

# Covarianza dinámica en un sistema odométrico real para la mejora de la localización con sensores a bordo.

Jonay Toledo  
(jttoledo@ull.es)

Bibiana Fariña, Leopoldo Acosta  
(bfarinaj@ull.edu.es, lacosta@ull.es)

## Resumen

*En este artículo se presenta una estrategia de fusión sensorial para mejorar el sistema de localización de una silla de ruedas inteligente. Para conseguir una buena localización, la fusión de la información proporcionada por varios sensores es necesaria, en este caso telémetro laser, unidad de medida inercial y sistema odométrico. Los datos de cada sensor deben estar caracterizados por su covarianza. La estrategia clásica consiste en la asignación de una covarianza estática para el sensor odométrico, sin embargo con una covarianza dinámica, que realmente caracterice al sensor en tiempo real, se puede mejorar el resultado final. En este artículo se compara el resultado de la covarianza estática, frente a una calculada dinámicamente utilizando otro sensor externo. También se compara un modelo de fusión sensorial basado en velocidad constante, frente a otro modelo donde se especifica la odometría como sistema de evolución interno en el filtro de Kalman*

**Palabras clave:** Robotica móvil, localización, Filtro de Kalman, Odometría

## 1. Introduccion

El sensor más importante con el que cuenta un robot móvil para su localización es el sistema odométrico. Este normalmente consiste en un encoder óptico incremental acoplado a cada uno de los ejes motores del robot [15]. Es un sensor preciso, económico y sencillo de interpretar y procesar, sin embargo su principal limitación es que la posición se calcula incrementalmente, con lo que los pequeños errores que se van generando en la estimación del movimiento de las ruedas, se van acumulando y terminan generando un error muy grande.

Para compensar este comportamiento en aplicaciones reales, se suele utilizar un conjunto de sensores diferentes, para así a través de un algoritmo de fusión sensorial, conseguir una localización lo más precisa posible. Cada sensor tiene sus puntos fuertes y sus puntos débiles, y solo la combinación

de estos, puede llevar a un módulo de localización preciso en circunstancias variables.

Una de las técnicas de fusión sensorial más empleadas son los filtros de Kalman [11], [7] y sus variantes. La idea tras los filtros es utilizar un estimador estadístico, que a través de la información de múltiples sensores, obtenga una posición más precisa que el mejor de los sensores por separado. En concreto, para sistemas no lineales se utiliza un filtro extendido de Kalman, que linealiza el sistema no lineal a través de una serie de Taylor, para poder calcular la covarianza de la posición final. Uno de los pasos clave en el filtro es caracterizar la precisión de cada uno de los sensores a través de su covarianza instantánea. De esta manera el filtro solo tiene que tomar en cuenta esta covarianza a la hora de pesar la importancia final de cada medida.

En este artículo se presenta un sistema de localización para una silla de ruedas inteligente. La silla se muestra en la Figura 1, junto al conjunto de sensores que se utilizan para la localización. La silla ha sido diseñada para transportar a personas con un grado severo de discapacidad, permitiendo el movimiento autónomo de estos usuarios, que de otra forma no tendrían la posibilidad de moverse sin la ayuda de otra persona. La silla de ruedas es controlada por el usuario indicando el destino final, mientras que el sistema de navegación y localización, decidirán y ejecutarán la ruta óptima para llevar a la silla a su destino final. Los sensores permiten reconstruir el entorno y detectar obstáculos [2] para conseguir una navegación autónoma segura. El sistema de localización es una pieza clave para el éxito del movimiento de la silla, ya que un fallo en la localización provocaría un fallo en el resto de subsistemas con los que cuenta la silla.

La silla de ruedas cuenta con el siguiente conjunto de sensores:

- Odometría: La odometría consiste en el sentido del movimiento de las ruedas del robot a través de encoders ópticos acoplados a los ejes de giro de los motores. En el caso del prototipo, la resolución del encoder es de 8.800 pulsos por vuelta con una resolución de 0.04 grados. Con un diametro de rueda promedio

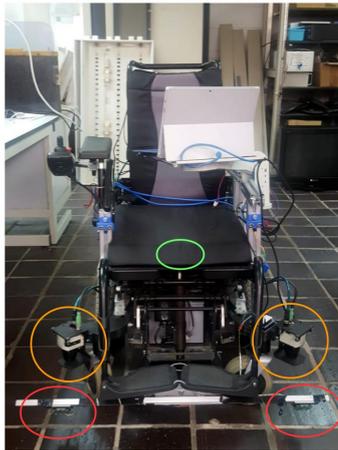


Figura 1: La silla de ruedas inteligente con el conjunto de sensores, incluyendo el telémetro láser, la odometría y los sensores doppler.

de 0,32 metros, obtenemos una resolución de movimiento de 0.1 milímetros. A través del movimiento de la rueda, y conocido el radio y distancia entre las mismas, se puede estimar la posición global de la silla.

