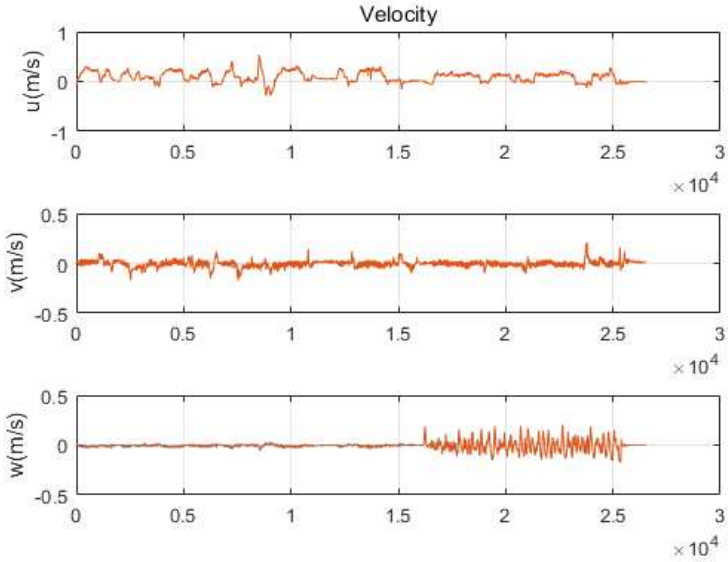

그림 4.2.6 선속도 추정 결과

Fig 4.2.6 Velocity estimation

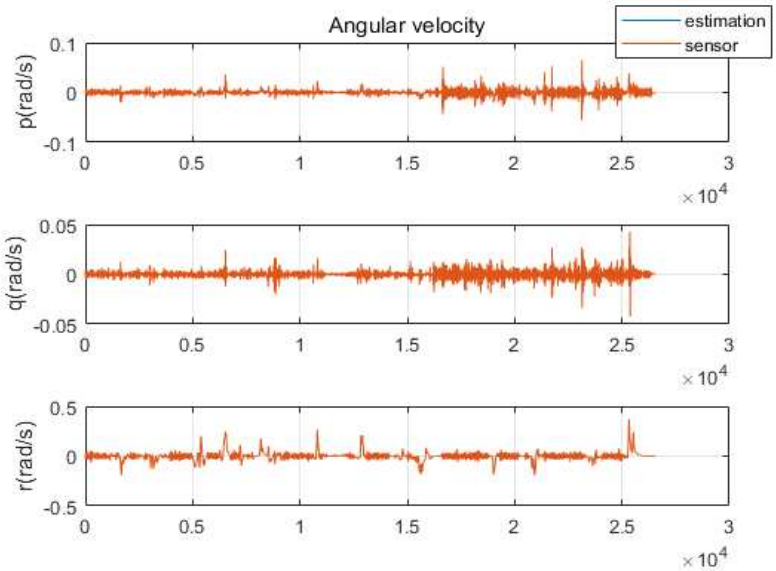

그림 4.2.7 각속도 추정 결과

Fig 4.2.7 Angular velocity estimation

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

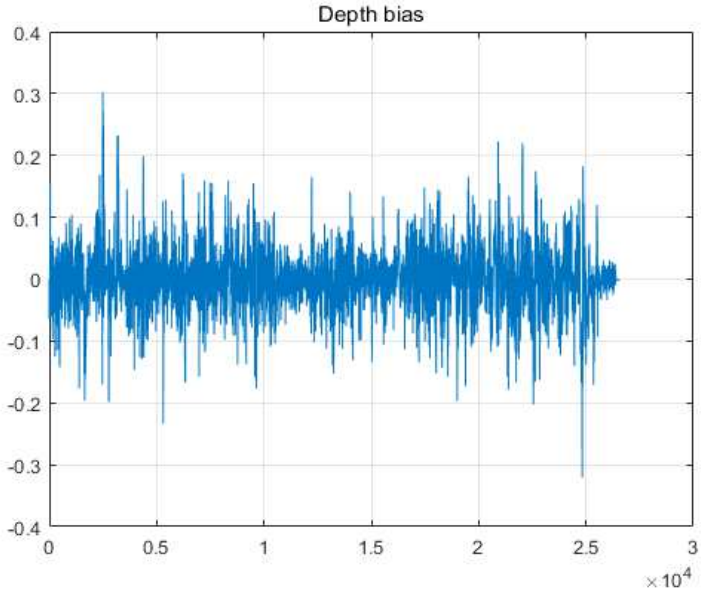

그림 4.2.8 수심의 편차 추정 결과

Fig 4.2.8 Depth bias estimation

제3절 IEKF SLAM

1. 시뮬레이션 조건

본 절에서는 불변 확장 칼만필터 SLAM을 매트랩(matlab) 기반으로 프로그래밍하여 시뮬레이션 한 결과이다. 시뮬레이션은 두 개의 가상 데이터를 만들어 사용했으며, 각 시간마다 모든 특징점의 좌표 및 로봇의 이동거리, 자세 변화량을 측정한다는 조건으로 생성하였다. 첫 번째 시뮬레이션은 모든 특징점의 위치를 안다는 전제하에 실험하였고 두 번째 시뮬레이션은 모든 특징점의 위치를 모른다는 전제하에 실험을 하였다.

첫 번째 시뮬레이션에 대한 실험 조건은 다음과 같다. ① 그림 4.3.1과 같이 (0, 0)을 기준으로 반지름이 100인 원형 모양으로 로봇이 주행한다. ② 총 노드의 개수는 100개이며, 총 특징점의 개수는 10개이다. ③ 거리 오차의 표준편차는 약 1m, 각도 오차의 표준편차는 0.1rad을 주었다. ④ 초기 조건은 다음과 같다. 