Revista **EIA**





Revista EIA ISSN 1794-1237 e-ISSN 2463-0950 Año XIX/ Volumen 22/ Edición N.44 Julio - diciembre 2025 Reia4424 pp. 1-20

Publicación científica semestral Universidad EIA, Envigado, Colombia

PARA CITAR ESTE ARTÍCULO / TO REFERENCE THIS ARTICLE /

Durán-Puentes, S. A.; Acosta-Amaya, G. A.; Miranda-Montoya, D. A. y Jimenez-Builes, J. A. Fusión Sensorial No Lineal Basada en Regresión de Soporte Vectorial para la Estimación de Distancia en Robótica Móvil

Revista EIA, 22(44), Reia4424 pp. 1-20 https://doi.org/10.24050/reia. v22i43.1899

Autor de correspondencia: Jimenez-Builes, J. A. Licenciado en docencia de computadores, magister en ingeniería de sistemas, doctor en ingenieríasistemas Correo electrónico: jajimen1@unal.edu.co

Recibido: 01-06-2025 **Aceptado:** 20-06-2025 **Disponible online:** 01-07-2025 Fusión Sensorial No Lineal Basada en Regresión de Soporte Vectorial para la Estimación de Distancia en Robótica Móvil

> Santiago Alexander Durán-Puentes¹ Gustavo Alonso Acosta-Amaya¹ Deimer Andrés Miranda-Montoya² M Jovani Alberto Jimenez-Builes²

1. Politécnico Colombiano Jaime Isaza Cadavid, Colombia 2. Universidad Nacional de Colombia, Sede Medellín

Resumen

La estimación precisa de distancias es un desafío crítico en robótica móvil, especialmente en entornos dinámicos donde la incertidumbre de los sensores puede afectar la navegación y la evasión de obstáculos. Este artículo propone un método de fusión sensorial no lineal basado en Regresión de Soporte Vectorial (SVR) para mejorar la estimación de distancias, utilizando un sistema de bajo costo compuesto por una cámara Logitech C270 con marcadores fiduciales ArUco, un sensor ultrasónico HC-SR04, un microcontrolador ESP32 y el middleware ROS2. La configuración experimental recopiló datos de 20 a 400 cm en intervalos de 10 cm, incorporando oclusiones controladas para simular condiciones reales. El modelo SVR, optimizado con un núcleo de función de base radial (C=10, gamma=0.5, epsilon=0.5), fusiona datos visuales y acústicos para mejorar la robustez y precisión. Los resultados de las pruebas de validación (30-200 cm) muestran que las estimaciones de distancia fusionadas alcanzan un error absoluto promedio de 1.25 cm en condiciones normales, con un pico de error cuadrático medio de 35.44 cm² a 30 cm, indicando limitaciones en rangos cortos. Bajo oclusión, la fusión reduce los errores de los sensores individuales (por ejemplo, 19.81 cm para el sonar y 35.08 cm para la cámara a 100 cm) a un promedio de 32.49 cm. Las principales contribuciones incluyen un enfoque de fusión económico que incrementa la robustez en condiciones adversas y supera los métodos de un solo sensor. Futuras investigaciones explorarán técnicas de aprendizaje profundo y

sensores adicionales para abordar los desafíos en rangos cortos y oclusiones, siguiendo tendencias en integración multimodal de sensores para navegación autónoma.

Palabras clave: Fusión sensorial, regresión de soporte vectorial, estimación de distancia, robótica móvil, marcas fiduciales, sensor de ultrasonido.

Nonlinear Sensor Fusion Based on Support Vector Regression for Distance Estimation in Mobile Robotics

Abstract

Accurate distance estimation is a critical challenge in mobile robotics, particularly in dynamic environments where sensor uncertainties can impair navigation and obstacle avoidance. This paper proposes a nonlinear sensor fusion method based on Support Vector Regression (SVR) to enhance distance estimation using a lowcost setup comprising a Logitech C270 camera with ArUco fiducial markers and an HC-SR04 ultrasonic sensor, integrated via an ESP32 microcontroller and ROS2 middleware. The experimental setup involved collecting data from 20 to 400 cm with 10 cm intervals, incorporating controlled occlusions to simulate real-world conditions. The SVR model, optimized with a radial basis function kernel (C=10, gamma=0.5, epsilon=0.5), fuses visual and acoustic data to improve robustness and precision. Results from validation experiments (30-200 cm) show that the fused distance estimates achieve an average absolute error of 1.25 cm in normal conditions, with a peak mean squared error of 35.44 cm^2 at 30 cm, indicating limitations at short ranges. Under occlusion, the fusion mitigates errors from individual sensors (e.g., 19.81 cm for sonar, 35.08 cm for camera at 100 cm), reducing the average error to 32.49 cm. The main contributions include a cost-effective fusion approach that enhances distance estimation robustness in adverse conditions and outperforms single-sensor methods. Future work will explore deep learning techniques and additional sensors to address short-range and occlusion challenges, aligning with trends in multimodal sensor integration for autonomous navigation.

Keywords: Sensor fusion, support vector regression, distance estimation, mobile robotics, fiducial markers, ultrasonic sensor.

