

Jornadas de Automática

Evaluación de detección de caídas mediante visión computacional y radar

Sánchez-Girón, Celia^{a,*}, Duque-Domingo, Jaime^a, Gómez-García-Bermejo, Jaime^{a,b}, Zalama, Eduardo^{a,b}

^aDISA-ITAP, Universidad de Valladolid, C/ Dr Mergelina s/n, 47011 Valladolid, España

^bCARTIF Centro Tecnológico 47151, Valladolid, España

To cite this article: Sánchez-Girón, C., García-Gómez, M., Duque-Domingo, J., Gómez-García-Bermejo, J., Zalama, E. 2025. Evaluation of fall detection by computer vision and radar. *Jornadas de Automática*, 46.
<https://doi.org/10.17979/ja-cea.2025.46.12069>

Resumen

Las caídas representan el accidente más frecuente entre las personas mayores y, cuando ocurren en el domicilio, cerca del 70 % de quienes las sufren no logran levantarse por sí mismos ni solicitar ayuda de forma inmediata. Por ello, disponer de sistemas de detección automática de caídas resulta esencial para garantizar una respuesta rápida, reducir el tiempo de inatención y mejorar la calidad de vida de las personas mayores. En este estudio se comparan dos enfoques para la detección en el hogar: un sistema radar fijo, evaluado en diferentes configuraciones, y un detector de visión computacional integrado en un robot móvil, que cubre zonas ciegas sin necesidad de calibración previa. Ambos sistemas fueron sometidos a varias pruebas representadas en las mismas condiciones, simulando cinco tipos de caída en cuatro ubicaciones diferentes. El presente documento recoge los resultados obtenidos tras la experimentación, así como las situaciones más idóneas en las que utilizar cada sistema de detección.

Palabras clave: Visión por computadora, Sensores inteligentes, Detección de caídas, Robots móviles, Aprendizaje profundo.

Evaluation of fall detection by computer vision and radar

Abstract

Falls are the most frequent accident among the elderly and, when they occur at home, nearly 70 % of those who fall are unable to get up on their own or seek help immediately. Therefore, automatic fall detection systems are essential to ensure a rapid response, reduce inattention time and improve the quality of life of the elderly.

This study compares two approaches for detection in the home environment: a fixed radar system, evaluated in different configurations, and a computer vision-based detector integrated into a mobile robot, whose mobility allows it to cover blind areas without the need for prior calibration. Both systems were tested under controlled conditions, simulating five types of fall in four different locations. This paper presents the results obtained after experimentation, as well as the most suitable contexts for the application of each detection system.

Keywords: Computer vision, Smart sensors, Fall detection, Mobile robots, Deep Learning.

1. Introducción

El tema de la detección de caídas en adultos mayores es de suma importancia en el contexto de la salud pública y el cuidado domiciliario, ya que las caídas constituyen una de las principales causas de lesiones graves y hospitalizaciones en esta población (INE, 2023).

La creciente necesidad de métodos de monitoreo ha impul-

sado el desarrollo de diversas tecnologías, entre las cuales destacan las basadas en visión por computadora y las que utilizan tecnología radar. Estas dos aproximaciones poseen ventajas y limitaciones diferenciadas en términos de precisión, tiempo de respuesta, complejidad de implementación y adaptación a entornos domésticos. En este estudio se presentan y comparan dos aproximaciones tecnológicas complementarias para la detección automática de caídas: por un lado, un sistema radar

*Autor para correspondencia: celia.sanchez-giron@uva.es

comercial basado en análisis de señales Doppler; por otro, un sistema de visión por computador que emplea técnicas avanzadas de aprendizaje profundo, integradas en un robot social autónomo. En este artículo se presenta una revisión y análisis comparativo entre la detección de caídas basada en visión por computadora, apoyada en técnicas de estimación de poses y redes neuronales profundas, y métodos basados en tecnología radar, para entender las potencialidades y limitaciones de cada enfoque en la monitorización de la salud de adultos mayores en contextos reales.

