

SLAM Monocular Basado en UKF para la Localización de un Robot Móvil

Gonzalo Perez Paina Claudio Paz Martin Baudino Luis Canali

Centro de Investigación en Informática para la Ingeniería (CIII)
Universidad Tecnológica Nacional, Regional Córdoba, Argentina
<http://ciiii.frc.utn.edu.ar>



VIII Jornadas Argentinas de Robótica
12 al 14 de noviembre de 2014

- 1 Introducción y objetivos
- 2 Formulación del SLAM con filtro de Kalman (UKF)
- 3 SLAM monocular en robot móvil
- 4 Resultados de simulación y experimentales
- 5 Conclusiones y trabajos futuros

Introducción y objetivos

Localización y mapeo simultáneos (SLAM)

- Actualmente es un bloque fundamental de los sistemas de navegación autónoma
- Debido a que brindan una solución conjunta a dos de los problemas fundamentales a resolver para lograr robots móviles autónomos: **localización** y **mapeo**

Propósitos de aplicación del SLAM

- Online para localización
- Offline para la generación de mapas
- Online para actualización continua del mapa

Solución al SLAM online: **filtrado bayesiano** (EKF, UKF, EIF, PF, etc.)

Filtro de Kalman Unscented (UKF)

- Presenta una alternativa al EKF con menor error de linealización
- Más fácil de implementar que el EKF

Introducción y objetivos

Localización y mapeo simultáneos (SLAM)

- Actualmente es un bloque fundamental de los sistemas de navegación autónoma
- Debido a que brindan una solución conjunta a dos de los problemas fundamentales a resolver para lograr robots móviles autónomos: **localización** y **mapeo**

Propósitos de aplicación del SLAM

- Online para localización
- Offline para la generación de mapas
- Online para actualización continua del mapa

Solución al SLAM online: **filtrado bayesiano** (EKF, UKF, EIF, PF, etc.)

Filtro de Kalman Unscented (UKF)

- Presenta una alternativa al EKF con menor error de linealización
- Más fácil de implementar que el EKF

Introducción y objetivos

Localización y mapeo simultáneos (SLAM)

- Actualmente es un bloque fundamental de los sistemas de navegación autónoma
- Debido a que brindan una solución conjunta a dos de los problemas fundamentales a resolver para lograr robots móviles autónomos: **localización** y **mapeo**

Propósitos de aplicación del SLAM

- **Online para localización**
- Offline para la generación de mapas
- Online para actualización continua del mapa

Solución al SLAM online: **filtrado bayesiano** (EKF, UKF, EIF, PF, etc.)

Filtro de Kalman Unscented (UKF)

- Presenta una alternativa al EKF con menor error de linealización
- Más fácil de implementar que el EKF

Introducción y objetivos

Localización y mapeo simultáneos (SLAM)

- Actualmente es un bloque fundamental de los sistemas de navegación autónoma
- Debido a que brindan una solución conjunta a dos de los problemas fundamentales a resolver para lograr robots móviles autónomos: **localización** y **mapeo**

Propósitos de aplicación del SLAM

- **Online para localización**
- Offline para la generación de mapas
- Online para actualización continua del mapa

Solución al SLAM online: **filtrado bayesiano** (EKF, UKF, EIF, PF, etc.)

Filtro de Kalman Unscented (UKF)

- Presenta una alternativa al EKF con menor error de linealización
- Más fácil de implementar que el EKF

Introducción y objetivos

Solución del SLAM mediante **filtrado bayesiano**

● **Predicción**

Puede integrar información de sensores propioceptivos

Modelo de movimiento

● Sensores propioceptivos

- ▶ Unidades inerciales
- ▶ Odometría

● **Corrección**

Información de sensores exteroceptivos

Modelo de medición

● Sensores exteroceptivos

- ▶ Sensor de barrido láser
- ▶ Cámaras monoculares o estéreo
- ▶ Sensor RGBD (Kinect)