1. Introducción

En robótica móvil, uno de los principales retos es lograr una estimación precisa y confiable de la distancia a los obstáculos circundantes, lo que permite soportar tareas de navegación e interacción con el entorno. La incertidumbre, inherente a las mediciones suministradas por los sensores, ha dado lugar al desarrollo de métodos de fusión sensorial, en los cuales se combina la información de diversas fuentes para mejorar la calidad de las mediciones y superar las limitaciones de cada sensor cuando se considera de manera individual (Alatise y Hancke 2020; Krishnamurthi *et al.*, 2020). La integración de datos procedentes de diferentes sensores, permite obtener representaciones más precisas y robustas del entorno del robot, lo que resulta particularmente útil cuando las condiciones del entorno pueden cambiar rápidamente y los sensores se ven sujetos a ruido (Li *et al.*, 2019; Yeong *et al.*, 2021).

El filtro de Kalman (Kalman Filter, KF) es uno de los métodos más empleados en la fusión sensorial, principalmente debido a su capacidad para estimar el estado de los sistemas en tiempo real y su alta eficiencia computacional. Es adecuado para modelos de medición lineales, cuya incertidumbre se puede representar mediante una distribución normal (Kumari et al., 2021; Urrea y Agramonte, 2021). Una versión mejorada de este método es el filtro de Kalman extendido (Extended Kalman Filter--EKF), que permite manejar sistemas no lineales mediante una linealización basada en una expansión de primer orden. El EKF se utiliza ampliamente en tareas de localización y mapeo simultáneo (Simultaneous Localization and Mapping, SLAM), así como en la fusión de sensores GPS (Global Positioning System, GPS) e IMU (Inertial Measurement Unit, IMU) (Kaczmarek *et al.*, 2022; Lv *et al.*, 2022).

En este artículo se propone un método de fusión sensorial basado en un modelo de regresión de soporte vectorial (Support Vector Regression, SVR) el cual mejora la estimación de la distancia a obstáculos cercanos en robots móviles. El método integra marcas fiduciales ArUco en obstáculos estáticos, procesadas mediante técnicas de visión por computador, para obtener datos espaciales confiables. Además, se emplea un sensor ultrasónico que mide la distancia a

dichas marcas. La estimación de distancia se realiza combinando las medidas derivadas del procesamiento de las marcas ArUco con las obtenidas por el sensor ultrasónico. La fusión de información visual y acústica mejora la precisión y robustez de las estimaciones en entornos dinámicos con incertidumbre, al integrar datos complementarios de múltiples fuentes. Las principales contribuciones de este trabajo son: 1) un método de fusión sensorial de bajo costo que incrementa la robustez de la estimación de distancia, especialmente en condiciones adversas de iluminación o bloqueo parcial de las marcas; y 2) una mayor precisión en la estimación de distancias a obstáculos, superando las limitaciones individuales de cada sensor. El artículo se organiza como sigue: la sección dos muestra los trabajos previos; la sección tres detalla los materiales y métodos a través de los experimentos realizados; la sección cuatro analiza los resultados y se realiza la respectiva discusión sobre los mismos; y finalmente, la sección cinco presenta las conclusiones.

2. Trabajos previos

En (Housein et al., 2022) se examina la aplicación del EKF en escenarios prácticos, considerando tanto sus limitaciones como los desafíos que surgen al integrar sensores ruidosos o con datos faltantes. A través de simulaciones y pruebas experimentales, los autores demuestran cómo el EKF mejora significativamente la precisión en la localización de un robot móvil en comparación con métodos que emplean un solo sensor. Además, en este trabajo se discuten estrategias de optimización para el EKF, que permiten aumentar la estabilidad y fiabilidad del proceso de estimación del estado del robot, abordando problemas comunes como la deriva y el error acumulativo. Los desafíos comunes en la localización de robots móviles, como los ya mencionados de la acumulación de errores y la incertidumbre, son abordados en (Moreira et al., 2020), mediante un enfoque de localización basado en balizas (beacons) y utilizando filtros de Kalman para mejorar la estimación de la posición. En este trabajo discute además, las ventajas y limitaciones de este enfoque, considerando la distribución de las balizas y los parámetros de los filtros.

Otro método ampliamente utilizado es el filtro de partículas (Particle Filtrer, PF) el cual basa su estimación en técnicas de Monte Carlo secuenciales, sirve para modelar sistemas dinámicos no lineales y con distribuciones de probabilidad no gaussianas. El PF basa su funcionamiento en representar la distribución del estado del sistema mediante un conjunto de partículas ponderadas, donde cada partícula es una hipótesis del estado real (Hafez *et al.*, 2024). El algoritmo sigue un ciclo de predicción y actualización: primero, las partículas se propagan según un modelo de transición del sistema, y luego se les asigna un peso basado en la probabilidad de las observaciones sensoriales. Finalmente, mediante un proceso de re-muestreo, se eliminan partículas con baja probabilidad y se generan nuevas partículas alrededor de aquellas con mayor peso, mejorando así la precisión de la estimación (Mráz *et al.*, 2024).

