

Jornadas de Automática

Localización en entornos estructurados basada en la detección de esquinas

Bayón-Gutiérrez, Martín^a, Prieto-Fernández, Natalia^{a,*}, García-Rodríguez, Isaías^a, Benavides, Carmen^b, García-Ordás, María Teresa^a, Benítez-Andrades, José Alberto^b

^aGrupo de Investigación SECOMUCI, Departamento de Ingeniería Eléctrica y de Sistemas y Automática, Universidad de León, Campus de Vegazana s/n, 24071, León, España

^bGrupo de Investigación SALBIS, Departamento de Ingeniería Eléctrica y de Sistemas y Automática, Universidad de León, Campus de Vegazana s/n, 24071, León, España

To cite this article: Bayón-Gutiérrez, M., Prieto-Fernández, N., García-Rodríguez, I., Benavides, C., García-Ordás, M.T., Benítez-Andrades, J.A. 2024. Corner detection-based localization in structured environments. *Jornadas de Automática*, 45. <https://doi.org/10.17979/ja-cea.2024.45.10877>

Resumen

La gran exactitud y resolución que presentan las mediciones realizadas con sensores LiDAR (*Light Detection and Ranging*) los convierte en habituales en sistemas SLAM (*Simultaneous Localization and Mapping*). El gran volumen de datos proporcionado por dichos sensores se puede reducir a un conjunto de puntos característicos que definen el entorno, simplificando de este modo el proceso de mapeado y posicionamiento y reduciendo el almacenamiento necesario para preservar las medidas realizadas, así como el resultado del proceso SLAM llevado a cabo. En este trabajo se propone un sistema para la estimación de la trayectoria seguida por un elemento robótico basado únicamente en información LiDAR 2D. La nube de puntos es analizada para extraer las esquinas características que conforman el entorno de navegación, estimando así la trayectoria del robot mediante PLGO (*Pose-Landmark Graph Optimization*). Los resultados experimentales muestran como el sistema propuesto ofrece una precisión en la localización del robot comparable a la obtenida mediante técnicas ICP (*Iterative Closest Point*).

Palabras clave: Detección, Localización, Percepción y detección, Robots móviles, Seguimiento de trayectorias, Sistemas de posicionamiento.

Corner detection-based localization in structured environments

Abstract

LiDAR (Light Detection and Ranging) sensors provide high accuracy and high resolution readings of the environment, which makes them a common sensor to be used in SLAM (Simultaneous Localization and Mapping) systems. The large volume of data provided by these sensors can be reduced to a set of characteristic points that define the environment, consequently simplifying the mapping and positioning process, while reducing the storage needed to preserve the measurements taken by the robot as well as the result of the SLAM process carried out. In this work, we propose a system for the estimation of the trajectory followed by a robot equipped solely with a 2D LiDAR. The pointcloud is analyzed to extract a set of characteristic corners that compose the navigation environment, which allows for the estimation of the robot trajectory by means of PLGO (Pose-Landmark Graph Optimization). Experimental results show that the proposed method offers a localization accuracy similar to using ICP (Iterative Closest Point).

Keywords: Localization, Mobile robots, Perception and sensing, Positioning Systems, Sensing, Trajectory Tracking and Path Following.

1. Introducción

Las industrias, los servicios de logística y la vida cotidiana en general han sufrido en los últimos años un proceso de automatización sin precedentes. Desde los sistemas robóticos de almacenaje y transporte de mercancías hasta los robots autónomos para la limpieza del hogar, multitud de plataformas móviles requieren desplazarse por entornos, que en ocasiones son desconocidos, para completar su misión y asistir a los usuarios.