Objetivos

Obtener un esquema de SLAM monocular para la localización de un robot móvil, utilizando información de odometría para ajustar la escala

Introducción y objetivos

Solución del SLAM mediante **filtrado bayesiano**

- **Predicción**

Puede integrar información de sensores propioceptivos

Modelo de movimiento

- Sensores propioceptivos

- ▶ Unidades inerciales
- ▶ Odometría

- **Corrección**

Información de sensores exteroceptivos

Modelo de medición

- Sensores exteroceptivos

- ▶ Sensor de barrido láser
- ▶ Cámaras monoculares o estéreo
- ▶ Sensor RGBD (Kinect)

Objetivos

Obtener un esquema de SLAM monocular para la localización de un robot móvil, utilizando información de odometría para ajustar la escala

Introducción y objetivos

Solución del SLAM mediante **filtrado bayesiano**

- **Predicción**

Puede integrar información de sensores propioceptivos

Modelo de movimiento

- Sensores propioceptivos

- ▶ Unidades inerciales
- ▶ Odometría

- **Corrección**

Información de sensores exteroceptivos

Modelo de medición

- Sensores exteroceptivos

- ▶ Sensor de barrido láser
- ▶ Cámaras monoculares o estéreo
- ▶ Sensor RGBD (Kinect)

Objetivos

Obtener un esquema de SLAM monocular para la localización de un robot móvil, utilizando información de odometría para ajustar la escala

Introducción y objetivos

Solución del SLAM mediante **filtrado bayesiano**

- **Predicción**

Puede integrar información de sensores propioceptivos

Modelo de movimiento

- Sensores **propioceptivos**

- ▶ Unidades inerciales
- ▶ Odometría

- **Corrección**

Información de sensores exteroceptivos

Modelo de medición

- Sensores **exteroceptivos**

- ▶ Sensor de barrido láser
- ▶ Cámaras monoculares o estéreo
- ▶ Sensor RGBD (Kinect)

Objetivos

Obtener un esquema de SLAM monocular para la localización de un robot móvil, utilizando información de odometría para ajustar la escala

Introducción y objetivos

Solución del SLAM mediante **filtrado bayesiano**

- **Predicción**

Puede integrar información de sensores propioceptivos

Modelo de movimiento

- Sensores **propioceptivos**

- ▶ Unidades inerciales
- ▶ Odometría

- **Corrección**

Información de sensores exteroceptivos

Modelo de medición

- Sensores **exteroceptivos**

- ▶ Sensor de barrido láser
- ▶ Cámaras monoculares o estéreo
- ▶ Sensor RGBD (Kinect)

Objetivos

Obtener un esquema de SLAM monocular para la localización de un robot móvil, utilizando información de odometría para ajustar la escala

Introducción y objetivos

Solución del SLAM mediante **filtrado bayesiano**

- **Predicción**

Puede integrar información de sensores propioceptivos

Modelo de movimiento

- Sensores **propioceptivos**

- ▶ Unidades inerciales
- ▶ **Odometría**

- **Corrección**

Información de sensores exteroceptivos

Modelo de medición

- Sensores **exteroceptivos**

- ▶ Sensor de barrido láser
- ▶ **Cámaras monoculares** o estéreo
- ▶ Sensor RGBD (Kinect)

Objetivos

Obtener un esquema de SLAM monocular para la localización de un robot móvil, utilizando información de odometría para ajustar la escala

Contenido

- 1 Introducción y objetivos
- 2 Formulación del SLAM con filtro de Kalman (UKF)
- 3 SLAM monocular en robot móvil
- 4 Resultados de simulación y experimentales
- 5 Conclusiones y trabajos futuros

SLAM con filtro de Kalman

Vector de estado en SLAM

$$\mathbf{x} = \begin{bmatrix} \mathbf{r} \\ \mathbf{m} \end{bmatrix}, \quad \text{con} \quad \mathbf{r} = \begin{bmatrix} x \\ y \\ \phi \end{bmatrix}, \quad \mathbf{m} = \begin{bmatrix} \mathbf{m}_1 \\ \vdots \\ \mathbf{m}_N \end{bmatrix}$$

\mathbf{r} es la pose (posición y orientación) del robot, y $\mathbf{m}_i, i = 1, \dots, N$ las posiciones de las características que componen el mapa (puntos 3D).