En (Ortega *et al.*, 2020) se presenta un método de localización robusto para vehículos aéreos no tripulados (Unmanned Aerial Vehicle, UAV) en entornos interiores, donde el GPS no está disponible. Se basa en la fusión de datos de múltiples sensores, particularmente cámaras de odometría visual y detección de marcadores fiduciales empleando un PF. Este enfoque permite estimar la posición del UAV combinando información de distintos sensores y manejando incertidumbres en entornos dinámicos. También se compara el enfoque propuesto con otros métodos de localización, destacando su adaptabilidad a distintos entornos simulados.

En (Shen *et al.*, 2024) la investigación se enfoca en mejorar la precisión de la localización de robots móviles utilizando cámaras monoculares, combinando redes neuronales convolucionales (CNN) con un filtro de partículas para la estimación de la posición. Mientras que la CNN proporciona una predicción inicial, el filtro de partículas la refina, especialmente en la componente de traslación, generando trayectorias más precisas y suaves. Para evitar la degeneración de partículas, se implementa un re-muestreo secuencial SIR (Sampling-Importance Resampling, SIR), que mantiene las mejores hipótesis y descarta las menos representativas. Los resultados demuestran que esta combinación reduce significativamente el error de traslación en comparación con el uso exclusivo de CNN.

Otro método muy empleado es la fusión bayesiana, la cual corresponde a un enfoque probabilístico utilizado para combinar datos de múltiples sensores y mejorar la estimación del estado de un sistema. Se basa en el teorema de Bayes y permite actualizar las creencias sobre el estado de un robot a medida que se reciben nuevas mediciones. El método resulta particularmente útil cuando los sensores ofrecen información complementaria o tienen diferentes niveles de certeza. Al integrar las probabilidades de cada medición, la fusión bayesiana proporciona una estimación más robusta, especialmente en presencia de ruido o datos faltantes. En robótica móvil, se utiliza en aplicaciones como la localización, el mapeo y la navegación (Sander y Beyerer, 2013). El uso de la optimización bayesiana para mejorar la navegación segura de robots autónomos en entornos con incertidumbre de localización es propuesto en (Oliveira et al., 2020). El enfoque diseñado por los autores integra la incertidumbre en la localización en la optimización bayesiana (Bayesian Optimization, BO) para la navegación autónoma. Utilizando un proceso gaussiano a priori y una función de adquisición ajustada (Distance-based Upper Confidence Bound, DUCB), el algoritmo ajusta dinámicamente la trayectoria del robot en tiempo real, considerando tanto la incertidumbre en su posición como en el entorno. Los resultados experimentales muestran cómo este enfoque mejora la seguridad y la precisión en la navegación de robots en entornos complejos.

Más recientemente, las redes neuronales artificiales se han utilizado en la fusión sensorial. Su funcionamiento se basa en el aprendizaje automático a partir de bases de datos disponibles, lo que permite establecer relaciones no lineales sin necesidad de modelos matemáticos explícitos. Dependiendo de la arquitectura de red utilizada, se pueden extraer características relevantes, combinar información sensorial y generar estimaciones más precisas en comparación con los métodos tradicionales (Shaukat et al., 2021). Entre los métodos más utilizados, el Perceptrón Multicapa (Multilayer Perceptron, MLP) se destaca por su capacidad para modelar relaciones no lineales a partir de grandes volúmenes de datos, siendo ideal para combinar diferentes tipos de sensores como cámaras y lidar. Las Redes Neuronales Convolucionales (Convolutional Neural Network, CNN), por su parte, son ampliamente empleadas para la fusión de información visual y no visual, debido a su eficacia en la extracción de características espaciales, lo que las hace fundamentales en tareas de mapeo y SLAM. Las Redes Neuronales Recurrentes (Recurrent Neural Network, RNN) y las Memoria a Largo Corto Plazo (Long Short-Term Memory, LSTM) son esenciales cuando se deben manejar secuencias de datos temporales, como los generados por sensores dinámicos (IMU, GPS), permitiendo la integración de datos en tiempo real para mejorar la navegación autónoma. Los autoencoders, por otro lado, son eficaces para la reducción de la dimensionalidad de los datos sensoriales, permitiendo extraer las características más relevantes para tareas de predicción y clasificación. Finalmente, las Redes Neuronales Generativas Adversariales (Generative Adversarial Network, GAN) son útiles en la fusión sensorial cuando se requiere generar datos sintéticos de alta calidad a partir de las fuentes existentes, lo que puede mejorar el entrenamiento de modelos o la creación de representaciones del entorno. Estos métodos, cada uno con sus fortalezas, ofrecen soluciones avanzadas para la fusión sensorial en entornos dinámicos y complejos (Barreto et al., 2022; Tang et al., 2023).

En el estudio desarrollado por (Duan et al., 2002) las redes neuronales se emplean para procesar los datos de múltiples sensores, extrayendo características relevantes y fusionándose en un modelo unificado. En lugar de depender de modelos físicos estrictos, el aprendizaje automático permite procesar información redundante y encontrar patrones óptimos para la estimación del estado del sistema. Este enfoque se inspira en la integración multisensorial del sistema nervioso humano, donde diferentes tipos de señales se combinan para formar una percepción coherente del entorno. En (Andronie et al., 2023) se emplean las redes neuronales en la fusión sensorial integrando múltiples fuentes de datos mediante redes profundas (DNNs) y convolucionales (CNNs), permitiendo mejorar la percepción y toma de decisiones en tiempo real. Se combinan algoritmos de detección de objetos, análisis geoespacial y simulación digital para optimizar la navegación y localización en entornos dinámicos. Entre los métodos utilizados destacan la detección de objetos basada en aprendizaje profundo, la fusión de datos geoespaciales para mejorar la estimación de estados y la optimización de redes de sensores en IoRT, mejorando la eficiencia en la transmisión y procesamiento de datos.