2. Literatura previa

Aproximadamente el 30 % de los mayores de 65 años y el 50 % de los mayores de 80 años sufren al menos una caída al año (Ministerio de Sanidad, 2025). En los últimos años, la visión por computador ha emergido como una de las tecnologías más investigadas para la detección no intrusiva de caídas. En el campo de la visión artificial, se han explorado diversas áreas, como el reconocimiento de imágenes, la detección de objetos y el seguimiento de movimiento (Anwary et al., 2022; Rao et al., 2008). Autores como (Alam et al., 2022) presentan una revisión exhaustiva de técnicas basadas en aprendizaje profundo para la detección de caídas a partir de vídeo, describiendo arquitecturas de redes neuronales convolucionales (CNN) y conjuntos de datos de referencia como UR Fall Detection y UP-Fall.

De forma complementaria, (Gaya-Morey et al., 2024) llevan a cabo un estudio sistemático centrado en el reconocimiento de actividad humana y detección de caídas usando Deep Learning, analizando no solo modelos CNN sino también redes recurrentes (RNN) y técnicas de transferencia de aprendizaje aplicadas a cámaras RGB, de profundidad y térmicas. Estos trabajos coinciden en subrayar la alta sensibilidad alcanzable y la necesidad de mitigar falsos positivos derivados de movimientos voluntarios o posturas estáticas (por ejemplo, personas tumbadas).

La tecnología radar ofrece ventajas claras en términos de robustez frente a oclusiones, variaciones de iluminación y preservación de la privacidad. (Tewari et al., 2024) publican una revisión sistemática de técnicas radar para detección remota de caídas, clasificando los métodos según el tipo de procesamiento de señal (Micro-Doppler, Range-Doppler, Range-Doppler-Ángulos) y resaltando cómo el auge de radares FMCW y las configuraciones MIMO han potenciado la obtención de información angular y de distancia. Asimismo, autores como (Hu et al., 2024) hacen un repaso más general examinando 74 estudios desde el año 2000. El estudio concluye que el análisis de espectros Micro-Doppler combinado con clasificadores basados en *Machine Learning* (SVM, Random Forest) ha sido el enfoque predominante hasta la incorporación masiva de redes neuronales profundas.

3. Descripción de los sistemas tecnológicos

En esta sección se presentan los fundamentos técnicos, configuraciones y procedimientos experimentales empleados para comparar dos enfoques tecnológicos de detección de caídas: el sistema basado en radar de la empresa Ingevital,

y un sistema de visión artificial integrado en el robot social Temi. Ambos han sido evaluados en entornos controlados con sujetos humanos realizando diversas tipologías de caídas, permitiendo así una evaluación rigurosa y cuantitativa de su comportamiento.

3.1. Sistema radar de caídas

Se ha adquirido un radar de la empresa Ingevital (Ingevital, 2024) para detectar caídas y otras actividades en tiempo real. Ingevital es una empresa especializada en tecnologías de monitorización no intrusiva, particularmente centrada en el cuidado de personas mayores en el hogar. Entre sus soluciones destacan sus radares pasivos para la detección de constantes vitales y eventos críticos como las caídas. Estos dispositivos utilizan tecnología de radar de onda continua modulada en frecuencia (FMCW), que permite detectar presencia, movimiento y la posición de personas sin necesidad de llevar dispositivos encima ni utilizar cámaras, garantizando así la privacidad total del usuario.

El sistema utiliza algoritmos como KNN (*K-nearest Neighbors*) sobre características extraídas de señales Doppler para identificar cambios bruscos en la postura. Diseñado para entornos domésticos, ofrece monitorización no intrusiva de presencia, movimiento y constantes vitales. Se integra mediante un gateway y una aplicación móvil para una gestión remota eficiente.