En este contexto, resulta crucial que estos robots dispongan de los sensores y sistemas de localización capaces de estimar con gran exactitud la posición del robot con respecto a su entorno, así como la trayectoria de este a lo largo del tiempo. Este tema es objeto de estudio por los sistemas SLAM (Localización y mapeado simultáneos, por sus siglas en inglés). Sus principales fuentes de información en entornos interiores proceden de imágenes capturadas por una cámara, nubes de puntos obtenidas por un sensor LiDAR (*Light Detection and Ranging*), datos odométricos e inerciales. El procesamiento de los datos adquiridos a través de los sensores del robot puede realizarse utilizando el volumen de datos completo, como es el caso de las técnicas ICP (*Iterative Closest Point*), o mediante la extracción de puntos representativos del entorno (Ulas and Temeltas, 2013).

Diversos trabajos como (Vazquez-Martin et al., 2006; Campos et al., 2021; Guo et al., 2022; Shi et al., 2023) han presentado distintos sistemas de localización dependiendo de las características del entorno de funcionamiento, los sensores equipados o la capacidad de cómputo del sistema robótico. Estos puntos característicos pueden ser artificiales, como balizas, o pertenecer al propio entorno (Zeng et al., 2023). En el caso de interiores, los puntos característicos más habituales son tramos rectos y esquinas. Estas últimas, obtenidas a partir de la nube de puntos proporcionada por un LiDAR, son utilizadas directamente por algunos autores en el proceso SLAM (Vazquez-Martin et al., 2006; Altermatt et al., 2004) o en combinación con información odométrica (Lin et al., 2017) o inercial (Li et al., 2014).

En este trabajo, proponemos un sistema de localización para un robot de uso en interiores basado en la identificación de puntos característicos del entorno. El único sensor empleado en la adquisición de los datos es un LiDAR 2D rotatorio. El objetivo principal es reducir la dimensión de los datos utilizados en la estimación de la trayectoria seguida por el robot. Para ello, se extraen las esquinas que conforman el entorno de navegación y se utilizan estas como elementos de referencia para estimar la trayectoria del sistema robótico mediante un proceso de optimización no lineal. Nuestro sistema determina la trayectoria seguida por el robot en base a las coordenadas de las esquinas y a su concavidad obtenidas a partir de los datos del sensor. Este sistema proporciona una forma sencilla e intuitiva de abordar el problema de la localización en entornos estructurados, al mismo tiempo que reduce de forma significativa la dimensión los datos que deben ser almacenados y procesados por el sistema.

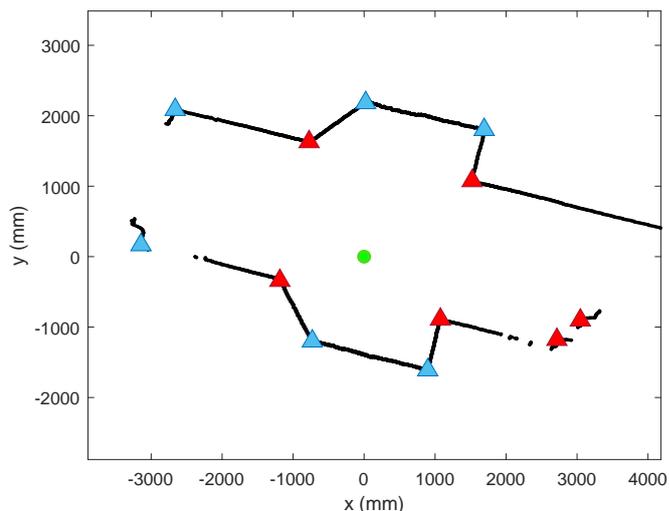


Figura 1: Representación de las esquinas detectadas en el entorno explorado. La posición del sensor se muestra en color verde, las esquinas convexas se representan en color rojo mientras que las esquinas cóncavas se representan en color azul.

2. Metodología

El sistema propuesto se basa en la estimación simultánea de la posición del robot y de las esquinas que componen el entorno, utilizadas como puntos de referencia o *landmarks*. Este problema se ha estudiado ampliamente en la literatura con nombres como *Landmark-based SLAM* o *Pose-Landmark Graph Optimization (PLGO)* (Grisetti et al., 2020; Schuster et al., 2016) y puede ser resuelto mediante la optimización de una función no lineal que involucre las posiciones del robot y los puntos característicos del entorno a lo largo del tiempo.