3. Materiales y métodos

En esta sección se detalla el diseño experimental, las herramientas hardware y software empleadas, así como los procedimientos utilizados para desarrollar y validar el método de fusión sensorial no lineal basado en Regresión de Soporte Vectorial (SVR) para la estimación de distancias en robótica móvil.

3.1. Configuración experimental

La Figura 1, ilustra la configuración experimental diseñada para la recopilación de datos necesaria en la implementación del método de fusión sensorial propuesto en este estudio. La plataforma experimental está compuesta por un trípode que sostiene una bandeja con el equipamiento sensorial, el cual incluye una cámara Logitech C270, un sensor de ultrasonido HC-SR04 y una tarjeta de desarrollo basada en el ESP32.

La cámara es utilizada para la captura de imágenes que contienen una marca fiducial, en este caso, un marcador ArUco de 9.5 × 9.5 cm fijado sobre una superficie estática (columna). Por su parte, el sensor de ultrasonido mide la distancia hasta la marca bajo el control del microcontrolador ESP32. Los datos de distancia obtenidos por este sensor son transmitidos al PC mediante una conexión WiFi, establecida a través de un router que opera en una red local. Mientras tanto, las imágenes capturadas por la cámara son transferidas al PC vía USB para su procesamiento posterior.

El sistema de adquisición de datos, compuesto por el trípode con los sensores (módulo sensorial) y el PC, se ubica inicialmente a 20 cm de la marca fiducial, en una posición perpendicular a la misma. Posteriormente, el módulo es desplazado en intervalos de 10 cm, realizando hasta 10 mediciones en cada posición. En cada punto, se registran tanto las lecturas del sensor de ultrasonido como las distancias estimadas mediante el procesamiento de la marca fiducial, incorporándose en una base de datos para su posterior análisis. Finalmente, el módulo sensorial alcanza una distancia máxima de 400 cm con respecto a la marca. **Figura 1.** Montaje experimental para la toma de medidas de distancia utilizando un sonar y una cámara. El microcontrolador ESP32 se encarga de la adquisición de datos del sensor de ultrasonido y los transmite vía WiFi a la PC. La cámara captura imágenes de las marcas ArUco para calcular la distancia mediante métodos de visión por computadora.



3.2. Generación del conjunto de datos usando el Middleware ROS

La estimación de distancia, tanto con base en las marcas Aruco como las basadas en el sensor de ultrasonido y su organización en una base de datos se llevó a cabo mediante el middleware ROS2 en su versión Humble instalado en el sistema operativo Pop_os 22.04. Esta configuración permitió obtener provecho de características de ROS como la facilidad de generar código modular, la ejecución distribuida y concurrente de procesos, la comunicación entre procesos y su compatibilidad con diferentes plataformas de hardware, como el PC y el microcontrolador para este caso. Específicamente para el ESP32 se empleó la versión de ROS para sistemas embebidos denominada micro-ROS. Aprovechando la modularidad de grano fino soportada por ROS, el nodo /data_collection en la figura 2 puede ser reemplazado por el nodo que implementa el modelo de fusión sensorial, pudiendo reutilizar los nodos de medición de distancia.

Para el procesamiento de la información contenida en las marcas fiduciales se empleó el paquete ROS *usb_cam* que corresponde a un driver de ROS para cámaras USB y la clase *ArUco* de la librería OpenCV, la cual se encapsuló en el nodo */markers_view* que se observa en el grafo de computación ROS de la figura 2. Este driver publica mensajes *sensor_ msgs/Image* en el topic */image_raw*. Dichas imágenes son convertidas del formato ROS a formato OpenCV mediante el paquete *cv_bridge*. El nodo */makers_view* fue codificado en Python. El nodo */sonar_node*, responsable del cálculo y publicación de distancias mediante el sonar, se codificó en C++ para micro-ROS y se ejecuta en el microcontrolador ESP32. Los nodos responsables de las medidas de distancia, publican periódicamente los mensajes correspondientes en los topics */sonar* y */ data*. En el primero se publican mensajes tipo *std_msgs/Float32* y en el segundo mensajes tipo *geometry_msgs/Vector3*. Los campos de interés de estas estructuras se muestran coloreadas en la figura 2. Finalmente se diseñó el nodo */data_collection* el cual se encuentra suscrito a los topics */sonar* y */ data* y es responsable de construir la base de datos requerida por el método de fusión sensorial.



