

Elizabeth López Lozada, Juan Humberto Sossa Azuela y Elsa Rubio Espino



# Detección inteligente de caídas para el cuidado de los adultos mayores

Las caídas son accidentes que frecuentemente les ocurren a los adultos mayores y representan la segunda causa de muerte a nivel mundial de este grupo de edad. Su detección es importante para brindar asistencia a los afectados de forma oportuna. Por ello, en este artículo se describe un sistema de video que detecta las caídas de forma automática mediante el uso de inteligencia artificial con una efectividad del 99 por ciento.

## Introducción

Las caídas son incidentes no intencionados que provocan la pérdida de equilibrio, provocando que una persona termine en el suelo o en otra superficie firme que la detenga. De acuerdo con la Organización Mundial de la Salud (OMS), México se encuentra en el segundo lugar de América en cuanto a caídas de personas mayores. En 2019, el 10% de los fallecimientos de adultos mayores en México se debió a una caída. Además, el Centro Nacional de Programas Preventivos y Control de Enfermedades reporta que en México el 65% de los adultos mayores experimentan caídas dentro de sus hogares.

Las caídas generan secuelas físicas y psicológicas en la vida de los adultos mayores, provocando un aumento en el miedo, la ansiedad y la depresión. Esto conduce a una disminución en su actividad diaria, lo que resulta en un equilibrio inadecuado durante la marcha y un debilitamiento muscular que afecta su movilidad e independencia. Por ello, es importante evitar y detectar estos eventos de emergencia para una intervención oportuna y mejorar la calidad de vida de los adultos mayores.

Por tanto, es importante el desarrollo de tecnologías que permitan asistir, prevenir, detectar y notificar de forma oportuna tanto a familiares como profesionales de la salud cuando se presentan accidentes que representen un riesgo para su salud (véase la [Figura 1](#)).





**Figura 1.** Los sistemas de detección de caídas permiten notificar a los familiares sobre el accidente y esto ayuda a que los adultos mayores reciban atención oportuna. Ilustración: Elizabeth López Lozada.

**El papel de la inteligencia artificial para la detección de caídas**

En el ámbito de la salud, la inteligencia artificial (IA) se ha convertido en una herramienta fundamental para el desarrollo de tecnologías. Éstas abarcan desde la asistencia y el cuidado de la salud de las personas, la gestión de medicamentos y el análisis de imágenes médicas, hasta la detección y prevención de caídas y accidentes, entre otras aplicaciones.

La IA les permite a los sistemas de monitoreo incorporar algoritmos para la detección, reconocimiento y predicción de caídas de manera autónoma. Esto significa que no es necesario que una persona intervenga para identificar la caída y enviar la notificación del evento.

Muchos de los enfoques de IA utilizan redes neuronales artificiales. Éstas son modelos de aprendizaje automático diseñados para tomar decisiones de manera similar al cerebro humano. Su funcionamiento se basa en el uso de datos de entrenamiento para aprender y mejorar su precisión con el tiempo.

En el ámbito de la detección de caídas, el objetivo es enseñarle a la computadora a identificar cuándo un evento corresponde a una caída. Para lograr esto, se utiliza un conjunto de datos compuesto por información que representa caídas y otros eventos que no lo son, cada uno identificado con una etiqueta correspondiente. Estos modelos se entrenan hasta alcanzar una alta precisión, lo que significa que la computadora puede identificar correctamente cuándo un video muestra una caída, minimizando la cantidad de errores.

**Tecnologías para la detección de caídas**

Las tecnologías para la detección de caídas pueden contar con una amplia gama de sensores, como acelerómetros y giroscopios colocados en dispositivos portátiles, o con cámaras de vigilancia dentro del hogar que permitan realizar el seguimiento de las actividades de las personas. Las principales ventajas y desventajas se muestran en la **Tabla 1**.

Como se observa en esa tabla, los acelerómetros y giroscopios, que son pequeños y ligeros, ofrecen una opción económica y fácil de integrar en dispositivos portátiles. Sin embargo, estos sensores requieren que el usuario los lleve puestos. Entonces, si una persona olvida usar los sensores, no se podrá detectar la

