

Método de asociación de datos basado en curvas B-Spline para el problema de SLAM en ambientes complejos

Alfredo Toriz Palacios¹, Abraham Sánchez López²

¹ Universidad Popular Autónoma del Estado de Puebla,
México

² Benemérita Universidad Autónoma de Puebla,
México

alfredo.toriz@upaep.mx, asanchez@cs.buap.mx

Resumen. En este documento se presenta una nueva propuesta para dar solución al problema de asociación de datos para SLAM destinado a la construcción de mapas de ambientes complejos. La idea principal de la que parte la propuesta, es la de utilizar curvas B-Splines como medio para describir obstáculos con geometrías complejas presentes en el área de trabajo y utilizar la información contenida en ellas para encontrar puntos característicos del ambiente que puedan ser asociados. La utilización de esta información para realizar una asociación más exacta es una de las principales contribuciones de este documento, ya que esta tiene un impacto directo sobre la localización del robot y en consecuencia en la calidad del mapa final. El problema es abordado inicialmente comparando los puntos de control que forman tanto las curvas que representan los obstáculos observados en un instante determinado, como las que representan los obstáculos almacenados en el mapa que se está construyendo, relacionando aquellos que se encuentran suficientemente cerca. A continuación, la curvatura de las B-Splines relacionadas es obtenida para extraer puntos característicos (Puntos de inflexión y esquinas) contenidos en las curvas. Finalmente, la información coincidente será utilizada para corregir la posición del robot y la de los obstáculos detectados. Numerosos experimentos han sido llevados a cabo usando información real y simulada, con la finalidad de validar los procesos y algoritmos propuestos en nuestro enfoque. Nuestro método, logra una gran precisión en la construcción de mapas de ambientes complejos, lo cual es casi imposible para las técnicas que existen actualmente.

Palabras clave. SLAM, asociación de datos, curvas B-Spline.

B-Splines Based Data Association Method for the SLAM Problem in Complex Environments

Abstract. This paper presents a new proposal to solve the problem of data association for SLAM used to build maps of complex environments. The main idea of this proposal is to use B-spline curves as a way to describe obstacles with complex geometries found in the environment and use the information contained in them to find characteristic points that may be associated. The use of this information for a more accurate association process is one of the major contributions of this work, because a robust association has a direct impact on the localization of the robot and thus the quality of the final map. The data association problem was initially addressed by comparing the control points that form both the curves representing the obstacles observed at a given time, and those that represent the obstacles stored in the map being constructed, relating those that are close enough. Then, the curvature of the related B-spline is obtained to extract characteristic points (inflection points and corners) contained in the curves. Finally, the matching information will be used to correct the position of the robot and the detected obstacles. We carried out numerous experiments by using real and simulated information in order to validate the processes and algorithms proposed in our approach. Our method achieves a great precision in map construction of complex environments, which is nearly impossible with techniques that currently exist.

Keywords. SLAM, data association, B-Spline curves.

1. Introducción

Uno de los retos fundamentales de la robótica de hoy, es el de obtener mecanismos robustos y eficientes para modelar ambientes de creciente complejidad usando robots móviles para su exploración. Este, es conocido como el problema de localización y mapeo simultaneo (SLAM), el cual básicamente trata de la necesidad de construir un modelo del entorno (el mapa) y estimar al mismo tiempo la ubicación del robot, utilizando únicamente observaciones relativas a las características más relevantes detectadas en el ambiente por sus sensores [18].

Muchos enfoques han tratado con este problema sin éxito, ya que la mayoría de estos métodos, intentan extraer características geométricas y representar sus posiciones en el mapa [6, 9, 12, 22], o discretizar el espacio en células [2, 7, 17] y clasificar cada una como ocupada o vacía, lo que restringe su campo de aplicación a ambientes con geometrías bien definidas o de dimensiones limitadas.

En consecuencia, nuevos métodos han surgido en la literatura que tratan de lidiar con el problema de SLAM para ambientes complejos [14,15,19], siendo uno de los más recientes el presentado por Pedraza et al en [19], en donde los autores proponen la utilización de curvas B-Spline como herramienta para la descripción de obstáculos con geometrías complejas; sin embargo, esta nueva forma de representación presenta en sí mismo un nuevo reto, en donde la dificultad radica en identificar características de ambiente semejantes, de forma que estas puedan ser utilizadas para corregir los errores odométricos del robot al momento de construir el mapa. Así, aunque el enfoque presentado por Pedraza en [19] resuelve el problema de la representación de obstáculos en entornos no estructurados, su aproximación utiliza un método de asociación de datos simple, que consiste en proyectar los rayos del sensor laser desde los objetos observados en la posición odométrica estimada, hasta los obstáculos localizados contenidos en el mapa, sin importar si estos puntos son realmente coincidentes, lo que puede ocasionar inconsistencias en el mapa creado dado que cualquier asociación falsa podría invalidar el proceso entero de SLAM.

De lo anterior, la asociación de datos es sin duda el aspecto más crítico del algoritmo de construcción de mapas de ambiente y considerado por algunos el problema más difícil en esta área de la robótica [18], ya que la correcta asociación entre características censadas durante una observación y las características del mapa son esenciales para una construcción exacta del mapa.

Así, el proceso de asociación de datos ha recibido gran atención en la literatura de la robótica en recientes años [1, 3, 8, 13, 14], y muchas soluciones han sido propuestas; sin embargo, la mayoría de estas están limitadas a características simples como líneas y puntos (impidiendo su uso en ambientes complejos), geometrías simples, o a curvas simples donde los algoritmos de asociación son muy rudimentarios. Aunque estas técnicas son apropiadas y permiten en algunos casos realizar un SLAM completo, aún es necesario desarrollar e implementar nuevas estrategias que puedan ser aplicables a casos más generales sin geometrías específicas.

