

Detección y clasificación de actividades de la vida diaria y de caídas en personas mediante lógica difusa

Edmundo Bonilla-Huerta, Eduardo Martínez-Juárez,
Roberto Morales-Caporal, Eduardo Vázquez-Urbina

Tecnológico Nacional de México,
Campus Apizaco,
México

{edmundo.bh, m23370044, roberto.mc,
m23370050}@apizaco.tecnm.mx

Resumen. En este artículo se analizan los movimientos de personas jóvenes y de la tercera edad utilizando datos recolectados a partir de un acelerómetro y un giroscopio. Se propone, en este estudio, un enfoque basado en la lógica difusa, para la clasificación de movimientos normales y de caídas. Los resultados obtenidos muestran que la fusión de los datos de un acelerómetro y un giroscopio pueden ser integrados en un sistema difuso para clasificar caídas y movimientos de la vida diaria con un 97,4 % de precisión.

Palabras clave: Tercera edad, acelerómetro, giroscopio, caídas, lógica difusa.

Detection and Classification of Daily Living Activities and Falls in People, Using Fuzzy Logic

Abstract. In this paper, the movements of young and elderly people are analyzed using data collected from an accelerometer and a gyroscope. In this study, a fuzzy logic-based approach is proposed for the classification of normal movements and falls. The results obtained show that the fusion of data from an accelerometer and a gyroscope can be integrated into a fuzzy system to classify falls and daily life movements with a 97.4% accuracy.

Keywords: Elderly people, accelerometer, gyroscope, falls, fuzzy logic.

1. Introducción

Las caídas son comunes entre las personas mayores y representan un desafío significativo para los sistemas de salud pública, generando costos en hospitalización, rehabilitación, atención domiciliaria, y más. Un sistema basado en sensores inerciales de bajo costo podría ser una herramienta eficaz para detectar caídas en esta población. La investigación sobre la actividad humana, en particular, las caídas y la utilización de dispositivos portátiles ha experimentado un desarrollo interesante en

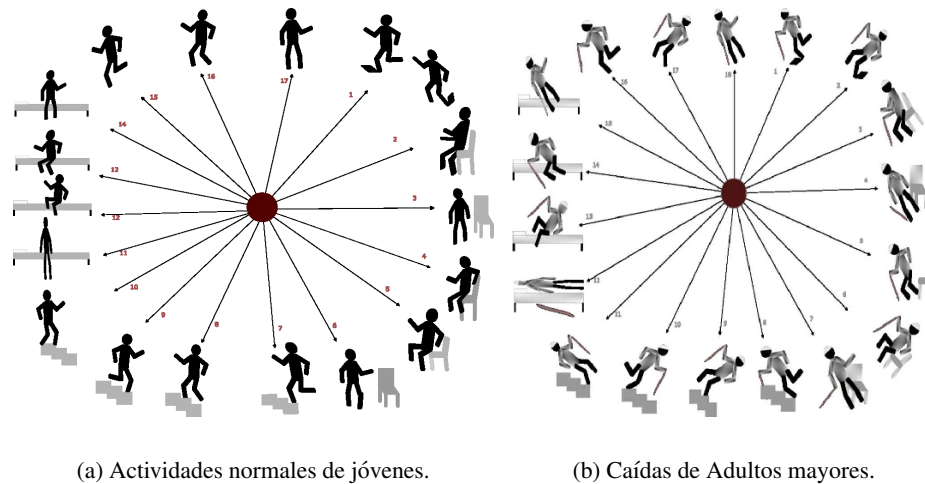


Fig. 1. Actividades de la vida diaria.

los últimos años. Sin embargo, hay pocos conjuntos de datos de libre acceso, todos registrados con teléfonos inteligentes, que sean eficientes, debido a la falta de datos de la población objetivo tales como la edad, su condición de salud, altura, peso entre otros.