- **Telémetro láser:** El telémetro láser permite capturar un perímetro de medida, indicando la distancia más cercana a cada punto. Concretamente se trata de dos sensores Sick TiM 551, con una distancia máxima de 10 metros, una resolución angular de 1 grado y un ángulo de visión de 270 grados. Utilizando dos barridos láser consecutivos, se puede calcular el movimiento relativo del robot.
- **Unidad de medida inercial (IMU):** Se utiliza un sensor MPU9250, que consiste en un acelerómetro, un magnetómetro y un giroscopio, integrados en el mismo circuito. Nuestras pruebas indican que el magnetómetro es demasiado impreciso para considerar sus medidas, además de que es muy difícil estimar el ruido de medida de este sensor. Se utilizará solo el giroscopio, concretamente el que mide el eje de giro  $z$  para integrarlo en el sistema de medida.

Los sensores que se utilizan en la silla de ruedas inteligente se pueden ver en la Figura 1. Los telémetros láser, marcados en un círculo naranja a través del algoritmo ICP (Iterative Closest Point) [13] estiman la precisión de la medida a través de una covarianza dinámica. Si dos barridos consecutivos coinciden de manera precisa en su forma, y estos barridos tienen muchos puntos singulares que permiten asegurar su coincidencia con precisión, el algoritmo nos devolverá un valor de covarianza

baja, lo que indica un error bajo. Sin embargo si dos barridos son diferentes, o tienen pocos puntos singulares para encontrar su similitud, la covarianza será alta. Esto puede ocurrir cuando se navega por un pasillo, donde los telémetros solo obtienen 2 líneas paralelas, impidiendo poder calcular el desplazamiento de un barrido al siguiente. Las dos medidas paralelas serán iguales con el robot parado, que avanzando a máxima velocidad.

El giroscopio incluido en la IMU marcado con verde en la Figura 1 es bastante preciso, siendo la medida afectada principalmente por ruido blanco electrónico. En este caso se puede estimar la covarianza del sensor fijando un valor estático que indique la varianza estimada de la medida. De esta manera se representa los posibles errores, y se podrá utilizar este sensor de acuerdo a la precisión de los otros sensores disponibles en un algoritmo de fusión sensorial.

El sensor odométrico es la base del sistema de localización, sin embargo estimar su precisión plantea múltiples problemas. El sistema solo sensa el movimiento de las ruedas, sin embargo, si estas están deslizándose o se está produciendo algún otro tipo de error, esto debería quedar reflejado en la covarianza. El sistema clásico utiliza un valor de covarianza estática, como medida promedio de la precisión de la odometría. Sin embargo, esto puede sobreestimar el efecto de la odometría en el algoritmo de fusión sensorial cuando hay un error, por ejemplo un derrape, y subestimarla cuando funciona correctamente. De esta manera es interesante poder conocer dinámicamente la precisión del sensor, y pesar sus medidas para obtener una precisión final mayor. Para este propósito, se ha añadido un nuevo sensor al sistema, reflejado en la figura 1 en un círculo rojo. Se trata de un sensor de efecto doppler, que se utilizará para comparar su resultado frente al de la odometría, y de esta manera, ajustar la covarianza cuando los dos sensores difieran. Si el resultado del sensor doppler es similar a el de la odometría, podemos asumir que tenemos un buen comportamiento y la covarianza será baja. Sin embargo si ambos sensores difieren, la covarianza será alta indicando que la medida no es del todo fiable.

Utilizando esta estrategia en un algoritmo de fusión sensorial, se puede mejorar sensiblemente el comportamiento final del sistema de localización, obteniendo un sistema más preciso. Este artículo se centrará en describir el sistema de localización utilizando estas técnicas.

El artículo está organizado de la siguiente manera: en la sección 2 se describe el estado del arte, en la sección 3 se describe el modelo del sistema de fusión sensorial, con el sistema lineal y el modelo

real, en la sección 3 se presentan los resultados obtenidos y en la sección 5 las conclusiones.

## 2. Estado del Arte

El sistema de localización de un robot móvil esta basado en la fusión sensorial de múltiples sensores, de esta manera se aprovechan las fortalezas de cada uno de ellos y se limitan sus debilidades. Uno de los algoritmos más utilizados son los filtros de Kalman donde la información que proporciona cada sensor es pesada en función a su covarianza [8] [1]. La fusión de la información produce un resultado mejor que cada sensor individual. La covarianza de cada sensor depende en las propias características de este, y muchas veces simplemente se fija a un valor fijo prefijado a mano [14].

