

Cálculo de la covarianza de ICP para la localización de un robot diferencial mediante odometría y láser

Pablo De Cristóforis*[†], Thomas Fischer*[†] y Matías Nitsche*

*CONICET-Universidad de Buenos Aires, Instituto de Investigación en Ciencias de la Computación (ICC)

[†]Universidad de Buenos Aires, Facultad de Ciencias Exactas y Naturales, Departamento de Computación

Resumen—En esta trabajo se presenta un método probabilístico para resolver el problema de la localización de un robot diferencial. Se usa el Filtro Extendido de Kalman (EKF) para fusionar la información obtenida por registraciones de mediciones láser mediante ICP (*Iterative Closest Point*) con la información de odometría provista por *encoders*. Para utilizar EKF es necesario estimar la covarianza de cada fuente de información, sin embargo el algoritmo ICP no devuelve la covarianza asociada. En este trabajo se describe una forma de calcular esta covarianza. Los resultados obtenidos muestran que el método de fusión de sensores resulta en una estimación más precisa de la pose del robot en comparación con las estimaciones que se podrían obtener mediante odometría e ICP individualmente.

I. INTRODUCCIÓN

En aplicaciones de robótica móvil resulta indispensable abordar el problema de la localización, es decir, conocer la pose del robot (es decir, su posición y orientación) en el ambiente. Este problema puede ser abordado en forma absoluta o relativa. En los métodos absolutos, se localiza al robot respecto de un sistema de referencia o mapa, utilizando sensores exteroceptivos que permiten medir u observar directamente el entorno en cada instante de tiempo. No obstante, estos métodos dependen de información previa y/o infraestructura específica (como es el caso del Sistema de Posicionamiento Global o GPS), y no suelen ser muy precisos en la navegación a corto plazo.

Por otro lado, los métodos de localización relativa (también conocidos como de *dead-reckoning*) se basan en la idea de estimar la posición actual en forma incremental, a partir de la integración del desplazamiento respecto de la posición anterior. Un ejemplo clásico de *dead-reckoning* ampliamente utilizada en robots terrestres con ruedas es la odometría. Esta técnica consiste en utilizar sensores propioceptivos como los *encoders* que permiten traducir el giro de las ruedas durante un intervalo de tiempo en un desplazamiento lineal y angular del robot. Debido a que esta traducción de movimiento no suele ser precisa cuando se realizan rotaciones, se suelen incorporar otro tipo de sensores para mejorar la localización [1].

Los telémetros láser (o sensores láser) son capaces de medir distancias a los objetos del entorno con una resolución lineal de pocos milímetros. Ante cada sensado, se obtiene una nube de puntos que representa el contorno del ambiente dentro del rango de observación del sensor. A partir de obtener una transformación rígida que relacione una nube con la otra, es posible estimar el desplazamiento del robot durante ese

intervalo de tiempo. El problema de hallar una transformación rígida que describa cómo se alinean correctamente dos escaneos consecutivos es conocido como método de registración (o *scan matching*) [2], [3], [4]. Para realizar esta registración, existen diversos algoritmos. Uno de los más utilizados es *Iterative Closest Point* (o ICP) [5], [6].

El algoritmo ICP es muy utilizado para resolver el problema de la registración por láser. Sin embargo, asume que siempre habrá algún cambio perceptible del entorno, lo cual no es cierto en determinados contextos, por ejemplo un robot moviéndose en línea recta por un pasillo recto y uniforme. Debido a este problema, conocido como *perceptual aliasing*, no alcanza con usar un láser con ICP para obtener un sistema fiable de localización relativa. Para abordar este problema, es posible fusionar la estimación obtenida mediante el algoritmo ICP, con la obtenida con la odometría basada en *encoders*. Esto se pueda hacer utilizando algún tipo de filtro probabilístico, como el Filtro Extendido de Kalman (EKF por sus siglas en inglés) [7], [8], permite integrar sucesivas observaciones a través del tiempo y provee una predicción del estado del robot en todo momento.

Para utilizar correctamente EKF es necesario contar con un modelo de las incertidumbres de cada fuente de información. Éstas se ven reflejadas en la incertidumbre de cada predicción del estado, representada con una matriz de covarianza. El objetivo de este paper es presentar un método de localización probabilístico que fusiona la información obtenida por registraciones de mediciones láser mediante ICP con la información provista por odometría. Para modelar la incertidumbre asociada a las estimaciones obtenidas por el algoritmo ICP, se describe un método para el cálculo de la matriz de covarianza correspondiente.

II. CONCEPTOS PRELIMINARES

En esta sección introduciremos algunos conceptos preliminares como son la odometría basada en *encoders*, la registración de nubes de puntos obtenidas por un sensor y el algoritmo ICP.