Los movimientos de las actividades que realiza un adulto mayor en la vida diaria, generalmente son lentos, y si está asociados a un tipo de distrofia muscular o debilitamiento en las articulaciones, estos pueden llegar a ser muy lentos. Esto supone un desafío para detectar y clasificar estos movimientos, ya que el cambio de aceleración en una caminata no será muy notorio utilizando un acelerómetro o un giroscopio. Un ligero cambio de aceleración podría verse reflejado en un pico en el eje Y de un acelerómetro, sobre todo si la persona va a sentarse, va caminando, o incluso si tropezó con un objeto en casa o en la calle, o simplemente resbaló y la caída es inevitable.

Los acelerómetros triaxiales recolectan la aceleración lineal de tres ejes principales: la aceleración hacia adelante (eje y), la aceleración horizontal (eje x) y la aceleración vertical (eje z). Los acelerómetros proporcionan información de la aceleración lineal de una persona, cuando esta realiza diferentes tipos de movimientos. Por su parte un giroscopio tiene como propósito registrar datos de la velocidad angular, sobre todo si la persona realiza un cambio de rotación en un eje, porque esto indicaría que la persona se ha tropezado o resbalado, y ha sufrido una caída.

Si un giroscopio y un acelerómetro se acondicionan como un dispositivo externo en el cuerpo de una persona, este realiza mediciones de la velocidad angular en estrecha relación con el cuerpo. Las ventajas de utilizar un acelerómetro y un giroscopio es debido a su bajo costo, la miniturización de estos dispositivos, su bajo consumo de energía, su integración con otros dispositivos (una cámara, un sensor auditivo, una alarma vía bluetooth o la comunicación con otros dispositivos en la nube), y por su viabilidad de implementarlos en una tarjeta de control para monitorear actividades de la vida diaria (AVD).




Fig. 2. Sistema propuesto para la detección de caídas y actividades de la vida diaria.

2. Estado del arte

En este artículo [14], se presenta un sistema para detectar caídas, el cual es accesible y de bajo costo que utiliza sensores inerciales. Los sensores inerciales recopilan datos para identificar y detectar 4.444 condiciones de caída diferentes. Se probaron diferentes clasificadores de aprendizaje automático en el conjunto de datos de entrenamiento y se utilizó el mejor clasificador para entrenar los datos del sensor. Posteriormente, el modelo se comparó con datos de sensores desconocidos (recopilados de conjuntos de datos disponibles) para inferir en qué estado se encontraba la persona.

Los autores argumentan que, este sistema podría usarse potencialmente para la detección de caídas. En este artículo [11] se propone un procedimiento de detección de caídas, la cual consta de una unidad inercial que incorpora un acelerómetro triaxial, un giroscopio y un magnetómetro con combinación de información para realizar cálculos para conocer la ubicación de una caída. El algoritmo se ha probado en diferentes escenarios: los voluntarios realizaron recrearon caídas y ejercicios de la vida cotidiana. Al colocar el sensor portátil en el abdomen del sujeto, el dispositivo puede detectar caídas mejor que otras propuestas en la literatura.

Los resultados obtenidos son muy aceptables en las medidas de exactitud, sensibilidad y especificidad. En este artículo [16] se reporta un repositorio de caídas y ejercicios de la vida diaria (EVD) obtenidos con un dispositivo de desarrollo propio compuesto por un acelerómetro y un giroscopio. Esta base se compone de 19 EVD y 15 tipos de caída realizados por 23 adultos jóvenes, 15 tipos de EVD realizados por 14 personas mayores de 62 años, y datos de una persona de 60 años que realizó todas las EVD y caídas. Estos ejercicios se eligieron en base a un estudio y un examen escrito.

Se probó el conjunto de datos con un clasificador basado en umbrales, logrando hasta un 96 % de precisión. Un enfoque basado en lógica difusa, se reporta en [3], en donde se calcula el descubrimiento de caídas mediante la localización basada en un acelerómetro y un sensor de sonido para detectar una posible una caída.

Sin embargo, se ha demostrado que utilizar solo el acelerómetro no es suficiente para identificar con precisión una caída; ya que el acelerómetro también confunde algunos ejercicios de movimiento diarios, y los clasifica como caídas importantes. De esta manera, se crea un cálculo de ubicación de caída basado en lógica difusa para clasificar las señales del acelerómetro y el sensor de sonido, y de esta forma inferir si el evento se trata de una caída válida o no.