Sistema dinámico en tiempo discreto

- Ecuación de proceso:

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_k$$

donde \mathbf{u}_k es la entrada de control y $\mathbf{w}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_k)$ el ruido de proceso.

- Ecuación de medición:

$$\mathbf{z}_k = h(\mathbf{x}_k) + \mathbf{v}_k$$

donde $\mathbf{v}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_k)$.

Propagación de variables aleatorias

SLAM con filtro de Kalman

Vector de estado en SLAM

$$\mathbf{x} = \begin{bmatrix} \mathbf{r} \\ \mathbf{m} \end{bmatrix}, \quad \text{con} \quad \mathbf{r} = \begin{bmatrix} x \\ y \\ \phi \end{bmatrix}, \quad \mathbf{m} = \begin{bmatrix} \mathbf{m}_1 \\ \vdots \\ \mathbf{m}_N \end{bmatrix}$$

\mathbf{r} es la pose (posición y orientación) del robot, y $\mathbf{m}_i, i = 1, \dots, N$ las posiciones de las características que componen el mapa (puntos 3D).

Sistema dinámico en tiempo discreto

- Ecuación de proceso:

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_k$$

donde \mathbf{u}_k es la entrada de control y $\mathbf{w}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_k)$ el ruido de proceso.

- Ecuación de medición:

$$\mathbf{z}_k = h(\mathbf{x}_k) + \mathbf{v}_k$$

donde $\mathbf{v}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_k)$.

Propagación de variables aleatorias

SLAM con filtro de Kalman

Vector de estado en SLAM

$$\mathbf{x} = \begin{bmatrix} \mathbf{r} \\ \mathbf{m} \end{bmatrix}, \quad \text{con} \quad \mathbf{r} = \begin{bmatrix} x \\ y \\ \phi \end{bmatrix}, \quad \mathbf{m} = \begin{bmatrix} \mathbf{m}_1 \\ \vdots \\ \mathbf{m}_N \end{bmatrix}$$

\mathbf{r} es la pose (posición y orientación) del robot, y $\mathbf{m}_i, i = 1, \dots, N$ las posiciones de las características que componen el mapa (puntos 3D).

Sistema dinámico en tiempo discreto

- Ecuación de proceso:

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_k$$

donde \mathbf{u}_k es la entrada de control y $\mathbf{w}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_k)$ el ruido de proceso.



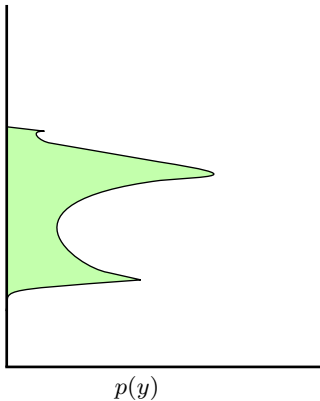
- Ecuación de medición:

$$\mathbf{z}_k = h(\mathbf{x}_k) + \mathbf{v}_k$$




donde $\mathbf{v}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_k)$.

Propagación de variables aleatorias




Propagación de variables aleatorias





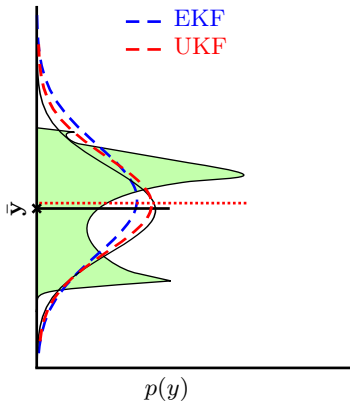
Propagación de variables aleatorias



Propagación de variables aleatorias



Propagación de variables aleatorias



Transformada Unscented, UT

Dada una v.a. $\mathbf{x} \in \mathbb{R}^L$, con $\mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, \mathbf{P}_x)$, y la v.a. \mathbf{y} dada por $\mathbf{y} = g(\mathbf{x})$.

