



# ACTAS DEL SIMPOSIO DE ROBÓTICA, BIOINGENIERÍA Y VISIÓN POR COMPUTADOR



**Universidad de Extremadura.  
Escuela de Ingenierías industriales  
Badajoz, 29 a 31 de mayo de 2024**





# **SIMPOSIO DE ROBÓTICA, BIOINGENIERÍA Y VISIÓN POR COMPUTADOR**

## **Actas**

**Badajoz, 29-31 de Mayo de 2024**



Cáceres, 2024

Actas de Simposio de Robótica, Bioingeniería y Visión por Computador  
Badajoz, 29-31 de Mayo de 2024

Editores: Santiago Salamanca Miño  
Emiliano Pérez Hernández  
Patricia Arroyo Muñoz  
Antonio J. Calderón Godoy  
Isaías González Pérez  
Jesús Lozano Rogado  
Pilar Merchán García  
José Ignacio Suárez Marcelo  
Inés Tejado Balsera  
Blas M. Vinagre Jara



1ª edición, 2024

Edita:  
Universidad de Extremadura. Servicio de Publicaciones  
Plaza de Caldereros, 2. 10003 Cáceres (España)  
Tel. 927 257 041; Fax 927 257 046  
[publicac@unex.es](mailto:publicac@unex.es)  
<http://publicauex.unex.es/>

E- ISBN.: 978-84-9127- 262-5 (edición digital)

Imagen de la portada generada con DALL-E de OpenAI

Acceso abierto en el [Repositorio Institucional de la Universidad de Extremadura](#)

**Dehesa** Repositorio  
Institucional



## **Comité Organizador**

Patricia Arroyo Muñoz  
Antonio J. Calderón Godoy  
Isaías González Pérez  
Jesús Lozano Rogado  
Pilar Merchán García  
Emiliano Pérez Hernández  
Santiago Salamanca Miño  
José Ignacio Suárez Marcelo  
Inés Tejado Balsera  
Blas M. Vinagre Jara

## **Comité Científico**

Óscar Reinoso García	(UMH)	Robótica
Eduardo Rocon de Lima	(CSIC)	Bioingeniería
Luis Payá Castelló	(UMH)	Visión por Computador

# Prefacio

Este simposio representará un punto de encuentro único para la presentación y discusión de los trabajos más recientes de los grupos temáticos de Robótica, Bioingeniería y Visión por Computador del Comité Español de Automática (CEA). Investigadores, académicos y profesionales convergerán en este espacio propicio para el intercambio de conocimientos y la exploración de colaboraciones futuras.

El escenario elegido para este evento es la Escuela de Ingenierías Industriales de la Universidad de Extremadura. Con Badajoz como telón de fondo, esta ciudad impregnada de historia y cultura, los participantes podrán disfrutar no solo de la riqueza científica-tecnológica del evento, sino también de la belleza y hospitalidad que ofrece la región de Extremadura.

El programa abarca una amplia gama de temas de los 3 grupos, sesiones paralelas, charlas plenarias, mesas redondas, presentaciones de empresas y un reconfortante programa social, proporcionando un ambiente propicio para el networking y el establecimiento de conexiones duraderas entre los participantes.

Los trabajos aceptados por los revisores de los distintos grupos temáticos han sido 25 de robótica, 16 de bioingeniería y 5 de visión por computador. Todos estos artículos son los que se encuentran recogidos en estas actas publicadas por el Servicio de Publicaciones de la UEx.