3.3. Modelo de fusión basada en regresión de soporte vectorial (SVR)

Los modelos SVR se usan frecuentemente para la predicción y ajuste de curvas, tanto en problemas de regresión lineal como no lineales. Resultan ser más eficientes cuando se dispone de un número pequeño a moderado de ejemplos de entrenamiento, ya que la complejidad de su entrenamiento depende del número de vectores de soporte seleccionados. A medida que el número de ejemplos crece, la eficiencia del SVR disminuye. Este método fue seleccionado debido a su capacidad para modelar relaciones no lineales entre las características del sistema, en este caso, las medidas de distancia provistas por la cámara en combinación con las marcas Aruco y el sensor de ultrasonido. Dado que el SVR es sensible a la escala de los datos, se aplicó una normalización de las características utilizando el StandardScaler de scikit-learn, transformando los datos de entrada para obtener una media de $\mu = 0$ y una desviación estándar de $\sigma =$ 1. Este paso garantiza que las diferentes unidades de medida de las características no afecten desproporcionadamente el rendimiento del modelo.

Se utilizó el núcleo radial (RBF) para el modelo SVR, el cual resulta conveniente para modelar relaciones no lineales. Los parámetros del modelo se ajustaron de la siguiente manera:

- C=10: parámetro que controla la penalización por errores en los datos de entrenamiento. Un valor alto de C permite un ajuste más preciso, pero suele ser propenso presentar sobreajustes.
- gamma=0.5: Determina la influencia de los puntos de entrenamiento sobre la función de regresión. Un valor pequeño implica un modelo más suave, mientras que grande puede hacer que el modelo se ajuste demasiado a los datos.
- epsilon=0.5: Define el margen de error dentro del cual las predicciones son consideradas aceptables sin penalización. Este parámetro ayuda a controlar la cantidad de ajuste fino que realiza el modelo.

El modelo y el escalador se encapsularon posteriormente en el nodo de fusión desarrollado para ROS. La figura 3 muestra en, **a**) el diagrama de bloques del modelo de fusión propuesto en este trabajo y en, **b**) el grafo de computación del sistema de fusión sensorial implementado en ROS.



4. Resultados y discusión

En la Figura 4 se muestra la configuración experimental utilizada para la validación del método de fusión basado en SVR. En el fondo, se observa la marca fiducial ArUco, que permite establecer la distancia mediante el procesamiento del flujo de imágenes proporcionado por la cámara. En la parte inferior derecha de la imagen se encuentra el microcontrolador con el sonar, el cual proporciona la distancia a la pared en la que se ha colocado la marca fiducial.



Revista EIA https://doi.org/10.24050/reia.v22i44.1899

Los resultados obtenidos se consigan en las tablas 1 y 2. Para la primera se establecieron distancias de referencia a la pared cada 10 cm, iniciando en 30 cm y hasta los 200 cm. Se incorporaron medidas complementarias a los 35, 75, 115, 145 y 185 cm, como puntos de referencias diferentes a los tomados en el conjunto de datos de entrenamiento construido anteriormente. Se etiquetaron las columnas de la tabla de la siguiente manera, **dr:** distancia real, **ds:** distancia sonar, **dc:** distancia cámara, **df:** distancia fusión, **Es:** error cuadrático medio de la medida del sonar, **Ec:** error cuadrático medio de la medida de la cámara, **Ef:** error cuadrático medio de la fusión.

dr	ds	dc	df	Es	Ec	Ef
30	30.2162	31.76	38.4190	0.023	1.549	35.440
35	35.1917	36.53	40.7880	0.018	1.170	16.750
40	39.7193	41.43	43.5951	0.039	1.022	6.462
50	49.6149	51.26	50.8690	0.074	0.794	0.378
60	58.5844	60.98	59.2233	1.002	0.480	0.302
70	68.8915	71.48	69.1830	0.614	1.095	0.334
75	73.7792	75.64	73.8917	0.745	0.205	0.614
80	78.3755	80.35	78.8161	1.320	0.061	0.701
90	88.3225	90.65	89.2564	1.407	0.211	0.276
100	98.0294	100.34	99.3759	1.942	0.058	0.195
110	109.8563	110.48	109.5478	0.010	0.115	0.102
115	112.7955	115.17	114.6712	2.430	0.014	0.054
120	117.7518	120.57	119.3377	2.527	0.162	0.219
130	128.0933	130.58	129.3053	1.818	0.168	0.241
140	137.9717	141.99	139.7731	2.057	1.980	0.026
145	143.0130	148.30	145.2125	1.974	5.445	0.023
150	147.5414	150.48	148.6579	3.022	0.115	0.901
160	158.3630	163.38	159.9605	1.340	5.712	0.001
170	167.6584	172.67	169.2424	2.742	3.564	0.287
180	177.4338	182.91	179.2166	3.293	4.234	0.307
185	183.4878	190.23	185.7536	1.143	13.676	0.284
190	191.3939	194.86	191.4575	0.971	11.810	1.062
200	200.8661	202.20	200.2372	0.375	2.420	0.028

En la tabla 1, que recopila mediciones de distancia en condiciones normales para distancias de referencia (dr) de 30 a 200 cm, se demuestra que el sistema de fusión basado en la regresión no lineal de soporte vectorial (SVR) logra estimaciones precisas, con valores de ds (distancia sonar), dc (distancia cámara) y df (distancia fusión) cercanos a **dr**. Por ejemplo, para **dr** = 100 cm, los valores son **ds** = 98.0294 cm, dc = 100.34 cm y df = 99.3759 cm, con un error promedio absoluto de aproximadamente 1.13 cm para ds, 1.28 cm para dc y 1.25 cm para df a lo largo de la tabla, calculado como el promedio de las diferencias absolutas respecto a dr. Los errores cuadráticos medios (Es, Ec, Ef) varían significativamente, **Es** oscila entre 0.010 y 3.293 cm², **Ec** entre 0.014 y 13.676 cm², y Ef entre 0.001 y 35.440 cm². El valor elevado de **Ef** en distancias cortas (35.440 cm² en dr = 30 cm) sugiere que la fusión sensorial es menos efectiva en rangos cercanos, posiblemente debido a limitaciones en la resolución de los marcadores ArUco o interferencias en el sonar. Esto plantea la necesidad de investigar ajustes en el regresor, como la optimización de hiperparámetros o la incorporación de datos adicionales en distancias cortas para mejorar la robustez.