- 1 Conjunto de puntos sigma
- 2 Propagación de puntos sigma
- 3 Estimación de media y covarianza

Transformada Unscented, UT

Dada una v.a. $\mathbf{x} \in \mathbb{R}^L$, con $\mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, \mathbf{P}_x)$, y la v.a. \mathbf{y} dada por $\mathbf{y} = g(\mathbf{x})$.

- 1 Conjunto de puntos sigma
- 2 Propagación de puntos sigma
- 3 Estimación de media y covarianza

Formar un conjunto con $2L + 1$ puntos sigma

$$\mathcal{X}_0 = \bar{\mathbf{x}}$$

$$\mathcal{X}_i = \bar{\mathbf{x}} + \left(\sqrt{(L + \lambda)\mathbf{P}_x} \right)_i \quad i = 1, \dots, L$$

$$\mathcal{X}_i = \bar{\mathbf{x}} - \left(\sqrt{(L + \lambda)\mathbf{P}_x} \right)_{i-n} \quad i = L + 1, \dots, 2L$$

donde $\lambda = \sigma^2(L + \kappa) - L$ es un parámetro de escalado.

Transformada Unscented, UT

Dada una v.a. $\mathbf{x} \in \mathbb{R}^L$, con $\mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, \mathbf{P}_x)$, y la v.a. \mathbf{y} dada por $\mathbf{y} = g(\mathbf{x})$.

- 1 Conjunto de puntos sigma
- 2 Propagación de puntos sigma
- 3 Estimación de media y covarianza

$$\mathcal{Y}_i = g(\mathcal{X}_i), \quad i = 0, \dots, 2L.$$

Transformada Unscented, UT

Dada una v.a. $\mathbf{x} \in \mathbb{R}^L$, con $\mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, \mathbf{P}_x)$, y la v.a. \mathbf{y} dada por $\mathbf{y} = g(\mathbf{x})$.

- 1 Conjunto de puntos sigma
- 2 Propagación de puntos sigma
- 3 **Estimación de media y covarianza**

$$\bar{\mathbf{y}} = \sum_{i=0}^{2L} W_i^{(m)} \mathcal{Y}^{(i)}$$

$$\mathbf{P}_y = \sum_{i=0}^{2L} W_i^{(c)} (\mathcal{Y}^{(i)} - \bar{\mathbf{y}})(\mathcal{Y}^{(i)} - \bar{\mathbf{y}})^T$$

$$\mathbf{P}_{xy} = \sum_{i=0}^{2L} W_i^{(c)} (\mathcal{X}^{(i)} - \bar{\mathbf{x}})(\mathcal{Y}^{(i)} - \bar{\mathbf{y}})^T$$

donde las constantes de peso $W_i^{(m)}$ y $W_i^{(c)}$ están dadas por

$$W_0^{(m)} = \lambda / (L + \lambda), \quad W_0^{(c)} = \lambda / (L + \lambda) + (1 - \alpha^2 + \beta)$$

$$W_i^{(m)} = W_i^{(c)} = 1 / (2(L + \lambda)), \quad i = 1, \dots, 2L$$

EKF vs. UKF

Filtro de Kalman Extendido

- Predicción

$$\hat{\mathbf{x}}_k^- = f(\hat{\mathbf{x}}_{k-1}, \hat{\mathbf{u}}_{k-1})$$

$$\mathbf{P}_k^- = \mathbf{F}_{k-1} \mathbf{P}_{k-1} \mathbf{F}_{k-1}^T + \mathbf{Q}_k$$