De lo anterior, en este documento presentamos una nueva propuesta para la asociación de datos en SLAM, destinado a la construcción de mapas de ambientes complejos basado en curvas B-Spline para la representación de los obstáculos del mapa. Nuestro enfoque propone una mejora de los actuales métodos de asociación de datos, el cual explota completamente la información contenida en la descripción paramétrica de geometrías arbitrarias. De esta forma, con la validación y creación de un modelado avanzado de mapas de entorno en forma de curvas B-Spline, las propiedades de esta representación (curvaturas, longitud de las curvas, puntos de inflexión) son usadas para obtener un método de asociación de datos robusto aplicable a cualquier situación.

2. El enfoque de SLAM basado en curvas B-Spline

La solución al problema SLAM es considerada por muchos como un requisito clave para dotar de verdadera autonomía a los robots móviles [13, 18]; sin embargo, aunque este problema ha sido objeto de importantes investigaciones en la última década, aún surgen importantes barreras que han

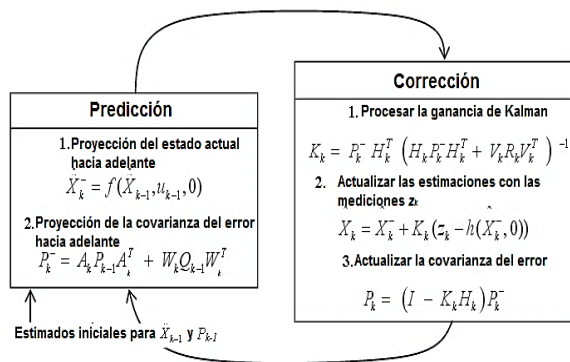


Fig. 1. Panorama completo de la operación del Filtro de Kalman Extendido

impedido que el problema tenga una solución completa, entre las que podemos mencionar las que tienen que ver con el modelado geométrico de entornos arbitrariamente complejos.

De lo anterior, Pedraza et al. Proponen en [19] un algoritmo de SLAM basado en curvas Spline como herramienta de representación del entorno. El objetivo de utilizar esta forma de representación, es el de contar con un mecanismo efectivo en el complejo problema de obtener un modelo del entorno que pueda describir el ambiente de trabajo con la mayor exactitud posible, sin hacer suposiciones ni simplificaciones peligrosas. La principal diferencia entre este enfoque y los algoritmos tradicionales de SLAM basados en características, es que no se confía en una geometría específica.

En su trabajo, los autores desarrollan técnicas y metodologías para adaptar esta novedosa forma de modelado del ambiente, en la segmentación y asociación de datos para posteriormente ser utilizados en el contexto del problema de SLAM a través de la aproximación clásica del Filtro de Kalman Extendido (EKF), mostrado en la figura 1. Las herramientas desarrolladas son descritas en esta sección.

a) Segmentación y ajuste de datos

El enfoque desarrollado por Pedraza parte del uso de un sensor laser para la adquisición de los datos del ambiente que proporciona para cada observación un conjunto de m puntos de datos en el espacio R^2 ligados entre sí por la única lógica que proporciona el sensor al hacer su barrido.

Para que esta información pueda ser utilizada por el método EKF de SLAM, inicialmente se deben segmentar los conjuntos de mediciones que representan los objetos físicos detectados.

La metodología presentada por Pedraza se basa en el análisis de las posiciones relativas de cada dos puntos consecutivos de datos láser, de los cuales se obtiene un conjunto inicial de $m-1$ vectores que conectan entre sí dos puntos de datos consecutivos obtenidos por el láser:

$$p_i = d_i - d_{i-1}. \quad (1)$$

A continuación dos comparaciones son realizadas con la intención de obtener los vectores finales de puntos que representen a los objetos en el mapa. La primera, en busca de elementos lo suficientemente cercanos como para pertenecer al mismo elemento del ambiente (Ecuación 2):

$$\max(\|p_i\|, \|p_{i+1}\|) \leq \eta \cdot \min(\|p_i\|, \|p_{i+1}\|). \quad (2)$$

Y una segunda comparación, en busca de un ángulo α_i formado por dos vectores p_i y p_{i+1} (ecuación 3) para determinar si los puntos que forman los vectores están lo suficientemente alineados como para ser considerados pertenecientes al mismo objeto:

$$|\alpha_i| \leq \alpha_{\max} \Leftrightarrow \cos(\alpha_i) \geq \cos(\alpha_{\max}). \quad (3)$$

Los autores establecen para $\eta \in [1.5, 2]$ y para $\alpha_{\max} \in [0, \pi/4]$ como valores adecuados. El proceso completo puede verse en la figura 2.

Es necesario mencionar que en esta última comparación, los autores optaron por considerar a ángulos α_i demasiado cerrados (esquinas) como un criterio de separación de características presentes en el mapa y no como un elemento distinguible del ambiente, ya que lo consideran trivial.

Finalmente, cada uno de los obstáculos obtenidos mediante el proceso de segmentación son ajustados a curvas B-Splines de grado 3 utilizando la ecuación 4 [4]:

$$D_k = C(t_k) = \sum_{i=0}^n N_{i,p}(t_k) X_i \quad \text{for } 0 \leq k \leq m. \quad (4)$$




Fig. 2. Criterio de segmentación de datos brutos provenientes del sensor láser. Imagen adaptada de [19]




Fig.3. Concordancia entre las curvas. a) Asociación burda. b) Asociación fina

b) Asociación de datos

Una a vez que los datos han sido segmentados, el siguiente paso consiste en establecer una correspondencia entre cada uno de los m segmentos obtenidos en el instante k , y una (o ninguna) de las n características contenidas en el mapa que está siendo construido (Figura 3).