Revista **EIA**

En la figura 5 (a) se trazan las distancias medidas por el sonar (**ds**, en rojo), la cámara (**dc**, en verde), y la fusión sensorial (**df**, en azul) frente a la distancia real (**dr**, en negro), que sigue una línea recta ideal. Las cuatro líneas están muy cercanas entre sí a lo largo del rango de 30 a 200 cm, lo que indica una alta precisión general en las mediciones de los sensores y el método de fusión. En la figura 5 (b) se presentan los errores cuadráticos medios en función de la distancia real (dr). Se observa una variabilidad significativa en los errores, con un pico notable en **Ef** (35.440 cm²) en **dr** = 30 cm, lo que indica que la fusión sensorial tiene un desempeño deficiente en distancias cortas. A partir de **dr** = 35 cm, los errores disminuyen drásticamente: Por ejemplo, en dr = 100 cm, los errores son Es = 1.942 cm², Ec = 0.058 cm² y Ef = 0.195 cm^2 , mostrando que la cámara (**Ec**) tiene un error excepcionalmente bajo en este punto, mientras que la fusión (Ef) supera al sonar pero no a la cámara. En distancias mayores, como dr = 185 cm, Ec alcanza un pico de 13.676 cm², lo que sugiere que la cámara es más susceptible a errores en rangos largos, posiblemente debido a la disminución de la resolución de los marcadores ArUco o a condiciones de iluminación. En contraste, Es v Ef permanecen más estables, con valores de 1.143 cm² y 0.284 cm², respectivamente, en el mismo punto. Esto indica que el sonar y la fusión son más robustos en distancias largas.

El experimento para obtener la tabla 2, tuvo como objetivo evaluar el desempeño del sistema de fusión bajo condiciones de oclusión que afectaran tanto al sonar como a la cámara. Se seleccionaron cinco distancias de referencia (**dr**: 70, 100, 130, 160 y 190 cm) para realizar las pruebas bajo condiciones controladas, donde se introdujeron obstrucciones deliberadas para simular escenarios realistas en los que los sensores enfrentan limitaciones, como objetos interpuestos o condiciones de visibilidad reducida. Las columnas de la tabla incluyen: dr (distancia real en cm), ds (distancia medida por el sonar sin oclusión), dc (distancia medida por la cámara sin oclusión), doc_s (distancia medida por el sonar bajo oclusión), **doc_c** (distancia medida por la cámara bajo oclusión), dfoc_s (distancia estimada por fusión sensorial bajo oclusión para el sonar) y dfoc_c (distancia estimada por fusión sensorial bajo oclusión para la cámara). Este experimento permitió comparar la precisión de las mediciones individuales de los sensores y la efectividad de la fusión sensorial en presencia de oclusiones.

Para simular oclusiones, se introdujeron obstrucciones físicas (por ejemplo, objetos opacos o reflectantes) que interfirieron parcialmente con el campo de visión de la cámara o la propagación de las ondas del sonar, afectando las mediciones de **doc_s** y **doc_c**. El SVR combinó las mediciones de ambos sensores para generar estimaciones de fusión (**dfoc_s** y **dfoc_c**) que buscan mitigar los errores inducidos por las oclusiones. Las mediciones se realizaron en un entorno controlado para garantizar la consistencia de las distancias de referencia y la reproducibilidad de las condiciones de oclusión.

dr	ds	dc	doc_s	doc_c	dfoc_s	dfoc_c
70	68.8745	71.39	30.2011	32.17	56.4187	56.8994
100	98.0294	100.27	19.8082	35.08	78.2650	81.7188
130	128.1448	130.58	30.4584	31.52	103.2459	105.8010
160	158.3490	162.68	31.2472	32.14	124.2301	131.7163
190	191.3939	193.28	30.4755	31.07	152.8853	155.3613

La tabla 2, revela un impacto notable de las obstrucciones en las mediciones individuales del sonar (doc_s) y la cámara (doc_c), con valores que oscilan entre 19.8082 y 35.08 cm, reflejando errores significativos en comparación con dr. Por ejemplo, para dr = 100cm, $doc_s = 19.8082$ cm y $doc_c = 35.08$ cm, lo que indica una subestimación severa, especialmente en el sonar. Sin embargo, las estimaciones de fusión bajo oclusión (dfoc_s y dfoc_c) muestran una mejora considerable, con valores entre 56.4187 y 155.3613 cm y un error promedio absoluto de 33.43 cm para dfoc_s y 31.54 cm para dfoc_c (calculado respecto a dr). Aunque estas estimaciones están más cerca de **dr** que las mediciones individuales con oclusión, los errores son mayores que en condiciones normales, sugiriendo que la fusión sensorial mitiga parcialmente el impacto de las oclusiones, pero no las elimina por completo. La diferencia promedio entre dfoc_s y dfoc_c es de 3.27 cm, lo que indica una consistencia relativa entre ambas estimaciones de fusión, pero también sugiere que la cámara podría ser más robusta frente a oclusiones en ciertos rangos.