**Tabla 1.** Descripción de los tipos de sensores para la detección de caídas y sus principales ventajas y desventajas.

Tipo de sensor	¿Qué hace?	Ventajas	Desventajas
Acelerómetros	Miden cómo se mueve el cuerpo y pueden detectar cuando hay cambios bruscos en la velocidad.	<ul style="list-style-type: none"> <li>• Pequeños y ligeros.</li> <li>• Fáciles de usar.</li> </ul>	<ul style="list-style-type: none"> <li>• Se llevan puestos.</li> <li>• Pueden dar falsas alarmas.</li> </ul>
Giroscopios	Miden la orientación del cuerpo y ayudan a detectar caídas al notar cambios en la inclinación.	<ul style="list-style-type: none"> <li>• Pequeños y ligeros.</li> <li>• Muy precisos.</li> </ul>	<ul style="list-style-type: none"> <li>• Debes llevarlos puestos.</li> <li>• Pueden dar falsas alarmas.</li> </ul>
Cámaras	Vigilan la casa y detectan caídas mirando las actividades en video.	<ul style="list-style-type: none"> <li>• No necesitas llevar nada puesto.</li> <li>• Monitorean todo el tiempo.</li> </ul>	<ul style="list-style-type: none"> <li>• Pueden invadir la privacidad.</li> <li>• Sólo funcionan donde hay cámaras.</li> </ul>

caída. Las personas pueden olvidar fácilmente ponerse estos dispositivos y, además, pueden sentirse incómodas teniendo que usar o vestir dispositivos adicionales.

Por otro lado, los sistemas basados en cámaras de video proporcionan un monitoreo continuo sin necesidad de que el usuario lleve o vista dispositivos especiales, como se muestra en la **Figura 2**. Una desventaja significativa de estos sistemas es la potencial invasión de la privacidad debido al uso de cámaras. Sin embargo, a diferencia de los acelerómetros, las cámaras no requieren que el usuario las lleve puestas y pueden ofrecer datos más completos para el análisis, lo que permite una detección más precisa y detallada de caídas.



**Figura 2.** Escenario propuesto para la implementación del prototipo. Ilustración: Elizabeth López Lozada.


### Desarrollo de tecnologías para la detección de caídas en México

En México, en el Centro de Investigación en Computación del Instituto Politécnico Nacional (CIC-IPN) se desarrolla un prototipo para la detección de caídas usando videos. El sistema propuesto en la **Figura 3** consiste en una etapa de procesamiento del video, la extracción de características y la detección de la caída.

Para el desarrollo de esta propuesta se utilizó el lenguaje de programación de Python junto con Ten-

sorFlow. El procesamiento de video, como se muestra en la **Figura 4**, consiste en identificar a las personas en el video y recortar el área donde sólo aparece la persona detectada. Para ello, utilizamos un método de seguimiento de personas llamado FairMOT e implementamos un programa que recorta el área en la que aparece la persona y ajusta el tamaño de los cuadros de video a  $224 \times 224$  píxeles.

A continuación, se extraen las características de cada cuadro de video utilizando las capas del modelo preentrenado MoviNet, que es el que usamos



**Figura 3.** Representación general del sistema de detección de caídas. Ilustración: Elizabeth López Lozada.




Figura 4. Procesamiento del cuadro de video con el seguimiento de personas y el recorte del cuadro de video. Foto: Elizabeth López Lozada.

**Redes neuronales convolucionales 3D**

Son un tipo de algoritmo de aprendizaje profundo diseñado para analizar datos tridimensionales, como imágenes volumétricas o videos.

en esta ocasión. Este modelo, compuesto por **redes neuronales convolucionales 3D**, permite procesar videos en tiempo real sin requerir mucha memoria. Además, es ideal para dispositivos con bajos recursos, como teléfonos celulares. Por ello, consideramos que este modelo es una herramienta valiosa para desarrollar tecnologías destinadas al cuidado de los adultos mayores.

**Redes neuronales recurrentes (RNR)**

Son un tipo de algoritmo de aprendizaje profundo diseñado para procesar secuencias de datos, como texto, audio o series temporales. A diferencia de las redes neuronales convolucionales, las RNR cuentan con conexiones que forman ciclos, lo que les permite mantener un estado interno y recordar información de pasos anteriores en la secuencia.

Finalmente, se propuso un enfoque para la detección de caídas que utiliza las capas que se muestran en el bloque inferior de la **Figura 3**. Este enfoque utiliza varias capas de procesamiento, comenzando con un proceso de promedios globales (*global average pooling*, en inglés) para simplificar los mapas de características y resaltar las partes más importantes de los cuadros de video. A continuación, se ajustan las dimensiones de los vectores de características.

Luego, se emplea un grupo de capas que incluyen un proceso de promedios máximos (*max pooling*, en inglés) y **redes neuronales recurrentes** (RNR o LSTM). Estas capas ayudan a aprovechar las características temporales del video para detectar caídas. Finalmente, se utilizan capas densas que reducen las características y producen una salida que indica si hubo una caída o no.