Fig. 3. Fuzzificación de entradas y salidas del modelo propuesto.

En esta investigación [21] se reporta que la detección de caídas previas al impacto mediante sensores inerciales portátiles ha aumentado debido a su potencial para desarrollar sistemas de prevención de lesiones relacionadas con caídas. Sin embargo, evaluar diferentes algoritmos es un desafío, ya que los investigadores rara vez comparten sus conjuntos de datos. Para abordar esto, los autores han desarrollado y publicado un conjunto de datos de movimiento a gran escala llamado "KFall", con etiquetas temporales para el tiempo de caída. Estos recursos pueden ayudar en el desarrollo de metodologías apoyadas con nueva tecnología para la detección de caídas y la prevención de lesiones en las personas mayores.

En este artículo [19], se realiza la comparación de tres tipos de fusión de datos recolectados de un acelerómetro y un giroscopio, para analizar la actividad humana. Este análisis se realizó en cuatro bases de datos públicas utilizando cuatro clasificadores de aprendizaje automático para validar los resultados. Los resultados reportados indican que su modelo de fusión supera algunas otros algoritmos propuestos en la literatura; sin embargo, la carga computacional requerida para el entrenamiento y la clasificación fue alta. Los resultados de esta propuesta sirven como base comparativa para otras técnicas de fusión de datos, aplicadas para el reconocimiento de actividades humanas.

En los artículos reportados en [8, 7, 10, 9, 5, 2, 12] se proporciona un análisis detallado de los sistemas de detección de caídas con énfasis en técnicas basadas en fusión multisensor. En su mayoría, utilizan la fusión de los datos de acelerómetros, giroscopios y magnetómetros. Algunos otros los fusionan con otros sensores como: sensores infrarrojos, kinect, cámaras, electrocardiogramas, radares, e incluso señales GPS obtenidas de los smartphones. Es importante señalar que en esos trabajos de investigación no se reporta la lógica difusa para realizar la fusión de los datos proporcionados por un acelerómetro y un giroscopio, como se propone en este artículo.

3. Base de movimientos

Para la realización de experimentos, se utilizó la base de caídas SysFall [16], la cual consiste de diferentes tipos de caídas, en la figura 1, se muestra esta información. Las actividades a analizar se enlistan como caídas:




Fig. 4. Histogramas de caminata para una persona joven.

1. Hacia adelante al caminar provocada por un resbalón.
2. Hacia atrás al caminar provocada por un resbalón.
3. Hacia atrás al caminar provocada por un resbalón.
4. Lateral al caminar provocada por un resbalón.
5. Hacia delante al caminar provocada por un tropiezo.
6. Hacia delante mientras se trota provocada por un resbalón.
7. Vertical al caminar provocada por desmayo.
8. Caída al caminar, provocada por desmayo.
9. Hacia adelante al intentar levantarse.
10. Lateral al intentar levantarse.
11. Hacia adelante al intentar sentarse.
12. Hacia atrás al intentar sentarse.
13. Lateral al intentar sentarse.
14. Hacia delante estando sentado, provocada por desmayo o quedarse dormido.
15. Hacia atrás estando sentado, provocada por desmayo o quedarse dormido.
16. Lateral estando sentado, provocada por desmayo o quedarse dormido.

4. Modelo propuesto

El modelo que se propone utiliza una base de movimientos disponible en internet y ampliamente referenciada en la literatura. En la figura 2, se muestra el modelo propuesto.