- Corrección

$$\hat{\mathbf{z}}_k^- = h(\hat{\mathbf{x}}_k^-)$$

$$\mathbf{R}_k^- = \mathbf{H}_k \mathbf{P}_k^- \mathbf{H}_k^T$$

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}_k^T (\mathbf{R}_k^- + \mathbf{R}_k)^{-1}$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \hat{\mathbf{z}}_k^-)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k^-$$

Filtro de Kalman Unscented

- Predicción

$$\hat{\mathbf{x}}_{k-1}, \mathbf{P}_{k-1} \xrightarrow{\text{UT}[f(\cdot)]} \hat{\mathbf{x}}_k^-, \mathbf{P}_k^-$$

- Corrección

$$\hat{\mathbf{x}}_k^-, \mathbf{P}_k^- \xrightarrow{\text{UT}[h(\cdot)]} \hat{\mathbf{z}}_k^-, \mathbf{R}_k^-$$

$$\mathbf{K}_k = \mathbf{P}_{xz,k} (\mathbf{R}_k + \mathbf{R}_k^-)^{-1}$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \hat{\mathbf{z}}_k^-)$$

$$\mathbf{P}_k = \mathbf{P}_k^- - \mathbf{K}_k (\mathbf{R}_k + \mathbf{R}_k^-) \mathbf{K}_k^T$$

$$\mathbf{F}_k = \left. \frac{\partial f(\mathbf{x}, \mathbf{u})}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}_{k-1}}, \quad \mathbf{H}_k = \left. \frac{\partial h(\mathbf{x})}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}_k^-}$$

EKF vs. UKF

Filtro de Kalman Extendido

- Predicción

$$\hat{\mathbf{x}}_k^- = f(\hat{\mathbf{x}}_{k-1}, \hat{\mathbf{u}}_{k-1})$$

$$\mathbf{P}_k^- = \mathbf{F}_{k-1} \mathbf{P}_{k-1} \mathbf{F}_{k-1}^T + \mathbf{Q}_k$$

- Corrección

$$\hat{\mathbf{z}}^- = h(\hat{\mathbf{x}}_k^-)$$

$$\mathbf{R}_k^- = \mathbf{H}_k \mathbf{P}_k^- \mathbf{H}_k^T$$

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}_k^T (\mathbf{R}_k^- + \mathbf{R}_k)^{-1}$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \hat{\mathbf{z}}_k^-)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k^-$$

$$\mathbf{F}_k = \left. \frac{\partial f(\mathbf{x}, \mathbf{u})}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}_{k-1}}, \quad \mathbf{H}_k = \left. \frac{\partial h(\mathbf{x})}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}_k^-}$$

Filtro de Kalman Unscented

- Predicción

$$\hat{\mathbf{x}}_{k-1}, \mathbf{P}_{k-1} \xrightarrow{\text{UT}[f(\cdot)]} \hat{\mathbf{x}}_k^-, \mathbf{P}_k^-$$

- Corrección

$$\hat{\mathbf{x}}_k^-, \mathbf{P}_k^- \xrightarrow{\text{UT}[h(\cdot)]} \hat{\mathbf{z}}_k^-, \mathbf{R}_k^-$$

$$\mathbf{K}_k = \mathbf{P}_{xz,k} (\mathbf{R}_k + \mathbf{R}_k^-)^{-1}$$

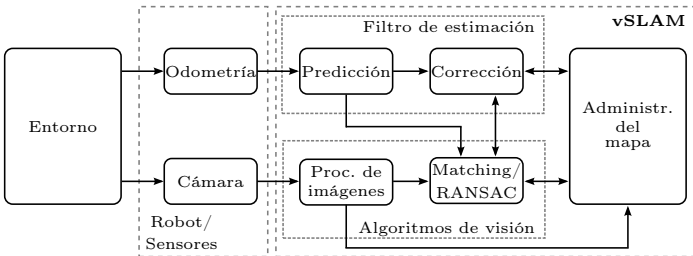
$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \hat{\mathbf{z}}_k^-)$$

$$\mathbf{P}_k = \mathbf{P}_k^- - \mathbf{K}_k (\mathbf{R}_k + \mathbf{R}_k^-) \mathbf{K}_k^T$$