La covarianza es la manera natural de caracterizar la precisión de un sensor, por lo que una covarianza estática prefijada no va a representar con la suficiente fiabilidad el comportamiento del sensor. El uso de una covarianza dinámica, que presente en tiempo real la precisión del sensor en cada instante puede mejorar sensiblemente el resultado final de la fusión sensorial, ya que el filtro tomará en cuenta el estado real del sensor en cada instante. Esto se encuentra en la bibliografía, como en [3] donde multiples sensores son integrados utilizando un filtro de Kalman y un esquema basado en covarianza dinámica. En [12] un sistema de asistencia a la conducción es diseñado utilizando múltiples sensores caracterizados por una covarianza dinámica.

Las sillas de ruedas inteligentes, son un caso concreto de robot autónomo y existe una amplia bibliografía sobre ellas. La principal característica de una silla de ruedas inteligente es que prima la seguridad. Han sido diseñadas para transportar a personas con un alto grado de vulnerabilidad con lo que cada movimiento debe ser comodo y seguro. En [5] se presenta una descripción de diferentes prototipos de sillas de ruedas inteligentes incluyendo una descripción de la tecnología y sus interfaces persona computador. En [10] se presenta una revisión de 2017 sobre los distintos proyectos de sillas de ruedas inteligentes. El sistema sensorial utilizado mayoritariamente consiste en la odometría, telémetros laser, IMU y cámaras para visión por computador, fusionando esta información para obtener una localización lo más precisa posible.

Trabajos previos utilizan diferentes técnicas para la fusión de la información sensorial y así mejorar la precisión de la localización en tiempo real. En el caso de sillas de ruedas inteligentes, una localización precisa es el primer paso para una navegación segura y cómoda para los usuarios. En

este artículo, se presenta una implementación de un sistema de fusión sensorial basado en el cálculo dinámico de la covarianza, lo que permite mejorar la precisión de la localización final, en comparación con el esquema clásico de covarianza estática prefijada. De esta manera se puede utilizar una covarianza pre-calculada para afrontar los errores sistemáticos, y aumentar la covarianza cuando se detecten los errores no sistemáticos y de esta manera restar importancia a la odometría durante la fusión de otros sensores, ganando en importancia el telémetro láser o la IMU.

## 3. Sistema de localización

La covarianza es un parámetro clave y debe ser especificada para cada sensor. En el caso presentado en este artículo, el telémetro láser, a través del algoritmo de localización, proporciona una covarianza dinámica, en función de la calidad de la relación entre 2 barridos consecutivos. La covarianza de la IMU, concretamente del giroscopio, está marcada por el ruido blanco electrónico, con lo que una covarianza estática representa de manera fiable su comportamiento. Sin embargo, la odometría puede tener un comportamiento muy variable, donde una covarianza estática puede representar correctamente su comportamiento en el caso de que no existan errores no sistemáticos [1]. Sin embargo cuando ocurre un error sistemático, debe aumentarse la covarianza. Al no tener una forma de medir los errores sistemáticos, se suele utilizar una covarianza estática de un valor superior al comportamiento ideal, para tratar de compensar ambos errores, sin embargo esta solución subestima el sensor en comportamiento ideal y lo sobre estima cuando hay errores sistemáticos. Un error no sistemático ocurre por ejemplo cuando el prototipo derrapa, con lo que el sistema odométrico detectará un movimiento que no se traduce en un movimiento real del prototipo.

$$\begin{aligned}
 L_k^l &= \frac{2*\pi*r_l*count_k^l}{encRes}; & L_k^r &= \frac{2*\pi*r_r*count_k^r}{encRes} \\
 \Delta\theta_k &= \frac{(L_k^l - L_k^r)}{WheelDisp} \\
 \Delta d_k &= \frac{(L_k^l + L_k^r)}{2} \\
 \theta_{k+1} &= \theta_k + \Delta\theta_k \\
 X_{k+1} &= X_k + \Delta d_k \cos(\theta_{k+1}) \\
 Y_{k+1} &= Y_k + \Delta d_k \sin(\theta_{k+1})
 \end{aligned}
 \tag{1}$$

Las ecuaciones que gobiernan la odometría se muestran en la ecuacion 1, donde  $L_k^l$  and  $L_k^r$  son el desplazamientos de la rueda izquierda y derecha de cada una de las ruedas,  $r_l$  y  $r_r$  son los radios de la rueda izquierda y derecha, y  $count_k^l$  y  $count_k^r$  las cuentas del encoder acoplado a cada una de las ruedas de la silla de ruedas.  $encRes$  es la resolu-

ción del encoder. La variación del ángulo  $\Delta\theta_k$  se calcula en base al desplazamiento de cada una de las ruedas y la separación entre ruedas *Wheeldisp*. A partir del ángulo y del incremento de desplazamiento global  $\Delta d_k$  se calcula la posición final del prototipo  $(X, Y, \theta)$ .