3.2. Sistema de visión por computador con robot Temi

El segundo enfoque se basa en la visión artificial aplicada mediante aprendizaje profundo, utilizando para ello el robot móvil Temi (Temi, 2024). Este robot, diseñado para la interacción social, está equipado con cámaras de alta definición y capacidades de navegación autónoma, lo que le permite moverse libremente por el hogar y capturar imágenes desde distintos ángulos y ubicaciones.

El sistema de detección de caídas forma parte de un plan representado en la Figura 1, en el que Temi capturará imágenes de los individuos en sus domicilios y se enviarán al método de detección de caídas para evaluar su posición. Si detecta a una persona en el suelo, el robot verifica su estado mediante una pregunta. Si el usuario responde negativamente, se contacta con su contacto de emergencia; en caso contrario, se continúa con la rutina diaria. Si no se detecta a nadie, el robot se desplaza a una nueva ubicación para volver a intentar la detección.

Para abordar la detección automática de caídas, se ha desarrollado una metodología innovadora que combina redes neuronales profundas con estrategias de mejora de la generalización del modelo (Sánchez-Girón et al., 2024).

El proceso de detección comienza con la adquisición de imágenes por parte del robot, que se envían al sistema de análisis visual para determinar si alguna persona en la escena ha sufrido una caída.

En la primera fase, el modelo YOLOv8 detecta objetos clave en la imagen, incluyendo personas y elementos contextuales como camas, sillas y sofás, considerados relevantes para interpretar correctamente la postura final del individuo. Con esta información, se extraen los *bounding boxes* de los objetos y se evalúa el solapamiento de los bounding boxes de los objetos y de las personas en la imagen. En la segunda fase del

sistema, las imágenes y las coordenadas obtenidas se procesan a través de varios modelos basados en redes convolucionales para determinar si la persona de la imagen se ha caído. Los modelos han sido entrenados utilizando el conjunto de datos FPDS (Maldonado-Bascon et al., 2019), que contiene 3867 imágenes de personas que se han caído y 1005 imágenes de personas realizando otras actividades. Las imágenes fueron capturadas en entornos cerrados con posturas diferentes y occlusiones variadas.

Los modelos han sido entrenados previamente mediante la técnica de generalización Cross Validation Voting (Domingo et al., 2022), que consiste en dividir el conjunto de entrenamiento en diferentes subconjuntos o *slots*, cada uno con su propio conjunto de validación. Para cada partición, se entrena un modelo ConvNeXt con *early stopping* sobre su validación específica, lo que ayuda a reducir el sobreajuste. Una vez entrenados los modelos, sus salidas se combinan utilizando *Soft Voting*, ponderando las predicciones según las probabilidades emitidas por cada modelo. Esta estrategia permite compensar los errores individuales de cada red y mejorar la robustez general del sistema frente a datos nuevos.

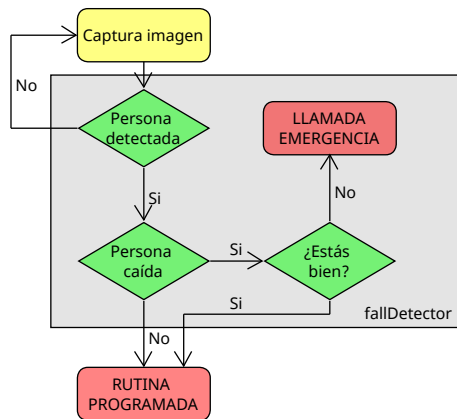


Figura 1: Plan de detección de caídas implementado en robot Temi

4. Configuración experimental

Con el objetivo de evaluar comparativamente el rendimiento de los sistemas de detección de caídas, basado en radar y basado en visión por computador, se diseñó un protocolo experimental controlado que garantizara condiciones homogéneas para ambos enfoques. Esta sección detalla las características del entorno de pruebas, los protocolos seguidos y las configuraciones específicas empleadas en cada sistema.

4.1. Entorno de pruebas

Los experimentos se llevaron a cabo en el laboratorio del Departamento de Ingenierías de Sistemas y Automática, en la Universidad de Valladolid, en un espacio simulado que replicaba las condiciones de una habitación doméstica típica. El entorno incluía una cama estándar (1.8 m x 0.9 m) elevada 0.5 m del suelo, rodeada de espacio libre en sus laterales y zona de los pies, permitiendo simular distintos tipos y ubicaciones de caídas.