Contenido

- 1 Introducción y objetivos
- 2 Formulación del SLAM con filtro de Kalman (UKF)
- 3 SLAM monocular en robot móvil**
- 4 Resultados de simulación y experimentales
- 5 Conclusiones y trabajos futuros

Esquema general




- Odometría como sensor propioceptivos
- Cámara monocular
 - ▶ Parametrización euclídea de puntos 3D

$$\mathbf{m}_{\text{EU}}^i = [x_i \quad y_i \quad z_i]^T \in \mathbb{R}^3$$

- ▶ Parametrización en profundidad inversa

$$\mathbf{m}_{\text{ID}}^i = [t_i^0 \quad \gamma_i \quad \psi_i \quad \rho_i]^T \in \mathbb{R}^5$$

Esquema general



- Odometría como sensor propioceptivos

- Cámara monocular

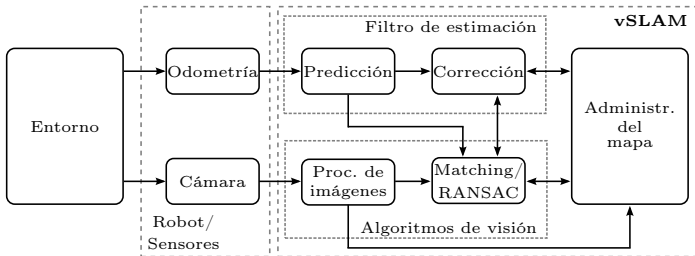
- ▶ Parametrización euclídea de puntos 3D

$$\mathbf{m}_{\text{EU}}^i = [x_i \quad y_i \quad z_i]^T \in \mathbb{R}^3$$

- ▶ Parametrización en profundidad inversa

$$\mathbf{m}_{\text{ID}}^i = [t_i^0 \quad \gamma_i \quad \psi_i \quad \rho_i]^T \in \mathbb{R}^5$$

Esquema general



- Odometría como sensor propioceptivos
- Cámara monocular


- ▶ Parametrización euclídea de puntos 3D

$$\mathbf{m}_{\text{EU}}^i = [x_i \quad y_i \quad z_i]^T \in \mathbb{R}^3$$

- ▶ Parametrización en profundidad inversa

$$\mathbf{m}_{\text{ID}}^i = [t_i^0 \quad \gamma_i \quad \psi_i \quad \rho_i]^T \in \mathbb{R}^5$$

Esquema general



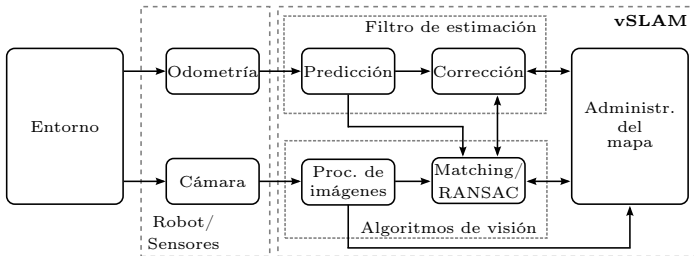
- Odometría como sensor propioceptivos
- Cámara monocular
 - ▶ Parametrización euclídea de puntos 3D

$$\mathbf{m}_{\text{EU}}^i = [x_i \quad y_i \quad z_i]^T \in \mathbb{R}^3$$

- ▶ Parametrización en profundidad inversa

$$\mathbf{m}_{\text{ID}}^i = [t_i^0 \quad \gamma_i \quad \psi_i \quad \rho_i]^T \in \mathbb{R}^5$$