Óscar Reinoso García  
Coordinador Grupo Robótica CEA

Eduardo Rocon de Lima  
Coordinador Grupo Bioingeniería CEA

Luis Payá Castelló  
Coordinador Grupo Visión por Computador CEA

# ÍNDICE

<b>1</b>	<b>Robótica</b>	<b>1</b>
1.1	<i>Juan Rodríguez Huelves, Sara Carrasco Martínez, Sofía Álvarez Arias, Marcos Maroto Gómez, Fernando Alonso Martín, Álvaro Castro-González, Miguel Ángel Salichs.</i> Diseño y aplicación de dispositivos de interacción multimodal para robots sociales . . . . .	1
1.2	<i>Sergio Merino Fidalgo, Celia Sánchez-Girón Coca, Eduardo Zalama, Jaime Gómez-García-Bermejo, Jaime Duque Domingo.</i> Cuidado de personas mayores mediante un robot social . . . . .	7
1.3	<i>Álvaro Correa Rosón, Eduardo Zalama, Jaime Gómez-García-Bermejo, Jaime Duque Domingo.</i> Desarrollo de un sistema de diálogo para robótica social mediante ChatGPT . . . . .	13
1.4	<i>Juliana Manrique Cordoba, Veronica Fuentes, Juan David Romero Ante, Jose Maria Sabater-Navarro.</i> Simulación de la cinemática inversa basada en la fórmula de producto de exponenciales: Aplicación al control articular del robot UR3e . . . . .	19
1.5	<i>Manuel Jesus Reyes Capelo, Fernando Gómez Bravo, Raúl Jiménes Naharro, Rafael López de Ahumada Gutierrez.</i> Una propuesta para el análisis emocional del movimiento del robot Pepper . . . . .	25
1.6	<i>Javier Monroy, P. Ojeda, J. Gonzáles Jiménez.</i> Localización de Emisiones de Metano al Aire Libre con Robótica Móvil . . . . .	31
1.7	<i>Francisco José Naranjo Campos, Ainhoa De Matías Martínez, Juan G. Victores, Jose Antonio Gutierrez Dueñas, Almudena Alcaide, Carlos Balaguer.</i> Detección y manipulación de botellas con el robot móvil manipulador TIAGo . . . . .	37
1.8	<i>Johnny J. Yopez-Figueroa, Juan G. Victores, Alberto Jardón, Carlos Balaguer.</i> Diseño Mecatrónico y Construcción de un Robot Móvil Omni-direccional de Tres Ruedas para Transporte de Carga en Ambientes Industriales . . . . .	43
1.9	<i>Alberto Rodríguez Sanz, Santiago Martínez, Bartek Łukawski, Elisabeth Menendez, Carlos Balaguer.</i> Estereolitografía: una alternativa para la fabricación de las articulaciones de un robot . . . . .	49
1.10	<i>Miriam Maximo Gutierrez, M. Ballesta, D. Valiente, E. Heredia-Aguado, O. Reinoso.</i> Localización topológica Monte Carlo basada en descripción de nubes de puntos LiDAR 3D . . . . .	55
1.11	<i>Celia Redondo Verdu, Álvaro Belmonte-Baeza, José Luis Ramón, Jorge Pomares.</i> Trajectory optimization of multipod robots with docking devices . . . . .	61
1.12	<i>Miguel García Gómez, Jaime Duque Domingo, Jaime Gómez-García-Bermejo, Eduardo Zalama.</i> Optimización de la teleoperación del robot Kinova Gen3 mediante realidad mixta . . . . .	67
1.13	<i>Ángel Rodríguez Castaño, José Ángel Acosta Rodríguez.</i> Algoritmo de optimización híbrido para la distribución del empuje en propulsores de barcos autónomos . . . . .	73
1.14	<i>Bartek Łukawski, Alberto Rodríguez Sanz, Juan G. Victores, Carlos Balaguer.</i> An open-source implementation of a force-torque sensor data acquisition device for the humanoid robot TEO . . . . .	79
1.15	<i>Alberto del Cerro Sánchez, Luis Mérida-Calvo, Vicente Feliu-Batlle.</i> Control por rechazo activo de las perturbaciones de los motores de un robot móvil que presentan retardo inducido por hardware . . . . .	85
1.16	<i>Claudia Sánchez Hernández, Daniel Rodríguez del Rosario, Lisbeth Karina Mena López, Concepción Alicia Monje Micharet, Susana Otero Belmar.</i> Evaluación de un sensor de deformación basado en una matriz polimérica de poliuretano termoplástico (TPU) aditivado con partículas de base carbono . . . . .	91
1.17	<i>Luis Mérida-Calvo, María Isabel Haro-Olmo, Salma Benftima, Saddam Gharab, Vicente Feliu-Batlle.</i> Protocolo de navegación y reconocimiento de un sistema háptico móvil basado en antenas flexibles . . . . .	97
1.18	<i>Enara Saratxaga, R. Alonso, A. Mancisidor, I. Leizea, I. Cabanes.</i> Integración de técnicas inteligentes de aprendizaje en un sistema de visión para aplicaciones de pick&place con un robot paralelo Delta . . . . .	103

1.19	<i>Jesús Lozano Rogado, Ángel López Luna, Félix Meléndez Velasco, Víctor Fernández Barrena, Nohely Santamaría Miranda, Patricia Arroyo Muñoz, Fernando Díaz García, Víctor González Blanco, José Ignacio Suárez Marcelo.</i> Combinación de un brazo robótico de 6-DOF con una nariz electrónica para la discriminación automática de muestras de corcho . . . . .	109
1.20	<i>Jesús de la Morena Duque, Jesús Antonio Pérez Santos, Francisco Ramos de la Flor, Andrés S. Vázquez Fernández-Pacheco.</i> Actuadores neumáticos blandos basados en hidrogeles inteligentes: avances hacia rigidez variable . . . . .	115
1.21	<i>Sofía Álvarez Arias, Marcos Maroto Gómez, Sara Carrasco Martínez, José Carlos Castillo Montoya, María Malfaz, Miguel Ángel Salichs.</i> Selección automática de comportamientos mediante estrategias de Deep Reinforcement Learning en el robot social Mini . . . . .	121
1.22	<i>Elisabeth Menendez, Santiago Martínez, Carlos Balaguer.</i> Selección y agarre robótico de objetos basada en el seguimiento de la mirada . . . . .	127
1.23	<i>Ana Calzada García, Bartek Łukawski, Juan G. Victores, Carlos Balaguer.</i> Teleoperation of the robot TIAGo with a 3D mouse controller . . . . .	133
1.24	<i>Jesús García Martínez, Javier Sevilla-Salcedo, José Carlos Castillo Montoya, Álvaro Castro-González, Miguel Ángel Salichs.</i> Estimando la región de atención mediante atención compartida en robots sociales . . . . .	139
1.25	<i>Enrique Mancha Sánchez, Andrés Joaquín Serrano Balbontín, Inés Tejado Balseira, Blas M Vinagre Jara.</i> Diseño y fabricación de microrrobot propulsado por campos magnéticos y plataforma experimental	145
<b>2</b>	<b>Bioingeniería</b>	<b>151</b>
2.1	<i>Blas M Vinagre Jara, Inés Tejado Balseira, Andrés Joaquín Serrano Balbontín, Enrique Mancha Sánchez.</i> El advenimiento de la robótica a escalas nano y micro . . . . .	151
2.2	<i>Andres Chavarrias Sanchez, David Rodriguez-Cianca, Pablo Lanillos.</i> RL-based control methodologies for exoskeletons: a summary . . . . .	156
2.3	<i>Adriana Torres Pardo, C. Mummolo, D. Rodriguez-Cianca, J.A. Gómez-García, J.C. Moreno, D. Torricelli.</i> Estabilidad de la marcha: estado del arte de las métricas actuales . . . . .	163
2.4	<i>Luc van Noort, Nikko Van Crey, Elliott Rouse, Ignacio Martínez-Caballero, Edwin van Asseldonk, Cristina Bayón.</i> Estudio de usabilidad de inGAIT-VSO: una órtesis de tobillo con modulación intrínseca de la rigidez para personalización de la asistencia . . . . .	169
2.5	<i>Ashwin Jayakumar, J. Bermejo-García, F. Romero-Sánchez, R. Agujetas Ortiz, F.J. Alonso-Sánchez.</i> Control de un exosuit de asistencia a la marcha basado en sinergias cinemáticas mediante FIS IA	175
2.6	<i>Luis Daniel Lledo Perez, Raul Martín Batanero, Yolanda Vales Gómez, Andrea Blanco Ivorra, José María Catalán Orts, Nicolás García Aracil.</i> ROAD: Plataforma de telerehabilitación para pacientes con daño cerebral y personas mayores .	179
2.7	<i>José García Villalón, Mario Ortiz García, Paula Soriano Segura, Eduardo Iáñez, José M. Azorín Poveda.</i> Análisis de la influencia de EEGNET en una BMI basada en máquina de estados para el control de un exoesqueleto de miembro inferior . . . . .	185
2.8	<i>Cristina Romero Mirete, Martín Durán Santos, Lluís Bernat Iborra, Carlos Alberto Jara Bravo, Andrés Úbeda Castellanos.</i> Estimación de fatiga muscular usando regresión lineal y HD-EMG . . . . .	191
2.9	<i>Paloma Mansilla Navarro, V. Muñoz, D. Copaci, D. Blanco Rojas.</i> Desarrollo y validación de modelos para la estimación de posiciones angulares en un exotraje a partir de sensores inerciales . . . . .	197