Así, el primer paso consiste en realizar una asociación denominada “burda” (Figura 3a), donde cada uno de los puntos de control de cada segmento de curva se comparan con los puntos de control de las características almacenadas en el mapa, usando el siguiente criterio:

$$\min(\text{dist}(X_{m,i}, X_{o,j})) \leq d_{\min} \quad \begin{cases} i = 1 \dots n_m \\ j = 1 \dots n_o \end{cases} \quad (5)$$

Así, si la distancia entre los puntos de control de la *Spline* en el mapa y los puntos de control de la *Spline* observada es mayor a cierto umbral d_{\min} , la asociación de elementos es descartada; en caso contrario, estos dos objetos son asociados y un nuevo paso de correspondencia es realizado como sigue (Figura 3b):

- Uno de los extremos de la curva observada se considera como el punto a , el punto más cercano al punto a en la *B-Spline* contenida en el mapa se considera como el punto b . Si b es uno de los extremos de la *B-Spline* en el mapa, entonces el punto más cercano a b en la *B-Spline* observada se calcula y se nombra como c , si no, el punto a se asocia con el punto b .
- El proceso se repite usando el otro extremo de la *B-Spline* observada como punto de inicio (punto d en la Figura 3b). Este punto se asocia con el punto e de la *B-Spline* en el mapa. Gracias a la propiedad de las *B-Splines* acerca de la posibilidad de conocer la longitud de la curva, los segmentos eb y dc pueden ajustarse para tener la misma longitud.

Finalmente, el uso del EKF en SLAM requiere una expresión matemática que permita utilizar la asociación de datos en el contexto de la localización para predecir las mediciones que se espera obtener del sensor dado la pose del robot y el conocimiento actual del ambiente en un instante k . Así, el modelo de observación presentado por Pedraza et al. Para el caso de las curvas *B-Splines* se reduce a encontrar la intersección de la línea recta que forma cada rayo del láser con las curvas contenidas en el mapa y las curvas observadas por el robot (Figura 4).

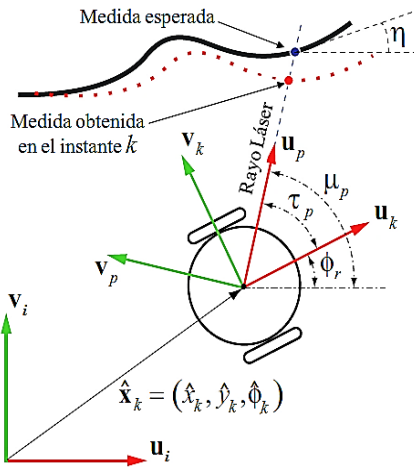


Fig. 4. Modelo de observación. Adaptado de [19]

Es importante mencionar, que este modelo de observación representa una forma riesgosa de trabajar en el método de localización, dado que las medidas esperadas no necesariamente coincidirán con las medidas observadas en el mapa, lo que puede provocar una localización incorrecta y por lo tanto un mapa de ambiente deficiente.

3. Nuestro aporte

Como se ha mencionado, uno de los aspectos crítico en el problema de SLAM es la correcta asociación de datos entre las características almacenadas en el mapa que está siendo construido, y los estados subyacentes que se están observando. Para el caso de [19], aunque la forma de modelado de los obstáculos es innovadora ya que el problema de SLAM puede extenderse a cualquier tipo de ambiente de trabajo sin importar su estructura, la forma en que los autores abordan la asociación de datos puede traer consigo problemas de inconsistencia en los mapas, lo que ha motivado el desarrollo de este trabajo de investigación.

Así, aunque esta investigación toma como base la forma de representación de ambientes basada en curvas B-Spline presentada por Pedraza et. al., se desarrolla una nueva forma de tratamiento y asociación de datos que opera de

forma coherente y robusta en el contexto del SLAM tomando ventaja de la información contenida en las curvas.

3.1. Administración de datos

De forma similar al método presentado en la sección 2, cuando el robot obtiene un nuevo conjunto de mediciones a través de su sistema de percepción, el primer objetivo es identificar claramente los objetos asociados con las mediciones y agruparlas en subconjuntos, para finalmente obtener las curvas B-spline que representan las porciones de los objetos detectados tan cerca como sea posible.

La segmentación de los datos brutos es realizada con el método de cluster adaptivo propuesto por Dietmayer [5], el cual permite dividir las mediciones obtenidas por el láser, usando únicamente un criterio de distancias entre dos puntos. Para explicar su funcionamiento se utiliza la figura 5, donde P_a y P_b representan dos puntos consecutivos detectados por el láser, y r_a y r_b son las distancias de estos puntos al origen de la coordenada. Dado el triángulo $O P_a P_b$, donde r_a y r_b son conocidos y α es la resolución angular del láser, podemos aplicar el teorema de cosenos para calcular la distancia entre P_a y P_b :

$$r_{ab} = \sqrt{r_a^2 + r_b^2 - 2r_a r_b \cos(\alpha)}. \quad (6)$$

Si la distancia r_{ab} cumple con:

$$r_{ab} \leq C_o + C_1 \min\{r_a - r_b\}, \quad (7)$$

donde C_o representa el ajuste del ruido del sensor laser y $C_1 = \sqrt{2(1 - \cos(\alpha))}$, entonces los puntos P_a y P_b formarán parte del mismo segmento de datos.

A diferencia del proceso presentado en la sección 2a, el método de Dietmayer permite mantener información relevante como esquinas y puntos de inflexión en los segmentos obtenidos, mismos que serán utilizados por el método de asociación de datos.

Una vez que los clusters son obtenidos (Figura 6 y 7), las mediciones correspondientes a cada




Fig. 5. Criterio de Dietmayer [5]




Fig. 6. Mediciones obtenidas con un sensor laser

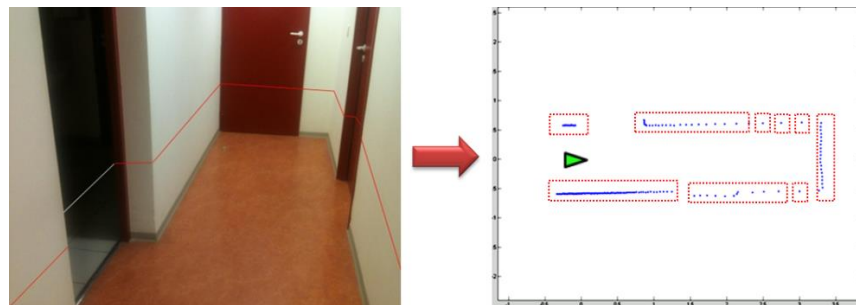


Fig. 7. Agrupación de puntos de medida obtenida con el método adaptativo propuesto por Dietmayer [5]

objeto detectado serán aproximadas utilizando curvas B-spline de grado 3 (ecuación 4).