Esquema general




- Odometría como sensor propioceptivos
- Cámara monocular
 - ▶ Parametrización euclídea de puntos 3D

$$\mathbf{m}_{\text{EU}}^i = [x_i \quad y_i \quad z_i]^T \in \mathbb{R}^3$$

- ▶ Parametrización en profundidad inversa

$$\mathbf{m}_{\text{ID}}^i = [\mathbf{t}_i^0 \quad \gamma_i \quad \psi_i \quad \rho_i]^T \in \mathbb{R}^5$$

Modelo de observación



$$\mathbf{d}(\gamma, \psi) = \begin{bmatrix} \cos \gamma \sin \psi \\ -\sin \psi \\ \cos \gamma \cos \psi \end{bmatrix}$$

- Profundidad inversa

$$\mathbf{z} = \mathbf{K}\mathbf{R}_g^c (\rho(\mathbf{t}^0 - \mathbf{t}_c^g) + \mathbf{d}(\gamma, \psi))$$

- Euclídea

$$\mathbf{z} = \mathbf{K}\mathbf{R}_g^c (\mathbf{m}_{\text{EU}} - \mathbf{t}_c^g)$$

$$\mathbf{z} = [u \quad v \quad w]^T \in \mathbb{P}^2 \implies \mathbf{z}_u = [u/w \quad v/w]^T \in \mathbb{R}^2 \implies \mathbf{z}_d.$$

donde








- $\mathbf{d}(\gamma, \psi)$: vector unitario en la dirección del rayo óptico
- $\{\mathbf{t}_c^g, \mathbf{R}_c^g\}$: transformación rígida entre la SCC y SCG
- \mathbf{K} : matriz de parámetros intrínsecos

Contenido

- 1 Introducción y objetivos
- 2 Formulación del SLAM con filtro de Kalman (UKF)
- 3 SLAM monocular en robot móvil
- 4 Resultados de simulación y experimentales**
- 5 Conclusiones y trabajos futuros


Resultados de simulación - EKF vs. UKF

Simulación de odometría




Resultados en simulación - EKF vs. UKF

EKF




UKF




Resultados en simulación - EKF vs. UKF

EKF

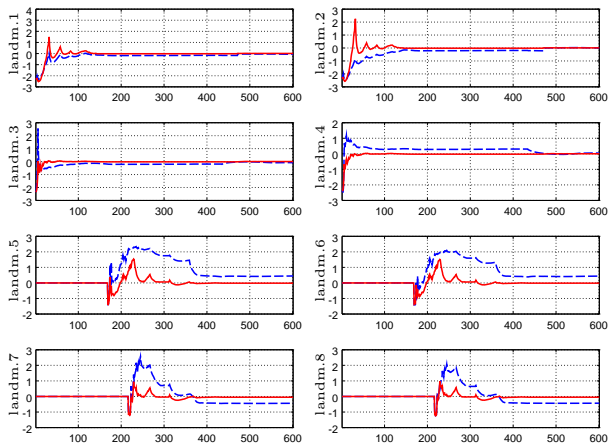


UKF




Resultados en simulación - EKF vs. UKF

Error en la estimación de profundidad de cada landmarks
(EKF - UKF)




Resultados en simulación - EKF vs. UKF


Estimación de la pose del robot
(EKF - UKF)

Resultados experimentales, UKF-SLAM

Robot móvil RoMAA-II





Datos de odometría



Sistema calibrado: \mathbf{K} , $\{t_r^c, \mathbf{R}_r^c\}$.



Resultados experimentales, UKF-SLAM

Estimación de la localización del robot (Odometría - Estimación)







Resultados experimentales, UKF-SLAM

Incertidumbre de landmarks y matriz de correlación final



Resultados experimentales, UKF-SLAM



Contenido

- 1 Introducción y objetivos
- 2 Formulación del SLAM con filtro de Kalman (UKF)
- 3 SLAM monocular en robot móvil
- 4 Resultados de simulación y experimentales
- 5 Conclusiones y trabajos futuros