2.10	<i>Marta González García, Pablo Romero Sorozábal, Gabriel Delgado Oleas, Eduardo Rocon de Lima.</i>	
	Sistema de visión por computador para análisis de la marcha . . . . .	203
2.11	<i>Jaime Duque Domingo, Raúl Gómez-Ramos, Eduardo Zalama, Jaime Gómez-García-Bermejo.</i>	
	Comportamiento de un modelo recurrente-transformador para la detección de actividades humanas mediante sensores desplegados en una vivienda . . . . .	209
2.12	<i>Yolanda Vales Gómez, José María Catalán Orts, Andrea Blanco Ivorra, Raul Martín Batanero, Luis Daniel Lledo Perez, Nicolás García Aracil.</i>	
	Validación de un nuevo sistema para la evaluación de la función motora del miembro superior de pacientes con hemiparesia . . . . .	215
2.13	<i>Edwin Daniel Oña Simbaña, Christian Martín Liebana, Carlos Balaguer, Alberto Jardón.</i>	
	Uso de serious games para evaluación funcional automatizada de la extremidad superior basada en escalas clínicas . . . . .	223
2.14	<i>Alfonso Rafael Gordon Cabello de los Cobos, María Lorenzo Pérez, Gabriel Delgado Oleas, Pablo Romero Sorozábal, Manuel Cebrian Ramos, Eduardo Rocon de Lima.</i>	
	Integración de Inteligencia Artificial Generativa en Entornos de Realidad Virtual para la Robótica de Rehabilitación . . . . .	229
2.15	<i>Lluís Bernat Iborra, Joan Francesc Alonso Lopez, Andrés Úbeda Castellanos, Mónica Marlene Martínez-Rojas.</i>	
	Framework en ROS para Decodificación Mioeléctrica mediante Aprendizaje por Demostración . . . . .	233
2.16	<i>Natalia Sempere Maciá, Koralie Porcel, Vicente Morell Gimenez, Andrés Úbeda Castellanos, Carlos Alberto Jara Bravo.</i>	
	Framework para rehabilitación gamificada con robots de efector final . . . . .	239
<b>3</b>	<b>Visión por Computador</b>	<b>245</b>
3.1	<i>Celia Sánchez-Girón Coca, Miguel García Gómez, Jaime Duque Domingo, Jaime Gómez-García-Bermejo, Eduardo Zalama.</i>	
	Detección de caídas con un robot social aplicando Visión Artificial . . . . .	245
3.2	<i>Francisco-Angel Moreno, Nicolás Álvarez Romero, Javier González-Jiménez.</i>	
	Estudio de localización de una cámara sin necesidad de crear mapas 3D . . . . .	251
3.3	<i>Eva Lancho Rivero, Andrea Dordio Ideas, María José Merchán García, Pilar Merchán García.</i>	
	Realidad extendida y discapacidad: Revisión bibliográfica sobre el uso de las tecnologías emergentes para el alumnado con necesidades educativas especiales . . . . .	257
3.4	<i>Enrique Heredia Aguado, David Valiente García, Arturo Gil Aparicio, Miriam Máximo, Luis Paya Castello.</i>	
	Fusión estática de imágenes del espectro visible y térmico para una mejor detección de personas mediante Redes Neuronales Convolucionales: un análisis del rendimiento . . . . .	263
3.5	<i>Diego Benavides, Ana Cignal, Eusebio de la Fuente, Javier Pérez Turiel.</i>	
	Modelo automático e integrable en tiempo real para la localización de herramientas de cirugía laparoscópica . . . . .	269



# Simposio de Robótica, Bioingeniería y Visión por Computador 2024



Sesion: <Robótica>

## Localización topológica Monte Carlo basada en descripción de nubes de puntos LiDAR 3D

Máximo, M.<sup>a,\*</sup>, Ballesta, M.<sup>a</sup>, Valiente, D.<sup>a</sup>, Heredia-Aguado, E.<sup>a</sup>, Reinoso, O.<sup>a</sup>

<sup>a</sup>Instituto de Investigación en Ingeniería de Elche (I3E), Universidad Miguel Hernández de Elche, Avda. de la Universidad s/n, 03202 Elche (Alicante), España.

**To cite this article:** Máximo, M., Ballesta, M., Valiente, D., Heredia-Aguado, E., Reinoso, O. 2024. Monte Carlo topological localization based on 3D LiDAR point cloud description. Simposio de Robótica, Bioingeniería y Visión por Computador, 2024, 1-5. <https://doi.org/>

### Resumen

La búsqueda de la ubicación de un robot es un aspecto clave dentro del campo de la robótica móvil. Un método que utiliza información de los sensores para determinar la pose del robot en entornos conocidos previamente es el método de localización Monte Carlo. En este estudio se ha utilizado una variante topológica del mismo, en el cual el objetivo es encontrar la posición del robot en el instante actual dentro de los nodos del mapa topológico. La información utilizada para la localización se obtiene de un sensor LiDAR, el cual realiza capturas de nubes de puntos que proporcionan información 3D del entorno. La información más característica de estas nubes de puntos es extraída y convertida a un descriptor obtenido mediante técnicas de aprendizaje profundo. Se han usado dos bases de datos diferentes para analizar cómo se comporta el algoritmo en entornos con características diferentes. Los resultados obtenidos, incluyendo error y tiempo de computación, demuestran la robustez del método.