Los resultados destacan la fortaleza del enfoque de fusión sensorial para mejorar la precisión en entornos desafiantes, pero también revelan limitaciones que merecen discusión. La mayor variabilidad en los errores de la primera tabla en distancias cortas y los errores significativos bajo oclusión en la segunda tabla sugieren que el regresor no lineal de soporte vectorial podría beneficiarse de un ajuste fino, como la incorporación de características adicionales (por ejemplo, información sobre la intensidad de la señal del sonar o la calidad de detección de los marcadores ArUco). Además, el contraste entre los errores bajos en condiciones normales (promedio de $Ef \approx 2.07 \text{ cm}^2$) y los valores más altos bajo oclusión (promedio de diferencias absolutas de **dfoc_s** y **dfoc_c** \approx 32.49 cm) indica que las oclusiones representan un desafío crítico para la robustez del sistema. Esto invita a explorar estrategias complementarias, como el uso de sensores redundantes, algoritmos de filtrado avanzados (por ejemplo, filtros de Kalman) o técnicas de aprendizaje profundo para modelar mejor las condiciones de oclusión. Asimismo, un análisis más detallado de los datos, como correlaciones entre los errores y las distancias, o pruebas en entornos más complejos, podría proporcionar información valiosa para optimizar el sistema en aplicaciones de robótica móvil.

5. Conclusiones

El experimento valida que la integración de datos de un sensor ultrasónico y una cámara con marcadores ArUco, mediante un modelo de Regresión de Soporte Vectorial (SVR), mejora significativamente la estimación de distancias en robótica móvil, alcanzando un error absoluto promedio de 1.25 cm en condiciones normales y reduciendo errores bajo oclusiones a un promedio de 32.49 cm. Este hallazgo refuerza la relevancia de la fusión multisensorial, un enfoque consolidado en la literatura reciente que reporta incrementos de precisión del 20-30% en navegación autónoma (Fayyad *et al.*, 2020), consolidando su aplicabilidad en entornos dinámicos.

El estudio presentado ofrece una solución económica y práctica que supera las limitaciones individuales de los sensores, demostrando robustez en condiciones adversas como oclusiones parciales y variaciones de iluminación. La integración con ROS2 y micro-ROS proporciona un marco escalable para la adquisición y fusión de datos, constituyendo una contribución valiosa para la comunidad científica y técnica, especialmente en contextos donde los recursos son limitados, alineándose con tendencias de desarrollo de sistemas accesibles en robótica móvil.

Se observa una limitación significativa en la precisión del modelo SVR a distancias cortas (error cuadrático medio de 35.44 cm² a 30 cm) y bajo oclusiones severas, lo que sugiere la necesidad de ajustes en el regresor o la incorporación de técnicas complementarias. Este resultado invita a explorar avances en aprendizaje profundo, como Redes Neuronales Convolucionales, que han mostrado mejoras del 25% en estimaciones de corto alcance (Li *et al.*, 2019, abriendo nuevas avenidas para futuras investigaciones en fusión sensorial.

Los hallazgos del experimento sientan las bases para futuras investigaciones que integren sensores adicionales, como LIDAR o cámaras térmicas, y modelos de inteligencia artificial multimodal, los cuales están ganando terreno en robótica autónoma con incrementos de precisión del 30% en entornos complejos (Tang *et al.*, 2019). Estas direcciones prometen avanzar en la robustez y versatilidad del sistema, facilitando su implementación en aplicaciones críticas como vehículos autónomos o robots de entrega en entornos urbanos desafiantes.

6. Referencias

- Alatise, M.; Hancke, G. (2020). A review on challenges of autonomous mobile robot and sensor fusion methods. *IEEE Access*, 8, 39830-39846. https://doi. org/10.1109/ACCESS.2020.2975643
- Andronie, M.; Lăzăroiu, G.; Iatagan, M.; Hurloiu, I.; Ștefănescu, R.; Dijmărescu, A.; Dijmărescu, I. (2023). Big data management algorithms, deep learning-based object detection technologies, and geospatial simulation and sensor fusion tools in the internet of robotic things. *ISPRS International Journal of Geo-Information*, 12(35). https://doi.org/10.3390/ijgi12020035
- Barreto, A.; Gómez, A.; Escobedo, J.; Cuan, E.; Cruz, S. (2022). Sensor data fusion for a mobile robot using neural networks. *Sensors*, 22(1), 305. https://doi. org/10.3390/s22010305