$$\begin{aligned} x_{k+1} &= f(x_k, u_k, w_k) \\ z_k &= h(x_k, v_k) \end{aligned} \tag{2}$$

El módulo de localización recibe la información del sensor y las covarianzas de los sensores, y produce como salidas la estimación de la posición. El filtro extendido de Kalman combina la información y un modelo del sistema con el objetivo de estimar la posición en tiempo real. La ecuación 2 presenta el modelo del sistema [9] donde  $x_{k+1}$  es el estado que se pretende estimar,  $z_k$  son las medidas de los sensores.  $f()$  es el modelo del sistema,  $u_k$  es la entrada,  $w_k$  es el ruido de sistema,  $h()$  es el modelo de observación de las medidas que dependen del ruido de medida  $v_k$ .

En desarrollos previamente publicados por nuestro grupo [6] el modelo se basaba en un modelo 2D de movimiento omnidireccional. Este modelo se basa en la suposición que la velocidad no cambia en un periodo de tiempo. Todos los sensores son integrados, incluyendo la odometría, como medidas externas y simplemente se calcula en el modelo el cambio de posición de una iteración a la siguiente. Este modelo se refleja en la ecuación 3 donde simplemente se implementa un modelo lineal de mantenimiento de la velocidad y actualización de la posición en función de la velocidad anterior.

$$\begin{aligned} x_{k+1} &= Ax_k + w_k; \\ \begin{bmatrix} X_{k+1} \\ Y_{k+1} \\ \theta_{k+1} \\ \dot{X}_{k+1} \\ \dot{Y}_{k+1} \\ \dot{\theta}_{k+1} \end{bmatrix} &= \begin{bmatrix} 1 & 0 & 0 & T & 0 & 0 \\ 0 & 1 & 0 & 0 & T & 0 \\ 0 & 0 & 1 & 0 & 0 & T \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} X_k \\ Y_k \\ \theta_k \\ \dot{X}_k \\ \dot{Y}_k \\ \dot{\theta}_k \end{bmatrix} + w_k \end{aligned} \tag{3}$$

En este artículo se va a cambiar la estructura del filtro de Kalman, integrando la odometría como entrada a un modelo no lineal del sistema a seguir, y eliminándola como medida. De esta manera, se consigue un mejor seguimiento del modelo que con un sistema de velocidad constante. El filtro extendido de Kalman estima el estado del robot en tiempo real utilizando un sistema no lineal, por este motivo, el filtro linealiza el modelo alrededor de la media y covarianza actual utilizando un desarrollo en serie de Taylor. Se realiza calculando la matriz de Jacobianos de los modelos de transición y observación, por lo que el modelo

debe ser diferenciable.

$$\begin{aligned} \tilde{x}_{k+1} &= Ax_k \\ P_{k+1} &= A_k P_k A_k^T + R_k \\ K_{k+1} &= P_k H_k^T [H_k P_k H_k^T + Q_k]^{-1} \\ \tilde{x}_{k+1}(+) &= \tilde{x}_k + K_k [z_k - H_k \tilde{x}_k] \\ P_{k+1}(+) &= [I - K_k H_k] P_k \end{aligned} \tag{4}$$

La ecuación 4 presenta el filtro de Kalman implementado, donde  $R_k$  es la covarianza del modelo, que indica la fiabilidad que le damos modelo marcado por el ruido  $w_k$  de la ecuación 2.  $Q_k$  es la covarianza de cada una de las medidas, en este caso la medida del telémetro láser y de la IMU. Esta covarianza puede ser estática o dinámica, en función del comportamiento del propio sensor. El filtro de kalman proporciona una estimación de la localización  $\tilde{x}_{k+1}(+)$  además de una covarianza de esta medida combinada  $P_{k+1}(+)$ , que siempre será mejor que la covarianza de cada sensor individual. La ecuación 5 muestra la matriz A para el modelo descrito en la ecuación 1.

$$A = \begin{bmatrix} 1 & 0 & A_{13} & A_{14} & A_{15} \\ 0 & 1 & A_{23} & A_{24} & A_{25} \\ 0 & 0 & 1 & 0 & A_{35} \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

$$\begin{aligned} A_{13} &= -v \sin(\theta + w/2)T & A_{24} &= \sin(\theta + w/2)T \\ A_{14} &= \cos(\theta + w/2)T & A_{25} &= \frac{1}{2}v \cos(\theta + w/2)T \\ A_{15} &= -\frac{1}{2}v \sin(\theta + w/2)T & A_{35} &= T \\ A_{23} &= V \cos(\theta + w/2)T \end{aligned} \tag{5}$$

El algoritmo se divide en los mismos pasos que el filtro de Kalman lineal, con dos etapas predicción y corrección. La ecuación 4 es válida para los dos sistemas, con el único cambio que la matriz A cambia por la de la ecuación 5.