Aunque la representación basada en B-splines reduce significativamente el ruido provocado por los errores del propio sistema de medición, un último suavizado de la curva debe ser realizado utilizando un filtro Gaussiano para garantizar que el proceso no encontrará puntos característicos

falsos. Entonces, una versión evolucionada de la curva puede ser procesada como sigue:

$$D_\sigma = \{x(u, \sigma), y(u, \sigma)\}, \quad (8)$$

donde:

$$x(u, \sigma) = x(u) \otimes g(u, \sigma), \quad y(u, \sigma) = y(u) \otimes g(u, \sigma). \quad (9)$$

Aquí, \otimes representa el operador de convolución y $g(u, \sigma)$ denota un filtro Gaussiano de amplitud

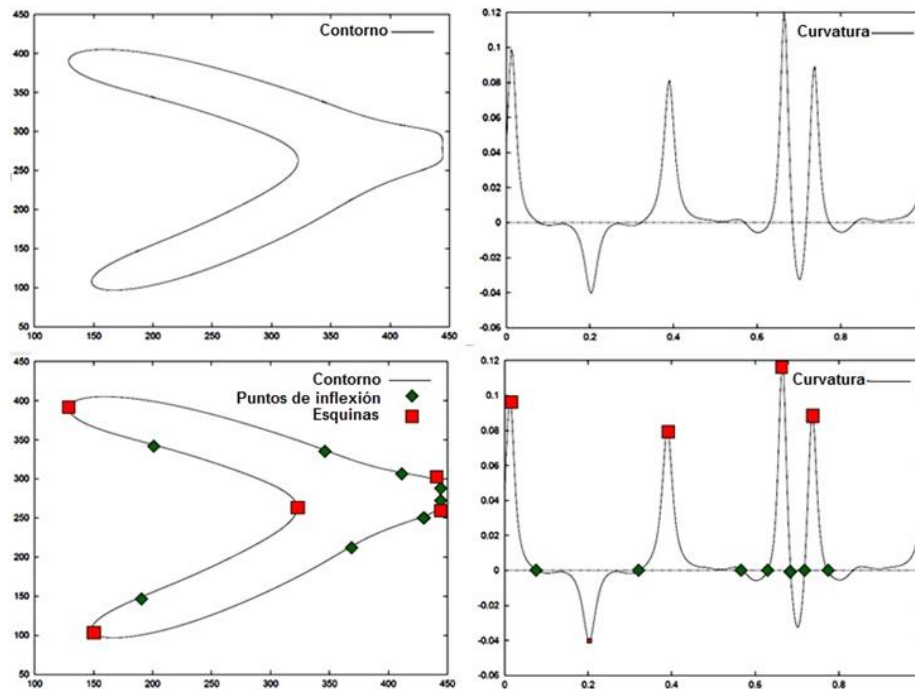


Fig. 8. Detección de puntos de inflexión y esquinas

σ ; elegido de tal forma que este sólo elimina el ruido, pero no información valiosa sobre la curva, forzando el valor a ser muy bajo. Ya que nuestro proyecto trabaja normalmente con curvas abiertas, un cierto número de puntos proporcional al doble de la anchura completa en la media máxima (Full Width at Half Maximum (FWHM)) para una Gaussiana, son simétricamente compensados a ambos extremos de la curva cuando esta es suavizada.

Finalmente, con la finalidad de que el proceso de asociación pueda ejecutarse efectivamente, se debe asegurar la invariabilidad en la resolución de la curva. Así, cada curva discreta B-spline debe ser almacenada tomando puntos equidistantes en ella con una distancia ε entre cada punto:

$$\text{dist}(\sum N_p(u)X, \sum N_p(u+1)X) \cong \varepsilon. \quad (10)$$

De lo anterior, obtenemos un vector paramétrico que contiene la B-spline.

Además del proceso descrito, una restricción sobre la longitud de la curva es aplica, esto debido a que objetos demasiado pequeños no proporcionan información suficiente y por lo tanto

no es interesante incluirlos en el mapa. También, aunque nuestro método está diseñado para trabajar en ambientes estáticos, esta restricción permite en cierta forma, filtrar elementos dinámicos (personas por ejemplo).

Una vez que las B-splines han sido obtenidas y elegidas, podemos buscar característica específica contenida en las curvas que serán de gran importancia en el proceso de localización. Esencialmente, dos tipos de características serán buscados en las curvas: puntos de inflexión y esquinas.

El tipo esquina es muy común y no requiere explicación. Por otro lado, el concepto de puntos de inflexión en una forma muy general se refiere al punto sobre la curva donde esta pasa de cóncava a convexa o viceversa. El proceso para obtener ambas características en la curva está basado en el espacio escalar de curvaturas CSS [16] el cual es usado para recuperar características geométricas invariantes (Figura 8).