El objetivo era evaluar la capacidad de ambos sistemas para detectar caídas en posiciones variadas y en condiciones

realistas, considerando además factores como la orientación del sensor, obstáculos, distancia al objeto caído y presencia de mobiliario.

Participaron cinco sujetos humanos (tres hombres y dos mujeres) con alturas comprendidas entre 1.65 y 1.90 metros y pesos entre 55 y 90 kg. A cada uno se le solicitó simular cinco tipos diferentes de caídas de forma controlada: caída hacia delante (1), caída hacia atrás (2), caída de lado (3), caída desde una silla (4), caída desde la cama (5). En la Figura 2 se muestran imágenes de las diferentes posiciones en las que los participantes han simulado la caída.

Además, para cada tipo de caída se establecieron cuatro ubicaciones en relación con la cama: a los pies de la cama (1), lateral izquierdo (2), lateral derecho (3), zona alejada de la cama (4). En la Figura 3 se indican (sobre un esquema de la aplicación de Ingevit) las ubicaciones escogidas de forma aproximada.

Estas combinaciones dieron lugar a un conjunto de situaciones altamente representativas de los escenarios en los que pueden producirse caídas reales dentro del hogar. En total se realizaron 150 ensayos controlados, distribuidos en 100 situaciones de caída y 50 situaciones de no caída, como agacharse, sentarse bruscamente, caminar rápidamente o tropezar sin llegar a caer. Estas situaciones se utilizaron para evaluar la capacidad de los sistemas de evitar falsos positivos.

4.2. Configuración del radar

La configuración inicial es clave para el correcto funcionamiento del sistema de detección de caídas. La colocación óptima del radar garantiza una cobertura del área de interés que se quiere controlar y minimiza la aparición de zonas ciegas, como se muestra en la Figura 3.




Figura 3: Zona ciega estimada del radar de caídas (marcada en violeta)

Por eso, además de realizar pruebas de diferentes caídas en diferentes puntos del entorno controlado, se han probado dos configuraciones en las que se ha colocado el radar de forma estratégica para evaluar posibles situaciones reales:

- **Configuración 1:** Radar situado centrado en el cabecero de la cama, buscando una cobertura uniforme en ambos laterales y el extremo inferior.
- **Configuración 2:** Radar desplazado 20 cm hacia la derecha desde el centro del cabecero, optimizando la detección en uno de los lados; útil en habitaciones donde la cama está pegada a una pared.