### 3.1. Covarianza dinámica con un sensor de efecto Doppler

Una manera de mejorar la localización final, es mejorar la información proporcionada por el sensor de odometría añadiendo un segundo sensor para estimar la calidad de su información, en este caso un sistema radar de efecto Doppler.

La bibliografía presenta distintos artículos sobre el uso de sensores radar en la localización. En [4] se aplica un algoritmo de scan matching a un radar de onda continua, comparando 2 barridos consecutivos. En [17] se presenta un algoritmo de scan matching basado en ICP sobre la información de un radar, o en [16] donde la información Doppler

de varias zonas de reflexión es utilizada para obtener la propia velocidad de movimiento del sistema.

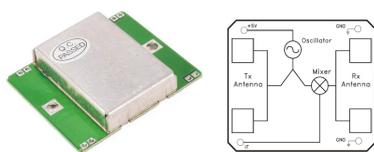


Figura 2: Sensor Doppler de bajo coste HB-100 con su esquema interno.

En este artículo se utiliza un radar Doppler de bajo coste para medir la velocidad de la silla de ruedas de manera alternativa a como lo hace la odometría. Si la velocidad de movimiento capturada por el sensor de efecto Doppler es distinta a la que nos proporciona la odometría, se aumentará la covarianza de la odometría indicando la posibilidad de encontrarnos frente a un error no sistemático en la odometría. El radar doppler es un modelo HB-100 figura 2. El modulo consiste en un oscilador dieléctrico, un mezclador de microondas y una antena. Es un radar de baja potencia con una frecuencia de emisión de 10.525 Ghz.

$$f_d = \left( \frac{c \pm v_r}{c \pm v_s} \right) f_0 \cos(\theta) \quad (6)$$

El efecto doppler es el cambio de frecuencia que se produce cuando se recibe una onda proveniente de un sistema en movimiento. La ecuación 6 representa el efecto Doppler donde  $f_d$  es la frecuencia de salida doppler,  $v_r$  es la velocidad del receptor,  $v_s$  es la velocidad de la fuente,  $c$  es la velocidad de la onda y  $f_0$  es la frecuencia de la onda emitida y  $\theta$  el ángulo de incidencia de la señal. En el caso de un sensor Doppler colocado en un robot, la velocidad de la fuente y la del receptor se suman duplicando la frecuencia doppler de salida esperada.

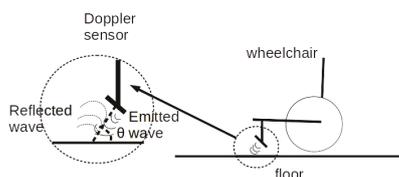


Figura 3: Esquema de funcionamiento del sensor Doppler.

La figura 3 muestra la posición del sensor doppler, instalado en cada lado de la silla de ruedas marcado en color rojo en la figura 1. Hay que tener en cuenta, que la frecuencia de salida doppler, es proporcional al ángulo de ataque del sensor doppler contra el suelo. En este caso se utiliza un ángulo de 45 grados para maximizar la potencia de la señal capturada con desplazamiento de frecuencia.

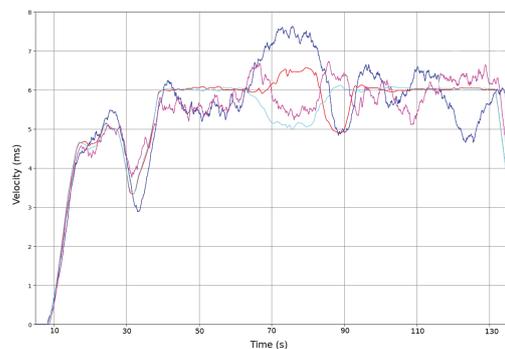


Figura 4: Velocidad de cada rueda calculada usando sensores doppler (rojo y rosa) y sensores odométricos (azul).

Se realizan una serie de pruebas para medir la calidad de la información generada por el sensor Doppler. El desplazamiento Doppler recibido es convertido a velocidad de avance utilizando la ecuación 6 e integrando la velocidad se obtiene el desplazamiento y se compara con la salida que proporciona la odometría. La figura 4 muestra la velocidad generada por el sensor Doppler y el sensor odométrico. El trazo rojo y rosa es la señal Doppler mientras que el azul claro y oscuro la señal de la odometría. Como vemos en la figura, el resultado de ambos sensores es similar, aunque el sensor Doppler es un poco más ruidoso.