II-A. Odometría basada en *encoders*

La odometría basada en *encoders* es una de las técnicas más utilizadas para estimar el movimiento de robots con sistemas de locomoción basados en ruedas. En este trabajo nos focalizamos en el sistema de tracción diferencial. Un vehículo

diferencial posee dos ruedas con motores independientes, situadas a ambos lados del chasis. Aún cuando la mayoría de los robots no respetan estrictamente este modelo, por ejemplo en el caso de los que utilizan cuatro ruedas u orugas, el modelo diferencial resulta en una simplificación aceptable.

Las ecuaciones de movimiento utilizadas en este modelo suponen entonces que los movimientos se realizan a partir del control independiente de dos motores, y que el desplazamiento de las ruedas es directamente traducible al desplazamiento real del robot, aunque esto no siempre es cierto. Por esta razón, se genera un error acumulativo y no acotado.

Usando las ecuaciones clásicas de odometría y asumiendo el modelo diferencial ($v_y = 0$), podemos escribir las velocidades lineales (en cada eje de coordenadas respecto del robot) y angular del robot en un instante de tiempo como el vector $[v_x, v_y, \omega_t]^\top$, que se calcula como:

$$m(d_{izq}, d_{der}) = \begin{bmatrix} v_x \\ v_y \\ \omega \end{bmatrix} = \begin{bmatrix} \frac{d_{izq} + d_{der}}{2} \cdot \frac{1}{\Delta t} \\ 0 \\ \frac{d_{izq} - d_{der}}{b} \cdot \frac{1}{\Delta t} \end{bmatrix} \quad (1)$$

donde b es el *baseline* o la distancia entre ruedas, d_{izq} , d_{der} son las distancias recorridas por cada rueda y se calculan como $d_{izq/der} = \pi 2r \frac{\Delta \alpha_{izq/der}}{c} g$, con r el radio de las ruedas (que se suponen iguales), c la cantidad de pulsos de encoders por cada revolución de la rueda, g la reducción de los motores y $\Delta \alpha_{izq/der}$ los pulsos (o cuentas) de *encoders* sensados en el lapso de tiempo Δt .

Para un movimiento incremental en un intervalo de tiempo, podemos proponer la siguiente matriz de covarianza Σ_d asociada los desplazamientos de cada rueda:

$$\Sigma_d = Cov(d_{izq}, d_{der}) = \begin{bmatrix} k_{der} |d_{der}| & 0 \\ 0 & k_{izq} |d_{izq}| \end{bmatrix} \quad (2)$$

donde k_{izq} , k_{der} son constantes de error que representan parámetros no determinísticos de la transmisión del motor y la interacción de las ruedas con el suelo.

La ecuación anterior se basa en que asumimos que los errores de las ruedas son independientes y que la varianza de los errores de las ruedas izquierda y derecha son proporcionales al valor absoluto de las distancias recorridas. Estas suposiciones, si bien no son perfectas, suelen ser suficientemente buenas. Los valores de las constantes k_{izq} y k_{der} dependen del robot y del entorno, y deben ser establecidas individualmente en cada caso de forma experimental.

Utilizando la aproximación de Taylor de primer orden para la función m (Ec. 1) se puede aproximar la covarianza Σ_m de la siguiente forma:

$$\Sigma_m = \mathbf{M} \cdot \Sigma_d \cdot \mathbf{M}^\top \quad (3)$$

donde \mathbf{M} es el jacobiano de la función m que se puede calcular como:

$$\mathbf{M} = \frac{\partial m(d_{izq}, d_{der})}{\partial (d_{izq}, d_{der})} = \begin{bmatrix} \frac{1}{2\Delta t} & \frac{1}{2\Delta t} \\ 0 & 0 \\ \frac{1}{b\Delta t} & -\frac{1}{b\Delta t} \end{bmatrix}. \quad (4)$$

II-B. Registración de nube de puntos

Una nube de puntos en dos dimensiones puede ser modelada en coordenadas homogénea mediante una matriz $\mathbf{X} \in \mathbb{R}^{3 \times n}$, compuesta de n puntos de la forma: $\mathbf{x}_i = [x_i, y_i, 1]^\top$ en coordenadas homogéneas, con lo cual \mathbf{X} queda definida de la siguiente forma:

$$\mathbf{X} = \begin{bmatrix} x_1 & x_2 & \cdots & x_n \\ y_1 & y_2 & \cdots & y_n \\ 1 & 1 & \cdots & 1 \end{bmatrix}$$