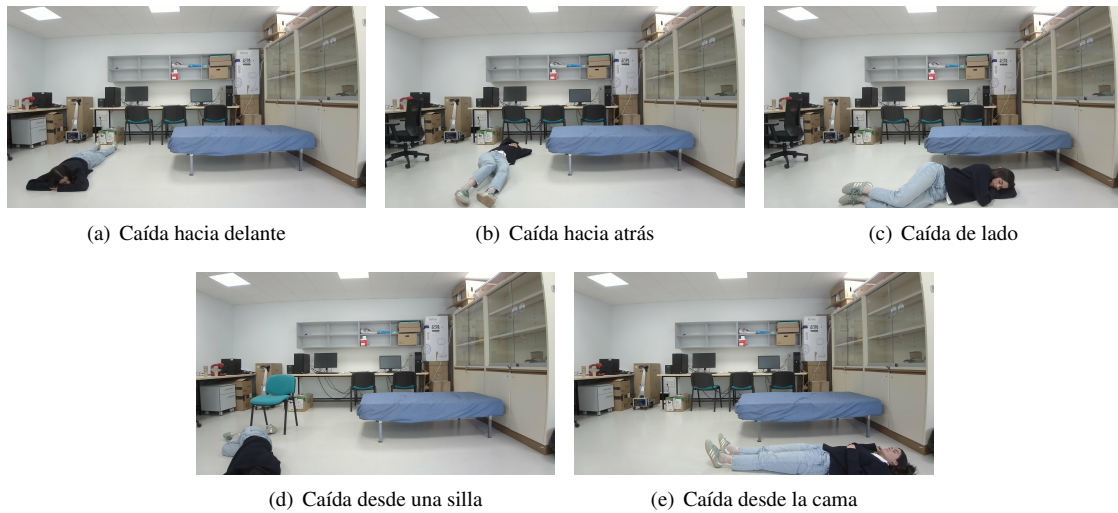


Figura 2: Ejemplos de tipos de caídas

Ambas configuraciones fueron evaluadas mediante los mismos ensayos y bajo idénticas condiciones ambientales. Los resultados permitieron valorar el impacto de la orientación física del radar sobre la eficacia de detección, así como la aparición de zonas ciegas o sensibilidad diferencial.

4.3. Configuración del sistema de visión

Como se ha comentado anteriormente, Temi es un robot social móvil que puede desplazarse a diferentes ubicaciones para asistir al usuario. De esta forma, el robot actuará no solo como plataforma de adquisición de datos visuales, sino también como un elemento proactivo del sistema que se desplazará por el entorno para mejorar la predicción. Las pruebas se realizaron en condiciones de iluminación estándar, sin interferencias externas ni movimiento de fondo, con el fin de evaluar exclusivamente la capacidad del modelo para discriminar caídas visuales en escenarios controlados.

Para comprobar el comportamiento del robot en unas condiciones próximas a la realidad, se escogieron dos posiciones alrededor del entorno de prueba, desde donde capturó imágenes estáticas de los participantes tras cada caída simulada.

Se ha planteado así porque el sistema de asistencia ante caídas contempla diferentes ubicaciones de captura de imágenes en una misma habitación. De esta forma, en una misma habitación habrá dos puntos fijos en los que se situará el robot para tomar imágenes y realizar la predicción. Si el sistema de asistencia se ejecuta, y el robot no detecta ninguna persona desde la primera ubicación de la habitación, entonces se desplazará hasta la segunda ubicación de la sala para evaluar el entorno desde varias perspectivas. Las imágenes tomadas desde las diferentes posiciones fueron procesadas posteriormente por el modelo de detección de caídas explicado anteriormente, sin intervención del robot en la clasificación.

5. Resultados

En esta sección se presentan los resultados obtenidos tanto por el sistema de detección de caídas basado en visión por computador como por el radar de caídas. Como se ha comentado anteriormente, para cada sistema se realizaron 100 pruebas

de caídas y 50 pruebas de no caídas, en las que participaron 5 sujetos diferentes. Estas pruebas se realizaron probando cinco tipos de caídas diferentes y cuatro ubicaciones en las que la persona simulaba una caída.

En la Figura 4 se muestran las matrices de confusión obtenidas a partir de las situaciones detectadas en cada uno de los sistemas. En la esquina superior derecha se representan los falsos negativos, es decir, caídas que no han sido detectadas; en la esquina inferior izquierda los falsos positivos, no caídas que han sido detectadas como caídas; los valores de la diagonal principal son las predicciones correctas que ha realizado el modelo. Igualmente, se han calculado distintas métricas para comparar el rendimiento global del sistema que se muestran en la Tabla 1.

Tabla 1: Métricas de rendimiento de los sistemas de detección de caídas

| Métrica | Visión | Radar (Conf. 1) | Radar (Conf. 2) |
|---------------------|--------|-----------------|-----------------|
| <i>Exactitud</i> | 0.87 | 0.88 | 0.73 |
| <i>Precision</i> | 0.88 | 1.0 | 1.0 |
| <i>Sensibilidad</i> | 1.00 | 0.83 | 0.62 |
| <i>F1-Score</i> | 0.93 | 0.91 | 0.77 |

La Tabla 1 resume las métricas de rendimiento global para cada sistema.