4.1. Magnitud de la señal del acelerómetro y giroscopio

La magnitud, de los datos recolectados por el acelerómetro en cada eje (x, y, z) . Estos ejes se representan comúnmente como vectores de aceleración en estas 3 direcciones: $Acel(x)$, $Acel(y)$ y $Acel(z)$. El cálculo de la aceleración total se obtiene mediante la siguiente ecuación:

$$M(A) = \sqrt{Acel(x)^2 + Acel(y)^2 + Acel(z)^2}. \quad (1)$$

La velocidad angular del giroscopio se realiza en los ejes : roll, pitch y yaw; estos se representan como vectores $Giros(x)$, $Giros(y)$ y $Giros(z)$ respectivamente. Para el giroscopio se aplica la misma fórmula para calcular la magnitud total:

$$M(G) = \sqrt{Giros(x)^2 + Giros(y)^2 + Giros(z)^2}. \quad (2)$$

4.2. Reducción de la gravedad

Para reducir los efectos de la gravedad en Las señales del acelerómetro, el método utilizado fue el de eliminar el valor medio de su señal. De esta forma se remueven las frecuencias muy bajas y muy altas producidas por los efectos del movimiento:

$$G = M(G) - \overline{M(G)}. \quad (3)$$

4.3. Normalización de la señal

Normalización de los datos en el intervalo $[0, 1]$ para el acelerómetro y el giroscopio utilizando la función max-min:

$$NG = \frac{G - \text{mín } G}{\text{máx } G - \text{mín } G}. \quad (4)$$

4.4. Picos de la señal

Se aplica una función para encontrar los picos de la señal de entrada normalizada de la magnitud del acelerómetro y del giroscopio, la cual devuelve un vector que contiene los máximos locales (picos). Un pico local se genera entre el mayor dato de la señal de dos muestras adyacentes. Los picos se generan en el orden en que aparecen. El análisis para descubrir patrones y clasificarlos se encuentra entre la amplitud de estos picos. Los picos detectados indican actividades estacionarias, muy importante si se trata de detectar caídas. Si la distancia entre picos se presentan en intervalos regulares, significa que la marcha de la persona es considerada normal, de lo contrario, hay una posible anomalía que hay que analizar.

4.5. Sistema de inferencia difuso

Un sistema de inferencia difusa (FIS) se puede utilizar como herramienta para identificar y clasificar patrones de los movimiento de personas. Debido a su flexibilidad, facilidad de comprensión y tolerancia a datos imprecisos, en este artículo se emplea un FIS para clasificar caídas y actividades de la vida diaria.




Fig. 5. Velocidades de aceleración en la caída de una persona adulta.

Fuzzificación. Para aplicar el FIS, se definieron 2 entradas y 1 salida (Ver Figuras 3a, 3b, y 3c). la primera entrada fuzzifica los picos obtenidos del acelerómetro, y la segunda las del giroscopio. La salida es la clasificación de la fusión de estas dos señales. La figura 3, ilustra este proceso.

Base de reglas. La parte principal del FIS es definir el conjunto de reglas difusas para identificar los movimientos de la vida diaria de los de una caída. El total de reglas SI-ENTONCES se muestran a continuación:

1. Si Picos-acelerómetro ES Mínimo Y Picos-Giroscopio ES Mínimo ENTONCES Posible-ADL.
2. SI Picos-acelerómetro ES Mínimo Y Picos-Giroscopio ES Medio ENTONCES Caída esta en curso.
3. SI Picos-acelerómetro ES Mínimo Y Picos-Giroscopio ES Máximo ENTONCES Caída detectada.
4. SI Picos-acelerómetro ES Medio Y Picos-Giroscopio ES Mínimo ENTONCES ADL.
5. SI Picos-acelerómetro ES Medio Y Picos-Giroscopio ES Medio ENTONCES Posible-ADL.
6. SI Picos-acelerómetro ES Medio Y Picos-Giroscopio ES Máximo ENTONCES Caída esta en curso.
7. SI Picos-acelerómetro ES Alto Y Picos-Giroscopio ES Mínimo ENTONCES posible-ADL.
8. SI Picos-acelerómetro ES Alto Y Picos-Giroscopio ES Medio ENTONCES ADL.
9. SI Picos-acelerómetro ES Alto Y Picos-Giroscopio ES Máximo ENTONCES ADL.

Defuzzificación. Para el proceso de transformación de los activaciones de las reglas difusas, se utiliza el método del centroide o centro del área para conocer el valor de salida. Este valor es la base para realizar el proceso de clasificación.