로봇의 초기 위치는 (100, 0)이다. 로봇의 초기 자세는 실제 로봇의 자세와 같다. 모든 초기 특징점 위치

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

는 실제 특징점 위치와 같다. ⑤ 실제 로봇의 이동 경로의 첫 번째 노드 위치 및 마지막 노드 위치는 (100, 0)이다.

두 번째 시뮬레이션에 대한 실험 조건은 다음과 같다. ① 로봇의 시작 위치는 (0, 0)이며 그림 4.3.2와 같이 주행한다. ② 총 노드의 개수는 17개이며, 총 특징점의 개수는 5개이다. ③ 거리 오차의 표준편차는 약 0.07m, 각도 오차의 표준편차는 0.087rad을 주었다. ④ 초기 조건은 다음과 같다. 로봇의 초기 위치는 (0, 0)이다. 로봇의 초기 자세는 실제 로봇의 자세와 같다. 모든 초기 특징점 위치는 (0, 0)이다.

2. 결과

그림 4.3.3은 첫 번째 시뮬레이션 결과이며, 그림 4.3.4는 두 번째 시뮬레이션 결과이다. 첫 번째 시뮬레이션은 특징점의 위치와 로봇의 위치 변화량 및 자세의 변화량을 기반으로 로봇의 위치 및 특징점 위치를 추정한 결과를 보였다. 두 번째 시뮬레이션의 경우 로봇의 이동 경로가 초반에는 약간의 오차가 있으나 후반에 갈수록 오차가 적어지는 것을 확인할 수 있다. 특징점의 경우 실제 특징점의 위치를 추정한 결과를 보였다.

