

Selección de Sensores y Creación de una Base de Datos para la Detección de Caídas
Humanas

Checa Chamorro David
Hidalgo Rivera Armando Felipe

Programa de Ingeniería Electrónica
Facultad de Ingeniería
Universidad CESMAG
San Juan de Pasto
2025

Selección de Sensores y Creación de una Base de Datos para la Detección de Caídas
Humanas

Checa Chamorro David
Hidalgo Rivera Armando Felipe

Proyecto de trabajo de grado en la modalidad Investigación presentada al comité
curricular del programa de Ingeniería Electrónica

Asesor
Eraso José Camilo

Programa de Ingeniería Electrónica
Facultad de Ingeniería
Universidad CESMAG
San Juan de Pasto
2025

AGRADECIMIENTOS

En primer lugar, quiero expresar mi más sincero agradecimiento a mi director de tesis, José Camilo Eraso, por su invaluable apoyo, orientación y paciencia a lo largo de este proceso. Su conocimiento y compromiso me han sido fundamentales para el desarrollo de este trabajo.

Quiero expresar mi más sincera gratitud a todas las personas que me han acompañado y apoyado durante el desarrollo de este trabajo de grado y a lo largo de mi formación académica.

En primer lugar, agradezco a Dios por darme la fortaleza, la sabiduría y las oportunidades para seguir adelante incluso en los momentos más difíciles.

A mi madre, cuya paciencia, amor y sacrificio ha sido el pilar fundamental de mi vida. Gracias por su constante apoyo emocional y económico, y por enseñarme a nunca rendirme.

A mis hermanos y demás familiares, por ser una fuente constante de motivación y alegría. Su presencia ha sido clave en mi crecimiento personal. Finalmente, agradezco a todos aquellos que, de alguna manera, contribuyeron a la realización de este trabajo, ya sea con su apoyo académico, emocional o práctico. Sin ustedes, este proyecto no habría sido posible.

Felipe Hidalgo.

AGRADECIMIENTOS

Primeramente, quiero expresar mi más sincero agradecimiento a mi director de tesis, José Camilo Eraso por su guía y apoyo constante durante todo el proceso de investigación y escritura de este trabajo. Su valiosa dirección y experiencia han sido cruciales para el éxito de este proyecto.

También deseo agradecer a mi familia, especialmente a mis padres, por su paciencia, comprensión y apoyo emocional durante este período de tiempo. Su amor y apoyo han sido fundamentales para mantener mi motivación y ánimo.

Agradezco también a mis colegas y amigos, quienes han compartido sus conocimientos y experiencias conmigo, lo que me ha permitido aprender mucho y mejorar mi investigación.

En general, este trabajo no hubiera sido posible sin el apoyo y colaboración de todas estas personas, y por ello estoy profundamente agradecido.

David Checa.

DEDICATORIA

Este trabajo está dedicado a mi madre y abuela, cuyo amor y apoyo incondicional han sido mi mayor fuente de fortaleza. Agradezco profundamente su sacrificio y por enseñarme a nunca rendirme, incluso en los momentos más difíciles.

También lo dedico a mis hermanos, sobrinos, y pareja, por ser mis compañeros y aliento constante, por su comprensión y por estar siempre a mi lado, motivándome a seguir adelante.

A todas las personas que han sido parte de mi vida y me han brindado su confianza, consejos y cariño, les agradezco desde lo más profundo de mi corazón.

Felipe Hidalgo.

Dedicado a mi familia, especialmente a mis padres, cuya fe, amor y apoyo incondicional han sido mi fuente de inspiración y energía para superar los desafíos y alcanzar esta meta.

Esta dedicatoria es un pequeño gesto de gratitud por su constante apoyo y por haberme enseñado la importancia de la perseverancia, la dedicación y la pasión por lo que se hace. Sin ustedes, este trabajo no tendría el mismo valor y significado. Gracias por creer en mí y por estar siempre ahí para mí en los momentos difíciles y en los momentos de triunfo. Este trabajo es un pequeño homenaje a su amor y dedicación.

David Checa.

Contenido

	Pág.
Lista de Figuras	12
Introducción	18
1. El problema de investigación.....	20
1.1 Objeto o Tema de Investigación.....	20
1.2 Línea de investigación.....	20
1.3 Sublínea de investigación.....	20
1.4 Planteamiento o Descripción del Problema	20
1.5 Formulación del Problema	22
1.6 Objetivos	23
1.6.1 Objetivo general.....	23
1.6.2 Objetivos específicos	23
1.7 Justificación.....	23
1.8 Viabilidad.....	25
1.9 Delimitación	26
2. Tópicos del marco teórico.....	28
2.1 Antecedentes	28
2.1.1 Algoritmo de detección de caídas para personas de la tercera edad	28
2.1.2 Dispositivo IOT detector de caídas para las personas de la tercera edad	31
2.1.3 A Large – Scale open motion Dataset (KFall) and benchmark algorithms for detecting pre-impact fall of the elderly using wearable inertial sensors.....	32
2.1.4 Detección automática de actividad en el hogar de personas mayores	36
2.1.5 Sistema de reconocimiento de actividades higiénicas con sensores multimodales.....	37
2.1.6 Base de datos multimodal para el reconocimiento de actividad humana	39

2.2	Enunciados de los supuestos teóricos.....	41
2.3	Definición de conceptos	43
2.3.1	Definición nominal de conceptos.....	43
2.3.2	Definición operativa de conceptos.....	44
2.4	Hipótesis.....	46
2.4.1	Hipótesis de investigación	46
2.4.2	Hipótesis nula.....	46
2.4.3	Hipótesis alternativa.....	46
3.	Metodología	47
3.1	Enfoque	47
3.2	Paradigma.....	47
3.3	Método	47
3.4	Tipo de investigación	48
3.5	Diseño de investigación	48
3.6	Universo	49
3.7	Muestra.....	49
3.8	Técnicas de recolección de información	49
3.8.1	Validez de la técnica	50
3.8.2	Confiabilidad técnica	51
3.9	Instrumentos de recolección de la información.....	51
4.	Resultados	53
4.1	Revisión de Antecedentes	53
4.1.1	Utilization of Barometric Sensors in Fall Detection Systems for Elderly Monitoring	55
4.1.2	A Survey on Fall Detection Systems Using Barometric Sensors	55

4.1.3	Performance of Integrated Accelerometer-Gyroscope Sensors in Fall Detection	55
4.1.4	Performance Analysis of Wearable Accelerometer-Gyroscope	56
4.1.5	Innovative Use of Microphone Sensors in Fall Detection Systems: A Preliminary Study	56
4.1.6	The Role of Acoustic Sensors in Fall Detection Systems for the Elderly: A Comparative Study.....	57
4.1.7	Enhanced Fall Detection System Using Deep Learning Algorithms and Multi-Sensor Data Fusion	57
4.1.8	A Fall Detection System Based on Inertial Sensors	58
4.1.9	Sound-Based Fall Detection Using Machine Learning Algorithms	58
4.1.10	A Hybrid System for Fall Detection Using Vibration Sensors.....	59
4.1.11	Multi-Sensor Based Fall Detection Using Deep Learning Techniques	59
4.1.12	Fall Detection System Using an Accelerometer and Microphone.....	60
4.1.13	Vibration-Based Fall Detection: An Experimental Study	60
4.1.14	Hybrid Fall Detection Using Sound and Motion Data	61
4.1.15	Detecting Falls Using a Wearable Device with Accelerometers	61
4.1.16	Sound Analysis for Fall Detection Using Wearable Devices	62
4.1.17	FallAIIID: A Comprehensive Dataset of Human Falls and Activities of Daily Living.....	62
4.1.18	Fall Detection Dataset.....	63
4.1.19	Human Fall Detection Algorithm Based on Random Forest and MPU6050..	64
4.1.20	Human Fall Detection Using Deep Learning and Wearable Sensors	64
4.1.21	Synthetic IMU Datasets and Protocols Can Simplify Fall Detection Experiments and Optimize Sensor Configuration	65

4.1.22	Fall Detection Based on Accelerometer and Gyroscope using Back Propagation	66
4.1.23	Sistema altamente portátil basado en sensores para el monitoreo de caídas humanas	67
4.1.24	Inertial measurement and heart-rate sensor-based dataset for geriatric fall detection using custom built wrist-worn device	67
4.1.25	Conjunto de datos de detección de caídas ascendentes: un enfoque multimodal	68
4.1.26	Alteration of Neural Network Activity With Aging Focusing on Temporal Complexity and Functional Connectivity Within Electroencephalography	69
4.1.27	CareFall: Automatic Fall Detection through Wearable Devices and AI Methods.....	70
4.1.28	Detección de caídas mediante Random Forest y MPU6050.....	70
4.1.29	Sistema de detección de caídas basado en IoT con MPU6050	70
4.1.30	Sistema de airbag para protección contra caídas utilizando MPU6050.....	71
4.1.31	Detección de caídas hacia adelante utilizando datos inerciales y aprendizaje automático.....	72
4.1.32	Evaluación de caídas como anomalías utilizando datos de acelerómetros de smartphones	72
4.1.33	Base de datos UniMiB SHAR para reconocimiento de actividades humanas	72
4.1.34	Conjunto de datos OxIOD para odometría inercial profunda.....	73
4.1.35	Evaluación experimental de detección de caídas utilizando datos de acelerómetros de smartphones	73
4.1.36	Base de datos UP-Fall para detección y reconocimiento de actividades	73
4.1.37	Evaluación de métodos de detección de caídas utilizando el conjunto de datos UP-Fall	74