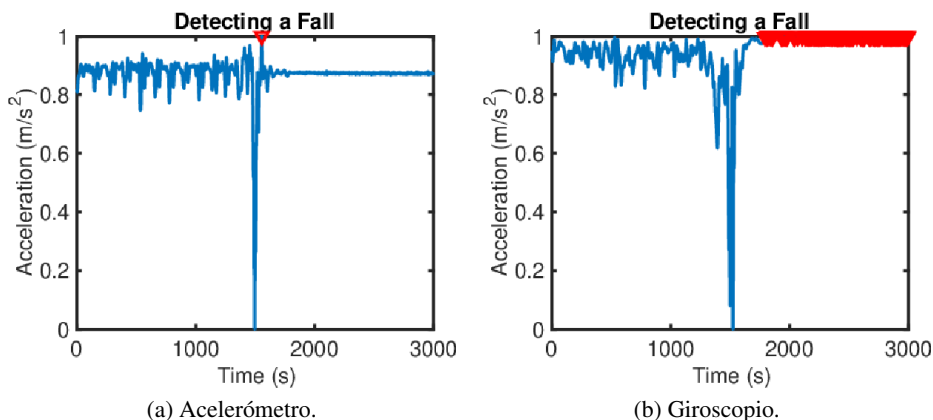


Fig. 6. Detección de caída de una persona adulta utilizando los dos sensores.

5. Análisis de resultados del modelo propuesto

En las figuras 4a y 4b, se muestran en forma de histograma, la distribución de los intervalos de picos de una persona joven caminando lento y rápido respectivamente. La distribución de la 4a, indica que el intervalo promedio de picos es de 8.4621. En contraste, en la figura 4b, el intervalo promedio es 15.4868. Estos valores indican los pasos promedio que la persona da en un intervalo de tiempo. En la Figura 5a y 5b, se muestran los datos recolectados del acelerómetro y del giroscopio cuando una persona ha sufrido una caída. El acelerómetro registró un cambio en los ejes x , y , z ; mientras que el giroscopio el eje que ha registrado esta caída es el eje y .

Estos datos son pre-procesados, es decir se obtiene su magnitud, se reduce la gravedad de ellos y se normalizan. Finalmente se encuentran los picos de cada sensor, para saber si se trata de una actividad de la vida diaria o de una caída. Como se ilustra en las Figuras 6a y 6b, los dos sensores complementan la información cuando se registra el evento de una caída de una persona adulta. En la Figura 6a se detecta el pico en el tiempo donde hay una pérdida de equilibrio. Mientras que en la Figura 6b se observa que efectivamente la persona ha caído, y el giroscopio detecta pequeños cambios en la velocidad angular, lo que indica que permanece en el suelo después de la caída. En estos momentos es cuando se activa el sistema de inferencia difuso para clasificar estos datos recolectados del acelerómetro y giroscopio respectivamente.

5.1. Discusión

La evaluación de nuestro modelo fue realizada mediante métricas de sensibilidad y especificidad:

$$\text{Sensitividad} = \frac{VP}{VP + FN}, \quad (5)$$

$$\text{Especificidad} = \frac{VP}{VP + FP}, \quad (6)$$

Tabla 1. Comparación de métricas de rendimiento (sensibilidad, especificidad, precisión y F_1 score) entre nuestro modelo y otros estudios previos en detección de caídas.

Modelo	Sensitividad	Especificidad	Precision	F_1 Score
ML algorithms [15]	–	–	–	95.91 %
Optimization [6]	96.30 %	96.20 %	–	–
Threshold [13]	–	–	–	93.3 %
SVM,ANN [4]	90.57 %	96.91 %	–	–
Transformed-based [20]	–	–	–	96.00 %
LSTM-based [20]	–	–	–	97.00 %
Threshold [17]	90.00 %	85.00 %	87.50 %	–
Vision [18]	90.33 %	89.66 %	89.73 %	90.02 %
Clustering-EGG [1]	–	–	–	97.1 %
Nuestro modelo	94.94 %	100 %	96.92 %	97.40 %