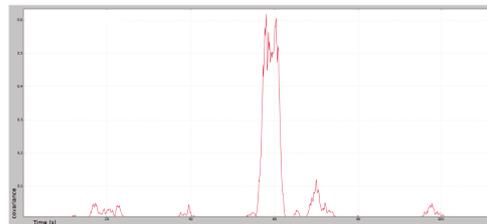


Figura 5: Covarianza dinámica como diferencia del sensor odométrico y el sensor Doppler, con un derrape en  $t=60s$ .

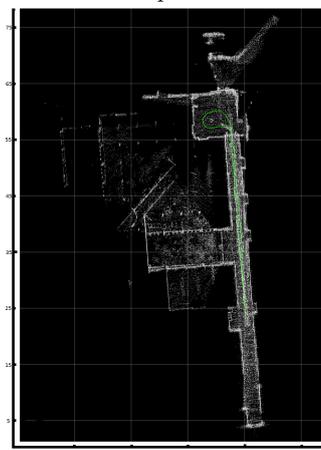
Si se comparan los resultado de velocidad proporcionados por el sensor odométrico y el sensor de efecto Doppler, su diferencia se puede utilizar como una medida de la calidad del resultado odométrico. El sensor Doppler no es lo suficiente fiable como para generar una fuente de datos por si sola, sin embargo es un buen detector de errores no sistemáticos. Si la silla de ruedas derrapa, el sensor doppler indicará una velocidad de movimiento baja, mientras que el sistema odométrico dará una velocidad alta. La diferencia utilizando una ventana de integración de los datos de 500 ms se puede utilizar como medida de la covarianza del sensor odométrico. En la figura 5 tenemos un ejemplo del error entre los dos sensores, donde en  $t=60$  segundos se produce un derrape del prototi-

po, el sensor odométrico deja de dar datos fiables. Al comparar el resultado de cada sensor se puede detectar el fallo de la odometría. Si se utiliza esta diferencia como odometría dinámica, esto permite estimar en tiempo real la precisión del sensor odométrico.

#### 4. Resultados



(a) El pasillo donde han sido realizadas las pruebas.

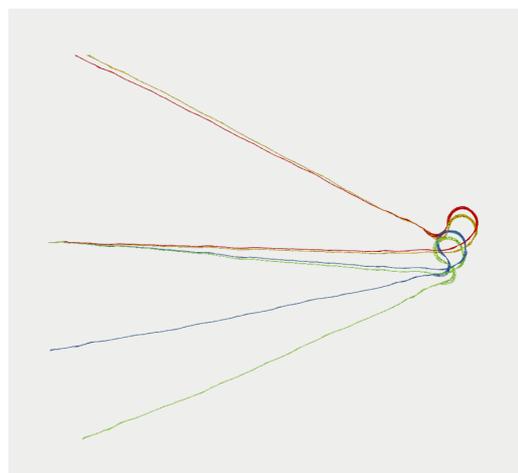


(b) Mapa del área de pruebas.

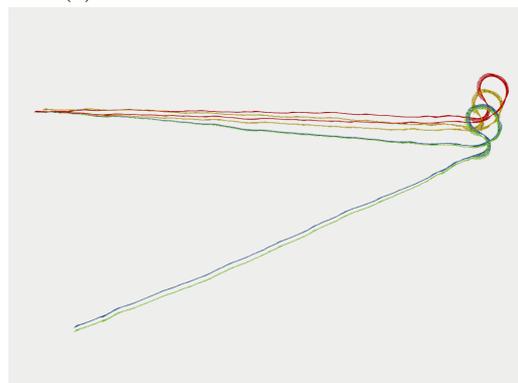
Figura 6: El escenario de las pruebas es un pasillo largo, con una zona de giro situada al final

Las pruebas han sido realizadas en un pasillo largo con una zona de giro al final del pasillo. En la figura 6 a podemos apreciar la estructura del pasillo con la silla de ruedas utilizada. En la figura 6 b podemos ver una reconstrucción de un plano de la zona, con la maniobra realizada marcada en verde. El plano ha sido realizado utilizando un sensor Velodyne HDL32, y el algoritmo LOAM para la reconstrucción 3D del entorno utilizando este sensor [18]. El Velodyne se utiliza solo para obtener un recorrido preciso de la zona y no como sensor para la localización.