4.1.38	Conjunto de datos para el desarrollo y optimización de algoritmos de detección de caídas	74
4.1.39	Evaluación de sensores para la detección de caídas utilizando IoT y métodos de aprendizaje profundo	75
4.2	Instrumentación y Materiales	78
4.2.1	Descripción de los Componentes.....	83
4.3	Diseño e implementación del sistema de sensores.....	97
4.3.1	Requerimientos del Sistema.....	98
4.3.2	Diseño del Sistema.....	99
4.3.3	Implementación del Sistema de Sensores	102
4.3.4	Rendimiento de los Sensores	105
4.3.5	Validación del Sistema	112
4.4	Diseño e Implementación Base de Datos.....	131
4.4.1	Diseño de la Base de Datos.....	132
4.4.2	Requerimientos de la Base de Datos.....	132
4.4.3	Integración y Pruebas de la Base de Datos	132
4.4.4	Organización de la Base de Datos	134
4.4.5	Estructura de la Base de Datos.....	136
4.4.6	Distribución de Eventos de Caída por Usuario.....	138
4.4.7	Clasificación de los Eventos de Caída	139
4.4.8	Análisis de resultados	142
4.4.9	Evaluación de los resultados	143
4.4.10	Análisis de Resultados del Algoritmo Naive Bayes	147
4.4.11	Factores de Riesgo Identificados	162
5.	Conclusión	163
6.	Recomendaciones	164

Referencias.....	165
------------------	-----

Lista de Figuras

Figura 1 Ubicación y envío de datos de los dispositivos para la adquisición de datos. Fuente: Rivadeneira (2023).....	28
Figura 2 Comparación Sensores Fuente: Capera-Peña, C y Huertas-Prieto, T. (2022)...	31
Figura 3 Comparación de sensores acelerómetros junto con un giroscopio Fuente: Capera-Peña, C y Huertas-Prieto, T. (2022) [9].....	32
Figura 4 Datos públicos basados en sensores inerciales portátiles para la detección de caídas Fuente: Yu, X., Jang, J., & Xiong, S. (2021) [12]	33
Figura 5 Tareas experimentales de 21 tipos de AVD y 15 tipos de caídas. Fuente: Yu, X., Jang, J., & Xiong, S. (2021) [12]	34
Figura 6 Organización del conjunto de datos de KFall proporcionado en el sitio web. Fuente: Yu, X., Jang, J., & Xiong, S. (2021) [12]	36
Figura 7 Ejemplo de señales de audio sin procesar a 44,1 kHz, espectrograma log-Mel (LM) y coeficiente Fuente: P. Rodríguez, A (2022) [17]	38
Figura 8 Parámetros entrenables, tiempo de aprendizaje, millones de instrucciones (MI) y tiempo de evaluación Fuente: P. Rodríguez, A (2022) [17]	39
Figura 9 Sistema de adquisición. Fuente: Martínez-Villaseñor, L., Ponce, H., & Espinosa- Loera, R. A. (2018) [18].....	40
Figura 10 Estructura JSON es: Datos, Tipo de datos, Sensor, Hora. Fuente: Martínez- Villaseñor, L., Ponce, H., & Espinosa-Loera, R. A. (2018) [18].....	40
Figura 11 Actividades y caídas incluidas en el conjunto de datos. Fuente: Martínez- Villaseñor, L., Ponce, H., & Espinosa-Loera, R. A. (2018) [18].....	41
Figura 12 Diagrama de bloques Búsqueda de antecedentes Fuente: Los autores.....	54
Figura 13 Detector Caídas Cámara Fuente: U. K. Kandagatla. 2023. [38]	63
Figura 14 Datos de entrenamiento adquiridos mediante simulación para la caída amortiguada (a) Velocidad registrada en los ejes X y Y [m/s]; b) aceleración registrada en los ejes X y Y. Fuente: F. Gómez, M. Aguayo and L. Avendaño. 2024. [40].....	64
Figura 15 Marco experimental del sistema propuesto. Fuente: P. Ravi, J. K. Aggarwal and C. Nugent. 2023. [41]	65

Figura 16 Extracción de características basada en valores promedio, valores máximos y valores mínimos. Fuente: Jefiza, A. Z., Putra, F. P. R., & Pratama, A. D. 2020. [42]	66
Figura 17 Rendimiento de detección de caídas en diferentes segmentos del cuerpo humano. Fuente: A. Mao, X. Ma, Y. He y J. Luo. 2017. [43]	67
Figura 18 Organización del conjunto de datos consolidado. Fuente: J. Martínez-Villaseñor, R. Ponce, A. Sánchez, J. Emmanuel García-González, D. T. Dzul, y J. A. Lozano. 2019. [45]	69
Figura 19 Bases de datos públicas seleccionadas para capacitar y evaluar CareFall. Fuente: D. Serrano, A. Rubio-Solis, J. M. Garzón, y M. Á. Vega-Rodríguez. 2023. [47]	70
Figura 20 Experimento de caída Fuente: N. K. S. Mohd, R. Hussin y M. F. M. Razali. 2023.....	71
Figura 21 Duración entre el movimiento de caída detectado y el impacto Fuente: N. Atmadja, A. Wahyudi y I. Fadlika. 2024.	71
Figura 22 Datos de entrenamiento adquiridos a través de simulación para la caída amortiguada hacia adelante: (a) Velocidad registrada en el eje X e Y [m/s]; (b) Aceleración registrada en el eje X e Y. Fuente: R. V. M. Romero, N. H. R. Sebastian y A. L. B. Francisco. 2024.	72
Figura 23 OxIOD Dataset Fuente: C. Chen, X. Zhu, J. Zhang, Y. Liu, H. Hu y H. Huang. 2018.....	73
Figura 24 La estructura JSON es: Datos, tipo de Datos, Sensor, Tiempo. Fuente: A. Martinez-Villaseñor, L. Ponce, A. Sanchez y J. A. Lozano. 2018.	74
Figura 25. Diagrama de flujo Instrumentación y Materiales Fuente: Los Autores	78
Figura 26. ESP32MINI	Fuente: Los Autores 88
Figura 27. BMP180	Fuente: Los Autores 90
Figura 28. MPU6050	Fuente: Los Autores..... 92
Figura 29. KY-037	Fuente: Los Autores 94
Figura 30. KY-031	Fuente: Los Autores 97
Figura 31 Esquema del sistema Fuente: Los Autores.....	99
Figura 32. Diagrama de flujo del dispositivo Fuente: Los Autores.....	101
Figura 33 Diseño del Circuito en KiCad. Fuente: Los Autores.....	102
Figura 34 Diseño Baquelita Fuente: Los Autores.....	103

Figura 35 Primer Prototipo del Sistema de Sensores Implementado	Fuente: Los Autores	105
Figura 36. Caída hacia adelante con BMP180	Fuente: Los Autores	106
Figura 37. Caída hacia adelante con MPU6050	Fuente: Los Autores	107
Figura 38. Caída hacia adelante con KY-037	Fuente: Los Autores	108
Figura 39. Caída hacia adelante con KY-031	Fuente: Los Autores	108
Figura 40 MPU6050 al sentarse	Fuente: Los Autores	110
Figura 41 BMP180 al sentarse	Fuente: Los Autores	111
Figura 42 KY-031 al sentarse	Fuente: Los Autores	111
Figura 43 KY-037 al sentarse	Fuente: Los Autores	112
Figura 44 Ubicación del Dispositivo	Fuente: Los Autores	113
Figura 45 Dispositivo en la Persona	Fuente: Los Autores	114
Figura 46 Numero de pruebas realizadas por Personas	Fuente: Los Autores	115
Figura 47 Implementación Final del Sistema	Fuente: Los Autores	118
Figura 48 Persona Caminando	Fuente: Los Autores	118
Figura 49 Persona Corriendo	Fuente: Los Autores	119
Figura 50 Persona Levantándose	Fuente: Los Autores	119
Figura 51 Persona Saltando	Fuente: Los Autores	120
Figura 52 Persona Sentada	Fuente: Los Autores	120
Figura 53 Persona Caída Hacia Adelante	Fuente: Los Autores	121
Figura 54 Persona Caída Hacia Atrás	Fuente: Los Autores	121
Figura 55 Persona Caída Laterales (Izquierda/Derecha)	Fuente: Los Autores	122
Figura 56 Persona Caída Sentada	Fuente: Los Autores	122
Figura 57 Gráfica caminar	Fuente: Los Autores	124
Figura 58 Gráfica Correr	Fuente: Los Autores	124
Figura 59 Gráfica Levantarse	Fuente: Los Autores	125
Figura 60 Gráfica Saltar	Fuente: Los Autores	126
Figura 61 Gráfica Sentarse	Fuente: Los Autores	126
Figura 62 Gráficas caída hacia adelante	Fuente: Los Autores	127
Figura 63 Gráfica caída hacia atrás	Fuente: Los Autores	128
Figura 64 Gráficas caída lateral izquierda	Fuente: Los Autores	129