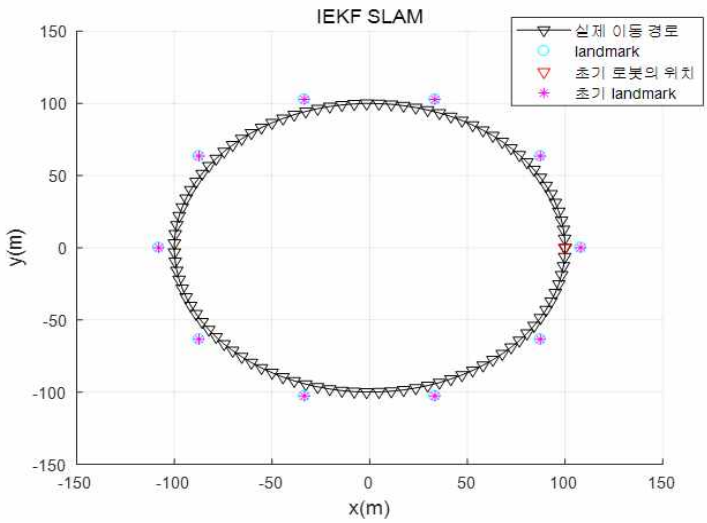

그림 4.3.1 첫 번째 시뮬레이션 초기 상태

Fig 4.3.1 Initial state of first simulation

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

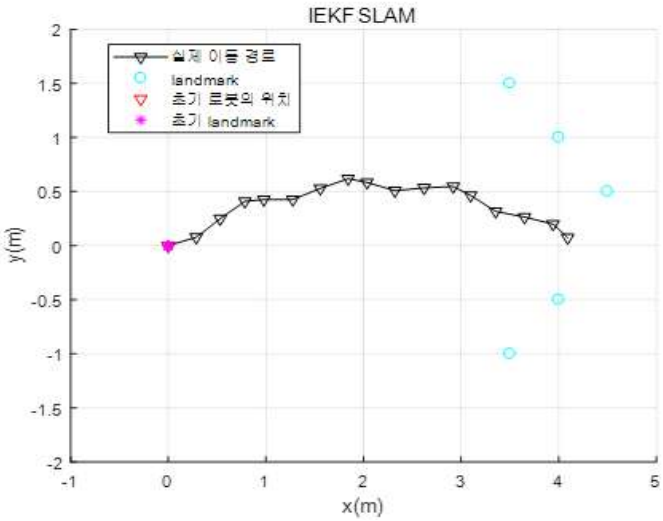

그림 4.3.2 두 번째 시뮬레이션 초기 상태

Fig 4.3.2 Initial state of second simulation

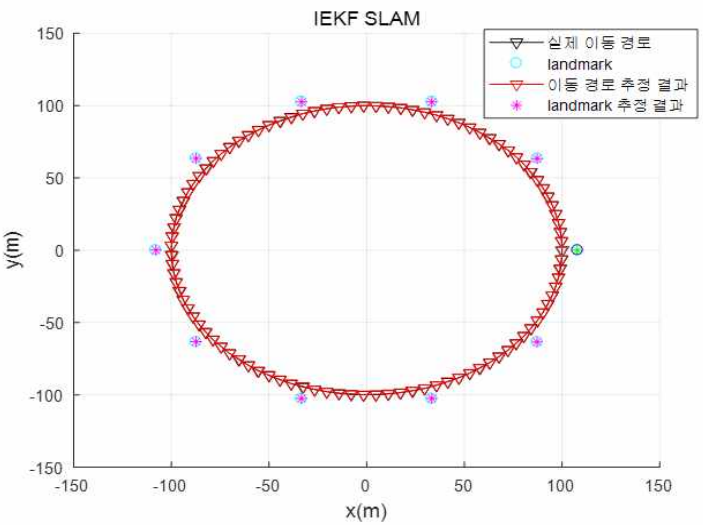

그림 4.3.3 첫 번째 시뮬레이션 결과

Fig 4.3.3 Result of first simulation

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

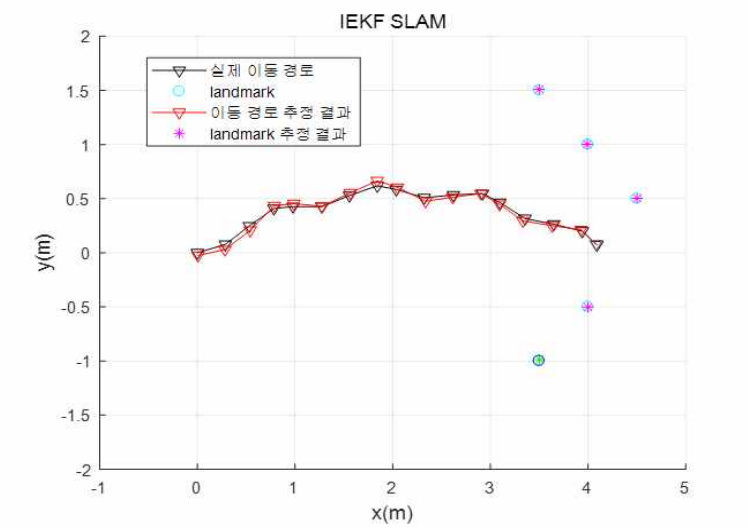

그림 4.3.4 두 번째 시뮬레이션 결과

Fig 4.3.4 Result of second simulation

제4절 Graph-based SLAM

1. 실험 환경 및 조건

본 절에서는 그래프 기반 SLAM 방법을 매트랩 프로그램을 사용하여 구현하고, Rainer Kuemmerle가 개발한 g2o(General graph optimization)을 사용하여 비교한다[15]. 실험 데이터는 취리히 연방공과대학(ETH Zurich) Autonomous System Lab의 'Wood autumn' 데이터 셋을 ICP(Iterative closest point) 방법에 적용하여 사용했다[16]. 