*Palabras clave:* localización Monte Carlo, robótica móvil, LiDAR, nubes de puntos, mapa topológico.

### Monte Carlo topological localization based on 3D LiDAR point cloud description

#### Abstract

Finding the location of a robot is a key aspect in the field of mobile robotics. One method that uses sensor information to determine the robot's pose in previously known environments is the Monte Carlo localization method. In this study, a topological variant of this method has been used, in which the objective is to find the position of the robot at the current instant within the nodes of the topological map. The information used for localization is obtained from a LiDAR sensor, which captures point clouds that provide 3D information about the environment. The most characteristic information of these point clouds is extracted and converted to a descriptor obtained by deep learning techniques. Two different databases have been used to analyse how the algorithm behaves in environments with different characteristics. The results obtained, including the error and computation time, demonstrate the robustness of the method.

*Keywords:* Monte Carlo localization, mobile robot, LiDAR, point clouds, topological map.

### 1. Introducción

Uno de los problemas fundamentales a los que se enfrenta la robótica móvil es la localización de un robot, es decir, conocer su posición y orientación en cada instante de tiempo. Para conseguirlo se recurre al uso de sensores, como pueden ser sensores de odometría (Ganganath and Leung, 2012) o sensores GPS. Estos tienen ciertas limitaciones como en el caso de sen-

sores de odometría, cuyo error aumenta conforme el robot se va desplazando por posible fricción o resbalamiento de las ruedas. En el caso del GPS, no puede ser utilizado en entornos de interior, además para que su error no sea demasiado elevado se ha de recurrir a sensores GPS RTK (Lygouras and Gasteratos, 2021), los cuales utilizan una base fija en una posición conocida para corregir el error del sensor GPS ubicado en el robot

\*Autor para correspondencia: mmaximo@umh.es

móvil. Debido a estas limitaciones, es necesario recurrir a otros métodos de localización.

Algunos de estos métodos hacen uso de sensores que permiten captar información del entorno como cámaras, con las cuales se obtienen imágenes del ambiente (Humenberger et al., 2022). O sensores LiDAR (Zou et al., 2022) los cuales permiten obtener nubes de puntos con información 3D del entorno.

Para contrastar la información obtenida con los sensores se recurre a la extracción de características con el fin de sintetizar la información más relevante dentro de un único descriptor global (Cabrera et al., 2022).

En cuanto a la búsqueda de la pose del robot a partir de la información de estos sensores, se recurre en numerosos casos a métodos probabilísticos para aproximar la posición y orientación del robot. Uno de estos algoritmos es el método de localización Monte Carlo (MCL) (Dellaert et al., 1999), al cual se le considera como un método de filtro de partículas (Javierre et al., 2019). Estos son utilizados para determinar el estado de un sistema que se ve modificado con el transcurso del tiempo. La información utilizada para la localización en algunos casos se corresponde con el uso de características de imágenes (Gil et al., 2005), (Fernandez et al., 2010), otros utilizan LiDAR u otros sensores, y en otras aplicaciones se recurre a la fusión de datos (Carrasco et al., 2021), (Perez-Grau et al., 2017), (Alejo et al., 2019).

En este trabajo, se ha realizado una adaptación del método MCL para su uso de manera topológica, en el que la posición del robot se estima en base a los nodos del mapa topológico construido previamente. Los mapas topológicos, a diferencia de los mapas métricos, no ofrecen una representación del espacio euclídeo, si no un modelo gráfico. Este modelo gráfico está compuesto por nodos los cuales representan una posición en el espacio e incluyen información sobre esta región. La información utilizada para la construcción de estos mapas proviene de sensores GPS y LiDAR, y la información de este último es contrastada para la estimación de la localización. Los resultados obtenidos de la estimación de la posición del robot se corresponden con una localización global. De esta manera el método nos permite aproximar la posición actual dentro de un mapa.

## 2. Localización Monte Carlo

### 2.1. Descripción del método

El algoritmo MCL tiene como objetivo estimar la posición y orientación del robot, es decir, su estado  $x_t = (x, y, \theta)$  en el instante de tiempo  $t$ , utilizando una serie de medidas  $Z^k = \{z_{k,i} = 1...k\}$  del entorno y los movimientos del robot  $u_{1:t} = \{u_1, u_2, \dots, u_t\}$ . La función de densidad de probabilidad  $p(x_t|z_{1:t}, u_{1:t})$  está representada mediante  $M$  muestras aleatorias llamadas partículas  $S_k = \{s_k^i; i = 1...M\}$ .

En la inicialización de este método en el instante de tiempo  $t = t_0$ , se genera un conjunto aleatorio de partículas  $S_0 = \{s_0^i\}$ . Una vez definido el conjunto inicial de partículas, se realiza el siguiente proceso de manera iterativa:

- Fase de predicción: en esta fase se genera un nuevo conjunto de partículas  $S_t$  respectivas al instante  $t$ , a partir del conjunto  $S_{t-1}$  y una señal de control  $u_t$ . Este nuevo conjunto nace como resultado de desplazar cada una de

las partículas del conjunto en el instante anterior según el movimiento de la señal de control.  $S_t$  representa la densidad  $p(x_t|z_{1:t}, u_{1:t})$ .