Figura 65 Gráficas caída lateral derecha Fuente: Los Autores	130
Figura 66 Gráficas caída sentado Fuente: Los Autores	131
Figura 67 Numero de ejemplos recopilados por clase Fuente: Los Autores	134
Figura 68 Carpetas 40 Personas Fuente: Los Autores	135
Figura 69 Carpeta Persona 1 Fuente: Los Autores	135
Figura 70 Intentos por Actividad en Persona 1 Fuente: Los Autores	136
Figura 71 Base de Datos Fuente: Los Autores.....	138
Figura 72 Porcentaje de Actividades Fuente: Los Autores.....	140
Figura 73 Actividad vs Número de personas Fuente: Los Autores	140
Figura 74 Porcentaje de las condiciones Fuente: Los Autores	141
Figura 75 Porcentaje de caídas Fuente: Los Autores.....	141
Figura 76 Porcentajes de actividades (Sin caídas) Fuente: Los Autores	142
Figura 77 Matriz de Confusión Actividades Fuente: Los Autores	144
Figura 78 Matriz de Confusión Caídas Fuente: Los Autores	145
Figura 79 Matriz de Confusión Fuente: Los Autores	145
Figura 80 Métricas de desempeño Fuente: Los Autores.....	146
Figura 81 Falsos Positivos VS Caídas Fuente: Los Autores	146
Figura 82 Porcentajes Obtenidos de la Base de Datos Los Autores	147
Figura 83 Matriz de Confusión para Detección de Caídas Fuente: Los Autores.....	149
Figura 84 a) Métricas de Rendimiento del Clasificador b) Curva ROC (Punto de Operación).....	150
Figura 85 Curva ROC para Detección de Caídas Fuente: Los Autores.....	151
Figura 86 a) Distribución de Scores por Clase b) Sensibilidad y Especificidad vs Umbral Fuente: Los Autores	152
Figura 87 Comparación de Características por Clase Fuente: Los Autores	153
Figura 88 Distribución de Eventos Fuente: Los Autores.....	153
Figura 89 Distribuciones Fuente: Los Autores	155
Figura 90 Métricas por Grupo de Edad Fuente: Los Autores.....	156
Figura 91 Curva ROC - Detección Caídas Fuente: Los Autores	157
Figura 92 Detectabilidad por Duración e Intensidad Fuente: Los Autores	158
Figura 93 Ajuste de Modelo de Regresión Fuente: Los Autores.....	158

Figura 94 a) Relación Duración Detección por Intensidad. b) Distribución Detección por Intensidad Fuente: Los Autores	159
Figura 95 a) Precisión por Ambiente. b) Precisión por Superficie Fuente: Los Autores	160
Figura 96 Métricas del sistema Fuente: Los Autores.....	160
Figura 97 Relación de Usuarios Fuente: Los Autores	162

Lista de Tablas

Tabla 1 Matriz de confusión.	Fuente: Rivadeneira (2023) [8].....	30
Tabla 2 Antecedentes	Fuente: Los Autores	78
Tabla 3 Comparación de Microcontroladores	Fuente: Los Autores	79
Tabla 4. Comparación Sensores Acelerómetro y Giroscopio	Fuente: Los Autores	80
Tabla 5. Comparación Sensores Barómetro	Fuente: Los Autores	81
Tabla 6. Comparación Sensores Micrófono	Fuente: Los Autores	82
Tabla 7. Comparación Sensores Vibración	Fuente: Los Autores	83
Tabla 8. Ponderación lineal de microcontroladores	Fuente: Los Autores	86
Tabla 9 Matriz de Confusión Microcontroladores	Fuente: Los Autores	87
Tabla 10. Ponderación lineal del Barómetro	Fuente: Los Autores	88
Tabla 11 Matriz de confusión sensor barómetro.	Fuente: Los Autores	89
Tabla 12. Ponderación lineal de Acelerómetro y Giroscopio	Fuente: Los Autores	90
Tabla 13 Matriz de Confusión Sensor Acelerómetro/Giroscopio	Fuente: Los Autores...	91
Tabla 14. Ponderación lineal del Micrófono	Fuente: Los Autores	92
Tabla 15 Matriz de Confusión Sensor Micrófono	Fuente: Los Autores.....	93
Tabla 16. Ponderación lineal del Sensor de Vibración	Fuente: Los Autores	95
Tabla 17 Matriz de Confusión Sensor Vibración	Fuente: Los Autores.....	96
Tabla 18 Número de intensidad de cada actividad	Fuente: Los Autores.....	115
Tabla 19 Número de Condiciones de toma de datos a cada persona	Fuente: Los Autor	116
Tabla 20 Resultados Naive Bayes	Fuente: Los Autores.....	161
Tabla 22 Tabla Sensor MPU6050	Fuente: Los Autores	173
Tabla 23 Tabla Sensor BMP180	Fuente: Los Autores	174
Tabla 24 Tabla Sensor KY-031	Fuente: Los Autores.....	175
Tabla 25 Tabla Sensor KY-037	Fuente: Los Autores.....	176

Introducción

En la actualidad, las caídas se consideran una de las principales causas de lesiones y muertes accidentales en todo el mundo, especialmente entre las personas adultas mayores. De acuerdo con la Organización Mundial de la Salud (OMS), en 2023 existían más de mil millones de personas con 60 años o más, y se estima que esta cifra podría duplicarse, alcanzando los 2.100 millones para el año 2050 [1]. Este rápido envejecimiento poblacional ha despertado una creciente preocupación por la seguridad y el bienestar de los adultos mayores, particularmente frente a los accidentes que pueden ocurrir en el hogar. En este contexto, las caídas se han consolidado como un problema de salud pública de gran relevancia, siendo la segunda causa global de muertes accidentales, con cerca de 684.000 fallecimientos al año. En Colombia, este tipo de accidente también tiene una alta incidencia, ubicándose como una de las principales causas de lesiones y la cuarta causa de muerte accidental [3].

Frente a esta situación, se ha hecho evidente la necesidad de crear tecnologías capaces de detectar caídas de manera temprana y precisa. Contar con sistemas automáticos que identifiquen este tipo de eventos no solo puede disminuir las consecuencias físicas y emocionales que conllevan, sino también aportar información útil para analizar patrones de movimiento diario y advertir posibles cambios en la salud o el comportamiento de una persona [4].

En este escenario surge el Reconocimiento de Actividades Humanas (HAR, por sus siglas en inglés: Human Activity Recognition), un campo de investigación que ha tomado gran importancia en los últimos años. Este enfoque combina conocimientos de distintas disciplinas, como la ingeniería, la salud, la biomecánica y la inteligencia artificial, con el propósito de identificar y clasificar diferentes movimientos del cuerpo humano. El HAR permite distinguir actividades cotidianas como caminar, correr o permanecer de pie, así como detectar eventos más críticos, como las caídas. Además de servir en el monitoreo y asistencia de personas, esta tecnología permite interpretar el movimiento humano de manera que se puedan prever conductas o condiciones que representen un riesgo para la integridad del individuo.

Existen diversas metodologías para el reconocimiento de actividades humanas, entre las que destacan la visión por computadora y el uso de sensores portátiles. Sin embargo, ambas presentan ciertos desafíos. Los métodos basados en visión computacional, por ejemplo, pueden verse afectados por la iluminación, la posición de la cámara o la presencia de obstáculos, además

de implicar un alto consumo de recursos y posibles riesgos para la privacidad [5]. Por su parte, los sensores portátiles pueden resultar costosos, incómodos o interferir con el movimiento natural del usuario, lo que en algunos casos genera resistencia a su uso, especialmente en personas mayores. Entre los dispositivos que suelen presentar estas limitaciones se encuentran los sensores de contacto, giroscopios y acelerómetros [6].

El presente proyecto se enfoca en el desarrollo de una base de datos destinada al entrenamiento y evaluación de un sistema de detección de caídas humanas. Para ello, se seleccionaron distintos sensores con el fin de recopilar información que registre diversas actividades, tanto normales como aquellas que involucren caídas. Este proceso permitirá obtener datos relevantes para el estudio de estos eventos, contribuyendo a la prevención de accidentes y al fortalecimiento de estrategias de cuidado en la población adulta mayor.

La prioridad de esta investigación es identificar los sensores más adecuados para la captura de información confiable, que permita construir una base de datos precisa y útil. El análisis contempla aspectos como la exactitud, la sensibilidad, el consumo energético, la conectividad, el costo y el grado de comodidad de los sensores empleados. Los resultados obtenidos buscan resaltar la importancia de implementar sistemas automáticos que detecten caídas y generen alertas oportunas, de modo que se pueda brindar atención inmediata y reducir las posibles secuelas físicas o emocionales. En definitiva, este proyecto pretende aportar al desarrollo de soluciones tecnológicas no invasivas, que garanticen comodidad y fiabilidad en la recolección de datos, contribuyendo así al bienestar y seguridad de las personas mayores.

1. El problema de investigación

1.1 Objeto o Tema de Investigación

Sensores y base de datos para el registro de señales que caracterizan las diferentes actividades humanas en especial caídas.

1.2 Línea de investigación

Sistemas de Automatización y Control: La línea de sistemas de automatización y control de la Universidad CESMAG desarrolla procesos investigativos orientados al modelamiento, simulación, diseño, desarrollo y evaluación de algoritmos de control, sistemas de control, sistemas inteligentes, control de procesos industriales, sistemas embebidos, acondicionamiento y procesamiento de señales, robótica, domótica e inteligencia artificial [7].

1.3 Sublínea de investigación

Inteligencia Artificial: La inteligencia artificial es una respuesta al deseo de aproximar el comportamiento humano y el pensamiento racional a diversos sistemas para la solución de determinadas problemáticas a través de diferentes técnicas para la solución de problemas, entre las que se destacan la lógica difusa, las redes neurales, los sistemas neuro-difusos y los algoritmos genéticos. De esta forma los resultados que se desprenden de los procesos investigativos desarrollados en esta línea se orientan a la generación de algoritmos y metodologías que presentan un comportamiento autónomo, dinámico que se adecua a la evolución del entorno [7].

1.4 Planteamiento o Descripción del Problema

De acuerdo con [8], el envejecimiento de la población y la falta de monitoreo constante en las personas mayores incrementan notablemente el riesgo de consecuencias graves ante una caída. Esto se debe a que los adultos mayores son más propensos a sufrir accidentes de este tipo por factores físicos, cognitivos y ambientales, entre los que se destacan la pérdida de movilidad y la debilidad muscular. Como resultado, una caída puede ocasionar lesiones severas, discapacidades permanentes o incluso la muerte, especialmente en aquellos casos donde las

personas viven solas y no cuentan con ayuda inmediata [9]. Según [10], cerca del 58% de las personas mayores de 80 años han sido reportadas como fallecidas tras sufrir caídas graves. Además, se proyecta que la población mundial de adultos mayores de 60 años se duplicará, pasando del 11% al 22% entre los años 2000 y 2050, lo que representa un aumento de 605 millones a aproximadamente 2.000 millones de personas [11]. En este contexto, la detección y el reconocimiento de caídas se consolidan como un reto importante para la salud pública y la calidad de vida.