Dos nubes de puntos \mathbf{X} y $\mathbf{X}' \in \mathbb{R}^{3 \times n}$ se encuentran en una registración cuando para cualquier par de puntos $\mathbf{x}_i \in \mathbf{X}$, $\mathbf{x}'_i \in \mathbf{X}'$, los mismos representan el mismo objeto en dos escaneos sucesivos. Es decir que existe una transformación rígida $\mathbf{H} \in \mathbb{R}^{3 \times 3}$ tal que puede alinear todos los puntos de ambas nubes:

$$\forall \mathbf{x}_i \in \mathbf{X}, \forall \mathbf{x}'_i \in \mathbf{X}', \exists \mathbf{H} / \|\mathbf{H}\mathbf{x}_i - \mathbf{x}'_i\| = 0$$

En general, se trabaja con transformaciones que directamente relacionan las dos nubes de la forma $\mathbf{H}\mathbf{X} = \mathbf{X}'$

Si ambas nubes de puntos provienen de mediciones obtenidas en momentos sucesivos por un sensor montado en un robot móvil, podemos estimar el movimiento del robot de la siguiente forma: partiendo de una pose inicial $\mathbf{H}_0 = \mathbf{I}$ (matriz identidad), la pose del robot en tiempo t se calcula:

$$\mathbf{H}_t = \mathbf{H}\mathbf{H}_{t-1} \dots \mathbf{H}_0 \quad (5)$$

donde \mathbf{H} es el movimiento estimado mediante la registración de un par de nubes de puntos entre los instantes t y $t-1$.

II-C. Algoritmo ICP

El algoritmo ICP introducido por Besl y McKay [9]; Chen y Medion [10] permite calcular una registración entre un par de nubes de puntos. La entrada del algoritmo son ambas nubes de puntos, un criterio de parada y, opcionalmente, una estimación inicial de la transformación. La salida del algoritmo es una transformación con un error por debajo de un cierto umbral definido. Esencialmente, los pasos del algoritmo ICP son:

1. Para cada punto de la nube de puntos fuente, buscar el punto más cercano en la nube de puntos de referencia y establecer una correspondencia entre ellos.
2. Calcular la transformación que mejor alinee cada punto de la nube fuente con su correspondiente punto en la nube referencia hallado en el paso anterior.
3. Transformar todos los puntos de la nube fuente mediante la transformación obtenida en el paso anterior.
4. Determinar si la transformación obtenida en el paso anterior es lo suficientemente buena usando como función de costo basada en el error.
5. Si la transformación obtenida es suficientemente buena, terminar, sino iterar (volver al paso 1).

Para establecer correspondencias entre la nube fuente y la nube referencia (paso 1) se suele realizar la búsqueda del k -ésimo vecino más cercano utilizando un árbol k -dimensional [11]. Con los pares de puntos ya apareados se eliminan *outliers* que

podrían ser resultado de errores de medición y se construye una transformación $\mathbf{H} \in \mathbb{R}^{3 \times 3}$ que describe cómo se alinean aproximadamente. Es decir, para $\mathbf{x}_i, \mathbf{x}'_i \in \mathbb{R}^3$, un punto de la nube fuente y un punto de la nube referencia respectivamente, buscamos una transformación lineal \mathbf{H} tal que $\mathbf{H}\mathbf{x}_i \simeq \mathbf{x}'_i$ (paso 2). Para determinar cuán buena es la transformación obtenida se transforman todos los puntos de la nube fuente (paso 3), y se emplea una métrica basada en la sumatoria del error cuadrático medio considerando las distancias entre los puntos \mathbf{x}'_i y los puntos \mathbf{x}_i transformados con la transformación \mathbf{H} (paso 4).

Se pueden distinguir dos métricas de error cuadrático medio: *point-to-point* [9] y *point-to-plane* [10]. La primera mide el error a partir del cálculo de la distancia de un punto a su vecino más cercano:

$$e(\mathbf{R}, \mathbf{t}) = \sum_i \|\mathbf{R}\mathbf{x}_i + \mathbf{t} - \mathbf{x}'_i\|^2$$

donde $\mathbf{R} \in \mathbb{R}^{3 \times 3}$ y $\mathbf{t} \in \mathbb{R}^3$ corresponden a la rotación y traslación asociados a la posición estimada. La segunda métrica consiste en medir la distancia de un punto al plano definido por los vecinos del punto correspondiente en la otra nube:

$$e(\mathbf{R}, \mathbf{t}) = \sum_i \|\mathbf{R}\mathbf{x}_i + \mathbf{t} - \tilde{\mathbf{x}}'_i\|^2$$

donde $\mathbf{R} \in \mathbb{R}^{3 \times 3}$ y $\mathbf{t} \in \mathbb{R}^3$ corresponden a la rotación y traslación asociados a la posición estimada respectivamente, y $\tilde{\mathbf{x}}'_i$ es la proyección de \mathbf{x}_i en el plano correspondiente a \mathbf{x}'_i .