- Fase de actualización: en esta fase se utiliza la observación  $z_t$  tomada por el robot, para calcular cada uno de los pesos  $w_t^i$  de las partículas del conjunto  $S_t$ . El proceso de esta asignación de pesos se describe en el siguiente apartado. De este proceso se obtiene para cada una de las partículas,  $s_t^i = \{x_t^i, w_t^i\}$ , con el que se realizará el muestreo con reposición. Este proceso se realiza de forma que cada partícula tenga una probabilidad determinada en función del peso de la misma.

En este trabajo, el método MCL se ha abordado con un enfoque topológico con el fin de realizar una localización global. En la Figura 1 se muestra un ejemplo de los datos que intervienen en este proceso. Por una parte, se muestra en azul las nubes de puntos capturadas en los nodos del mapa, marcados con equis. Por otra parte, se observa en rojo las nubes de puntos tomadas en las posiciones de la trayectoria, marcadas con equis. Esta trayectoria corresponde a las observaciones que realiza el robot en cada posición durante su recorrido.

En la aplicación del método topológico las partículas se inicializan en las posiciones de los nodos del mapa. En el proceso de iteración las partículas se desplazan entre nodos contiguos en el mapa. De esta manera, en cada nodo se tienen varias partículas a las que se les asigna una dirección, para que en iteraciones sucesivas se dirijan al nodo contiguo anterior o posterior. La medida  $z_k$  para el cálculo de los pesos se realiza a partir de las observaciones de la trayectoria del robot. El siguiente paso es el muestreo con reposición de las partículas, el cual se realiza de manera aleatoria con la probabilidad de selección dada por los valores de los pesos de las partículas. De esta manera el conjunto de partículas resultante tendrá la misma extensión que el conjunto de entrada, y estará compuesto por las partículas que hayan obtenido mayores pesos. Posteriormente, el proceso se continúa de manera iterativa.




Figura 1: datos utilizados en el método topológico, diferenciando entre nodos del mapa y posiciones de la trayectoria del robot.

### 2.2. Descriptores de nubes de puntos

La extracción de características de cada una de las nubes de puntos se realiza mediante una red de aprendizaje profundo (Cabrera et al., 2024) entrenada previamente con la base de

datos Oxford RobotCar (Maddern et al., 2017). Esta red permite embeber la nube en un descriptor de tamaño 1x512, el cual codifica las características más relevantes del entorno. De esta manera es posible distinguir una posición específica de un mapa basándose en la apariencia del entorno.

### 2.3. Métodos de pesado

El método MCL evalúa la probabilidad de cada una de las partículas generadas, es por ello que necesita de métodos que permitan realizar esta evaluación con el objetivo de estimar cuál es la posición correcta en base a las características del estado actual y de los anteriores.

Para dotar de un peso a cada una de las partículas se comparan las características del entorno observadas por el robot con las del mapa. El mapa está formado por N nodos bidimensionales, cada uno conteniendo una nube de puntos capturada en la posición  $(n_{j,x}, n_{j,y})$  donde se encuentra el nodo, y, a partir de esta nube de puntos, se obtiene su descriptor asociado  $d_j$ .

Por otra parte, considerando que el robot se va a localizar, este captura una nube de puntos en el instante de tiempo t, y de esta se obtiene su descriptor  $d_t$ , el cual compararemos con los descriptores del mapa. Basándonos en la distancia euclídea entre el descriptor actual  $d_t$  y los descriptores de los nodos del mapa  $\{d_1, d_2, \dots, d_N\}$ , seleccionaremos los B descriptores del mapa más cercanos al descriptor actual.

Una vez se ha obtenido  $d_t$  y los B descriptores más cercanos se procede al pesado de las partículas según los siguientes métodos:

- Método 1 (M1): el peso de cada partícula considera la distancia métrica entre la posición actual de la partícula y la posición del nodo en el mapa asociada a cada uno de los B descriptores más cercanos, siendo  $v_j = (n_{j,x}, n_{j,y}) - (x^i, y^i)$ , donde  $(x^i, y^i)$  es la posición de la partícula  $i$ . También interviene la matriz  $\Sigma_i = \text{diag}(\sigma^2, \sigma^2)$  para modelar el ajuste de los pesos. El peso total de cada partícula se calcula según (1).

$$\omega_i^i = \sum_{j=1}^B \exp(-v_j \Sigma_i^{-1} v_j^T) \quad (1)$$

- Método 2 (M2): este método además de tener en cuenta la distancia métrica entre la posición de la partícula y las posiciones del mapa, también tiene en cuenta la distancia en el espacio del descriptor, es decir, la distancia entre el descriptor actual,  $d_t$ , y los B descriptores más cercanos, siendo  $h_j = |d_j - d_t|$ . Posteriormente, se normalizan estas distancias para que la suma de las mismas sea 1. En este caso, también interviene la variable  $\Sigma_m = 1/\sigma^2$ . La expresión utilizada se muestra en (2).

$$\omega_i^i = \sum_{j=1}^B \exp(-v_j \Sigma_i^{-1} v_j^T) \exp(-h_j \Sigma_m^{-1} h_j^T) \quad (2)$$

- Método 3 (M3): en este caso se tienen en cuenta los mismos parámetros descritos en el método anterior, pero en lugar de realizar el sumatorio de las distancias, se realiza el producto. El cálculo de  $\omega_i^i$  se describe en (3).

$$\omega_i^i = \prod_{j=1}^B \exp(-v_j \Sigma_i^{-1} v_j^T) \exp(-h_j \Sigma_m^{-1} h_j^T) \quad (3)$$

### 3. Bases de datos

Con el fin de evaluar el método propuesto, se han realizado experimentos haciendo uso de dos bases de datos diferentes: la primera es Oxford RobotCar, y la segunda ha sido adquirida en el campus de la Universidad Miguel Hernández (UMH).

Estos datos han sido fraccionados para crear el mapa y una trayectoria. Tanto mapa como trayectoria, contienen información relativa al GPS, y capturas de nubes de puntos tomadas con LiDAR. En las trayectorias, el GPS es tomado únicamente como *ground truth* para evaluar la localización obtenida con MCL.