Las investigaciones enfocadas en el reconocimiento de actividades en adultos mayores suelen centrarse en identificar acciones básicas y breves, como caminar, caer, desmayarse, sentarse o acostarse. Sin embargo, a pesar de las diferencias en los enfoques y el número de actividades analizadas, la mayoría de los estudios sobre Reconocimiento de Actividades Humanas (HAR) comparten una serie de desafíos comunes. Entre ellos se destacan el alto costo computacional, la similitud entre movimientos, el ruido presente en las señales, las condiciones del entorno y la variabilidad en la forma en que distintas personas ejecutan una misma acción. Por ello, la correcta selección y configuración de sensores para el registro de señales se convierte en un aspecto fundamental y a la vez complejo dentro del proceso de reconocimiento de actividades humanas.

Una elección inadecuada de sensores puede afectar de manera significativa la calidad de los datos y, en consecuencia, la construcción de una base de datos confiable. En este sentido, la presente investigación se propone seleccionar los sensores más adecuados para el registro y monitoreo de caídas humanas. A partir de los datos obtenidos, se construirá una base de datos que podrá ser utilizada en futuros estudios orientados al entrenamiento y evaluación de algoritmos de inteligencia artificial dedicados a la detección automática de caídas. Dicho sistema permitiría, en un escenario aplicado, emitir una alerta de emergencia que indique la hora, el tipo de caída y la identificación de la persona afectada, facilitando así una atención médica rápida y reduciendo los posibles efectos adversos.

Diversos estudios han empleado distintos tipos de sensores, como giroscopios, acelerómetros, sensores de presión o de sonido, entre otros. No obstante, aún no existen bases de datos de acceso público que incluyan de manera integral la información proveniente de varios de estos dispositivos. Además, la literatura científica actual presenta cierta incertidumbre sobre cuáles sensores ofrecen mejores resultados en términos de precisión, sensibilidad, consumo

energético, conectividad, costo y grado de invasividad. Esta falta de consenso resalta la importancia de realizar una revisión sistemática que permita definir criterios claros y orientar futuras investigaciones en el área.

La correcta selección de sensores es crucial tanto para los proyectos en curso como para el desarrollo de soluciones futuras, ya que influye directamente en la precisión y la eficacia de los sistemas de detección. Para la creación de algoritmos confiables, es indispensable contar con bases de datos robustas que incluyan registros de caídas simuladas o reales en condiciones controladas, así como datos correspondientes a actividades cotidianas.

Por otro lado, la detección automática de caídas en adultos mayores requiere soluciones tecnológicas que no interfieran con su comodidad ni limiten su movilidad. Uno de los principales desafíos consiste en encontrar sensores no invasivos, precisos y confiables, capaces de registrar señales fisiológicas o de movimiento que permitan identificar un evento de caída de manera oportuna. Sin embargo, gran parte de las bases de datos existentes fueron elaboradas con información obtenida de voluntarios jóvenes o mediante simulaciones poco realistas, utilizando únicamente sensores inerciales básicos como acelerómetros y giroscopios [12]. No se dispone, por ejemplo, de bases públicas que incluyan sensores acústicos o de presión, lo que limita la diversidad de información y la calidad del análisis. A esto se suman problemas de ruido, errores de medición y datos incompletos [13], los cuales reducen el rendimiento de los modelos predictivos.

El verdadero reto, por tanto, radica en la ausencia de bases de datos sólidas y completas que representen escenarios realistas de caídas, integrando múltiples tipos de sensores. Ante esta carencia, la presente investigación plantea la construcción de una base de datos propia que recopile información obtenida de sensores seleccionados cuidadosamente por el equipo, incluyendo opciones menos exploradas como los sensores de sonido y de vibración. Con ello, se busca avanzar hacia modelos más precisos y adaptados a situaciones reales, que en un futuro puedan aplicarse de manera efectiva en el monitoreo y protección de personas adultas mayores.

1.5 Formulación del Problema

Varias investigaciones han dedicado sus esfuerzos al reconocimiento de caídas humanas mediante diversos sensores. Sin embargo, se ha observado que los sensores utilizados pueden tener un costo elevado y son susceptibles a influencias externas como la luz, el ruido y el

movimiento. Además, suelen resultar incómodos para las personas mayores, lo que podría restringir sus movimientos y dar lugar a otros incidentes. En consecuencia, la presente investigación se focaliza en la búsqueda de sensores apropiados para el reconocimiento de caídas humanas.

Este estudio plantea la siguiente pregunta de investigación: ¿Cuáles son los sensores más adecuados y eficaces para la caracterización de caídas humanas, y de qué manera pueden ser empleados para construir una base de datos que registre y almacene las señales asociadas a las caídas detectadas?

1.6 Objetivos

1.6.1 Objetivo general

Desarrollar una base de datos, que registre y almacene información proveniente de sensores adecuados para un sistema de detección de caídas humanas.

1.6.2 Objetivos específicos

- Identificar los sensores adecuados para el reconocimiento de caídas a partir de una revisión de antecedentes.
- Diseñar e implementar el sistema de sensores, permitiendo la captura de señales relevantes en la detección de una caída humana.
- Diseñar e implementar una base de datos para el registro de señales de sensores que representan caídas humanas.

1.7 Justificación

La presente investigación tiene como propósito principal desarrollar una base de datos que recopile señales obtenidas a partir de sensores no invasivos empleados en la detección de caídas humanas. La relevancia de este proyecto radica en que una base de datos bien estructurada, con información real y representativa, constituye el punto de partida esencial para el diseño y entrenamiento de modelos de aprendizaje automático orientados al reconocimiento de eventos de caída. Según [8], el uso de dispositivos electrónicos como sensores para el reconocimiento de caídas puede prevenir lesiones y complicaciones en la salud física o mental, además de reducir la carga que representan estos incidentes para los sistemas de salud.

Asimismo, este tipo de tecnología contribuye a fortalecer la confianza y autonomía de las personas mayores, especialmente de aquellas que viven solas y enfrentan mayores riesgos.

El proceso de envejecimiento conlleva importantes desafíos en materia de seguridad y bienestar. En el caso de los adultos mayores, las caídas son uno de los eventos más preocupantes, ya que pueden ocasionar lesiones graves, afectar la salud física y mental e incluso provocar la muerte [9]. De acuerdo con [14], a nivel mundial las caídas se encuentran entre las principales causas de lesiones y discapacidades, y representan la segunda causa más común de muertes accidentales. En Estados Unidos, por ejemplo, se estima que cada 11 segundos una persona de la tercera edad es atendida en una sala de urgencias por una caída, y cada 19 minutos ocurre una muerte asociada a este tipo de incidente. Con el aumento constante de la población mayor, estas cifras tienden a incrementarse de manera preocupante. En esta misma línea, [15] señala que las caídas son una de las principales causas de lesiones no intencionales en personas mayores de 65 años, registrándose alrededor de 37,3 millones de casos que requieren atención médica y más de 646.000 muertes cada año.

La adecuada selección de sensores para registrar las señales que caracterizan una caída humana, junto con la creación de una base de datos específica, constituye un paso fundamental en el desarrollo de sistemas automáticos de detección. Estos avances pueden tener un impacto directo en la prevención de lesiones y en la mejora de la calidad de vida de la población adulta mayor.

Esta investigación adquiere una importancia particular en el contexto actual, marcado por el crecimiento constante de la población de la tercera edad. A medida que aumenta el número de personas mayores que viven solas, también se incrementa el riesgo de sufrir caídas que puedan derivar en lesiones graves o incluso en la pérdida de la vida. Por ello, abordar esta problemática es esencial no solo para fortalecer la seguridad y el bienestar de este grupo poblacional, sino también para fomentar el desarrollo de nuevas tecnologías de detección y respuesta ante emergencias.

En la actualidad, la mayoría de las bases de datos disponibles presentan limitaciones importantes, como la falta de información multimodal por ejemplo, registros provenientes de sensores de sonido o de presión, la baja calidad en la recolección de datos o la utilización de escenarios poco realistas. La base de datos propuesta en esta investigación busca llenar ese vacío, proporcionando información más completa y confiable que pueda servir de apoyo tanto para este

proyecto como para futuras investigaciones en el campo de la detección de caídas humanas. Al enfocarse en la población adulta mayor, este trabajo pretende contribuir directamente al mejoramiento de su calidad de vida, promoviendo una detección temprana de caídas y una respuesta rápida ante situaciones potencialmente peligrosas.

1.8 Viabilidad

La viabilidad del proyecto titulado “Selección de Sensores y Creación de una Base de Datos para la Detección de Caídas Humanas” se analiza desde distintas perspectivas con el propósito de determinar su factibilidad general. Desde el punto de vista técnico, la ejecución del proyecto requiere conocimientos sólidos y experiencia en áreas como la revisión sistemática de literatura científica, la evaluación y calibración de sensores, la instrumentación de los dispositivos, el procesamiento de señales de movimiento y la administración de bases de datos. Estos aspectos garantizan que el proceso de diseño y desarrollo se realice de manera estructurada y confiable.