최적화 과정은 50번 반복했다. 그림 4.4.1은 시뮬레이션 초기 설정이다. 청색 그래프는 기준값이며, 흑색 그래프는 ICP 특징점 추정에 의한 데드 레크닝(dead-reckoning) 추정 결과이며, 적색 그래프는 초기 노드들의 위치를 의미한다. 초기 노드들의 위치는 (0, 0)이며 자세는 0 rad이다.

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

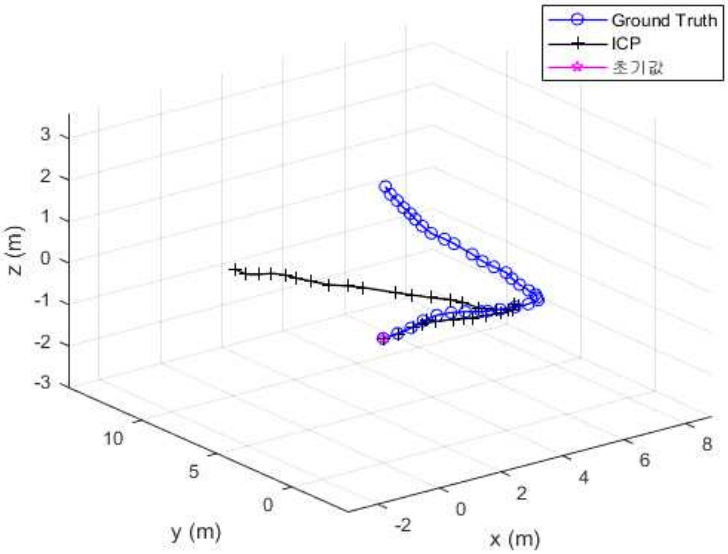

그림 4.4.1 최적화 전

Fig 4.4.1 Before optimization

2. 결과

그림 4.4.2는 그래프 기반 SLAM의 최적화 과정을 g2o에 의하여 구현한 결과이다. 최적화 과정은 50번 반복했다. 그림 4.4.3은 매트랩 프로그램을 사용한 그래프 기반 SLAM 결과이다. 청색 그래프는 기준값이며, 적색 그래프는 매트랩 시뮬레이션 결과이며, 녹색 그래프는 g2o의 결과이며, 흑색 그래프는 ICP 특징점 추정에 의한 데드 레크닝 추정 결과이다. 그래프 기반 SLAM으로 최적화한 위치 추정 결과가 ICP 특징점 추정에 의한 데드 레크닝 추정 방법보다 기준값에 비슷한 결과가 나왔다. 또한, g2o를 사용한 시뮬레이션 결과와 매우 비슷한 결과가 나온 것을 확인할 수 있다. 하지만, 기준값과 비교하였을 때 오차가 크다는 것을 확인 할 수 있다. ICP 방법에 의해 만들어진 엣지 정보들의 신뢰성이 낮아서 위치 추정 결과의 정확성이 떨어진 것으로 분석된다.