3.2. Búsqueda de características distinguibles en las curvas B-Splines

La búsqueda de características particulares en las curvas que definen los objetos, está completamente basada en la curvatura de la B-Spline, la cual está definida como la medida local que indica cuanto una curva se ha alejado de una línea recta; mas formalmente, la curvatura de un punto $X_u=[x_u, y_u]$ en la B-spline está definido como la cantidad igual a la inversa del radio del círculo osculador en el punto (el círculo que toca tangencialmente a la curva en el punto X_u), lo que significa que cuanto menor es el radio ρ de este círculo, más grande será la curvatura en este punto ($1/\rho$). La fórmula para procesar la curvatura puede ser expresada como:

$$k(u, \sigma) = \frac{\dot{x}(u, \sigma)\ddot{y}(u, \sigma) - \ddot{x}(u, \sigma)\dot{y}(u, \sigma)}{(\dot{x}(u, \sigma)^2 + \dot{y}(u, \sigma)^2)^{\frac{3}{2}}}. \quad (11)$$

Donde, de acuerdo con las propiedades de convolución, las derivadas de cada elemento pueden ser fácilmente calculadas ya que conocemos las formas exactas de la primera y segunda derivada del kernel Gaussiano usado y. Así:

$$\dot{x}(u, \sigma) = \frac{\partial}{\partial u}(x(u) \otimes g(u, \sigma)) = x(u) \otimes \dot{g}(u, \sigma), \quad (12)$$

$$\ddot{x}(u, \sigma) = \frac{\partial^2}{\partial u^2}(x(u) \otimes g(u, \sigma)) = x(u) \otimes \ddot{g}(u, \sigma), \quad (13)$$

$$\dot{y}(u, \sigma) = y(u) \otimes \dot{g}(u, \sigma), \quad (14)$$

$$\ddot{y}(u, \sigma) = y(u) \otimes \ddot{g}(u, \sigma). \quad (15)$$

De lo anterior, la lista de curvaturas de la B-Spline es obtenida mediante la ecuación (5), con la cual la obtención de los puntos de inflexión en la curva es realizada simplemente buscando en esta lista un cambio de signo entre dos curvaturas consecutivas. Por otro lado, la búsqueda de esquinas está basada en el trabajo de He et al. presentado en [10]. Aquí, el detector está basado en propiedades locales y globales de la curvatura (Figura 8).

Ya que nuestro sistema usa en la mayoría de los casos curvas abiertas, consideraremos como medida de seguridad y certeza solo esquinas limitadas en ambos lados por puntos de inflexión.

3.3. Asociación de datos

Con el objetivo de facilitar el entendimiento del enfoque propuesto, esta sección presenta un ejemplo ilustrativo, el cual será descrito en cada fase de su desarrollo; así, en la figura 9 podemos observar un ejemplo que corresponde a la evolución de la exploración del robot hasta un instante $k+s$, donde tres objetos $B_{0,1}$, $B_{0,2}$ y $B_{0,3}$ son detectados (mostrados en rojo) dentro del rango de visión del sensor (circunferencia en línea punteada). Esta imagen subraya la posición odométrica como una aproximación a priori de la verdadera posición del robot obtenida con el modelo de movimiento, ya que errores propios de este y ruido en el sistema sensorial, llevarán al robot a una posición real diferente a la esperada. Por esta razón, los objetos $B_{0,1}$, $B_{0,2}$ y $B_{0,3}$ aparecen desplazados y no se superponen exactamente con los objetos a los que pertenecen.

De forma análoga al método de la sección 2b, la asociación de B-splines considerará inicialmente solo los puntos del polígono de control que genera las curvas. En este paso, las distancias entre los puntos de los polígonos de control de todos los objetos son obtenidas asociando las curvas observadas en la posición $k+s$, con las curvas de referencia almacenadas en el mapa, usando el criterio mostrado en la ecuación 3. Donde $X_{0,i}$ y $X_{RSL,i}$ son los puntos de control de las splines observadas y de las splines en el mapa que se está construyendo respectivamente, $dist(X_{RSL,i}, X_{0,i})$ representa la distancia Euclidiana entre dos puntos. Finalmente n_m y n_o son el número de puntos de control de las spline en el mapa y de las spline observadas en la posición $k+s$ respectivamente. Al final de esta primera etapa, las splines con un número mínimo μ_{min} de puntos de control relacionados, serán asociados.

En la figura 10, podemos observar como las curvas ($B_{RSL 1}$, $B_{O 2}$) and ($B_{RSL 2}$, $B_{O 3}$) han sido asociadas ya que tienen 5 y 7 puntos relacionados de sus polígonos de control respectivamente, obtenidos de la ecuación 5.

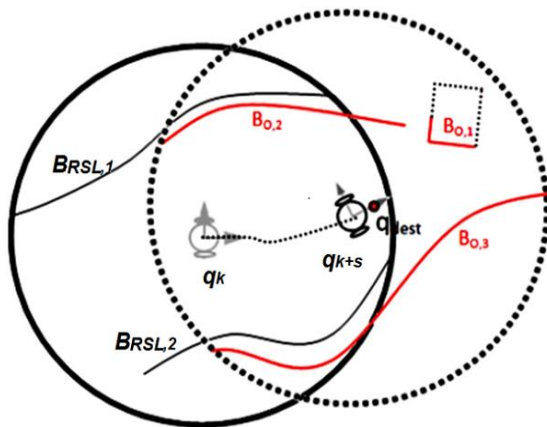


Fig. 9. Robot en la posición odométrica q_{k+s} con tres obstáculos detectados dentro de su rango de detección




Fig. 10. Asociación áspera realizada con los puntos de control de las curvas

Si en este punto existen curvas relacionadas, el siguiente paso es realizar una asociación fina; para lo cual, se buscarán esquinas y puntos de inflexión contenidas en las curvas relacionadas; si esto ha sido posible, los elementos encontrados serán usados para realizar una asociación precisa entre cada par de curvas ($B_{RSL,i}, B_{o,j}$).

La información acerca del tipo de característica y de la curvatura en ese punto serán usados para evitar errores en este paso de asociación (figura 11). Si en alguna de las curvas relacionadas ningún elemento ha sido encontrado (líneas o curvas demasiado suaves), el proceso de asociación fina será ejecutado encontrando los puntos más cercanos a los finales de las curvas relacionadas como se propone en [19].

Una vez que todos los elementos están relacionados, una búsqueda de los puntos inicial y final de las curvas relacionadas es realizada. Tomando los puntos de inflexión o las esquinas más extremas como puntos iniciales contenidas en ambas curvas relacionadas, tomaremos algunos puntos continuos en la curva paramétrica hacia su final.