El proyecto aborda una problemática actual y de gran relevancia, enmarcada en el creciente envejecimiento de la población y la necesidad de mejorar la seguridad de las personas mayores, especialmente aquellas que viven solas y presentan un mayor riesgo de sufrir caídas. En este contexto, la iniciativa busca ofrecer una alternativa tecnológica accesible que contribuya al bienestar y la autonomía de este grupo poblacional.

La propuesta resulta viable desde los puntos de vista técnico, ético y económico. En cuanto al componente técnico, se dispone de sensores no invasivos y de fácil acceso capaces de registrar señales relevantes como aceleración, rotación, presión y sonido sin comprometer la comodidad del usuario. Desde el ámbito ético, las pruebas fueron diseñadas para realizarse en un entorno controlado y seguro, utilizando colchonetas y otros elementos de protección con el fin de minimizar cualquier riesgo físico durante la simulación de caídas. Además, se contempla la posibilidad de registrar diferentes tipos de caídas (hacia adelante, hacia atrás y laterales, tanto izquierda como derecha), así como actividades cotidianas como caminar, sentarse, levantarse, correr y saltar. Este enfoque permitirá construir un conjunto de datos diverso y representativo, capaz de diferenciar entre caídas reales y movimientos similares que podrían generar falsos positivos.

Desde la perspectiva económica, el proyecto se mantiene dentro de un rango de costos razonable gracias al uso de sensores de bajo costo y plataformas abiertas como Arduino o Raspberry Pi, además de herramientas de software libre como Excel, Python y MySQL. Estos recursos permiten desarrollar un sistema eficiente sin requerir una gran inversión, lo cual refuerza su factibilidad y sostenibilidad.

En conjunto, la combinación de viabilidad técnica, ética y económica demuestra que la creación de la base de datos propuesta es completamente factible. Asimismo, se proyecta como un aporte de alto valor académico y social, al sentar las bases para el desarrollo de futuros sistemas de detección de caídas más precisos, accesibles y orientados a la protección de las personas adultas mayores.

1.9 Delimitación

El proyecto se centra en la investigación y desarrollo de tecnologías orientadas a la selección de sensores y la creación de una base de datos para la detección de caídas humanas. Para ello, se realizó una evaluación exhaustiva de distintos sensores, considerando criterios fundamentales como precisión, sensibilidad, consumo energético, conectividad, resistencia, costo y grado de invasividad. Este análisis incluyó desde la revisión de documentos y estudios previos hasta la simulación y calibración práctica de los sensores, asegurando un enfoque integral y riguroso.

El alcance del proyecto abarca también la construcción de una base de datos que registre eventos de caída humana, incorporando información de diferentes tipos de caídas, tales como caídas hacia adelante, hacia atrás, laterales y desde la posición sentada. Además, se incluyó un registro de actividades cotidianas realizadas por una persona, con el fin de obtener datos que permitan diferenciar movimientos normales de eventos de caída. Entre las actividades seleccionadas se encuentran caminar, sentarse, levantarse, correr y saltar, lo que garantiza una recopilación de información variada y representativa de situaciones reales.

Es importante destacar que todos los experimentos se llevaron a cabo en un entorno controlado, priorizando la seguridad durante las pruebas. Para las simulaciones de caídas se emplearon elementos de protección, como colchonetas, que minimizan cualquier riesgo físico. Cabe señalar que, en esta etapa del proyecto, no se incluyeron personas mayores de 60 años, dado que el enfoque principal fue establecer procedimientos, calibrar los sensores y validar la

metodología. La recopilación de información se realizó de manera sistemática, mediante la ejecución de simulaciones cuidadosamente planificadas y la calibración de los sensores en condiciones específicas.

El objetivo final de esta fase es proporcionar una base sólida para seleccionar los sensores que ofrezcan un rendimiento óptimo en la detección de caídas. Los datos obtenidos, precisos y confiables, servirán como fundamento para futuras aplicaciones, asegurando que la base de datos refleje escenarios realistas y pueda apoyar de manera efectiva el desarrollo de sistemas de detección automatizados.

2. Tópicos del marco teórico

2.1 Antecedentes

2.1.1 Algoritmo de detección de caídas para personas de la tercera edad

En [8] se propone el diseño de un algoritmo que sea capaz de identificar una caída de una actividad común, con el propósito de que se implemente en dispositivos electrónicos portátiles, como se muestra en la Figura (1).




Figura 1 Ubicación y envío de datos de los dispositivos para la adquisición de datos.

Fuente: Rivadeneira (2023)

En [8] se menciona que se utilizaron modelos matemáticos para describir la trayectoria y determinar la pérdida de balance. Se utilizó la siguiente Ecuación (1):

$$\beta = \cos^{-1}\left(\frac{a_y(t)}{a_x^2(t)+a_x^2(t)+a_x^2(t)}\right) \quad (1)$$

Donde:

β : Representa el ángulo de inclinación del dispositivo con respecto al eje Y.

\cos^{-1} : Es la función arco coseno, utilizada para obtener el valor del ángulo a partir de una razón trigonométrica.

$a_x(t)$: Es la aceleración medida en el eje X en el instante de tiempo.

$a_y(t)$: Es la aceleración medida en el eje Y en el instante de tiempo t.

$a_z(t)$: Es la aceleración medida en el eje Z en el instante de tiempo t.

$\sqrt{(a_x^2(t) + a_y^2(t) + a_z^2(t))}$: Corresponde a la magnitud total del vector de aceleración, la cual se utiliza para normalizar el valor y obtener un ángulo realista.

Además, se menciona que el algoritmo se elaboró a partir de la Ecuación de Torricelli cinemática clásica [8]. Ecuación (2).

$$v^2 = v_0^2 \pm 2a\Delta x \quad (2)$$

Donde:

v : Representa el inicio de la velocidad en (m/s) del cuerpo.

v_0^2 : Representa el final de la velocidad en (m/s) del cuerpo.

Δx : Distancia recorrida en metros.

a : Es la aceleración en (m/s^2).

Describe un movimiento lineal con aceleración constante a lo largo de un eje. Estas fórmulas matemáticas fueron utilizadas para modelar el comportamiento de la aceleración y la trayectoria durante una caída, lo que permitió diseñar un algoritmo capaz de detectar una caída con alta precisión.

El modelo matemático que define una caída lateral está dado por la Ecuación (3).

$$w^2 = \frac{3g(1-\cos \varphi)}{l} \quad (3)$$

Donde:

l : Es la distancia entre la cintura y el suelo en metros.

φ : Es el ángulo del eje cuando cae en radianes.

g : Es la gravedad en (m/s^2).

En donde a partir de las pruebas experimentales se obtuvieron los siguientes resultados, mostrados en la Tabla (1).

Actividad	VP	VN	FP	FN
Agacharse		20		
Levantar un objeto		20		
Caminar		20		
Acostarse/Levantarse		20		
Sentarse		20		
Subir las escaleras/Bajar las escalera		17	3	
Sentadilla		20		
Caída de rodilla	18			2
Caída Frontal	19			1
Caída Posterior	19			1
Caída Lateral	20			
Caída Frontal Flexionando Rodilla	19			1
Caída Posterior Flexionando Rodilla	20			
Caída Lateral Flexionando Rodilla	20			
Total 1	135	137	3	5

Tabla 1 Matriz de confusión.

Fuente: Rivadeneira (2023) [8]

Donde:

VP: Son los verdaderos positivos.

VN: Son los verdaderos negativos.

FP: Son los falsos positivos.

FN: Son los falsos negativos.

Se debe tener en cuenta que los espacios en blanco equivalen a 0, como se muestra en la Tabla (1).

Además, se menciona el umbral seleccionado para la detección de caídas y su comparación con los datos adquiridos en las pruebas experimentales [8].

Se presentan algunas recomendaciones para futuras investigaciones. Se sugiere mejorar el tiempo de respuesta del sistema de amortiguación de impacto de la caída, lo que permitiría la implementación de más métodos de sistemas de amortiguación y no limitarse por el tiempo de respuesta que tiene actualmente.

2.1.2 Dispositivo IOT detector de caídas para las personas de la tercera edad

En [9] realizan la comparación y selección de sensores, se tuvieron en cuenta aspectos como precio, alimentación, conexión, rango y margen de detección. En el caso específico de los acelerómetros, se compararon cuatro módulos diferentes: ADXL345, MMA845X, ADXL335 y MPU6050 como se muestra en la Figura (2).

Comparación de sensores					
Sensores Acelerómetros					
Acelerómetro	Precio (COP)	Alimentación	Conexión	Rango seleccionable	Detección
Módulo ADXL345	\$11.000	Voltaje de alimentación: de 3.6 V	Conexión a través de interfaz I2C	Rango de medición seleccionable +/- 2, 4, 8 y 16 g	Detección de picos de aceleración dobles y sencillos y detección de caída libre
Módulo MMA845X	\$15.000	Voltaje de alimentación: 1,9 V a 3,6 V	Interfaz I2C salida digital (funciona a 2,25 MHz con 4,7 kW pullup)	Rango de medición seleccionable: $\pm 2g / \pm 4g / \pm 8g$ Tipo de salida de datos (ODR) de 1,56 Hz a 800 Hz	Tres canales integrados de detección de movimiento
Módulo ADXL335	\$19.000	Voltaje de alimentación: 3.3 a 5 V	Conexión a través de interfaz I2C	Rango de medición +/-3g	Tres ejes de sensado
Módulo LIS3DH 3	\$14.000	Voltaje de alimentación: 1.7 V a 3.6 V	IIC/SPI interfaz de salida digital 16 bits de salida de datos	2g/ +6g/4g + 8g/+ 16 g	La detección de caída libre cuando reconoce que el dispositivo está en caída libre: así como la aceleración medida a lo largo de todos los ejes

Figura 2 Comparación Sensores
Fuente: Capera-Peña, C y Huertas-Prieto, T. (2022)

Se evaluaron parámetros como la detección, alimentación, rango seleccionable, costos, etc. Luego de la comparación, se eligieron los sensores que mejor se adaptaran a la conexión y programación de ambos, y se procedió a hacer muestreos de información para interpretar cada

una de las señales enviadas y captadas por cada uno de ellos. Posteriormente realizaron la comparación del sensor acelerómetro junto con un giroscopio donde evaluaron parámetros tales como la detección, alimentación, rango seleccionable, costos, etc. Como se muestra en la Figura (3).