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

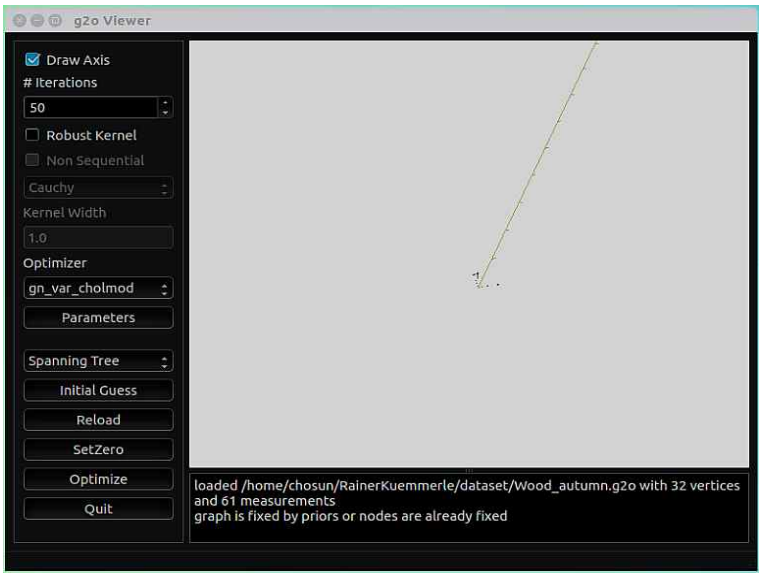

(a) optimize 전

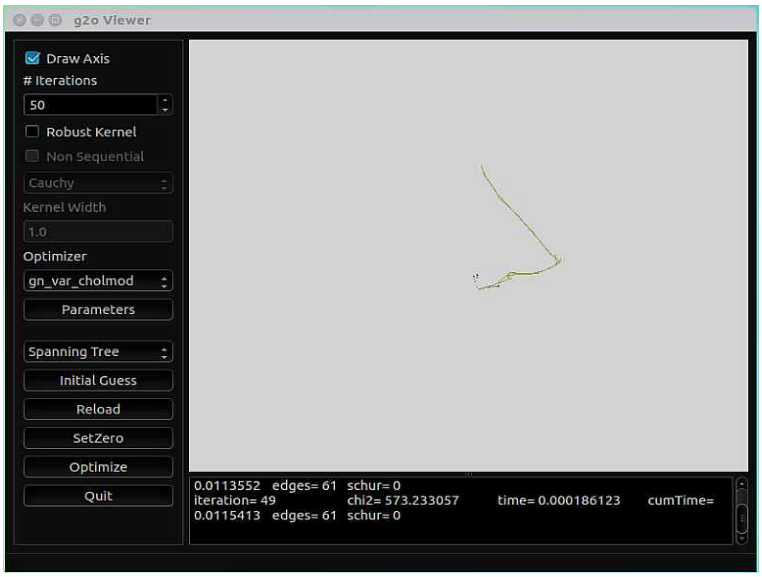

(b) optimize 후

그림 4.4.2 g2o 구동 결과

Fig 4.4.2 Result of g2o

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

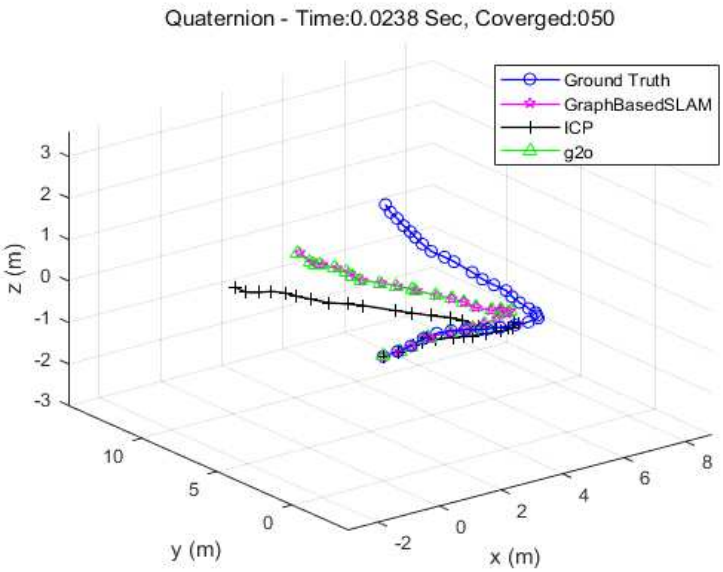

그림 4.4.3 최적화 결과

Fig 4.4.3 Result of optimization

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

제5장 결론

본 논문에서는 무인 이동 로봇의 위치 및 자세 추정, 지도 작성에 대한 연구이다. 위치 및 자세 추정을 하기 위해 각속도 편차 보정 방법과 센서 복합 항법을 사용했으며, 지도 작성을 하기 위해 불변 확장 칼만 필터 SLAM, 그래프 기반 SLAM 방법을 사용했다. 각속도 편차 보정 방법을 사용한 확장 칼만 필터 방법은 기존 확장 칼만 필터 방법을 사용한 자세 추정 결과보다 오차가 적은 결과를 보였다. 센서 복합 항법은 여러 센서 측정값을 융합함으로서 위치 및 자세를 추정하였으며 불안정한 측정값을 보정했다. 불변 확장 칼만 필터 SLAM은 주변 특징점 위치를 추정함으로서 지도를 작성하며 동시에 로봇의 위치를 구했다. 그래프 기반 SLAM은 데드 레크닝 추정 결과보다 좋은 결과가 나왔지만, 엣지 정보들의 신뢰성이 낮아 정확성이 떨어졌다. 향후, 각속도 편차 보정 방법과 센서 복합 항법을 융합하여 더 정확한 위치 추정 및 자세 추정을 할 예정이다. 불변 확장 칼만 필터 SLAM은 Matrix Lie group에 대해 더 연구하고 실제 로봇을 사용한 측정값을 사용하여 알고리즘을 개선할 예정이다. 그래프 기반 SLAM은 ICP 방법 이외의 엣지 정보 생성 방법에 대해 조사하여 엣지 정보들의 신뢰성을 높여 정확한 지도 작성 및 위치 추정을 할 예정이다.