Puesto que, como se ha descrito en el apartado 2.2, el entorno se codificará mediante un descriptor de apariencia de nubes de puntos, se va a evaluar la estimación de la localización en zonas con entornos de similar apariencia. Para ello se ha realizado una clusterización de los descriptores en 40 *clusters*, mediante el uso del algoritmo *k-means*. En la Figura 2 puede observarse cómo la agrupación de los *clusters* se realiza de manera que un mismo *cluster* está compuesto por nodos del mapa

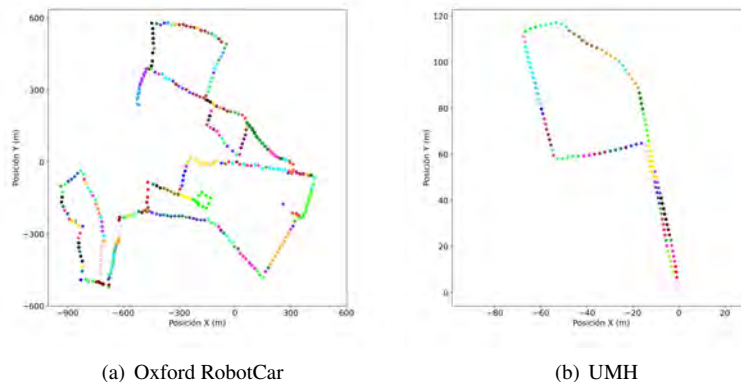
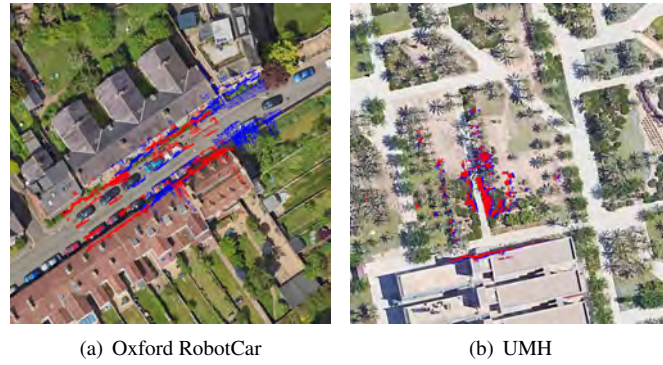


Figura 2: clusterización de los descriptores de cada uno de los mapas de las bases de datos utilizadas, empleando el método *k-means* con 40 *clusters*. (a) Oxford RobotCar; (b) UMH.



(a) Oxford RobotCar

(b) UMH

Figura 3: apariencia en vista satelital con nubes de puntos pertenecientes al mapa y a la trayectoria del robot marcadas en azul y rojo, respectivamente, para cada una de las bases de datos utilizadas en este trabajo: (a) Oxford RobotCar; (b) UMH.

correspondientes a un entorno con poca variación en su apariencia.

Cabe señalar que la base de datos Oxford RobotCar está compuesta por varias capturas en distintos días de una misma ruta. Se ha seleccionado la captura de un mismo día para segregar el mapa y la trayectoria del robot.

De esta manera, se obtiene un mapa con 397 nodos, con una separación media entre contiguos de  $21.43 \pm 3.19$  metros, y una trayectoria con 397 posiciones separadas una distancia media de  $21.45 \pm 3.90$  metros. Además, la distancia entre cada una de las posiciones de la trayectoria y su nodo del mapa más cercano es  $10.09 \pm 5.25$  metros.

La segunda base de datos consta de información relativa a una ruta capturada en el campus de la UMH. El mapa contiene 136 nodos cada uno con una nube de puntos adquirida en una posición específica, y separados una distancia de  $2.32 \pm 0.05$  metros. De manera similar, la distancia entre las posiciones de la trayectoria es de  $2.32 \pm 0.04$  metros. Y las distancias entre una posición de la trayectoria y su nodo del mapa más cercano son de  $0.39 \pm 0.02$  metros.

Respecto a las diferencias entre ambas bases de datos, se ha de destacar que la apariencia de los mapas de las nubes de puntos es distinta, pues en la base de datos de Oxford RobotCar las capturas han sido tomadas en las calles de una ciudad y en la base de datos de la UMH, el robot se encuentra mayormente en-

tre vegetación, tal y como se observa en las imágenes satelitales de la Figura 3.

#### 4. Resultados

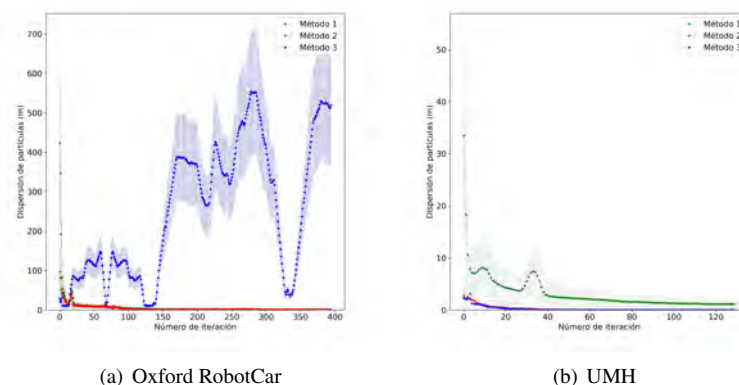
En este apartado se muestran los resultados obtenidos para las dos bases de datos detalladas en el apartado anterior. Cabe destacar que para todos los experimentos se han realizado 10 simulaciones y se ha obtenido una media de los mismos, ya que el algoritmo evaluado se trata de un método probabilístico, por lo que se ha tenido en cuenta una posible variabilidad.