A diferencia de otros trabajos, donde los puntos característicos del entorno se representan como marcadores fiduciarios, puntos de luz, o puntos de acceso inalámbrico (Xing et al., 2020; Huang et al., 2023), en este trabajo proponemos utilizar la propia estructura del entorno como elemento de referencia, estimando las esquinas que forman los distintos elementos del entorno. Esta metodología permite reducir en gran medida el volumen de datos de trabajo respecto a un sistema de localización basado en el uso de técnicas ICP, típicamente utilizados en los sistemas SLAM.

2.1. Extracción de puntos característicos

El sistema PLGO que planteamos requiere el conocimiento de las esquinas que definen el entorno mapeado. La extracción de las mismas se lleva a cabo empleando la metodología *Weighted Conformal LiDAR-Mapping (WCLM)* (Prieto-Fernández et al., 2023). Esta metodología estima los parámetros que definen la esquina, como la intersección de dos tramos rectos, en el dominio complejo inverso. La expresión genérica que define una recta en dicho dominio es:

$$\mathbf{x}_Q \cdot \mathbf{x}_i - \mathbf{y}_Q \cdot \mathbf{y}_i = 1 \quad (1)$$

donde \mathbf{x}_i e \mathbf{y}_i son las coordenadas cartesianas de cualquier punto i -ésimo perteneciente a la recta y las coordenadas \mathbf{x}_Q e \mathbf{y}_Q son los parámetros que definen dicha recta en el dominio complejo inverso, obteniéndose mediante mínimos cuadrados totales (Prieto-Fernández et al., 2023).

Una vez conocidas las coordenadas \mathbf{x}_{Q_j} e \mathbf{y}_{Q_j} de las rectas j -ésimas que conforman el entorno, se procede a la extracción de las esquinas que lo definen. Las coordenadas cartesianas de una esquina $(\mathbf{x}_c, \mathbf{y}_c)$ se pueden obtener resolviendo el sistema (2) que representa la intersección de las rectas j y $j + 1$.

$$\begin{aligned} \mathbf{x}_{Q_j} \cdot \mathbf{x}_c - \mathbf{y}_{Q_j} \cdot \mathbf{y}_c &= 1 \\ \mathbf{x}_{Q_{j+1}} \cdot \mathbf{x}_c - \mathbf{y}_{Q_{j+1}} \cdot \mathbf{y}_c &= 1 \end{aligned} \quad (2)$$

La concavidad y la convexidad de las esquinas es otro de los parámetros considerados en este trabajo, facilitando así el emparejamiento de las mismas en posiciones sucesivas. Tal y como puede verse en la Figura 1, el carácter cóncavo de una esquina permanece invariante con la posición del LiDAR dentro del entorno. Este parámetro se utiliza como restricción en el sistema no lineal reduciendo así la ambigüedad en el emparejamiento.

2.2. Estimación de la posición del robot

Una vez obtenidas las esquinas del entorno, empleamos un proceso de PLGO en el que de forma iterativa se optimizan todas las posiciones de los puntos característicos del entorno y aquellas que el robot ha mantenido durante la navegación.

Para ello, dado $\mathbf{L} = \{\mathbf{L}_1, \mathbf{L}_2, \dots, \mathbf{L}_N\}$ un conjunto de esquinas y $\mathbf{X} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M\}$ las posiciones del robot a lo largo del tiempo, la solución del problema consiste en encontrar una configuración de \mathbf{L} y \mathbf{X} que minimicen la ecuación de error modelada por:

$$\mathbf{E} = \sum \|f(\mathbf{L}_i, \mathbf{X}_j) - \mathbf{Z}_{ij}\|^2 \quad (3)$$

Donde $f(\cdot)$ representa la estimación de la posición relativa de una esquina respecto a una posición del robot y \mathbf{Z}_{ij} hace referencia a la medición observada por el robot de dicha esquina.