En cualquiera de los dos casos, la transformación \mathbf{H} es considerada como la solución si $e(\mathbf{R}, \mathbf{t}) \leq \tau$, donde $\tau \in \mathbb{R}^3$ es un umbral definido de acuerdo a la fidelidad con la que se requiera la estimación. Lo anterior asegura la convergencia a un mínimo local, partiendo de una estimación inicial, y por lo tanto el algoritmo siempre termina. Si bien *point-to-point* es generalmente más estable, requiere un pre-procesamiento de los datos, perjudicando la performance de la registración, por lo que se recomienda utilizar la métrica *point-to-plane*.

III. CÁLCULO DE LA COVARIANZA DE ICP

Para poder fusionar la información provista por la registración del láser con la de odometría mediante el Filtro Extendido de Kalman (EKF) tenemos que estimar el error producido por cada fuente de información, es decir, calcular una matriz de covarianza correspondiente para cada caso. La covarianza asociada a la odometría se obtiene a partir de la Ecuación (3), con lo cual resta calcular la covarianza correspondiente a ICP.

Para esto existen dos enfoques: el cálculo de la covarianza por muestreo del espacio de resultados y el cálculo por una fórmula cerrada [12], [13]. El primer enfoque consiste en el muestreo de todos los posibles resultados del algoritmo, para así obtener una caracterización de la distribución de probabilidad de los resultados. Este proceso es computacionalmente muy costoso, por lo que resulta impracticable para aplicaciones de robótica de tiempo real.

En contraposición al enfoque basado en muestreo, Bengtsson et al. [13] propone el llamado *Método del Hessiano*.

Este método es rápido de calcular, pero no es suficientemente preciso, por lo que no sirve para resolver el problema de la localización. Por otro lado, Censi [12] propone un método más preciso para calcular la covarianza del algoritmo ICP. Este método consiste en considerar a ICP como un algoritmo de minimización de una función de error $e(\mathbf{H}, \tilde{\mathbf{X}})$ donde \mathbf{H} es la registración de la nube de puntos $\tilde{\mathbf{X}}$ que obtuvimos en el último sensado. La función de error $e(\mathbf{H}, \mathbf{X})$ dependerá de la implementación de ICP que estemos utilizando (*point-to-point* o *point-to-plane*).

Como en el caso considerado en el presente trabajo las nubes de puntos son obtenidas a partir de un telémetro láser, las mediciones vienen dadas en coordenadas polares $\mathbf{x}_i = [\rho_i, \varphi_i]^\top$. Además, como los ángulos φ_i están determinados por la resolución del sensor, la entrada al algoritmo ICP es simplemente el vector de distancias $\tilde{\mathbf{X}} = \{\rho_i\}$.

Podemos pensar al algoritmo ICP de la siguiente forma:

$$\hat{\mathbf{H}} = \text{ICP}(\tilde{\mathbf{X}}) = \arg \min_{\mathbf{H}} e(\mathbf{H}, \tilde{\mathbf{X}})$$

Luego, la aproximación de primer orden a la covarianza de $\hat{\mathbf{H}}$ que representa la covarianza del algoritmo de ICP esta dada por:

$$\Sigma_{\text{ICP}} = \text{Cov}(\hat{\mathbf{H}}) \simeq \frac{\partial \text{ICP}}{\partial \mathbf{X}} \text{Cov}(\mathbf{X}) \frac{\partial \text{ICP}}{\partial \mathbf{X}}^\top \quad (6)$$

Como el algoritmo ICP es iterativo y no conocemos su fórmula cerrada, no se puede calcular explícitamente $\partial \text{ICP} / \partial \mathbf{X}$. Sin embargo, $\text{ICP}(\mathbf{X})$ y \mathbf{X} están relacionadas por una función implícita. De hecho, $\hat{\mathbf{H}}$ es punto crítico de la función de error evaluada en la nube de puntos obtenida del último sensado $\tilde{\mathbf{X}}$ ya que $\partial e(\hat{\mathbf{H}}, \tilde{\mathbf{X}}) / \partial \mathbf{X} = \mathbf{0}^\top$.

Luego, utilizando el teorema de la función implícita obtenemos una expresión para $\partial \text{ICP} / \partial \mathbf{X}$:

$$\left. \frac{\partial \text{ICP}(\mathbf{X})}{\partial \mathbf{X}} \right|_{\mathbf{X}=\tilde{\mathbf{X}}} = - \left(\frac{\partial^2 e}{\partial \mathbf{H}^2} \right)^{-1} \left. \frac{\partial^2 e}{\partial \mathbf{X} \partial \mathbf{H}} \right|_{\mathbf{H}=\text{ICP}(\tilde{\mathbf{X}})}$$