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

참고문헌

[1] NY. Ko, et al, “Attitude estimation using depth measurement and AHRS data for underwater vehicle navigation.” OCEANS 2016-Shanghai. IEEE, 2016, 1-4.

[2] NY. Ko, et al, "Synchronous and asynchronous application of a filtering method for underwater robot localization." International Journal of Humanoid Robotics, 13(02), 2016, 1550038.

[3] 노성우, 외, “해저 지형정보를 이용하는 수중 로봇 위치추정 방법의 구현 및 성능 비교.” 한국지능시스템학회 논문지, 25(1), 2015, 70-77.

[4] G. Welch and G. Bishop, “An intruduction to the Kalman filter.” Department of Computer Science, University of North Carolina. ed:Chapel Hill, NC, unpublished manuscript.

[5] G. Grisetti, et al, “A tutorial on graph-based SLAM.” IEEE Intelligent Transportation Systems Magazine, 2(4), 2010, 31-43.

[6] 고낙용, 정준혁, “편차 보정된 각속도를 사용하는 수중 로봇의 자세 추정.” 한국수중·수상로봇기술연구회 2017년 춘계학술대회, 2017.

[7] MD. Hua, et al, “Nonlinear attitude estimation with measurement decoupling and anti-windup gyro-bias compensation.” IFAC Proceedings, 44(1), 2011, 2972-2978.

[8] 정석기, 외, “UUV 의 DVL 항법을 위한 자세 추정 방법 비교.” 로봇학회논문지, 9(4), 2014, 216-224.