A pesar de que el método presentado en la sección 2.1 permite clasificar las esquinas detectadas en dos grupos, i.e. esquinas cóncavas o convexas, dentro de cada uno de estos grupos las esquinas resultan indistinguibles entre sí. Por esto, hemos establecido el siguiente criterio de asociación de esquinas en lecturas sucesivas del sensor.

Dado \mathbf{L} un conjunto de esquinas detectadas y \mathbf{Z}_{ij} una lectura realizada por el robot, de una potencial esquina \mathbf{L}_i , se realiza una búsqueda en el conjunto \mathbf{L} con la que obtenemos \mathbf{L}^* , aquella esquina cuya distancia euclídea con la esquina de referencia es menor.

En caso de que esta distancia sea superior a un valor umbral, se considera que \mathbf{L}_i se trata de una esquina no detectada aún y que, por tanto, debe ser añadida al conjunto \mathbf{L} , mientras que en el caso contrario, se asocia la lectura \mathbf{Z}_{ij} a la esquina \mathbf{L}^* detectada previamente.

Cabe destacar que en el caso de que se disponga de información sobre la característica de concavidad de las esquinas, la búsqueda de la esquina más próxima se realizará teniendo en cuenta exclusivamente aquellas cuya concavidad sea igual a la esquina de referencia, evitando de esta forma la asociación por error de medidas que no correspondan a la misma esquina.

2.3. Implementación

Por conveniencia, utilizamos el paradigma de optimización de *Factor Graphs* (Dellaert, 2012) en el que la información del sistema se modela en forma de grafo bipartito, donde los vértices son los conjuntos \mathbf{L} , \mathbf{X} y \mathbf{Z} , mientras que las aristas representan la relación entre las distintas variables.

En este trabajo $\mathbf{L}_i \in \mathbb{R}^2$ representa las posiciones de las esquinas, $\mathbf{X}_j \in SE(2)$ representa las posiciones tomadas por el robot y $\mathbf{Z}_{ij} \in \mathbb{R}^2$ representa las mediciones de las esquinas realizadas por el robot desde las distintas posiciones.

Una vez modelado el problema en forma de grafo, utilizamos el *framework SRRG Solver* para optimizar la ecuación (3) mediante la técnica de mínimos cuadrados (Grisetti et al., 2020).

3. Resultados Experimentales

El robot utilizado en la fase experimental, equipado con el sensor *RPLiDAR S2* de *Slamtec*, ha permitido evaluar el comportamiento de nuestro sistema en la estimación de la trayectoria seguida por el robot en varios entornos. En concreto, ha sido teleoperado en varias salas de la Escuela de Ingenierías Industrial, Informática y Aeroespacial de la Universidad de León. Durante el desarrollo de las pruebas experimentales, el robot no dispone de ningún sistema de odometría ni de estimación externa de su posición, por lo que la localización de este depende, exclusivamente, de los datos adquiridos por el sensor LiDAR 2D y el procesamiento de los mismos.

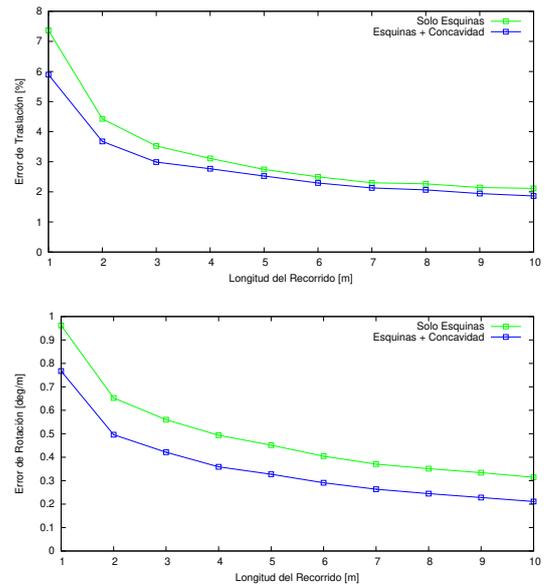


Figura 2: Resultados experimentales de los métodos propuestos respecto al baseline. En azul se representa el método que tiene en cuenta la característica de concavidad de las esquinas, mientras que en el método indicado en verde las esquinas son indistinguibles entre sí.