Reemplazando esta última Ecuación en (6), obtenemos:

$$\text{Cov}(\hat{\mathbf{H}}) \simeq \left(\frac{\partial^2 e}{\partial \mathbf{H}^2} \right)^{-1} \frac{\partial^2 e}{\partial \mathbf{H} \partial \mathbf{X}} \text{Cov}(\mathbf{X}) \frac{\partial^2 e}{\partial \mathbf{H} \partial \mathbf{X}}^\top \left(\frac{\partial^2 e}{\partial \mathbf{X}^2} \right)^{-1} \quad (7)$$

Además, por ser $\left(\frac{\partial^2 e}{\partial \mathbf{H}^2} \right)^{-1}$ una matriz simétrica, podemos reescribir la ecuación anterior de la siguiente manera:

$$\text{Cov}(\hat{\mathbf{H}}) \simeq \frac{\partial \text{ICP}}{\partial \mathbf{X}} \text{Cov}(\mathbf{X}) \frac{\partial \text{ICP}}{\partial \mathbf{X}}^\top$$

con

$$\frac{\partial \text{ICP}}{\partial \mathbf{X}} = \left(\frac{\partial^2 e}{\partial \mathbf{H}^2} \right)^{-1} \frac{\partial^2 e}{\partial \mathbf{H} \partial \mathbf{X}}$$

donde $\text{Cov}(\mathbf{X})$ es la matriz de covarianza de las mediciones láser, es decir, la incertidumbre sobre la estimación de la distancia ρ_i en cada dirección que mide el sensor. Es razonable suponerla con desvío constante σ_ρ , por lo tanto $\text{Cov}(\mathbf{X}) = \mathbf{I} \sigma_\rho^2$. Simplificando, podemos reescribir:

$$\Sigma_{\text{ICP}} = \text{Cov}(\hat{\mathbf{H}}) \simeq \sigma_\rho^2 \frac{\partial \text{ICP}}{\partial \mathbf{X}} \frac{\partial \text{ICP}}{\partial \mathbf{X}}^\top \quad (8)$$

La forma cerrada de la covarianza de ICP se puede calcular entonces utilizando la función de error $e(\mathbf{H}, \mathbf{X})$ del paso de minimización de ICP. Por razones de espacio el cálculo de las derivadas $\frac{\partial^2 e}{\partial \mathbf{H}^2}$ y $\frac{\partial^2 e}{\partial \mathbf{H} \partial \mathbf{X}}$ no se transcriben aquí.

IV. LOCALIZACIÓN MEDIANTE FUSIÓN DE SENSORES

El método de localización propuesto se basa en la fusión mediante EKF de la información proveniente por odometría y por la registración laser utilizando el algoritmo ICP. Vamos a considerar el caso de un robot que se mueve sobre un plano en dos dimensiones, por lo tanto podemos definir el vector estado del robot para el instante t como

$$\mathbf{x}_t = [x_t, y_t, \theta_t, v_{x,t}^W, v_{y,t}^W, \omega_t]$$

donde x e y representan la posición del robot, θ la orientación y v_x^W, v_y^W, ω las velocidades lineales y angular, respectivamente (notar la diferencia con v_x, v_y que están respecto del marco de referencia del robot). Todas las coordenadas están dadas respecto del eje de referencia del mundo.

El modelo de proceso a utilizar en el filtro de EKF se basa en un modelo cinemático clásico definido por la siguiente función:

$$f(\mathbf{x}_t, \mathbf{w}) = \mathbf{x}_{t-1} + \Delta t \begin{bmatrix} v_{x,t-1}^W \\ v_{y,t-1}^W \\ \omega_{t-1} \\ 0 \\ 0 \\ 0 \end{bmatrix} + \mathbf{w}$$

donde $\mathbf{w} \sim \mathcal{N}(\mathbf{0}, \mathbf{Q})$.

Notar que este es un modelo general que refleja la cinemática de un robot holonómico sin restricciones y con velocidades constantes. Sin embargo, para este trabajo se consideró el caso de un robot con locomoción diferencial (no holonómico) como se observa en la ecuación (1). El ruido del modelo de movimiento \mathbf{Q} debe ajustarse experimentalmente.