Sensores Acelerómetro y Giroscopio					
Acelerómetro	Precio (COP)	Alimentación	Conexión	Rango seleccionable	Detección
MPU6500	\$12.000	Voltaje de alimentación: 3V - 5V	Comunicación I2C y SPI, con ADC de 16-bits	Rango de aceleración: $\pm 2, 4, 8, 16G$. Rango del Giroscopio: 250, 500, 1000, 2000°/s.	Detección de 3 ejes de acelerómetro y 3 ejes del giroscopio
MPU6050 GY-521	\$9.500	Voltaje de alimentación: 3V - 5V	Protocolo I2C para su comunicación. hardware de conversión analógico-digital de 16 bits	Rango acelerómetro: $\pm 2g, \pm 4g, \pm 8g$ y $\pm 16g$ Sensibilidad giroscopio: 131 LSBs/dps Rango giroscopio: $\pm 250dps, \pm 500dps, \pm 1000dps$ y $\pm 2000dps$	Detección de 3 ejes de acelerómetro y 3 ejes del giroscopio
BMI160	\$21.000	Voltaje de alimentación: 3V - 5V	Comunicación estándar: protocolos IIC/SPI	Rango de aceleración: $\pm 2 \pm 4 \pm 8 \pm 16g$ Rango del Giroscopio: $\pm 125 \pm 250 \pm 500 \pm 1000 \pm 2000$ °/s	Detección de 3 ejes de acelerómetro y 3 ejes del giroscopio

Figura 3 Comparación de sensores acelerómetros junto con un giroscopio
Fuente: Capera-Peña, C y Huertas-Prieto, T. (2022) [9]

Para el prototipo del sistema, se eligieron el sensor MPU6050 y el GPS NEO 6M-V2. El sensor MPU6050 fue seleccionado debido a que las señales recopiladas por el mismo mostraban el comportamiento de los ejes X, Y y Z en aceleración y posición, y el GPS NEO 6M-V2 fue elegido por su costo y las señales provenientes de las lecturas de latitud y longitud, por medio de la conexión con el protocolo UART. Además, se identificó que la tarjeta de desarrollo ESP32 era la opción más adecuada para la conexión y programación de ambos.

2.1.3 *A Large – Scale open motion Dataset (KFall) and benchmark algorithms for detecting pre-impact fall of the elderly using wearable inertial sensors*

En [12] realizan un conjunto de datos de movimiento abierto a gran escala, denominado KFall, contiene datos sobre varios niveles físicos de actividades de la vida diaria (AVD) y caídas, que van desde comportamientos de baja actividad hasta escenarios de alta dinámica e incluso casi caídas. El conjunto de datos se generó a partir de 32 varones jóvenes coreanos y contiene movimientos que se adoptaron directamente del conjunto de datos SisFall, que cuenta con el mayor tipo de caídas y AVD. El conjunto de datos incluye datos de sensores inerciales

portátiles, como mediciones de acelerómetros y giroscopios, así como grabaciones de vídeo de los participantes realizando las actividades, como se muestra en la Figura (4).

Public dataset	Types of ADLs/falls	Subjects No.	Sensor data type	Temporal labels for the fall time
DLR Frank et al. (2010)	15/1	19	[§] A, G, M	No
tFall Medrano et al. (2014)	Not typified/8	10	A	No
MobiFall Vavoulas et al. (2014)	9/4	24	A, G, O	No
Cogent labs Ojetola et al. (2015)	8/6	42	A, G	No
TST fall Gasparini et al. (2015)	4/4	11	A	No
MobiAct Vavoulas et al. (2016)	9/4	57	A, G, O	No
Erciyes University Özdemir (2016)	16/20	14	[§] A, G, M	No
UMAFall Casilari et al. (2017b)	8/3	17	[§] A, G, M	No
SisFall Sucerquia et al. (2017)	19/15	38	A, G	No
UniMB SHAR Micucci et al. (2017)	9/8	30	A	No
IMUFD Aziz et al. (2017)	8/7	10	[§] A, G, M	No
CMDFALL Tran et al. (2018)	12/8	50	A	No
CGU-BES Wang et al. (2018)	8/4	15	A, G	No
DU-MD Saha et al. (2018)	8/2	10	A	No
UP-Fall Martínez-Villaseñor et al. (2019)	6/5	17	A, G	No
FallAID Saleh et al. (2021)	*44/35	15	[§] A, G, M, B	No
KFall (Our dataset)	21/15	32	A, G, O	Yes

Figura 4 Datos públicos basados en sensores inerciales portátiles para la detección de caídas

Fuente: Yu, X., Jang, J., & Xiong, S. (2021) [12]

Donde:

- A: Acelerómetro, mide la aceleración lineal (cambios en la velocidad). Detecta movimientos bruscos como caídas.
- G: Giroscopio, mide la velocidad angular (rotación). Ayuda a distinguir caídas de movimientos normales.
- I: IMU, unidad de medición inercial que combina varios sensores para medir movimiento y orientación.
- M: Magnetómetro, mide la orientación respecto al campo magnético terrestre (dirección).
- O: Orientación, datos de orientación calculados a partir de la fusión de sensores (por ejemplo, ángulos de Euler o cuaterniones).
- B: Barómetro, mide la presión atmosférica para estimar cambios de altura (por ejemplo, una caída al suelo).
- Public dataset: Nombre del conjunto de datos y referencia del autor/año.
- Types of ADLs/falls: Número de tipos de Actividades de la Vida Diaria (ADL) y caídas registradas (por ejemplo, 15/1 = 15 actividades normales y 1 tipo de caída).

- Subjects No.: Número de participantes que realizaron las pruebas.
- Temporal labels for the fall time: Indica si el conjunto de datos tiene etiquetas temporales para el instante exacto de la caída (“Yes” o “No”).

Se debe aplicar un complejo algoritmo de fusión de sensores para obtener la medición de la orientación.

Para el mismo tipo de caída, los autores consideraron todas las direcciones posibles (izquierda, derecha, adelante, atrás) bajo dos condiciones (con y sin recuperación); 12 AVD fueron movimientos de las manos, y separaron una AVD cíclica en dos, como sentarse y levantarse [12].

El conjunto de datos KFall se generó a partir de 32 varones jóvenes coreanos que realizaron 21 tipos de AVD y 15 tipos de caídas mientras llevaban un sensor inercial de nueve ejes acoplado en la parte baja de la espalda [12]. Los datos de movimiento recogidos por el sensor incluían la aceleración, la velocidad angular y el ángulo de Euler, como se muestra en la Figura (5).

Task ID	Activity	Trials
D01	Stand for 30 s	1
D02	Stand, slowly bend the back with or without bending at knees, tie shoe lace, and get up	5
D03	Pick up an object from the floor	5
D04	Gently jump (try to reach an object)	5
D05	Stand, sit to the ground, wait a moment, and get up with normal speed	5
D06	Walk normally with turn (4 m)	5
D07	Walk quickly with turn (4 m)	5
D08	Jog normally with turn (4 m)	5
D09	Jog quickly with turn (4 m)	5
D10	Stumble while walking	5
D11	Sit on a chair for 30 s	1
D12	Sit on the sofa (back is inclined to the support) for 30 s	1
D13	Sit down to a chair normally, and get up from a chair normally	5
D14	Sit down to a chair quickly, and get up from a chair quickly	5
D15	Sit a moment, trying to get up, and collapse into a chair	5
D16	Stand, sit on the sofa (back is inclined to the support), and get up normally	5
D17	Lie on the bed for 30 s	1
D18	Sit a moment, lie down to the bed normally, and get up normally	5
D19	Sit a moment, lie down to the bed quickly, and get up quickly	5
D20	Walk upstairs and downstairs normally (five steps)	5
D21	Walk upstairs and downstairs quickly (five steps)	5
F01	Forward fall when trying to sit down	5
F02	Backward fall when trying to sit down	5
F03	Lateral fall when trying to sit down	5
F04	Forward fall when trying to get up	5
F05	Lateral fall when trying to get up	5
F06	Forward fall while sitting, caused by fainting	5
F07	Lateral fall while sitting, caused by fainting	5
F08	Backward fall while sitting, caused by fainting	5
F09	Vertical (forward) fall while walking caused by fainting	5
F10	Fall while walking, use of hands to dampen fall, caused by fainting	5
F11	Forward fall while walking caused by a trip	5
F12	Forward fall while jogging caused by a trip	5
F13	Forward fall while walking caused by a slip	5
F14	Lateral fall while walking caused by a slip	5
F15	Backward fall while walking caused by a slip	5

Figura 5 Tareas experimentales de 21 tipos de AVD y 15 tipos de caídas.