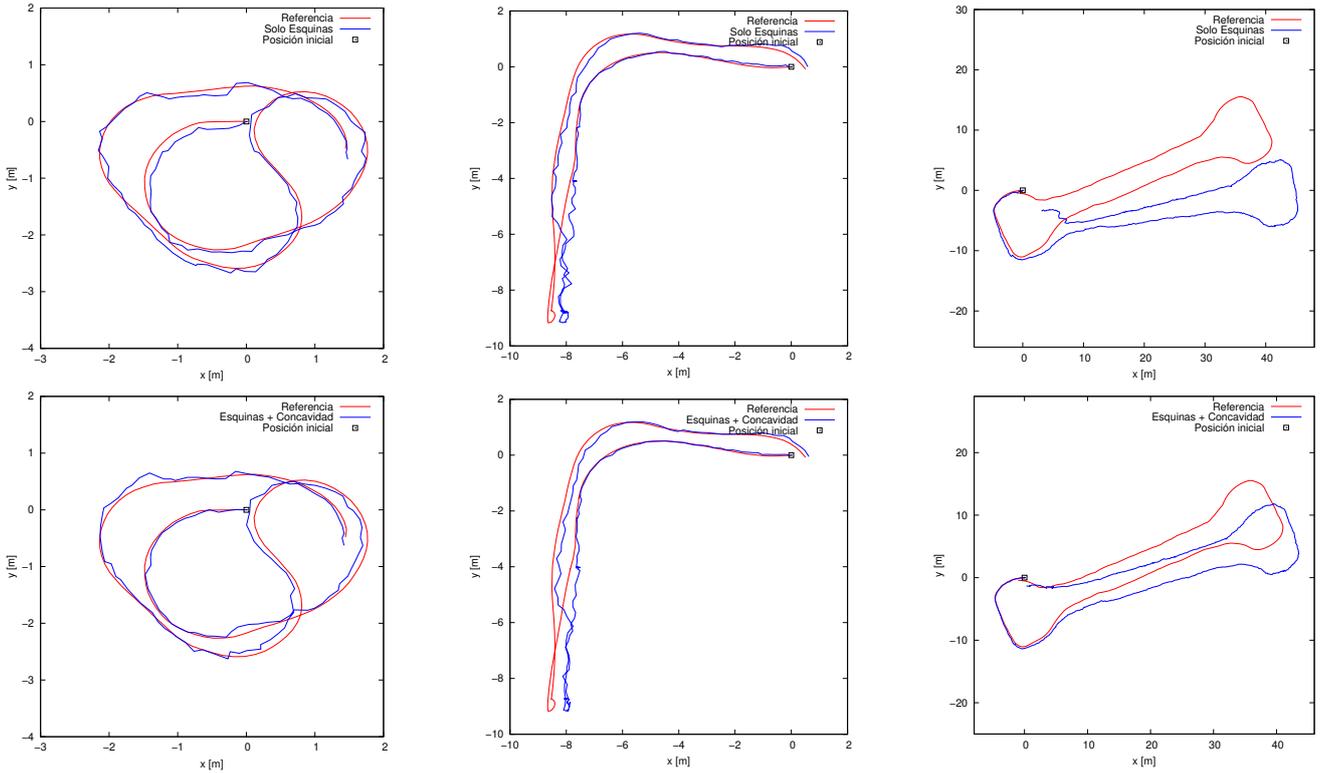


Figura 3: Estimación de la trayectoria seguida por el robot en diversos escenarios. En la fila superior, se ignora la característica de concavidad de las esquinas, mientras que en la fila inferior se diferencia entre esquinas cóncavas y convexas, de forma que las esquinas detectadas solo puedan ser asociadas con esquinas del mismo tipo detectadas previamente.