En la figura 7 y 8 se muestra un ejemplo de funcionamiento de localización en el entorno descrito. En la figura 7a y 8a se representa la aplicación de un modelo de filtro de Kalman lineal de velocidad constante, mientras que que la figura 7b y 8b se aplica el modelo completo de la odometría como se indica en la sección 4. En estas figuras la traza



(a) Modelo lineal velocidad constante.

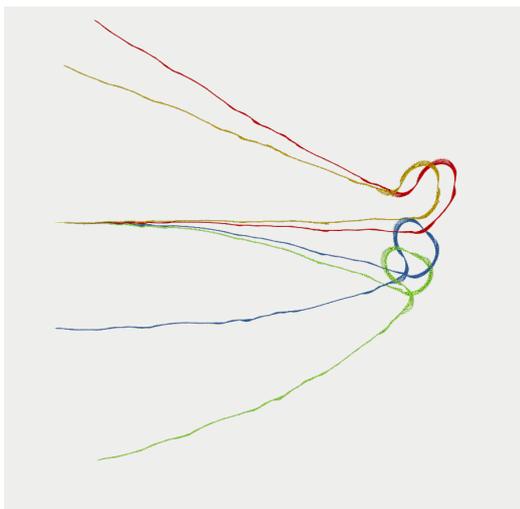


(b) Modelo no lineal real.

Figura 7: Experimento realizado con la silla de ruedas para a modelo lineal sencillo y b modelo no lineal real.

verde representa el sensor odométrico únicamente, la traza azul la combinación de IMU, telémetro láser y odometría donde se da mayor peso a la odometría, la amarilla la combinación de sensores donde se da mayor peso al láser y la roja la fusión sensorial con covarianza dinámica calculada a partir del sensor de efecto doppler. El experimento comienza por un pasillo largo, esta zona es complicada para el láser ya que no tiene suficientes puntos singulares para realizar un correcto ICP, solo ve 2 líneas paralelas que no le permiten calcular el avance. Después se llega a la zona de giro, que es una zona de suelo deslizante, donde las ruedas tienden a derrapar, y se vuelve al punto de inicio por el mismo pasillo.

La traza verde, que representa la odometría, es la misma en ambas pruebas, donde se comprueba que el desplazamiento es correcto, pero que el derrape en el giro hace que la orientación falle y la posición final sea mala. La traza azul representa un sistema donde se ha pesado de más la información que proviene de la odometría en la combinación



(a) Modelo lineal velocidad constante.



(b) Modelo no lineal real.

Figura 8: Segundo experimento realizado.

sensorial, se puede ver que su comportamiento se parece mucho a el de la odometría. La traza amarilla representa un experimento donde se ha pesado más el láser, se comprueba que la posición final no es la correcta, ya que a pesar que la orientación es satisfactoria, la posición final de la silla queda un par de metros retrasada, debido a la pérdida de distancia del sensor láser al recorrer el pasillo. La traza roja representa la fusión sensorial utilizando la covarianzaq dinámica del doppler, se puede ver que funciona correctamente en el modelo real, mientras que el lineal, que no tiene en cuenta la dinámica del modelo no consigue corregir lo suficiente.

Como se puede apreciar, en el mismo experimento, los resultados son mejores con un modelo no lineal en el filtro de Kalman. Y dentro de la posible combinación de sensores, la covarianza dinámica es la que presenta un mejor resultado.

## 5. Conclusiones

En este artículo se presenta una comparativa de métodos de fusión sensorial basadas en la odometría como sensor principal. Se presentan 2 formas de afrontar el filtro de Kalman, como sistema lineal de velocidad constante, o a través de un modelo real del sistema. Utilizando estos modelos se prueba un sistema de fusión sensorial para la odometría, telémetro láser y IMU para tratar de obtener la localización más precisa.

Para mejorar la localización de la odometría se ha añadido un segundo sensor para medir la calidad de la información odométrica. Este sensor consiste en un radar de efecto Doppler que comparando la información de velocidad que proporciona con la de la odometría se puede utilizar para calcular una covarianza dinámica que caracterice el sensor.

Se han realizado pruebas con distintas combinaciones, obteniendo como mejor resultado el sistema de reconstrucción con el modelo real y covarianza dinámica en el sensor odométrico. Consiguiendo una reconstrucción muy cercana a la real.

## 6. Agradecimientos

Los autores agradecen la contribucion del Ministerio de Ciencia y Tecnología a través del proyecto SIRTAPE DPI2017-90002-R.