[9] 고낙용, 외, “DVL 비동작 환경에서의 무인 수중 운송체의 항법.” 한국수중·수상로봇기술연구회 2018년 추계학술대회, 2018.

[10] 고낙용, 정준혁, “Invariant EKF 를 사용한 2 차원 환경에서의 SLAM 구현.” 제어로봇시스템학회 국내학술대회 논문집, 2018, 10-11.

[11] S. Bonnable, et al, “Invariant Extended Kalman Filter: theory and application to a velocity-aided attitude estimation problem.” Decision and Control, 2009 held jointly with the 2009 28th Chinese Control Conference. CDC/CCC 2009. Proceedings of the 48th IEEE Conference, 2009, 1297-1304.

[12] A. Barrau and S. Bonnabel, “An EKF-SLAM algorithm with consistency properties.” arXiv preprint arXiv:1510.06263, 2015.

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

[13] 김태균, 외, “그래프 기반 방법을 사용한 무인 이동체의 이동 궤적 추정.” 제어로봇시스템학회 국내학술대회 논문집, 2017, 338-339.

[14] 고낙용, 정준혁, “g2o를 사용한 그래프 기반 SLAM 구현.” 제13회 한국로봇종합학술대회 논문집, 2018.

[15] R. Kummerle, et al, “g 2 o: A general framework for graph optimization.” IEEE Int. Conf. on Robotics and Automation, 2011, 3607-3613.

[16] http://projects.asl.ethz.ch/datasets/

Collection @ chosun

조선대학교
CHOSUN UNIVERSITY

감사의 글

2016년에 연구실에 들어와 연구실 생활을 시작하며 2017년에 대학원에 입학하였습니다. 세월이 빠르게 흘러 벌써 졸업을 앞두고 있습니다. 약 2년간 연구실 생활을 하며 많은 것을 배우고 여러 일을 경험하였습니다. 학문을 더 공부하고자 대학원에 진학하여 자율주행에 관한 학문을 공부했습니다. 처음에는 힘들고 어려웠으며 포기하고 싶은 생각도 많이 했습니다. 하지만 그럴 때마다 저의 방향성을 제시해주시며 고민을 해결해주신 지도교수님이신 고낙용 교수님께 진심으로 감사드립니다. 교수님의 많은 지원을 통해 많은 것을 배웠으며 무사히 졸업을 준비 할 수 있었습니다. 그리고 지도교수님 만큼 많은 도움을 주신 최한수 교수님, 이진이 교수님, 반성범 교수님, 곽근창 교수님께 정말로 감사드립니다.

연구실에 들어왔을 때부터 많은 것을 알려주며 챙겨준 석기 형한테는 항상 감사한 마음을 갖고 있습니다. 또한, 연구실에 들어와서 지금까지 같이 지내온 동기 송경섭한테도 감사한 마음을 갖고 있습니다. 언제나 어려운 일이나 서로 모르는 문제를 해결할 때 곁에서 도와준 멋진 친구입니다. 그리고 연구실 후배라는 이유로 언제나 도움을 많이 주신 성우 형과 태균이형, 효섭이 형도 감사합니다. 먼저 사회로 나간 경험자로서의 충고 및 지식을 많이 알려 주셨고 앞으로 졸업 후 진로에 대해 많은 이야기를 해주셨습니다. 마지막으로 연구실 후배인 장영수, 안태용, 강이턴, 이규은, 정다빈에게도 고맙습니다. 어려운 일이 있을 때 항상 격려해주고 긍정적인 분위기를 조성해준 후배들이었습니다.

대학교 시절 및 대학원 시절 동안 고향에서 떨어져 지내는 저를 항상 응원해주신 부모님께도 감사합니다. 힘들 일이 있을 때 항상 격려해주시고 응원해주셨습니다. 그리고 언제나 부족한 저를 잘 챙겨주던 친누나에게도 감사합니다. 멀리 떨어져 있어도 잘 챙겨주고 응원해줬습니다.

Collection @ chosun