El número de puntos a tomar, es el máximo número de elementos que pueden ser tomados en el segmento de curva de menor longitud de las dos relacionadas desde el punto característico más extremo hacia el final de la curva.

Lo anterior puede ser visto en detalle en las curvas relacionadas ($B_{RSL,2}, B_{o,3}$) en la Figura 12. Aquí, observamos que el punto inicial representado por el círculo azul fue tomado eligiendo seis elementos de la curva paramétrica (mostrados en línea discontinua azul) a partir del punto de inflexión, representado por el círculo verde, al extremo inicial de la curva.

La longitud del segmento de curva $B_{o,3}$ desde el inicio de la curva al punto de inflexión es más grande que el segmento de curva $B_{RSL,2}$ desde el inicio de la curva al punto de inflexión y por lo tanto, los elementos del segmento de curva con al punto de inflexión es más grande que el segmento de curva $B_{RSL,2}$ desde el inicio de la curva al punto de inflexión y por lo tanto, los elementos del segmento de curva con menor longitud seguramente estarán contenidos en el otro de mayor longitud.

El mismo proceso es realizado en el extremo final de la curva, donde, 15 puntos de la curva paramétrica fueron tomados desde la esquina, representada con el diamante verde, dado que el segmento de curva de menor longitud desde la esquina al extremo de la curva perteneciente a $B_{RSL,2}$ contiene solo 15 puntos.

Finalmente, cuando el proceso de asociación es terminado, las curvas relacionadas tendrán una apariencia similar al de la figura 13.

4. Resultados experimentales

Aunque la asociación de datos es un problema general aplicable y necesario para cualquier algoritmo de SLAM, en esta sección hemos decidido aplicar nuestra propuesta utilizando el Filtro de Kalman Extendido para SLAM.




Fig. 11. Asociación de los puntos de inflexión y esquinas entre las curvas de la RSL y las curvas observadas. Los círculos verdes representan los puntos de inflexión mientras que los diamantes representan esquinas




Fig. 12. Ejemplo de cómo el punto inicial y final de los segmentos de curva relacionados son encontrados




Fig. 13. Segmentos de curva relacionados con el proceso de asociación de datos descrito. Los círculos azules, representan los extremos de las curvas relacionadas mientras que los círculos y diamantes verdes representan los puntos de inflexión y las esquinas de la curva respectivamente

Lo anterior fue hecho con la finalidad de realizar una comparación de nuestro algoritmo de asociación de datos, con la propuesta presentada por Pedraza et al. en [19], ya que este es uno de los pocos trabajos que ha lidiado con el problema de representación de ambientes complejos utilizando la misma herramienta de descripción de obstáculos que se utilizó en este documento, pero con una aproximación a la asociación de datos diferente. Esta comparación tiene como objetivo verificar el impacto que la asociación de datos tiene sobre la localización del robot y por lo tanto en la calidad del mapa final.

Las pruebas hechas al método propuesto, fueron realizadas usando un robot diferencial real y simulado Pioneer P3DX equipado con un sensor laser Hokuyo URG-04lx, el cual tiene un rango de detección de 0.02 a 4 metros aproximadamente con una desviación típica (σ) de 1% de la medida, una resolución angular de 0.36 grados y un ángulo de escaneo de 240 grados. Además, el robot tiene un anillo de 16 sensores ultrasónicos de los cuales 6 de ellos posicionados en la parte trasera del robot son usados para obtener información del ambiente en los 120° donde el sensor laser no puede ver.




Fig. 14. Ambiente simulado LIRMM

El ambiente simulado usado para nuestras pruebas, es una adaptación de las instalaciones del Laboratorio de informática, Robótica y Micro-electrónica de Montpellier y es mostrado en la figura 14.

La estrategia de asociación de datos desarrollada en este documento, así como cualquier otra solución propuesta en este campo es validada usando como criterio el rendimiento computacional, calidad del mapa y la consistencia de los algoritmos.

Sin embargo, a diferencia de los métodos cuya representación del ambiente está basada en geometrías específicas y donde mucha de la información adquirida por los sensores es desperdiciada, nuestro enfoque explota la máxima cantidad de información posible proporcionada por el sensor evitando simplificaciones peligrosas.

La figura 15 muestra los resultados de experimentos de SLAM para la estrategia que hemos desarrollado.

La figura 15a muestra la trayectoria real del robot (línea continua azul), la trayectoria odométrica (línea punteada verde) y la trayectoria obtenida por el método EKF-SLAM (línea roja punteada). Por otro lado, cuando hay certeza sobre la trayectoria real del robot (como en las simulaciones) es posible realizar algunas comprobaciones para dar una idea de la calidad de los algoritmos desde el punto de vista de su consistencia.

Por esta razón, ha sido posible incluir en la figura 15b, la representación del error odométrico (línea azul) en X , Y y Θ , así como errores de localización (línea roja punteada), lo cual nos permite tener una idea de la calidad final del mapa, ya que esto tiene una influencia directa sobre la precisión de la localización del robot dada la estrecha relación que existe entre la localización

espacial de los obstáculos y la ubicación del robot (Figura 16).

A partir de los datos obtenidos con nuestro enfoque, y tomando como referencia los errores mostrados por el método de SLAM presentado por Pedraza et al. [19], concluimos que el método de asociación de datos propuesto mejorando notablemente la calidad del mapa y los errores que este presenta como se muestra en la figura 17.

Finalmente, en esta sección presentamos experimentos con datos reales en ambientes reales, para validar los resultados presentados. En todas las pruebas se muestran los mapas obtenidos considerando sólo la información odométrica reportada por el robot y los mapas obtenidos después de aplicar el método SLAM con nuestra propuesta de asociación de datos.