$$\text{Precision} = \frac{VP + VN}{VP + VN + FP + FN}, \quad (7)$$

$$F_1 \text{ score} = \frac{2 \times \text{Precision} \times \text{Sensitividad}}{\text{Precision} + \text{Sensitividad}}, \quad (8)$$

donde VP, VN, FP y FN, corresponden a valores Verdaderos Positivos, Verdaderos Negativos, Falsos Positivos y Falsos Negativos, respectivamente; los cuales son obtenidos de la matriz de confusión, al clasificar actividades de la vida diaria y caídas. VP, indica una caída detectada correctamente. FP, indica una caída mientras se realizaba una actividad de la vida diaria (ADL); mientras que VN indica que no es una caída sino una ADL, y finalmente FN, detecta incorrectamente una caída cuando se trata de una ADL. En la tabla 1, se muestran los resultado de nuestro modelo; así como una comparación con otras metodologías similares reportadas en la literatura; las cuales utilizan como base las lecturas de un acelerómetro y un giroscopio.

La comparación se realizó solo en aquellas metodologías que utilizan las mismas métricas de evaluación. En algunos casos solo reportan alguna de ellas. Las que no se reportan aparecen en la tabla con un guión. Como se puede observar nuestro modelo logra un 100 % de especificidad para detectar caídas. Se obtiene un F_1 score del 97,40 %. Estos resultados son ligeramente superiores a otros métodos como los que incluyen umbrales, algoritmos de aprendizaje máquina, redes neuronales y técnicas de agrupamiento entre otros.

6. Conclusiones y trabajos futuros

Nuestro modelo propuesto muestra un desempeño muy bueno, con respecto a la utilización de modelos muy sofisticados como las Máquinas de Soporte Vectorial (SVM), las cuales son generalmente muy difíciles de parametrizar.

Incluso las Redes Neuronales Artificiales, las cuales por su naturaleza estocástica y configuración de capas intermedias, dependen de una tasa de aprendizaje, el cual si el aprendizaje es lento pueden converger en un número de épocas alto. Si el aprendizaje es rápido quedan atrapadas en un mínimo/máximo local y no un mínimo/máximo global. En el futuro se va a diseñar una base de creación propia de movimientos de la vida diaria y caídas. Se tienen contemplados dos escenarios: Actividades de la vida diaria en interiores y exteriores. Las caídas se van a recrear utilizando personas jóvenes que practican gimnasia. Para ello se va a diseñar el aparato que fusione las señales de un acelerómetro, un giroscopio y una magnétometro y enviar señales a través de un celular o un sensor sonoro para activar alertas.