Para evaluar el funcionamiento del método propuesto, hemos comparado este con la estimación de la trayectoria del robot proporcionada por un sistema SLAM-ICP que utilizamos como trayectoria de referencia o *baseline*. Tanto el sistema propuesto como el SLAM-ICP emplean únicamente información procedente del sensor LiDAR 2D. Se ha calculado la desviación de nuestro sistema respecto a la *baseline* utilizando dos métricas de error relativo, el error de traslación y el error de rotación, evaluados en distintos intervalos entre 1 y 10 metros, de forma similar a la presentada en (Geiger et al., 2012).

Estas métricas nos permiten evaluar la eficiencia de nuestro sistema de una forma robusta, siguiendo la misma metodología que es utilizada por otros autores de trabajos similares. La Tabla 1 y la Figura 2 presentan los resultados de acuerdo a las métricas de evaluación, mientras que la Figura 3 muestra la trayectoria seguida por el robot en los entornos estudiados en comparación con la estimación realizada por el sistema SLAM-ICP.

Como se puede observar en la Tabla 1, la diferenciación de la concavidad de las esquinas detectadas tiene gran implicación en la calidad de la estimación de la posición del robot a lo largo del tiempo. De forma general, ambos sistemas producen una estimación de la posición del robot similar a la generada por el método SLAM-ICP. Sin embargo, estas modificaciones son más apreciables en uno de los entornos, que corresponde al de mayores dimensiones de aquellos que han sido analizados, véase la Figura 3.

Tabla 1: Resultados experimentales

Método	$E_{\text{traslación}}$ %	$E_{\text{rotación}}$ grados/m
Esquinas indistinguibles	5.779	0.497
Esquinas con concavidad	4.994	0.368

Tabla 2: Número medio de puntos por cada escaneo del sensor

Entorno	ICP	Esquinas
Entorno 1	3491	30
Entorno 2	3575	23
Entorno 3	3483	57

Cabe destacar que la simplificación de las lecturas realizadas por el sensor LiDAR a un conjunto característicos de esquinas que definen el entorno permite lograr una reducción en la dimensión de los datos superior al 98 % en los entornos experimentales evaluados. Tal y como puede observarse en la Tabla 2, el número medio de puntos para cada escaneo del lector es mucho menor, con la consecuente reducción del espacio necesario para almacenar las lecturas realizadas por el sensor, así como el resultado del proceso SLAM llevado a cabo.

4. Conclusiones

En este trabajo, presentamos un sistema de localización para robots móviles basado en la identificación de las esquinas que conforman un espacio estructurado y el uso de estas como puntos de referencia con respecto a la posición del robot. El sistema propuesto supone una solución simple al problema de estimar la posición de un robot en un entorno desconocido, y reduce de forma significativa la cantidad de datos a procesar con respecto a soluciones basadas en el método ICP.

Los resultados experimentales propuestos demuestran que nuestro sistema es capaz de localizar de forma razonable la posición del robot en el entorno en comparación con el clásico SLAM-ICP y muestran una mejora sustancial en la localización del robot cuando las esquinas detectadas son clasificadas teniendo en cuenta su característica de concavidad.

Cabe destacar que el sistema propuesto se basa exclusivamente en el uso de sensores LiDAR y la detección de esquinas a partir de dichos datos, sin recurrir a otras fuentes de información como las lecturas de los encoders de las ruedas del robot, que podrían permitir reducir aún más el error de localización, tal y como analizaremos en futuras revisiones de este trabajo.

Agradecimientos

Este trabajo se encuentra parcialmente financiado por la Universidad de León en el marco del "Programa Propio de Investigación de la Universidad de León 2021".