Para los experimentos, seleccionamos 1 386 videos de los conjuntos de datos NTU RGB+D 60 y CAUCAFall para entrenar al modelo. Este conjunto

de datos se dividió en un conjunto de entrenamiento que contiene el 80% de los datos y un conjunto de validación con el 20% restante. Los videos seleccionados se caracterizan por mostrar escenas de personas que sufren una caída y escenas en las que ocurre alguna otra acción. Del total de videos, 893 presentan escenas de caídas y 523 muestran otras actividades.

Estos videos muestran escenas en interiores bien iluminados, en las que sólo aparece una persona cuyo cuerpo completo es siempre visible y sin obstrucciones. Las acciones se capturaron desde tres ángulos: frontal (0°), inferior (45°) y superior (45°), como se muestra en la **Figura 5**.

Para finalizar, se usaron los videos seleccionados para enseñarle al modelo a detectar caídas. Este proceso, conocido como “época”, consiste en mostrarle al modelo los videos para que ajuste sus parámetros basándose en ellos. Este proceso se repite muchas veces hasta que el modelo comete la menor cantidad de errores y se vuelve más preciso.

Entrenamos al modelo propuesto en este trabajo durante 10 épocas. Se utilizó un optimizador llamado Adam, que es el algoritmo que ajusta los parámetros del modelo para mejorar su rendimiento. Además, se usó una función de pérdida llamada Sparse Categorical Crossentropy, que mide cuán lejos están los resultados del modelo de los resultados reales. Como



**Figura 5.** Posición de las cámaras para tomar las muestras de video. Ilustración: Elizabeth López Lozada.

resultado, el modelo alcanzó una precisión del 99 % en la detección de caídas. Esto significa que, de 100 casos, el sistema detectará 99 correctamente.

### ■ Implementación del detector de caídas

■ Para la primera implementación del detector de caídas, se decidió utilizar una cámara de video conectada a una computadora. La cámara se coloca en una habitación a la altura de un metro y medio, apuntando directamente hacia el área que se quiere observar. Las pruebas de detección de caídas se realizaron a una distancia de entre dos y tres metros de la cámara. En esta etapa inicial, se aseguraron condiciones de buena iluminación, es decir, con la habitación bien iluminada.

Esta configuración es sencilla y directa, ya que sólo requiere una cámara y una computadora. Además, las condiciones de buena iluminación aseguran que las imágenes capturadas sean claras, lo que mejora la precisión en la detección de caídas.

Uno de los principales inconvenientes es la dependencia de una buena iluminación, que puede no estar disponible en todas las situaciones. Además, la posición fija de la cámara y la distancia limitada a dos metros pueden afectar la eficacia del sistema.

Para mejorar este sistema, sería beneficioso desarrollar algoritmos que funcionen bien en diversas condiciones de iluminación, incluidos entornos con poca luz. Además, utilizar múltiples cámaras o cámaras con ángulos ajustables permitiría cubrir áreas más grandes y distancias variables.

### ■ Retos y oportunidades

■ Un sistema de detección de caídas basado en video presenta varios retos y oportunidades. Uno de los principales retos es la privacidad, ya que, al instalar cámaras en un hogar, los habitantes pueden sentir que su privacidad y seguridad están siendo comprometidas. Para abordar esto, sería crucial implementar técnicas que protejan la privacidad del usuario, como la anonimización de las imágenes, para mejorar la aceptación del sistema por parte de los usuarios.

Además, la efectividad del sistema puede verse comprometida por las condiciones de iluminación. En ambientes con poca luz, la precisión de la detección podría disminuir y, por otro lado, puede ser problemática la obstrucción de la imagen por objetos que bloqueen la visibilidad de las personas en el video. Para mitigar estos desafíos, se pueden tomar varias medidas. Por ejemplo, se pueden colocar las cámaras en lugares estratégicos donde es menos pro-



bable que los objetos bloqueen la vista, e implementar algoritmos que detecten y manejen obstrucciones en tiempo real.

La integración con otras tecnologías, como sensores adicionales (acelerómetros y giroscopios), puede complementar y mejorar la detección de caídas. Además, las microcomputadoras, como la Raspberry Pi 5, ofrecen ventajas como el ser más económicas que las computadoras de escritorio, la facilidad de conexión a redes para enviar notificaciones, portabilidad, discreción y menor consumo de energía. Por ello, consideramos que la siguiente etapa del trabajo será la implementación del modelo propuesto en una Raspberry Pi 5 y poner a prueba el desempeño del prototipo.