Fuente: Yu, X., Jang, J., & Xiong, S. (2021) [12]

Donde:

- Task ID: Identificador de tarea, es una etiqueta única para cada tipo de actividad o caída. Por ejemplo, D01, D02, F01...
- Activity: Actividad o tipo de caída, describe lo que el participante debía realizar (actividad normal o simulación de caída).
- Trials: Repeticiones o ensayos, cuántas veces se repitió esa actividad en el experimento (por ejemplo, 5 veces cada una).
- D: Daily Activity (ADL — Activity of Daily Living), actividades normales de la vida diaria (no son caídas).
- F: Fall, tareas que simulan diferentes tipos de caídas.
- D01: Stand for 30s, permanecer de pie durante 30 segundos, actividad normal.
- D02: Stand, slowly bend the back, inclinarse hacia adelante para simular agacharse, actividad normal.
- D08: Jog normally with turn (4 m), correr suavemente con un giro, actividad normal.
- D13: Sit on a chair and cross legs, sentarse en una silla y cruzar las piernas, actividad normal.
- F01: Forward fall when trying to sit down, caída hacia adelante al intentar sentarse, caída.
- F04: Forward fall while walking caused by tripping, caída hacia adelante al caminar por tropezar, caída.
- F10: Backward fall while walking caused by slipping, caída hacia atrás al caminar por resbalar, caída.

El conjunto de datos se construyó junto con una cámara de vídeo sincronizada a una alta frecuencia de imagen de 90 Hz, lo que lo convierte en el primer conjunto de datos público para la detección de caídas antes del impacto, y no sólo para la detección después de la caída.

Según [12] el conjunto de datos de KFall se diferencia de otros conjuntos de datos disponibles públicamente en varios aspectos. En primer lugar, incluye referencia de vídeo sincronizada y datos de sensores de movimiento, lo que permite etiquetas temporales precisas para el tiempo de caída y permite que el conjunto de datos se utilice para la detección de caídas previa al impacto, no solo para la detección posterior a la caída. En segundo lugar, cubre casi todas las actividades diarias típicas y las caídas, proporcionando a los investigadores y profesionales una base común para desarrollar nuevos algoritmos y tecnologías sobre la

detección de caídas previas al impacto y la prevención proactiva de lesiones. Como se muestra en la Figura (6).

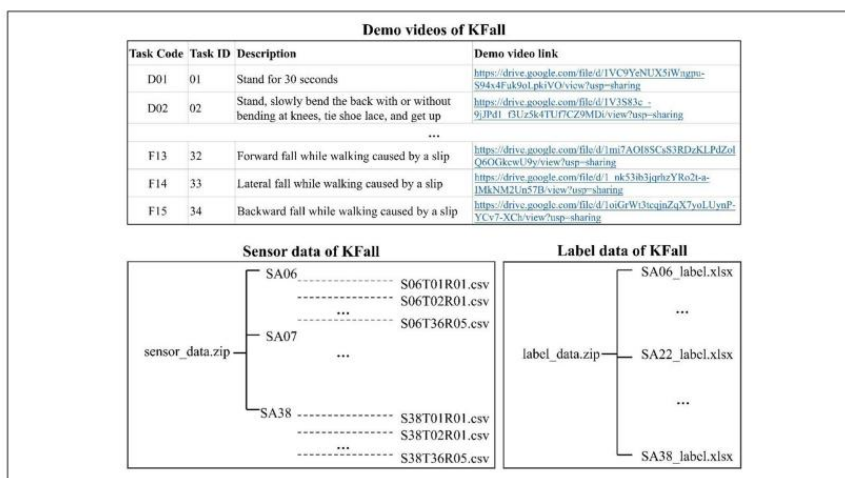


Figura 6 Organización del conjunto de datos de KFall proporcionado en el sitio web.
Fuente: Yu, X., Jang, J., & Xiong, S. (2021) [12]

2.1.4 Detección automática de actividad en el hogar de personas mayores

La investigación [16] se centra en el cuidado y en el análisis del comportamiento físico de adultos mayores de 60 años, utilizando sensores con frecuencias de muestreo que oscilan entre 20 Hz y 50 Hz que emiten los sensores móviles, GPS móvil, cámara móvil para saber la posición de la persona, por el lado de salud hay termómetro corporal, pulsímetro, tensiómetro, oxímetro, glucómetro, etc.

En la parte de la casa se ubican los demás sensores como termómetro, barómetro, cámaras, infrarrojos pasivos y activos entre otros sensores para el registro de datos en el ambiente, en la parte de procesamiento de datos se utiliza imputación en árbol, i-Tree, factorización multi-matricial, k vecinos más cercanos, k-NN, descarte de instancias, junto con técnicas de distribución de ruido como función de distribución acumulativa (ECDF), análisis de la independencia de componentes (ICA) [16]. De lo anterior se llegó a lo siguiente:

1. La recopilación masiva de datos y el tedioso proceso de anotación hace que sea necesaria su automatización.
2. El video y los sensores ambientales trabajan en entornos fijos lo que no los hace adecuados para el reconocimiento de actividad.

3. Los sensores ambientales se ven muy afectados por el ruido y es algo que se debe resolver.
4. El uso de deep learning online puede reportar grandes beneficios en la mejora de la detección, sin embargo, los sensores, especialmente los móviles, sólo usan modelos que ya han sido entrenados offline, de modo que se haya reducido al máximo la comunicación con el servidor y la computación local en el dispositivo para así ahorrar energía.

Es necesario obtener modelos más flexibles para reconocer las actividades de alto nivel, como la combinación de sensores o fusionar la información con el contexto.

2.1.5 Sistema de reconocimiento de actividades higiénicas con sensores multimodales

En [17] se utilizan varios sensores de humedad, sonido, movimiento, entre otros para la prevención de accidentes en el baño y monitoreo de la salud de la persona. En esta etapa, el enfoque principal se centra en el uso del sensor de sonido, el cual permite obtener una mejor comprensión del entorno y de los eventos que pueden ocurrir en él. Este sensor se emplea para el entrenamiento del sistema de inteligencia artificial, recolectando datos durante un periodo determinado mediante una Raspberry Pi. Para ello, se configuró el sensor con una frecuencia de muestreo de 44.1 kHz, permitiendo registrar con precisión las variaciones acústicas del ambiente. Posteriormente, las señales capturadas se procesan y se representan a través de espectrogramas y coeficientes de frecuencia, con el fin de evaluar el desempeño del sistema.

Como se observa en la Figura (7), se presentan distintos patrones de sonido correspondientes a diversas actividades, como el ruido de una cisterna, una ducha, un grifo, un secador, una conversación e incluso el silencio, lo que evidencia la capacidad del sistema para distinguir entre diferentes contextos sonoros.

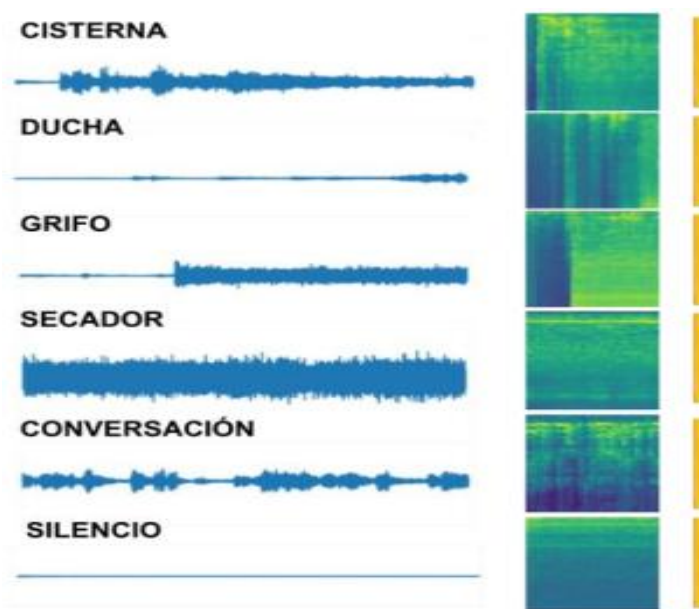


Figura 7 Ejemplo de señales de audio sin procesar a 44,1 kHz, espectrograma log-Mel (LM) y coeficiente

Fuente: P. Rodríguez, A (2022) [17]

Posteriormente, se realizó una prueba de aproximadamente 12 minutos, durante la cual una persona ejecutó diversas actividades cotidianas con el fin de registrar datos reales del entorno. El modelo basado en espectrogramas y coeficientes mel-frecuenciales (CNN + MFCC) alcanzó una precisión del 97.5%, demostrando un desempeño sólido en la detección y clasificación de los sonidos registrados.

Además, se recopilieron detalles técnicos relevantes para la evaluación de cada modelo, incluyendo el número de parámetros entrenables, el tiempo de aprendizaje, la cantidad de millones de instrucciones procesadas y el tiempo de evaluación. Estas pruebas se llevaron a cabo en una Raspberry Pi 3B, configurada con una frecuencia de 400 MHz, lo que permitió analizar el comportamiento del sistema en un entorno de bajo consumo.

Los resultados obtenidos se resumen en la Figura (8), donde se evidencia el rendimiento de ambos modelos durante el proceso de entrenamiento y evaluación [17].

	Trainable Parameters	Learning Time	Millions of Instructions (MI)	Evaluation Time
Model CNN + MFCC	1.7 M	96 min	230.4×10^3 MI	2.53 s
Model CNN + LM	23.3 M	207 min	496.8×10^3 MI	2.81 s

Figura 8 Parámetros entrenables, tiempo de aprendizaje, millones de instrucciones (MI) y tiempo de evaluación

Fuente: P. Rodríguez, A (2022) [17]

Donde:

Modelo CNN: Aprendizaje profundo con redes neuronales convolucionales (CNN por sus siglas en inglés).

MFCC: Coeficientes cepstrales de frecuencia Mel escalados.

LM: Espectrograma log-mel.