- Duan, S.; Shi, Q.; Wu, J. (2022). Multimodal sensors and ML-based data fusion for advanced robots. *Advanced Intelligent Systems*, 4(12), 2200213. https://doi.org/10.1002/aisy.202200213
- Fayyad, J.; Jaradat, M.; Gruyer, D.; Najjaran, H. (2020). Deep learning sensor fusion for autonomous vehicle perception and localization: A review. *Sensors*, 20(15), 4220. https://doi.org/10.3390/s20154220
- Hafez, O.; Joerger, M.; Spenko, M. (2024). How safe is particle filtering-based localization for mobile robots? An integrity monitoring approach. *IEEE Transactions on Robotics*, 40, 3372–3387. https://doi.org/10.1109/TR0.2024.3420798
- Housein, A. A.; Xingyu, G.; Li, W.; Huang, Y. (2022). Extended Kalman filter sensor fusion in practice for mobile robot localization. *International Journal of Advanced Computer Science and Applications*, 13(2), 33-38. https://doi.org/10.14569/ IJACSA.2022.0130204
- Kaczmarek, A.; Rohm, W.; Klingbeil, L.; Tchórzewski, J. (2022). Experimental 2D extended Kalman filter sensor fusion for low-cost GNSS/IMU/Odometers precise positioning system. *Measurement*, 193, 110963. https://doi.org/10.1016/j. measurement.2022.110963
- Krishnamurthi, R.; Kumar, A.; Gopinathan, D.; Nayyar, A.; Qureshi, B. (2020). An overview of IoT sensor data processing, fusion, and analysis techniques. *Sensors*, 20(21), 6076. https://doi.org/10.3390/s20216076
- Kumari, N.; Kulkarni, R.; Ahmed, M.; Kumar, N. (2021). Use of Kalman filter and its variants in state estimation: A review. En: *Artificial Intelligence for a Sustainable Industry 4.0* (pp. 213-230). https://doi.org/10.1007/978-3-030-77070-9_13
- Li, C.; Fahmy, A.; Sienz, J. (2019). An augmented reality based human-robot interaction interface using Kalman filter sensor fusion. *Sensors*, 19(20), 4586. https:// doi.org/10.3390/s19204586
- Li, Y.; He, L.; Zhang, X.; Zhu, L.; Zhang, H.; Guan, Y. (2019). Multi-sensor fusion localization of indoor mobile robot. En: *IEEE International Conference on Real-time Computing and Robotics (RCAR)* (pp. 481-486). https://doi.org/10.1109/ RCAR47638.2019.9044006
- Lv, M.; Wei, H.; Fu, X.; Wang, W.; Zhou, D. (2022). A loosely coupled extended Kalman filter algorithm for agricultural scene-based multi-sensor fusion. *Frontiers in Plant Science*, 13, 849260. https://doi.org/10.3389/fpls.2022.849260
- Moreira, A.; Costa, P.; Lima, J. (2020). New approach for beacons based mobile robot localization using Kalman filters. *Procedia Manufacturing*, 51, 512-519. https://doi.org/10.1016/j.promfg.2020.10.072
- Mráz, E.; Trizuljak, A.; Rajchl, M.; Sedláček, M.; Štec, F.; Stanko, J.; Rodina, J. (2024). Multi-sensor fusion for robust indoor localization of industrial UAVs using particle filter. *Journal of Electrical Engineering*, 75(4), 304-316. https://doi. org/10.2478/jee-2024-0037

- Oliveira, R.; Ott, L.; Guizilini, V.; Ramos, F. (2020). Bayesian optimisation for safe navigation under localisation uncertainty. En: *Robotics Research: The 18th International Symposium ISRR* (pp. 489-504). Springer International Publishing. https://doi.org/10.48550/arXiv.1709.02169
- Ortega, J.; Gutiérrez, O.; Aguirre, J. (2022). Simulación del control de un robot móvil tipo Rover basado en fusión de sensores mediante filtro de partículas. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, 10, 100-106. https:// doi.org/10.29057/icbi.v10iEspecial6.9366
- Sander, J.; Beyerer, J. (2013). Bayesian fusion: Modeling and application. En: 2013 Workshop on Sensor Data Fusion: Trends, Solutions, Applications (SDF) (pp. 1-6). IEEE. https://doi.org/10.1109/SDF.2013.6698254
- Shaukat, N.; Ali, A.; Javed, M.; Moinuddin, M.; Otero, P. (2021). Multi-sensor fusion for underwater vehicle localization by augmentation of RBF neural network and error-state Kalman filter. *Sensors*, 21(4), 1149. https://doi.org/10.3390/ s21041149
- Shen, Y.; Liu, H.; Liu, X.; Zhou, W.; Zhou, C.; Chen, Y. (2024). Localization through particle filter powered neural network estimated monocular camera poses. *arXiv* preprint, arXiv:2404.17685. https://doi.org/10.48550/arXiv.2404.17685
- Tang, Q.; Liang, J.; Zhu, F. (2023). A comparative review on multi-modal sensors fusion based on deep learning. *Signal Processing*, 213, 109165. https://doi. org/10.1016/j.sigpro.2023.109165
- Urrea, C.; Agramonte, R. (2021). Kalman filter: Historical overview and review of its use in robotics 60 years after its creation. *Journal of Sensors*, 2021(1), 9674015. https://doi.org/10.1109/MSP.2025.3569395
- Yeong, D.; Velasco, G.; Barry, J.; Walsh, J. (2021). Sensor and sensor fusion technology in autonomous vehicles: A review. *Sensors*, 21(6), 2140. https://doi. org/10.3390/s21062140