Referencias

- Altermatt, M., Martinelli, A., Tomatis, N., Siegwart, R., 2004. Slam with corner features based on a relative map. In: 2004 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)(IEEE Cat. No. 04CH37566). Vol. 2. IEEE, pp. 1053–1058.
DOI: 10.1109/IR0S.2004.1389536
- Campos, C., Elvira, R., Rodríguez, J. J. G., M. Montiel, J. M., D. Tardós, J., 2021. Orb-slam3: An accurate open-source library for visual, visual-inertial, and multimap slam. *IEEE Transactions on Robotics* 37 (6), 1874–1890.
DOI: 10.1109/TR0.2021.3075644
- Dellaert, F., 2012. Factor graphs and gtsam: A hands-on introduction. Tech. rep., Georgia Institute of Technology.
- Geiger, A., Lenz, P., Urtasun, R., 2012. Are we ready for autonomous driving? the kitti vision benchmark suite. In: Conference on Computer Vision and Pattern Recognition (CVPR).
DOI: 10.1109/CVPR.2012.6248074
- Grisetti, G., Guadagnino, T., Aloise, I., Colosi, M., Della Corte, B., Schlegel, D., 2020. Least squares optimization: From theory to practice. *Robotics* 9 (3), 51.
DOI: 10.3390/robotics9030051
- Guo, S., Rong, Z., Wang, S., Wu, Y., 2022. A lidar slam with pca-based feature extraction and two-stage matching. *IEEE Transactions on Instrumentation and Measurement* 71, 1–11.
DOI: 10.1109/TIM.2022.3156982
- Huang, J., Wen, S., Liang, W., Guan, W., 2023. Vwr-slam: Tightly coupled slam system based on visible light positioning landmark, wheel odometer, and rgb-d camera. *IEEE Transactions on Instrumentation and Measurement* 72, 1–12.
DOI: 10.1109/TIM.2022.3231332
- Li, R., Liu, J., Zhang, L., Hang, Y., 2014. Lidar/mems imu integrated navigation (slam) method for a small uav in indoor environments. In: 2014 DGON inertial sensors and systems (ISS). IEEE, pp. 1–15.
DOI: 10.1109/InertialSensors.2014.7049479
- Lin, W., Hu, J., Xu, H., Ye, C., Ye, X., Li, Z., 2017. Graph-based slam in indoor environment using corner feature from laser sensor. In: 2017 32nd Youth academic annual conference of chinese association of automation (YAC). IEEE, pp. 1211–1216.
DOI: 10.1109/YAC.2017.7967597
- Prieto-Fernández, N., Fernández-Blanco, S., Fernández-Blanco, Á., Benítez-Andrades, J. A., Carro-De-Lorenzo, F., Benavides, C., 2023. Weighted conformal lidar-mapping for structured slam. *IEEE Transactions on Instrumentation and Measurement* 72, 1–10.
DOI: 10.1109/TIM.2023.3284143
- Schuster, F., Keller, C. G., Rapp, M., Haueis, M., Curio, C., 2016. Landmark based radar slam using graph optimization. In: 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC). pp. 2559–2564.
DOI: 10.1109/ITSC.2016.7795967
- Shi, Z., Wang, P., Liu, W., Gao, C., 2023. Multi-sensor slam assisted by 2d lidar line features. In: International Conference on Haptics and Virtual Reality. Springer, pp. 73–80.
DOI: 10.1007/978-3-031-56521-2_7
- Ulas, C., Temeltas, H., 2013. A fast and robust feature-based scan-matching method in 3d slam and the effect of sampling strategies. *International Journal of Advanced Robotic Systems* 10 (11), 396.
DOI: 10.5772/56964
- Vazquez-Martín, R., Nuñez, P., del Toro, J., Bandera, A., Sandoval, F., 2006. Adaptive observation covariance for ekf-slam in indoor environments using laser data. In: MELECON 2006-2006 IEEE Mediterranean Electrotechnical Conference. IEEE, pp. 445–448.
DOI: 10.1109/MELCON.2006.1653134
- Xing, B. Y., Dang, R. N., Xu, P., Jiang, C. X., Jiang, L., apr 2020. Slam algorithm for aruco landmark array based on synchronization optimization. *Journal of Physics: Conference Series* 1507 (5), 052011.
DOI: 10.1088/1742-6596/1507/5/052011
- Zeng, Q., Tao, X., Yu, H., Ji, X., Chang, T., Hu, Y., 2023. An indoor 2d lidar slam and localization method based on artificial landmark assistance. *IEEE Sensors Journal*.
DOI: 10.1109/JSEN.2023.3341832