En estos resultados se ha evaluado el grado en el que difiere la posición real y la estimación realizada por el método MCL. La posición real es conocida ya que disponemos de su *ground truth* gracias a los datos del GPS. Por otra parte la estimación de MCL es obtenida según la Ecuación 4 como la posición media del conjunto de partículas de esa iteración.

$$\hat{s}_t = \frac{1}{M} \sum_{i=1}^M s_t^{[i]} \quad (4)$$

##### 4.1. Evaluación de los métodos de pesado

Se han evaluado los tres métodos de pesado propuestos para el algoritmo MCL topológico. Para ello la métrica utilizada ha sido la dispersión entre las partículas, mediante el cálculo de la



(a) Oxford RobotCar

(b) UMH

Figura 4: evolución en la dispersión de las partículas, entendida como la media entre las distancias de cada una de las partículas con la estimación realizada con el método MCL topológico en cada base de datos: (a) Oxford RobotCar; (b) UMH. Se compara dicha dispersión para cada uno de los métodos de pesado propuestos.

Oxford			UMH		
Error M1 (m)	Error M2 (m)	Error M3 (m)	Error M1 (m)	Error M2 (m)	Error M3 (m)
11.54±0.38	9.61±0.26	205.79±38.88	1.72±0.38	0.40±0.01	0.44±0.01

Tabla 1: error medio y desviación para cada uno de los métodos de pesado propuestos.

Oxford			UMH		
Nº partículas	Tiempo/nodo (s)	Error medio (m)	Nº partículas	Tiempo/nodo (s)	Error medio (m)
794	0.26	9.62±1.09	272	0.09	0.40±0.03
1588	0.36	9.73±0.32	544	0.12	0.42±0.02
2382	0.46	9.73±0.31	816	0.15	0.42±0.03
3176	0.58	9.25±0.45	1088	0.18	0.41±0.01

Tabla 2: coste computacional por nodo y error medio obtenido para en función del número de partículas definido en la aplicación del método MCL topológico.

distancia entre la posición de cada una de las partículas y la estimación realizada con MCL. En la Figura 4 puede observarse cómo influye la selección de un método a nivel de dispersión de las partículas. En la Tabla 1 se muestran los resultados obtenidos de error medio para cada método; este error se corresponde con la distancia entre la estimación realizada con MCL y la posición GPS conocida en ese punto de la trayectoria.

Como se observa, el error mínimo es el obtenido con el método de pesado M2, es por ello que, para los resultados del siguiente apartado, se ha seleccionado este método. En los resultados obtenidos con el método M2, se puede observar que los errores obtenidos con ambas bases de datos se corresponden con valores similares a las distancias reales entre los puntos de la trayectoria y los nodos del mapa. De esta manera, la localización global se realiza con éxito, ya que este método aproxima la posición al nodo más cercano.

#### 4.2. Evaluación del método topológico

En el método MCL topológico intervienen diferentes parámetros, entre ellos está el número de partículas. Se han realizado simulaciones modificando este parámetro, con el fin de evaluar cómo afecta al error final y al tiempo de cómputo. Estos resultados se muestran en la Tabla 2. En esta tabla podemos comprobar cómo a un mayor número de partículas el tiempo de computación aumenta. Además, los tiempos de computación son mayores para la base de datos de Oxford RobotCar puesto que el número de nodos en el mapa es mayor, y esto hace que se

tenga que realizar comparaciones con un mayor número de observaciones. Los resultados de error muestran un valor similar independientemente del número de partículas, por esta razón, y, por suponer un mayor coste computacional, la mejor solución del método vendrá dada mediante la definición de un número intermedio de partículas.

Para el vehículo utilizado en la trayectoria de Oxford RobotCar, el tiempo de adquisición entre capturas ha sido de 2.56 segundos aproximadamente. Atendiendo nuevamente a la Tabla 2, se comprueba que el tiempo de cómputo de la estimación MCL es mucho menor y por tanto viable su aplicación en tiempo real.

Este método funciona de tal manera que, una vez se han descartado ciertas partículas, estas nunca vuelven a representar una posible hipótesis. Por ello, se han evaluado los resultados desde distintas posiciones iniciales del robot, con el fin de analizar el comportamiento del método al probar diferentes entornos como punto de inicio. Estos resultados se muestran en la Figura 5. Se puede comprobar cómo el método es robusto ante estos cambios, pues el error no varía sustancialmente entre experimentos. En el caso concreto de la base de datos de la UMH los errores medios son los siguientes:  $0.41±0.29$ ,  $0.42±0.22$  y  $0.58±0.71$  metros, por lo que los cambios entre uno y otro son mínimos.

Por último, la Figura 6 representa, con algunas iteraciones, la evolución del algoritmo de localización. Como se muestra, las partículas tienden a converger a la posición correcta.




Figura 5: error obtenido con el método MCL topológico en cada uno de las posiciones de la trayectoria, cuando el robot comienza su recorrido en diferentes nodos del mapa para cada una de las bases de datos analizadas: (a) Oxford RobotCar; (b) UMH.

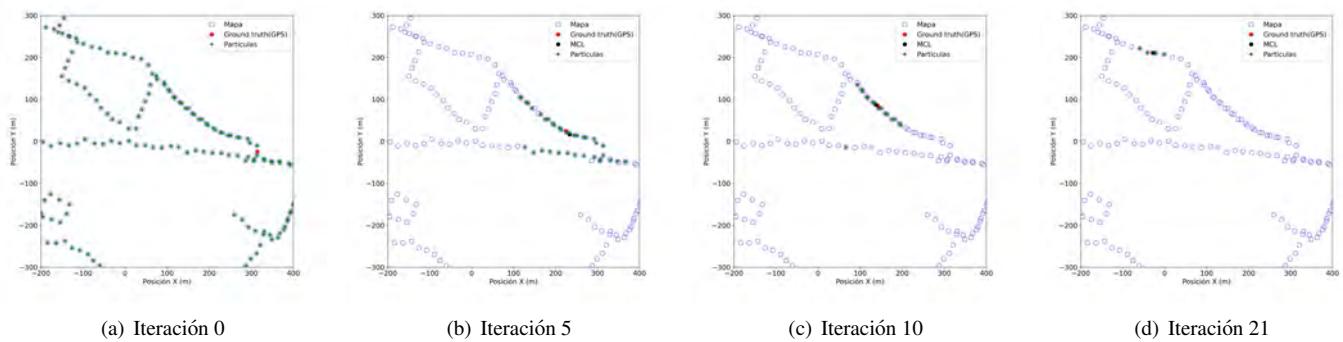


Figura 6: posición de las partículas con respecto de los nodos del mapa, en diferentes iteraciones durante la ejecución del método MCL topológico.