Por un lado, el sistema de visión alcanza una alta sensibilidad y un F1-score de 0,93, lo que indica que detecta correctamente la mayoría de las caídas, aunque presenta un mayor número de falsos positivos, como se observa en la Figura 4. Esto se debe a que el modelo basado en visión por computador en ocasiones confunde cuando una persona está tumbada en la cama y cuando está tirada en el suelo.

Por otro lado, el radar destaca porque ha detectado correctamente todas las situaciones que no eran caídas, lo que significa una elevada precisión. En cuanto a las configuraciones probadas, se observa que cuando el radar se sitúa en el centro del cabecero (Configuración 1) logra una exactitud de 0.88, ligeramente superior al de visión, pero su sensibilidad (0.83) revela que deja escapar aproximadamente un 17 % de las caídas. Al desplazar el radar (Configuración 2), la sensi-




Figura 4: Matrices de confusión de los sistemas

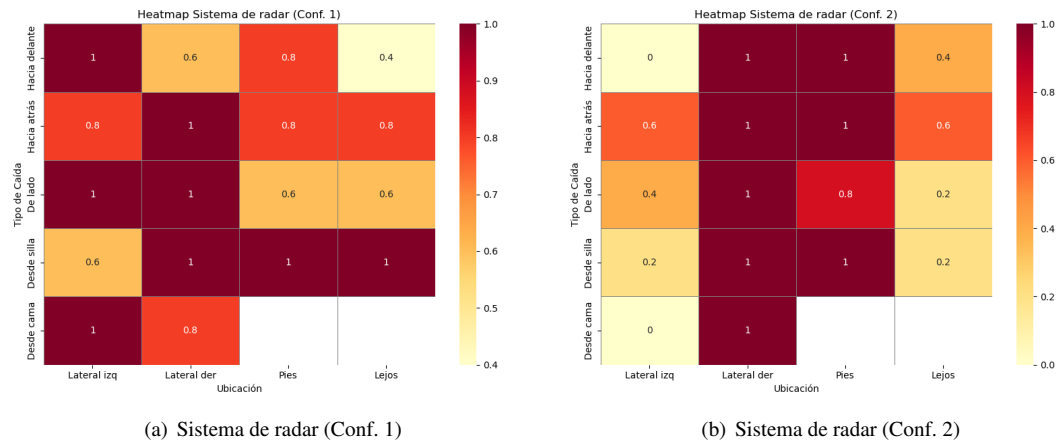


Figura 5: Mapas de calor de los sistemas

lidad cae a 0.62 y la exactitud desciende a 0.73, manteniendo, sin embargo, la precisión elevada por su buen comportamiento ante no-caídas.

Con el fin de explicar las diferencias entre las configuraciones elegidas para el radar de caídas, se ha obtenido el mapa de calor o *heatmap* (Figura 5) de la sensibilidad de los sistemas, cruzando la categoría de tipo de caída con la ubicación de la misma para visualizar los patrones de detección en diferentes combinaciones. Las cuadrículas que relacionan la caída "Desde la cama" las ubicaciones "Pies" "Lejos" aparecen sin datos en los mapas de calor, ya que hemos considerado que no tendría sentido que el usuario tuviera un accidente desde la cama en estas localizaciones.

Si analizamos el mapa de calor de la primera configuración, en la que el radar está en el centro del cabecero de la cama, se observa que la sensibilidad media más alta se alcanza en el lateral izquierdo (0.88) y el lateral derecho (0.88), mostrando un comportamiento simétrico y equilibrado en ambos lados de la cama. La zona de los pies de la cama también presenta un buen nivel de detección (0.80), mientras que la ubicación *lejos de la cama* muestra la sensibilidad más baja (0.70), indicando que la distancia es un factor limitante en la precisión del radar.

En el caso de la configuración con el radar desplazado, todas las pruebas en las que los sujetos se han caído en el lateral derecho han sido detectadas correctamente, lo que demuestra que el radar tiene una visibilidad óptima en esa zona. Por el contrario, la ubicación *lateral izquierdo* representa el punto ciego más crítico, con una sensibilidad media de 0.20, lo que

evidencia una cobertura desigual en el área de detección.