En este trabajo, tanto la odometría basada en *encoders* como la registración por ICP son tomadas en el filtro EKF como mediciones de velocidad lineal y angular del robot (relativas a su marco de referencia), obtenidas a partir del desplazamiento relativo sentido en el último intervalo de tiempo:

$$\mathbf{z} = [v_x, v_y, \omega]^T + \mathbf{v}$$

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

A su vez, para utilizar EKF para la fusión de sensores, debemos definir el modelo de observación $h(\mathbf{x}_t)$ que relaciona las mediciones con el vector de estado. Para ello, basta con llevar las velocidades expresadas en el marco del mundo (W) al marco de referencia del robot:

$$h \left(\begin{bmatrix} x \\ y \\ \theta \\ v_x^W \\ v_y^W \\ \omega \end{bmatrix} \right) = \begin{bmatrix} v_x \\ v_y \\ \omega \end{bmatrix} = \begin{bmatrix} v_x^W \cos(\theta) - v_y^W \sin(\theta) \\ v_x^W \sin(\theta) + v_y^W \cos(\theta) \\ \omega \end{bmatrix}$$

Para finalizar, en el caso en el que la observación corresponde a una medición obtenida mediante odometría, \mathbf{R} se define según la ecuación (3), mientras que si corresponde a una observación obtenida mediante ICP, \mathbf{R} se define según la ecuación (8). Estas incertezas modelan el ruido propio de los sensores (*encoders* y sensor laser) y determinan el impacto de observar sus mediciones al estimar el desplazamiento relativo del robot en cada caso (odometría e ICP).

V. RESULTADOS

Se utilizaron *datasets* disponibles públicamente que son parte del proyecto Rawseeds [14]. Este repositorio de datos fue generado a partir de diversos recorridos de un robot móvil Robocom de locomoción diferencial tanto en entornos interiores como exteriores. Los *datasets* de Rawseeds cuenta con información de la pose real del robot en todo momento (*ground-truth*), obtenida a partir del uso de un sistema de localización externo compuesto por cámaras que observan al robot en todo momento, en el caso del ambiente interior, o de un GPS de alta precisión, para exteriores.

De los sensores láser disponibles en los *datasets* se optó por utilizar el sensor de mayor alcance (LMS291) con el objetivo de contar con la mayor información posible ante cada muestreo, es decir, se buscó evaluar el desempeño del método de localización en condiciones favorables de sensado. Entre las características principales se puede mencionar: frecuencia de muestreo: 75 Hz, distancia máxima de sensado: 80 m, campo de visión: 180°, resolución angular: 0,25°, error aproximado a máxima distancia: 10 mm.

Se realizaron experimentos para analizar la covarianza estimada para ICP con el método propuesto, calcular el error de posición y orientación de un robot móvil en una trayectoria y comparar el resultado de la generación de mapas de nubes de puntos. Sobre los conjuntos de datos analizados, por cuestiones de espacio se muestran a continuación sólo los resultados obtenidos para el recorrido 27b de Rawseeds generado dentro de un edificio de la Università di Milano-Bicocca, en Milán.

V-A. Análisis de la covarianza estimada para ICP

A continuación se puede observar la covarianza estimada para ICP en dos áreas de interés dentro recorrido 27b de Rawseeds. Para analizar los resultados, mostramos las elipses correspondientes a las covarianzas de dos casos típicos de registración láser mediante ICP: una curva (A), un pasillo con algunos objetos (B) (ver Figura 1). Para poder visualizar los datos de covarianza de ICP, se utilizaron elipses que representan un intervalo de confianza del 95% para una distribución Gaussiana bivariada.

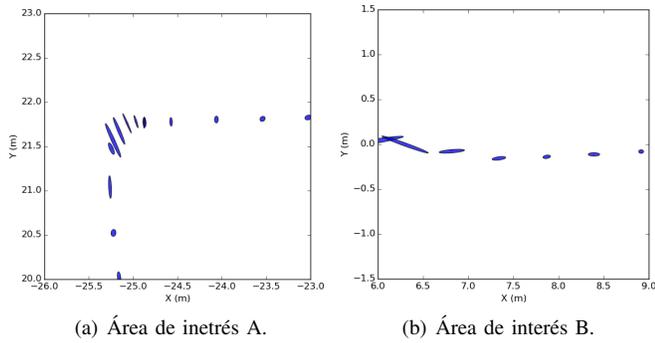


Figura 2. Análisis de la covarianza estimada para ICP mediante elipses que representan un intervalo de confianza del 95% para una distribución Gaussiana bivariada. Dos áreas de interés en el recorrido: (a) en una curva y (b) en un pasillo recto con objetos.

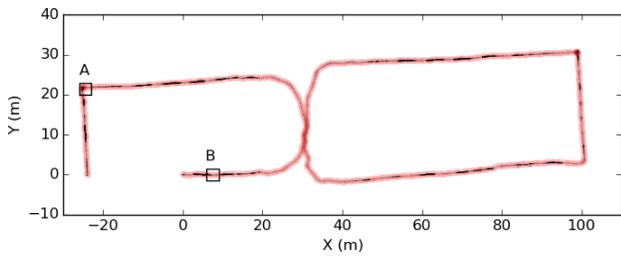


Figura 1. Recorrido completo, marcando dos áreas de interés: A y B.