## 5. Conclusiones y trabajos futuros

En este trabajo se ha evaluado el método MCL para la localización de robots mediante la información de nubes de puntos 3D capturadas por sensores LiDAR. La información de estas nubes de puntos ha sido procesada para obtener una versión codificada del entorno, mediante un descriptor de apariencia global. Este descriptor se ha obtenido a partir de redes neuronales de aprendizaje profundo cuyos datos de entrenamiento proceden de la base de datos Oxford RobotCar, utilizada en este trabajo. Además, se han evaluado los resultados del MCL propuesto con otra base de datos adquirida en un entorno muy distinto al del conjunto entrenado.

Los resultados de error obtenidos demuestran que el método MCL topológico consigue realizar una localización global del robot en ambos entornos, ya que los errores son similares a las distancias reales entre las posiciones de las trayectorias y del mapa. Además, es viable su uso en tiempo real ya que el coste de computación entre posiciones de la trayectoria es inferior al tiempo de desplazamiento del robot en una distancia similar a la existente entre nodos.

Por último, se propone como trabajo futuro, realizar una localización local a partir de la localización global obtenida, con el fin de obtener una mayor precisión en la estimación de la posición del robot.

## Agradecimientos

Esta publicación forma parte del proyecto PROMETEO/2021/075 financiado por la Generalitat Valenciana. También ha sido posible gracias al proyecto TED2021-130901B-I00, financiado por MCIN/AEI/10.13039/501100011033 y por la Unión Europea “NextGenerationEU”/PRTR.

## Referencias

Alejo, D., Caballero, F., Merino, L., 2019. A Robust Localization System for Inspection Robots in Sewer Networks. *Sensors* 19, 4946. DOI: 10.3390/s19224946

Cabrera, J. J., Cebollada, S., Flores, M., Reinoso, O., Payá, L., 2022. Training, Optimization and Validation of a CNN for Room Retrieval and Description of Omnidirectional Images. *SN Computer Science* 3 (4), 271. DOI: 10.1007/s42979-022-01127-8

Cabrera, J. J., Santo, A., Gil, A., Viegas, C., Payá, L., 2024. Minkunext: Point cloud-based Large-scale Place Recognition using 3D Sparse Convolutions. DOI: 10.48550/arXiv.2403.07593

Carrasco, P., Cuesta, F., Caballero, R., Pérez-Grau, F. J., Viguria, A., 2021. Monte-Carlo Localization for Aerial Robots using 3D LiDAR and UWB sensing. 2021 International Conference on Unmanned Aircraft Systems (ICUAS), 354–360. DOI: 10.1109/ICUAS51884.2021.9476732

Dellaert, F., Fox, D., Burgard, W., Thrun, S., 1999. Monte Carlo Localization for Mobile Robots. *Proceedings 1999 IEEE international conference on robotics and automation 2*, 1322–1328. DOI: 10.1109/ROBOT.1999.772544

Fernandez, L., Gil, A., Paya, L., Reinoso, O., 2010. An Evaluation of Weighting Methods for Appearance-based Monte Carlo Localization using Omnidirectional Images. *Proc. of the 2nd Workshop on Omnidirectional Robot Vision. IEEE International Conference on Robotics and Automation (ICRA)*, 13–18.

Ganganath, N., Leung, H., 2012. Mobile robot localization using odometry and kinect sensor. 2012 IEEE International Conference on Emerging Signal Processing Applications, 91–94. DOI: 10.1109/ESPA.2012.6152453

Gil, A., Reinoso, O., Vicente, A., Fernández, C., Payá, L., 2005. Monte Carlo Localization Using SIFT Features. *Pattern Recognition and Image Analysis: Second Iberian Conference, IbPRIA 2005, Estoril, Portugal*, 623–630. DOI: 10.1109/ICMTMA.2009.576

Humenberger, M., Cabon, Y., Pion, N., Weinzaepfel, P., Lee, D., Guérin, N., Sattler, T., Csurka, G., 2022. Investigating the Role of Image Retrieval for Visual Localization: An Exhaustive Benchmark. *International Journal of Computer Vision* 130 (7), 1811–1836. DOI: 10.1007/s11263-022-01615-7

Javierre, P., Alvarado, B. P., de la Puente, P., 2019. Particle Filter Localization Using Visual Markers Based Omnidirectional Vision and a Laser Sensor. *Third IEEE International Conference on Robotic Computing (IRC)*, 246–249. DOI: 10.1109/IRC.2019.00045

Lygouras, E., Gasteratos, A., 2021. A novel moving-base RTK-GPS-Based wearable apparatus for precise localization of humans in peril. *Microprocessors and Microsystems*, 82, 103833. DOI: 10.1016/j.micpro.2021.103833

Maddern, W., Pascoe, G., Linegar, C., Newman, P., 2017. 1 year, 1000 km: The Oxford RobotCar Dataset. *The International Journal of Robotics Research* 36(1), 3–15. DOI: 10.1177/0278364916679498

Perez-Grau, F. J., Caballero, F., Viguria, A., Ollero, A., 2017. Multi-sensor three-dimensional Monte Carlo localization for long-term aerial robot navigation. *International Journal of Advanced Robotic Systems* 14, 1–15. DOI: 10.1177/1729881417732757

Zou, Q., Sun, Q., Chen, L., Nie, B., Li, Q., Jul, 2022. A Comparative Analysis of LiDAR SLAM-Based Indoor Navigation for Autonomous Vehicles. *IEEE Transactions on Intelligent Transportation Systems* 23 (7), 6907–6921. DOI: 10.1109/TITS.2021.3063477