En cuanto al tipo de caída, los resultados sugieren que el radar tiene una mayor capacidad de detección cuando el usuario se cae de espaldas, aunque tampoco se ve un patrón claro en este aspecto.

Al plantear dos configuraciones diferentes para el radar (uno centrado en el cabecero y otro desplazado unos centímetros), no solo comparamos cómo varía la zona de cobertura, sino que también ponemos de manifiesto una lección clave en sistemas de sensorización: pequeños cambios en la posición inicial pueden tener un impacto muy significativo en el rendimiento. Un error de posicionamiento de apenas unos centímetros puede pasar de un rendimiento excelente a uno inaceptable.

En el caso del sistema de visión, de 100 caídas simuladas se detectaron correctamente 96, como se muestra en la Figura 4. Estas 4 situaciones no detectadas se deben a que en esas pruebas el detector YOLO no consiguió localizar a la persona en la imagen, por lo que el sistema careció de información para clasificar el evento como caída.

El sistema de detección de caídas basado en visión por computador no requiere ninguna configuración previa del entorno, pues trabaja exclusivamente sobre la imagen captada. En escenarios con cámara fija, es posible especializar el modelo para que reconozca caídas en zonas concretas, aprovechando la posición invariable de muebles y elementos, como se ha hecho en la configuración inicial del sistema de radar. Esto mejoraría su precisión a costa de perder flexibilidad para adaptarse a distintos entornos.

La propuesta de un sistema de detección de caídas basado en visión integrado en un robot móvil combina la alta fiabilidad del detector de imágenes con la capacidad de movimiento autónomo, de modo que, tras un primer análisis en la posición inicial, el robot puede desplazarse a otras zonas predefinidas del entorno para realizar comprobaciones adicionales. Así, si una caída no es identificada en el primer punto de observación, el dispositivo avanza a la siguiente ubicación de la habitación y vuelve a capturar una nueva imagen, garantizando una doble verificación que minimiza los falsos negativos y cubre posibles zonas ciegas sin necesidad de múltiples cámaras fijas.

6. Conclusiones

El sistema basado en radar demuestra una elevada fiabilidad para discriminar movimientos cotidianos y responde bien a distintos perfiles de usuario y tipos de caída. Sin embargo, su eficacia depende en gran medida de la autoconfiguración inicial y de la adaptación al entorno: la posición del radar puede convertir áreas en puntos muertos o mejorar notablemente la cobertura en zonas críticas. Mientras la configuración centrada en el cabecero ofrece un 83 % de detección de caídas, un desplazamiento de apenas unos centímetros reduce esta tasa al 62 % al generar “puntos ciegos” significativos.

El detector basado en visión por computador alcanza una exactitud elevada, identificando correctamente la gran mayoría de las caídas. Además, este enfoque funciona sin calibración ambiental, lo que facilita su despliegue en diferentes entornos. A pesar de esto, este sistema puede confundirse con personas tumbadas de manera estática sobre la cama, interpretando estas posturas como caídas y generando falsas alarmas.

Integrar el detector de visión en un robot móvil permite al sistema cubrir el entorno de forma dinámica. Si en una ubicación no se detecta la caída, el robot se desplaza a la siguiente posición para efectuar una segunda comprobación, minimizando falsos negativos y cubriendo zonas inaccesibles para una sola cámara fija.

El sistema de visión por computador ofrece buenos resultados a la hora de detectar si una persona se ha caído en su domicilio y es fácilmente adaptable, ya que no necesita ninguna configuración inicial. Aunque requiere gestionar posibles falsas alarmas por personas tumbadas, tiene la ventaja de que al estar integrado en un robot móvil puede desplazarse a otra ubicación para tomar una foto y realizar una nueva predicción, lo que ofrece una segunda verificación al sistema.