En la Figura 2(a) se puede observar como aumenta el tamaño y cambia la orientación de la elipse a medida que el robot efectúa un giro en la curva y luego vuelve a reducirse el tamaño cuando el láser percibe las paredes del pasillo nuevamente. Estas variaciones indican cambios en la certeza de la información de pose obtenida mediante ICP. En la Figura 2(b) puede evaluarse el caso del pasillo con objetos. Se puede observar como la elipse disminuye su tamaño indicando menor covarianza, es decir, mayor certeza sobre la información proporcionada por ICP cuando nos aproximamos a los objetos y se agranda en el sentido del pasillo cuando no tenemos otras referencias más que las paredes laterales del pasillo.

V-B. Análisis del error de posición y orientación

En la Figura 3 podemos observar la comparación del método de localización propuesto (fusión de sensores mediante EKF con covarianza estimada para ICP) respecto de utilizar sólo odometría o sólo ICP y medir el error en el cálculo de la posición en cada momento de la trayectoria respecto de la trayectoria real (*ground-truth*). Se puede apreciar que el recorrido del robot calculado por el método de localización propuesto se aproxima más a la trayectoria real que el recorrido calculado sólo por odometría o sólo por el algoritmo de ICP.

En la Figura 4, se muestra el error absoluto de posición y orientación respecto del *ground-truth* según cada uno de los tres métodos analizados: fusión mediante EKF entre odometría e ICP con covarianza calculada según se presenta en este trabajo, sólo ICP, y sólo odometría. Se puede apreciar cómo el error producido al fusionar la información provista por ICP

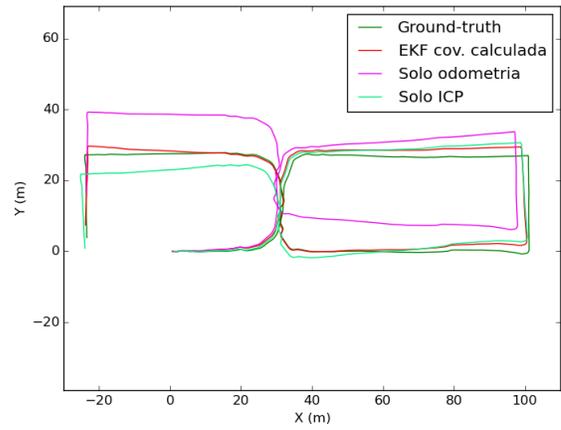
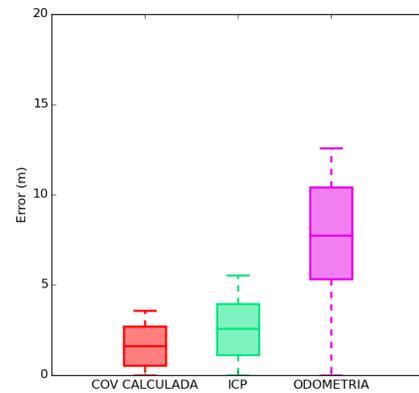
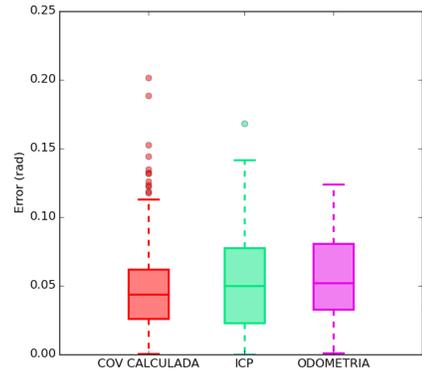


Figura 3. Comparación de la trayectoria estimadas para el recorrido 27b del dataset RAWSEEDS.



(a) Diagrama de caja del error absoluto de posición.



(b) Diagrama de caja del error absoluto de orientación.

Figura 4. Análisis de Error absoluto de posición y orientación de la trayectoria.

utilizando la estimación de la covarianza es menor que en los otros dos métodos evaluados.

V-C. Análisis del mapa generado por las nubes de puntos

Si bien no es el foco del trabajo, el método propuesto permite generar un mapa del entorno recorrido a partir de



(a) Mapa generado mediante odometría basada en *encoders*.



(b) Mapa generado mediante ICP (*Iterative Closest Point*).



(c) Mapa generado mediante fusión por EKF de odometría e ICP utilizando covarianzas estimadas para ICP según el método propuesto.

Figura 5. Comparación de mapas generados para diferentes variantes del método de localización.

acumular periódicamente las nubes de puntos correspondientes a cada sensado. Estos mapas fueron construidos utilizando como origen la posición y orientación del láser según las diferentes variantes del método de localización. El resultado también puede compararse con el plano del entorno de la Figura 5.