Conclusiones y trabajos futuros

Conclusiones

- Esquema de SLAM monocular aplicado a un robot móvil, utilizando la información de odometría para ajustar la escala
- Inicialización de landmarks con profundidad inversa y filtro UKF para la estimación
- Los resultados de simulación muestran un mejor comportamiento del filtro UKF comparado con el EKF
- Los resultados experimentales muestra una estimación suficientemente precisa para una correcta asociación de datos

Trabajos futuros

- Evaluación más exhaustiva en caminos de mayor longitud
- Propuesta de esquema de calibración online de los parámetros extrínsecos de la cámara

Conclusiones y trabajos futuros

Conclusiones

- Esquema de SLAM monocular aplicado a un robot móvil, utilizando la información de odometría para ajustar la escala
- Inicialización de landmarks con profundidad inversa y filtro UKF para la estimación
- Los resultados de simulación muestran un mejor comportamiento del filtro UKF comparado con el EKF
- Los resultados experimentales muestra una estimación suficientemente precisa para una correcta asociación de datos

Trabajos futuros

- Evaluación más exhaustiva en caminos de mayor longitud
- Propuesta de esquema de calibración online de los parámetros extrínsecos de la cámara

Conclusiones y trabajos futuros

Conclusiones

- Esquema de SLAM monocular aplicado a un robot móvil, utilizando la información de odometría para ajustar la escala
- Inicialización de landmarks con profundidad inversa y filtro UKF para la estimación
- Los resultados de simulación muestran un mejor comportamiento del filtro UKF comparado con el EKF
- Los resultados experimentales muestra una estimación suficientemente precisa para una correcta asociación de datos

Trabajos futuros

- Evaluación más exhaustiva en caminos de mayor longitud
- Propuesta de esquema de calibración online de los parámetros extrínsecos de la cámara

Conclusiones y trabajos futuros

Conclusiones

- Esquema de SLAM monocular aplicado a un robot móvil, utilizando la información de odometría para ajustar la escala
- Inicialización de landmarks con profundidad inversa y filtro UKF para la estimación
- Los resultados de simulación muestran un mejor comportamiento del filtro UKF comparado con el EKF
- Los resultados experimentales muestra una estimación suficientemente precisa para una correcta asociación de datos

Trabajos futuros

- Evaluación más exhaustiva en caminos de mayor longitud
- Propuesta de esquema de calibración online de los parámetros extrínsecos de la cámara

Conclusiones y trabajos futuros

Conclusiones

- Esquema de SLAM monocular aplicado a un robot móvil, utilizando la información de odometría para ajustar la escala
- Inicialización de landmarks con profundidad inversa y filtro UKF para la estimación
- Los resultados de simulación muestran un mejor comportamiento del filtro UKF comparado con el EKF
- Los resultados experimentales muestra una estimación suficientemente precisa para una correcta asociación de datos

Trabajos futuros

- Evaluación más exhaustiva en caminos de mayor longitud
- Propuesta de esquema de calibración online de los parámetros extrínsecos de la cámara

Conclusiones y trabajos futuros

Conclusiones

- Esquema de SLAM monocular aplicado a un robot móvil, utilizando la información de odometría para ajustar la escala
- Inicialización de landmarks con profundidad inversa y filtro UKF para la estimación
- Los resultados de simulación muestran un mejor comportamiento del filtro UKF comparado con el EKF
- Los resultados experimentales muestra una estimación suficientemente precisa para una correcta asociación de datos

Trabajos futuros

- Evaluación más exhaustiva en caminos de mayor longitud
- Propuesta de esquema de calibración online de los parámetros extrínsecos de la cámara



SLAM Monocular Basado en UKF para la Localización de un Robot Móvil

Gonzalo Perez Paina, Claudio Paz, Martin Baudino, Luis Canali

Centro de Investigación en Informática para la Ingeniería (CIII)
Universidad Tecnológica Nacional, Regional Córdoba

Gonzalo F. Perez Paina
gperez@scdt.frc.utn.edu.ar

Gracias por su atención