Referencias

1. Al-Dujaili, M. J., Dhaam, H. Z., Mezeel, M. T.: An intelligent fall detection algorithm for elderly monitoring in the internet of things platform. *Multimedia Tools and Applications*, vol. 83, no. 2, pp. 5683–5695 (2023) doi: 10.1007/s11042-023-15820-0
2. Dentamaro, V., Gattulli, V., Impedovo, D., Manca, F.: Human activity recognition with smartphone-integrated sensors: a survey. *Expert Systems with Applications*, vol. 246, pp. 123143 (2024) doi: 10.1016/j.eswa.2024.123143
3. Er, P. V., Tan, K. K.: Non-intrusive fall detection monitoring for the elderly based on fuzzy logic. *Measurement*, vol. 124, pp. 91–102 (2018) doi: 10.1016/j.measurement.2018.04.009
4. Fula, V., Moreno, P.: Wrist-based fall detection: Towards generalization across datasets. *Sensors*, vol. 24, no. 5, pp. 1679 (2024) doi: 10.3390/s24051679
5. Gharghan, S. K., Hashim, H. A.: A comprehensive review of elderly fall detection using wireless communication and artificial intelligence techniques. *Measurement*, vol. 226, pp. 114186 (2024) doi: 10.1016/j.measurement.2024.114186
6. Huynh, Q. T., Nguyen, U. D., Irazabal, L. B., Ghassemian, N., Tran, B. Q.: Optimization of an accelerometer and gyroscope-based fall detection algorithm. *Journal of Sensors*, vol. 2015, pp. 1–8 (2015) doi: 10.1155/2015/452078
7. Khan, S. S., Hoey, J.: Review of fall detection techniques: A data availability perspective. *Medical Engineering and Physics*, vol. 39, pp. 12–22 (2017) doi: 10.1016/j.medengphy.2016.10.014
8. Koshmak, G., Loutfi, A., Linden, M.: Challenges and issues in multisensor fusion approach for fall detection: Review paper. *Journal of Sensors*, vol. 2016, pp. 1–12 (2016) doi: 10.1155/2016/6931789
9. Newaz, N. T., Hanada, E.: The methods of fall detection: a literature review. *Sensors*, vol. 23, no. 11, pp. 5212 (2023) doi: 10.3390/s23115212
10. Nooruddin, S., Islam, M. M., Sharna, F. A., Alhetari, H., Kabir, M. N.: Sensor-based fall detection systems: a review. *Journal of Ambient Intelligence and Humanized Computing*, vol. 13, no. 5, pp. 2735–2751 (2021) doi: 10.1007/s12652-021-03248-z
11. Pierleoni, P., Belli, A., Palma, L., Pellegrini, M., Pernini, L., Valenti, S.: A high reliability wearable device for elderly fall detection. *IEEE Sensors Journal*, vol. 15, no. 8, pp. 4544–4553 (2015) doi: 10.1109/jsen.2015.2423562
12. Qu, Z., Huang, T., Ji, Y., Li, Y.: Physics sensor based deep learning fall detection system. *arXiv* (2024) doi: 10.48550/arXiv.2403.06994
13. Rakhman, A. Z., Nugroho, L. E., Widyawan, Kurnianingsih: Fall detection system using accelerometer and gyroscope based on smartphone. In: *Proceedings of the 1st International Conference on Information Technology, Computer, and Electrical Engineering*, pp. 99–104 (2014) doi: 10.1109/icitacee.2014.7065722

14. Rodrigues, T. B., Salgado, D. P., Cordeiro, M. C., Osterwald, K. M., Filho, T. F., de-Lucena, V. F., Naves, E. L., Murray, N.: Fall detection system by machine learning framework for public health. *Procedia Computer Science*, vol. 141, pp. 358–365 (2018) doi: 10.1016/j.procs.2018.10.189
15. Saeed, M. A., Hashem-Almourish, M., Alqady, Y. A., Alsharabi, H., Alkhorasani, H., Alsorori, S., Saeed, A. Y. A.: Predicting fall in elderly people using machine learning. In: *Proceedings of the International Congress of Advanced Technology and Engineering*, pp. 1–5 (2021) doi: 10.1109/icoten52080.2021.9493442
16. Sucerquia, A., López, J., Vargas-Bonilla, J.: Sisfall: A fall and movement dataset. *Sensors*, vol. 17, no. 1, pp. 198 (2017) doi: 10.3390/s17010198
17. Tang, D., Usman, A. B., Abba, A.: Fall detection system with accelerometer and threshold-based algorithm . *YHIoT Research Journal*, vol. 1, no. 1 (2021)
18. Wang, Y., Deng, T.: Enhancing elderly care: Efficient and reliable real-time fall detection algorithm. *Digital Health*, vol. 10 (2024) doi: 10.1177/20552076241233690
19. Webber, M., Rojas, R. F.: Human activity recognition with accelerometer and gyroscope: A data fusion approach. *IEEE Sensors Journal*, vol. 21, no. 15, pp. 16979–16989 (2021) doi: 10.1109/jsen.2021.3079883
20. Yhdego, H., Paolini, C., Audette, M.: Toward real-time, robust wearable sensor fall detection using deep learning methods: a feasibility study. *Applied Sciences*, vol. 13, no. 8, pp. 4988 (2023) doi: 10.3390/app13084988
21. Yu, X., Jang, J., Xiong, S.: A large-scale open motion dataset (kfall) and benchmark algorithms for detecting pre-impact fall of the elderly using wearable inertial sensors. *Frontiers in Aging Neuroscience*, vol. 13 (2021) doi: 10.3389/fnagi.2021.692865