La figura 18 muestra el ambiente real del corredor LIRMM. El mapa obtenido con nuestra estrategia de SLAM es mostrado en la figura 19a, mientras que el mapa odométrico obtenido utilizando solo información odométrica es mostrado en la figura 19b. En estas imágenes se puede observar el impacto que la localización del robot tiene en la calidad final del mapa (figura 19c) y el rol tan importante que la asociación de datos tiene, ya que el utilizar información con una acumulación sistemática de errores en las medidas de datos espaciales resulta en un mapa deficiente.

Considerando que nuestro enfoque ha sido creado para construir mapas de ambientes complejos, otro experimento es realizado utilizando el entorno real mostrado en la figura 20a. En este ejemplo, podemos observar que la construcción del mapa sería imposible utilizando un método clásico basado en líneas y puntos. La figura 20b muestra el mapa obtenido con nuestro enfoque.

5. Conclusiones

Se ha propuesto un método de asociación de datos basado en el análisis de las curvaturas de las curvas B-spline relacionada. Aquí, usamos las técnicas de imágenes digitales CSS [16], puntos de inflexión y técnicas de extracción de esquinas utilizadas en el campo del reconocimiento de




Fig. 15. Experimento de exactitud y consistencia para el EKF-SLAM basado en el enfoque de asociación de datos presentado en este documento. a) Trayectorias efectuadas por el robot con error odométrico (línea verde), robot con posición ideal (línea azul) y robot localizado utilizando el método de asociación de datos presentado en este trabajo (línea roja). b) Errores en X, Y, Theta reportados por el robot con error odométrico (línea azul), y por el robot localizado basado en el método de asociación de datos presentado en este trabajo (línea roja)




Fig.16. Mapa obtenido con el método de asociación de datos para SLAM presentado en este trabajo

patrones. Este mecanismo de asociación no sólo permite establecer una correspondencia robusta entre las observaciones realizadas por el robot y los objetos contenidos en el mapa de trabajo, sino que facilita la correspondencia paramétrica entre cada par de elementos representativos asociados.

Mostramos también una serie de pruebas en simulación del método de SLAM basado en

nuestra propuesta de asociación de datos, las cuales han permitido validar nuestra aproximación. En ellas, se muestran la precisión obtenida con nuestro enfoque así como con enfoques recientemente mostrados, permitiéndonos verificar que los niveles de error muestran mejoras significativas a los obtenidos con otros métodos.

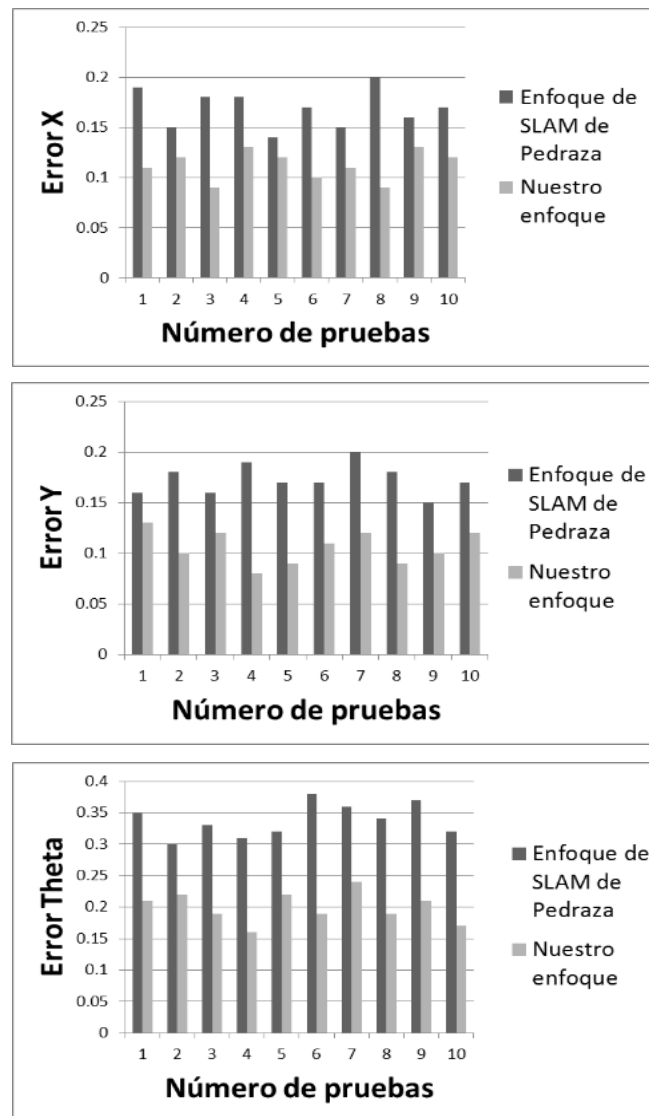


Fig. 17. Errores obtenidos con las estrategias de SLAM con asociación de datos simple [9] y SLAM con nuestro enfoque de asociación de datos

Al final, mostramos los mapas obtenidos con datos reales que permitan evaluar la aplicabilidad práctica del método propuesto, lo que nos permitió comprobar su usabilidad en ambientes reales.

El método de asociación de datos desarrollado en este trabajo propone una mejora sustancial al método de SLAM para ambientes complejos presentado en [19], no solo por manejar de forma

integral la información contenida en las curvas B-Spline que representan los objetos, sino por establecer correspondencias exactas que evitan el desperdicio de tiempo en el tratamiento de asociaciones superfluas dentro de los métodos de SLAM; además, se tiene la ventaja adicional de proporcionar siempre una localización más precisa y consistente y una estimación de mapa robusta.



Fig. 18. Ambiente corredor real usado para las pruebas




Fig. 19. a) Ambiente corredor real adquirido con el método de SLAM basado en el método de asociación de datos propuesto. b) Ambiente corredor real adquirido usando solo información odométrica. c) Diferencia entre los mapas obtenidos con el método de SLAM y con información odométrica pura.