La Configuración 1 del radar (centrado en el cabecero) es ideal cuando se desea equilibrar cobertura y fiabilidad, pues ofrece sensibilidad media-alta (0.83) en todas las direcciones alrededor de la cama, minimizando zonas ciegas. En cambio, la Configuración 2 (radar desplazado) conviene en escenarios donde interesa priorizar la vigilancia de un área específica, por ejemplo, uno de los costados de la cama si está pegada a la pared. De esta forma se logrará mejorar la predicción a cambio

de sacrificar cobertura en el lado opuesto.

En conjunto, el radar fijo resulta útil para detectar caídas y otras actividades dentro de una habitación en una zona limitada, para garantizar el área de cobertura; el sistema de detección de caídas integrado en el robot móvil permite localizar a la persona que se ha caído y asistirle de forma directa, aunque puede tener un peor comportamiento a la hora de predecir situaciones en las que la persona no se ha caído.

Estos resultados demuestran que tanto la combinación de visión por computador y movilidad autónoma, como el uso estratégico de radar, ofrecen una solución de detección de caídas altamente fiable y aplicable en entornos domésticos.

Agradecimientos

La investigación que se presenta en este trabajo ha recibido financiación del proyecto ROSO-GAR PID2021-123020 OB-I00 financiado por MCI-N/AEI/10.13039/501100011033/FEDER, UE, y del proyecto EIAROB Financiado por la Consejería de Familia de la Junta de Castilla y León - Next Generation EU.

Referencias

- Alam, E., Sufian, A., Dutta, P., Leo, M., 2022. Vision-based human fall detection systems using deep learning: A review. *Computers in biology and medicine* 146, 105626.
- Anwary, A. R., Rahman, M. A., Muzahid, A. J. M., Ul Ashraf, A. W., Patwary, M., Hussain, A., 2022. Deep learning enabled fall detection exploiting gait analysis. In: 2022 44th Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC). pp. 4683–4686. DOI: 10.1109/EMBC48229.2022.9871964
- Domingo, J. D., Aparicio, R. M., Rodrigo, L. M. G., 2022. Cross validation voting for improving cnn classification in grocery products. *IEEE Access* 10, 20913–20925.
- Gaya-Morey, F. X., Manresa-Yee, C., Buades-Rubio, J. M., 2024. Deep learning for computer vision based activity recognition and fall detection of the elderly: a systematic review. *Applied Intelligence* 54 (19), 8982–9007.
- Hu, S., Cao, S., Toosizadeh, N., Barton, J., Hector, M. G., Fain, M. J., 2024. Radar-based fall detection: A survey [survey]. *IEEE robotics & automation magazine* 31 (3), 170–185.
- INE, 2023.
- Ingevital, 2024. URL: <https://ingevital.com/>
- Maldonado-Bascon, S., Iglesias-Iglesias, C., Martín-Martín, P., Lafuente-Arroyo, S., 2019. Fallen people detection capabilities using assistive robot. *Electronics* 8 (9), 915.
- Ministerio de Sanidad, G. d. E., 2025. URL: <https://estilosdevidasaludable.sanidad.gob.es/seguridad/caidas/mayores/home.htm>
- Rao, S., Pramod, N., Paturu, C. K., 2008. People detection in image and video data. In: *Proceedings of the 1st ACM workshop on vision networks for behavior analysis*. pp. 85–92.
- Sánchez-Girón, C., Zalama, E., Gómez-García-Bermejo, J. D.-D., 7 2024. Integración convnext-yolo mediante cvv para detectar caídas en robot social. *XLV Jornadas de Automática*. DOI: <https://doi.org/10.17979/ja-cea.2024.45.10788>
- Temi, R., 2024. URL: <https://www.robottemi.com/product/temi/>
- Tewari, R. C., Routray, A., Maiti, J., 2024. State-of-the-art radar technology for remote human fall detection: a systematic review of techniques, trends, and challenges. *Multimedia Tools and Applications* 83 (29), 73717–73775.