Consideramos que, comparada con sistemas que utilizan sensores, la detección por video no depende de que el usuario lleve dispositivos consigo, lo que es una gran ventaja. No obstante, en lugares como el baño, colocar una cámara puede no ser adecuado,

por lo que desarrollar sistemas integrales que combinen información de dispositivos móviles y cámaras podría ser la solución más completa.

### Conclusión

Se presentó una propuesta para la detección automática de caídas mediante inteligencia artificial. Se desarrolló un modelo basado en redes neuronales artificiales que alcanzó una precisión del 99 % al utilizar el modelo MoviNet. Para aumentar la robustez y aplicabilidad de nuestro sistema, en trabajos futuros incorporaremos videos con mayores variaciones en iluminación, ángulos de cámara y posibles obstrucciones, a fin de evaluar el desempeño del modelo en condiciones más realistas. Además, seguiremos perfeccionando el sistema para asegurar su eficacia en escenarios reales, lo que implicará la integración de datos variados y la adaptación del modelo a estos nuevos contextos.



### ■ Consideraciones adicionales

■ Con el aumento de la población de adultos mayores, es de suma importancia desarrollar tecnologías para mejorar su salud y calidad de vida. La IA puede crear modelos que detecten caídas automáticamente e integrarlos en dispositivos de asistencia. Es esencial que los gobiernos inviertan en estas tecnologías para beneficiar a los adultos mayores.

Los autores agradecen a la Secretaría de Educación, Ciencia, Tecnología e Innovación de la Ciudad de México, a la Secretaría de Investigación y Posgrado del Instituto Politécnico Nacional y a la Secretaría de Ciencia, Humanidades, Tecnología e Innovación por el apoyo económico brindado para la realización de esta investigación.

#### Elizabeth López Lozada

Instituto Politécnico Nacional, Centro de Investigación en Computación.  
elopezl2020@cic.ipn.mx

#### Juan Humberto Sossa Azuela

Instituto Politécnico Nacional, Centro de Investigación en Computación.  
hsossa@cic.ipn.mx

#### Elsa Rubio Espino

Instituto Politécnico Nacional, Centro de Investigación en Computación.  
erubio@cic.ipn.mx

### Lecturas recomendadas

Nagusi Intelligence Center (s. f.), *Inteligencia artificial para las personas mayores: Aplicaciones y oportunidades de negocio*, Barcelona, Nagusi Intelligence Center. Disponible en: <[https://www.bizkaia.eus/documents/9027320/11569571/%2307\\_Inteligencia+Artificial\\_VF-ES.pdf](https://www.bizkaia.eus/documents/9027320/11569571/%2307_Inteligencia+Artificial_VF-ES.pdf)>, consultado el 21 de enero de 2025.

Organización Mundial de la Salud (octubre de 2024), “Envejecimiento y salud”, OMS [en línea], Centro de Prensa. Disponible en: <<https://www.who.int/es/news-room/fact-sheets/detail/ageing-and-health>>, consultado el 21 de enero de 2025.

Organización Panamericana de la Salud (s. f.), “Envejecimiento saludable: Datos y visualizaciones”, OPS [en línea]. Disponible en: <<https://www.paho.org/es/envejecimiento-saludable-datos-visualizaciones>>, consultado el 21 de enero de 2025.

Quinayás Burgos, C. A., D. F. Quintero Benavidez, E. Ruiz Omen y J. L. Narváez Semanate (2020), “Sistema de detección de caídas en personas utilizando video vigilancia”, *Ingeniare: Revista Chilena de Ingeniería*, 28(4):684-693. Disponible en: <<https://dx.doi.org/10.4067/S0718-33052020000400684>>, consultado el 21 de enero de 2025.

TensorFlow (s. f.), *TensorFlow* [en línea]. Disponible en: <<https://www.tensorflow.org/?hl=es-419>>, consultado el 21 de enero de 2025.

Terra Jonas, L., K. Vitorelli Diniz Lima, M. Inácio Soares, M. A. Mendes, J. V. da Silva y P. M. Ribeiro (2014), “Evaluación del riesgo de caídas en las personas mayores: ¿cómo hacerlo?”, *Gerokomos*, 25(1):13-16. Disponible en: <<https://dx.doi.org/10.4321/S1134-928X2014000100004>>, consultado el 21 de enero de 2025.

Usmani, S., A. Saboor, M. Haris, M. A. Khan y H. Park (2021), “Latest research trends in fall detection and prevention using machine learning: A systematic review”, *Sensors*, 21(15):5134. Disponible en: <<https://doi.org/10.3390/s21155134>>, consultado el 21 de enero de 2025.