En la Figura 5(a) se ve como los errores en la estimación de la pose calculada por odometría basada *encoders* produce una deformación considerable en el mapa generado. Esto se debe principalmente al error producido por el cálculo de la rotación utilizando odometría. En la Figura 5(b) se ve un mejor resultado al construir el mapa utilizando la pose obtenida por ICP. En este caso, las esquinas del mapa fueron mejor reproducidas, ya que la rotación fue mejor estimada. De todas formas, vemos un desfase en el mapa producto de los errores en el cálculo de la traslación del robot. Por último, si analizamos la Figura 5(c) se puede apreciar que el resultado de la reconstrucción utilizando la fusión de sensores mediante EKF y la covarianza calculada por el método propuesto es más

fiel que la reconstrucción utilizando sólo ICP o sólo odometría. Esto se debe a que EKF es capaz de combinar mejor la información, si las incertidumbres modeladas se corresponden con la distribución de los errores en la realidad.

VI. CONCLUSIONES

En el presente trabajo se presenta un método probabilístico de localización utilizando como fuentes de información la odometría por *encoders* y las mediciones provenientes de un telémetro láser registradas mediante el algoritmo ICP. Los datos de las distintas fuentes de localización son fusionados mediante un Filtro Extendido de Kalman. Esto es posible gracias a poder modelar la covarianza para el resultado de la registración de las nubes de puntos mediante ICP. De esta forma se mejoró el resultado respecto de utilizar sólo ICP o sólo odometría para calcular la pose del robot. La mejora en precisión se puede observar analizando las métricas de error absoluto de posición y orientación respecto de la información de *ground-truth* provista por los datasets utilizados, así como también en los mapas del ambiente construidos a partir de conocer la pose del robot.

REFERENCIAS

- [1] J. Borenstein, H. R. Everett, L. Feng, and D. Wehe, "Mobile robot positioning-sensors and techniques," DTIC Document, Tech. Rep., 1997.
- [2] J.-S. Gutmann and C. Schlegel, "Amos: Comparison of scan matching approaches for self-localization in indoor environments," in *Advanced Mobile Robot, 1996., Proceedings of the First Euromicro Workshop on*. IEEE, 1996, pp. 61–67.
- [3] F. Lu and E. Milios, "Robot pose estimation in unknown environments by matching 2d range scans," *Journal of Intelligent and Robotic Systems*, vol. 18, no. 3, pp. 249–275, 1997.
- [4] S. Se, D. Lowe, and J. Little, "Mobile robot localization and mapping with uncertainty using scale-invariant visual landmarks," *The international Journal of robotics Research*, vol. 21, no. 8, p. 735, 2002.
- [5] Y. Chen and G. Medioni, "Object modeling by registration of multiple range images," in *Robotics and Automation, 1991. Proceedings., 1991 IEEE International Conference on*. IEEE, 1991, pp. 2724–2729.
- [6] P. Besl and N. D. McKay, "A method for registration of 3-d shapes," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 14, no. 2, pp. 239–256, Feb 1992.
- [7] Z. Trajanoski and P. Wach, "Fuzzy filter for state estimation of a gluco-regulatory system," *Computer methods and programs in biomedicine*, vol. 50, no. 3, pp. 265–273, 1996.
- [8] R. E. Kalman, "A new approach to linear filtering and prediction problems," *Transactions of the ASME-Journal of Basic Engineering*, vol. 82, no. Series D, pp. 35–45, 1960.
- [9] P. J. Besl and N. D. McKay, "A method for registration of 3-d shapes," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 14, no. 2, pp. 239–256, Feb. 1992.
- [10] Y. Chen and G. Medioni, "Object modelling by registration of multiple range images," *Image Vision Comput.*, vol. 10, no. 3, pp. 145–155, Apr. 1992.
- [11] M. Greenspan and M. Yurick, "Approximate k-d tree search for efficient icp," in *3-D Digital Imaging and Modeling, 2003. 3DIM 2003. Proceedings. Fourth International Conference on*, Oct 2003, pp. 442–448.
- [12] A. Censi, "An accurate closed-form estimate of icp's covariance," in *Proceedings 2007 IEEE International Conference on Robotics and Automation*. IEEE, 2007, pp. 3167–3172.
- [13] O. Bengtsson and A.-J. Baerfeldt, "Robot localization based on scan-matching—estimating the covariance matrix for the {IDC} algorithm," *Robotics and Autonomous Systems*, vol. 44, no. 1, pp. 29 – 40, 2003, best Papers of the Eurobot '01 Workshop.
- [14] S. Ceriani, G. Fontana, A. Giusti, D. Marzorati, M. Matteucci, D. Migliore, D. Rizzi, D. G. Sorrenti, and P. Taddei, "Rawseeds ground truth collection systems for indoor self-localization and mapping," *Autonomous Robots*, vol. 27, no. 4, pp. 353–371, 2009.