Fig. 20. a) Ambiente complejo usado para las pruebas. b) Mapa del ambiente complejo real adquirido con el método de SLAM

Referencias

1. **Beinhofer, M., Kretschmar, H., & Burgard, W. (2013).** Deploying Artificial Landmarks to Foster Data Association in Simultaneous Localization and Mapping. *IEEE International Conference on Robotics and Automation (ICRA)*. DOI: 10.1109/ICRA.2013.6631325.
2. **Brooks, A. & Bailey, T. (2009).** *HybridSLAM: Combining FastSLAM and EKF-SLAM for reliable mapping*. Algorithmic Foundation of Robotics VIII, Springer Berlin Heidelberg. pp. 647–661. DOI: 10.1007/978-3-642-00312-7_40.
3. **Cooper, J., Roy, N., Gustafson, D., & McConley, M. (2005).** *A comparison of data association techniques for Simultaneous Localization and Mapping*. Massachusetts Institute of Technology, Dept. of Aeronautics and Astronautics.
4. **De Boor, C. (1978).** *A Practical Guide to Splines*. Springer-Verlag, New York.
5. **Dietmayer, K., Sparbert, J., & Streller, D. (2001).** Model based object classification and object tracking in traffic scenes from range images. *Proceedings of the IV IEEE Intelligent Vehicles Symposium*.
6. **Dissanayake, M.W.M.G., Newman, P., Clark, H.F., Durrant-Whyte., & Csobza, M. (2001).** A solution to the simultaneous localization and map building (slam) problem. *IEEE Transactions on Robotics and Automation*, Vol. 17, No. 3, pp. 229–241. DOI: 10.1109/70.938381.
7. **Grisetti, G., Stachniss, C., & Burgard, W. (2005).** Improving Grid-based SLAM with Rao-Blackwellized Particle Filters by Adaptive Proposals and Selective Resampling. *IEEE International conference on robotics and Automation*. DOI: 10.1109/ROBOT.2005.1570477.
8. **Guerra, E., Munguía, R., Bolea, Y., & Grau, A. (2013).** New validation algorithm for data association in SLAM. *ISA Transaction*, Vol. 52, No. 5, pp. 662–671. DOI: 10.1016/j.isatra.2013.04.008.
9. **Guivantand, J. & Nebot, E. (2001).** Optimization of the Simultaneous localization and map building algorithm for real time implementation. *IEEE Transactions on Robotic and Automation*, Vol.17, No. 3, pp. 242–257. DOI: 10.1109/70.938382.
10. **He, X. & Yung, N. (2008).** Corner detector based on global and local curvature properties. *Optical Engineering*. Vol. 47, No. 5, DOI:10.1117/1.2931681.
11. **Johannsson, H., Kaess, M., Fallon, M., & Leonard, J. (2013).** Temporally scalable visual SLAM using a reduced pose graph. *IEEE International Conference on Robotics and Automation (ICRA)*. DOI: 10.1109/ICRA.2013.6630556.
12. **Leonard, J.J., Durrant-Whyte, H.F., & Cox, I.J. (1992).** Dynamic map building for an autonomous mobile robot. *International Journal of Robotics Research*, Vol. 11, No. 4, pp. 286–298. DOI: 10.1109/IROS.1990.262373.
13. **Leung, C., Huang, S., & Dissanayake, G. (2008).** Active SLAM for structured environments. *IEEE Int. Conf. Robot. Automat.*, pp. 1898–1903. DOI:10.1109/ROBOT.2008.4543484.
14. **Liu, M., Huang, S., & Dissanayake, G. (2011).** Feature based SLAM using laser sensor data with maximized information usage. *IEEE International Conference on Robotics and Automation (ICRA)*,

- Shanghai, China. DOI: 10.1109/ICRA.2011.5980504.
15. **Liu, M., Huang, S., Dissanayake, G., & Kodagoda, S. (2010).** Towards a consistent SLAM algorithm using B-Splines to represent environments. *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. DOI: 10.1109/IROS.2010.5649703.
 16. **Mokhtarian, F. (1995).** Silhouette-based isolated object recognition through curvature scale space. *IEEE Pattern Analysis and Machine Intelligence*, Vol. 17, No. 5, pp. 539–544. DOI: 10.1109/34.391387.
 17. **Nieto, J., Bailey, T., & Nebot, E. (2006).** Scan-SLAM: Combining EKF-SLAM and scan correlation. *Field and service robotics*, Springer Berlin Heidelberg, pp. 167–178. DOI: 10.1007/978-3-540-33453-8_15.
 18. **Nieto, J., Guivant, J., Nebot, E., & Thrun, S. (2003).** Real time data association for fastslam. *IEEE International Conference on Robotics and Automation*. DOI: 10.1109/ROBOT.2003.1241630.
 19. **Pedraza, L., Rodríguez-Losada, D., Matia, F., Dissanayake, G., & Miro, J. (2009).** Extending the Limits of Feature-Based SLAM with B-Splines. *IEEE Transactions on Robotics*, Vol. 25, No. 2, pp. 353–366. DOI: 10.1109/TRO.2009.2013496.
 20. **Sun, R., Ma, S., Li, B., Wang, M., & Wang, Y. (2011).** A Simultaneous Localization and Mapping Algorithm in Complex Environments: SLASEM. *Advanced Robotics*, Vol. 25, No. 6-7, pp. 941–962. DOI: 10.1163/016918611X563373.
 21. **Zhang, L. & Ghost, B. (2000).** Line segment based map building and localization using 2D laser range finder. *IEEE International conference on robotics and Automation*. DOI: 10.1109/ROBOT.2000.846410.
 22. **Zhang, S., Xie, L., & Adams, M. (2004).** Gradient model based feature extraction for simultaneous localization and mapping in outdoor applications. *IEEE Control, Automation, Robotics and Vision Conference*. DOI: 10.1109/ICARCV.2004.1468864.

*Artículo recibido el 15/12/2015; aceptado el 29/03/2017.
Autor de correspondencia es Alfredo Toriz Palacios.*