## English summary

### Dinamic covariance in an actual odometric system with on board sensors.

#### Abstract

*In this paper a sensor fusion strategy is presented in order to improve the localization system of an intelligent wheelchair. The sensors used in the sensorial fusion are a Lidar, an odometric system and a IMU. Each sensor data is characterized by its covariance. The classic approach set a static covariance for the odometric system, however with a dynamic covariance wich characterize the sensor real time better results can be obtained. In this paper static covariance is compared to dynamic one using an external sensor. The Kalman model is also compared between a lineal continuous velocity model and a real odometric model.*

**Keywords:** Mobile robotics, Localization, Kalman Filter, Odometry

## Referencias

- [1] Mary B. Alatise and Gerhard P. Hancke. Pose estimation of a mobile robot based on fusion of imu data and vision data using an extended kalman filter. *Sensors*, 17(10), 2017.
- [2] R. Arnay, J. Hernández-Aceituno, J. Toledo, and L. Acosta. Laser and optical flow fusion for a non-intrusive obstacle detection system on an intelligent wheelchair. *IEEE Sensors Journal*, 18(9):3799–3805, May 2018.
- [3] C. Barrios, Y. Motai, and D. Huston. Intelligent forecasting using dead reckoning with dynamic errors. *IEEE Transactions on Industrial Informatics*, 12(6):2217–2227, Dec 2016.
- [4] S. H. Cen and P. Newman. Precise ego-motion estimation with millimeter-wave radar under diverse and challenging conditions. In *2018 IEEE International Conference on Robotics and Automation (ICRA)*, pages 1–8, May 2018.
- [5] Brígida Mónica Faria, Luís Paulo Reis, and Nuno Lau. A survey on intelligent wheelchair prototypes and simulators. In Álvaro Rocha, Ana Maria Correia, Felix . B Tan, and Karl . A Stroetmann, editors, *New Perspectives in Information Systems and Technologies, Volume 1*, pages 545–557, Cham, 2014. Springer International Publishing.
- [6] Bibiana Fariña, Jonay Toledo, Jose Ignacio Estevez, and Leopoldo Acosta. Improving robot localization using doppler-based variable sensor covariance calculation. *Sensors*, 20(8), 2020.
- [7] Tiantian Huang, Hui Jiang, Zhuoyang Zou, Lingyun Ye, and Kaichen Song. An integrated adaptive kalman filter for high-speed uavs. *Applied Sciences*, 9(9), 2019.
- [8] Vladimír Kubelka, Lorenz Oswald, François Pomerleau, Francis Colas, Tomáš Svoboda, and Michal Reinstein. Robust data fusion of multimodal sensory information for mobile robots. *Journal of Field Robotics*, 32(4):447–473, 2015.
- [9] T. D. Larsen, K. L. Hansen, N. A. Andersen, and Ole Ravn. Design of kalman filters for mobile robots; evaluation of the kinematic and odometric approach. In *Proceedings of the 1999 IEEE International Conference on Control Applications (Cat. No.99CH36328)*, volume 2, pages 1021–1026 vol. 2, Aug 1999.
- [10] J. Leaman and H. M. La. A comprehensive review of smart wheelchairs: Past, present, and future. *IEEE Transactions on Human-Machine Systems*, 47(4):486–499, Aug 2017.
- [11] Q. Li, R. Li, K. Ji, and W. Dai. Kalman filter and its application. In *2015 8th International Conference on Intelligent Networks and Intelligent Systems (ICINIS)*, pages 74–77, Nov 2015.
- [12] M. Michaelis, P. Berthold, D. Meissner, and H. Wuensche. Heterogeneous multi-sensor fusion for extended objects in automotive scenarios using gaussian processes and a gmphd-filter. In *2017 Sensor Data Fusion: Trends, Solutions, Applications (SDF)*, pages 1–6, Oct 2017.
- [13] E. B. Olson. Real-time correlative scan matching. In *2009 IEEE International Conference on Robotics and Automation*, pages 4387–4393, May 2009.
- [14] Pradeep Ravikumar, Martin J. Wainwright, Garvesh Raskutti, and Bin Yu. High-dimensional covariance estimation by minimizing l1 -penalized log-determinant divergence. *Electron. J. Statist.*, 5:935–980, 2011.
- [15] Jonay Toledo, Jose D. Piñeiro, Rafael Arnay, Daniel Acosta, and Leopoldo Acosta. Improving odometric accuracy for an autonomous electric cart. *Sensors*, 18(1), 2018.
- [16] Damien Vivet, Paul Checchin, and Roland Chapuis. Localization and mapping using only a rotating fmcw radar sensor. *Sensors*, 13(4):4527–4552, 2013.
- [17] E. Ward and J. Folkesson. Vehicle localization with low cost radar sensors. In *2016 IEEE Intelligent Vehicles Symposium (IV)*, pages 864–870, June 2016.
- [18] Ji Zhang and Sanjiv Singh. Loam: Lidar odometry and mapping in real-time. In *Robotics: Science and Systems*, 2014.



© 2022 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC 4.0 license (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).