2.1.6 Base de datos multimodal para el reconocimiento de actividad humana

En [18] el sistema de adquisición de datos para la detección de caídas y el reconocimiento de actividades es un sistema que detecta datos de diferentes partes del cuerpo como el cuello, la cintura, el muslo, la muñeca de la mano, señales, y ausencia/presencia en un área delimitada. El sistema utiliza cuatro unidades de medición inercial (IMU), un casco de electroencefalograma (EEG), cuatro sensores infrarrojos ambientales, una RaspberryPI3, un PC y un USB externo Bluetooth. Los datos se manipulan para convertirlos en la estructura JavaScript Object Notation (JSON) y luego se envían a Firebase (sin base de datos SQL) a través del método de comunicación API REST. Este sistema puede proporcionar información rica para clasificar y detectar las caídas y predecir las actividades ADL. El sistema de adquisición se muestra en la Figura (9).




Figura 9 Sistema de adquisición.

Fuente: Martínez-Villaseñor, L., Ponce, H., & Espinosa-Loera, R. A. (2018) [18]

La adquisición de datos para este proyecto consta en realidad de 3 pasos: Detección, Extracción y Almacenamiento. En el paso de detección, cada componente comienza a detectar las acciones con los diferentes sensores al mismo tiempo. Los datos a sensor son: IMU's (Acelerómetro (X, Y, y Z), Luz Ambiental (L), y Velocidad Angular (X (rad/s), Y (rad/s), y Z (rad/s))), Casco EEG (señales), y Sensor Infrarrojo (ausencia-presencia con valor binario). En la etapa de extracción, los datos se manipulan para convertirlos a la estructura JSON (JavaScript Object Notation). En el paso de almacenamiento, los datos se envían a través de una solicitud POST para ser almacenados en Firebase (base de datos noSQL) [18].

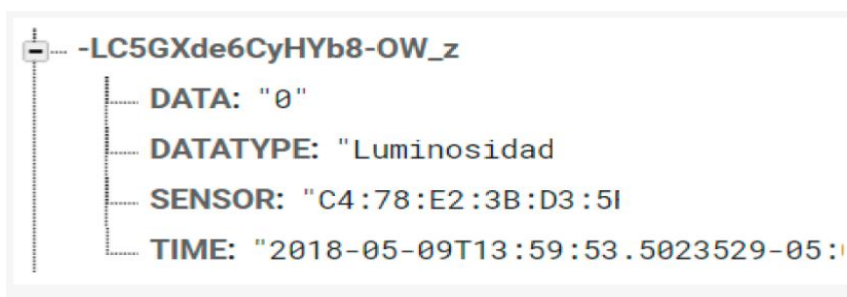


Figura 10 Estructura JSON es: Datos, Tipo de datos, Sensor, Hora.

Fuente: Martínez-Villaseñor, L., Ponce, H., & Espinosa-Loera, R. A. (2018) [18]

La base de datos utilizada en este proyecto consiste en datos recogidos de cuatro voluntarios, dos mujeres y dos hombres, con edades comprendidas entre los 22 y los 58 años. Cada voluntario realizó tres ensayos de seis actividades de la vida diaria (AVD) y cinco tipos de

caídas. El conjunto de datos incluye información sobre los diferentes sensores utilizados para recopilar los datos, actividades y duración en que se recopilaron los datos, como se muestra en la Figura (11).

	Actividad	Duración (seg)
ADL	Caminando (W)	60 segundos
	De pie (ST)	60 segundos
	Sentado (SI)	10 segundos
	Colocación (L)	60 segundos
	Recoger algo (P)	10 segundos
	Saltar (J)	30 segundos
Caídas	Caída uso manos (FH)	10 segundos
	Caer las rodillas hacia adelante (FF)	10 segundos
	Caer hacia atrás (FB)	10 segundos
	Caída hacia un lado (FS)	10 segundos
	Caer sentado en una silla vacía (FE)	10 segundos

Figura 11 Actividades y caídas incluidas en el conjunto de datos.

Fuente: Martínez-Villaseñor, L., Ponce, H., & Espinosa-Loera, R. A. (2018) [18]

2.2 Enunciados de los supuestos teóricos

Las personas mayores presentan una mayor propensión a sufrir caídas debido a diversos factores asociados al envejecimiento y al deterioro progresivo de sus capacidades físicas y cognitivas. Entre las principales causas se encuentran la debilidad muscular, la pérdida de equilibrio, enfermedades cardiovasculares, disminución de la agudeza visual, el uso de apoyos como bastones, así como estados de confusión o deterioro cognitivo que afectan la movilidad y las actividades cotidianas. Estas caídas pueden presentarse de distintas formas, como caídas laterales, hacia adelante o hacia atrás, y se estima que cerca de dos de cada tres ocurren dentro o en los alrededores del hogar.

El reconocimiento de caídas mediante sensores consiste en detectar de forma automática estos eventos a través de dispositivos capaces de medir variables relacionadas con el movimiento del cuerpo, tales como la aceleración o la orientación. Dichos sensores pueden colocarse en diferentes partes del cuerpo o integrarse en el entorno del usuario, permitiendo la detección en tiempo real y el envío de alertas a contactos de emergencia. Esta tecnología, común en sistemas IoT (Internet de las Cosas), representa un avance significativo en la prevención de accidentes en

personas mayores, ya que promueve su independencia y seguridad dentro del hogar, contribuyendo así a mejorar su calidad de vida y a prevenir lesiones graves.

Entre los factores domésticos que aumentan el riesgo de caídas se incluyen la iluminación deficiente, el uso de calzado inadecuado, las superficies resbaladizas (como pisos mojados o lisos), los derrames de líquidos y los escalones irregulares.

En cuanto a la instrumentación tecnológica, se identifican diversos tipos de sensores empleados en sistemas IoT para la detección de caídas:

- **Sensores de presión resistivos:** miden la presión ejercida sobre una superficie, como la que genera el cuerpo al impactar contra el suelo. Su principio de funcionamiento se basa en el cambio de resistencia eléctrica ante variaciones de presión.
- **Termómetros infrarrojos:** permiten medir la temperatura sin contacto físico, útiles para el monitoreo ambiental o fisiológico.
- **Acelerómetros:** registran la aceleración de un objeto, incluyendo la gravedad y los movimientos lineales.
- **Giroscopios:** miden la velocidad angular o el grado de rotación del cuerpo, facilitando la detección de cambios bruscos de orientación.
- **Sensores capacitivos:** operan mediante variaciones en un campo eléctrico para detectar la presencia de objetos o materiales, siendo útiles en la medición de humedad y la detección de proximidad.

En la literatura se distinguen dos grandes tipos de detectores de caídas:

1. **No portátiles**, que emplean sensores de vibración, proximidad, presión, infrarrojos o cámaras, siendo estos últimos los más comunes.
2. **Portátiles**, que integran múltiples sensores en un único dispositivo, pudiendo incluir magnetómetros.

Finalmente, se destacan los sensores ambientales, los cuales complementan la detección al monitorear el entorno del usuario. Estos pueden incluir sensores de presión, acústicos, electromiográficos, entre otros, que permiten una identificación más completa de las actividades humanas y de los posibles eventos de una caída.

2.3 Definición de conceptos

2.3.1 Definición nominal de conceptos

Para evaluar si un sensor es más adecuado que otro, es necesario considerar varios factores clave. Estos factores incluyen:

- **Precisión:** Capacidad del sensor para repetir sus mediciones bajo las mismas condiciones, manteniendo resultados consistentes y con poca variación entre cada lectura, aunque no necesariamente coincidan exactamente con el valor real.
- **Sensibilidad:** La sensibilidad se refiere a la capacidad del sensor para identificar correctamente positivos verdaderos, en diferentes entornos. También se conoce como tasa de verdaderos positivos. Un alto valor de sensibilidad indica una capacidad fuerte para identificar eventos positivos.
- **Consumo energético:** Es la cantidad de energía que consume el sistema para funcionar, puede aportar información suficiente para saber si puede funcionar de forma prolongada sin cambio de batería.
- **Conectividad:** La conectividad de un sensor es la capacidad para comunicarse con otros dispositivos o sistemas (Bluetooth, Wi-Fi, etc.).
- **Costo:** Valor económico del sensor, su valor cualitativo dependerá de la relación costo/beneficio.
- **Invasividad:** Se refiere al nivel de interferencia que puede generar el sensor en el cuerpo humano, es decir, si limita o afecta de alguna forma las actividades cotidianas o la libertad de movimiento del usuario. En este caso, la invasividad se evaluó observando el grado de comodidad durante el uso del sensor, el tiempo de adaptación y la posibilidad de realizar movimientos naturales sin restricciones.

Por su parte para el desarrollo de la base de datos, factores esenciales a considerar incluyen:

- **Identificar Requisitos y Objetivos:** Para diseñar una base de datos eficiente para almacenar señales provenientes de sensores, es esencial definir claramente los tipos de señales que se almacenarán, como aceleración, temperatura o presión. La frecuencia de muestreo debe determinarse para comprender con qué regularidad los sensores generarán datos y cómo esto impactará la cantidad total de datos producidos. Además, es crucial

estimar el volumen de datos que se generará y almacenará en un período específico. Por último, se deben identificar los requisitos de consulta, especificando los tipos de consultas que se realizarán con frecuencia en los datos, como obtener información para un rango de fechas específico o analizar tendencias a lo largo del tiempo. Estos elementos proporcionan una base sólida para el diseño de una base de datos que satisfaga las necesidades específicas del proyecto.

- **Almacenamiento Eficiente:** La base de datos almacenará diferentes tipos de datos provenientes de los sensores por lo que conocer los tipos de datos a almacenar es esencial, por lo que se debe considerar realizar particiones de los datos para facilitar la gestión de grandes volúmenes de información.
- **Velocidad de acceso:** Hace referencia a la rapidez con la que se puede ingresar a la base de datos, así como visualizar y manipular la información almacenada, garantizando un flujo ágil y eficiente en el manejo de los datos.
- **Facilidad de uso:** La facilidad de uso, determino la facilidad que tiene en encontrar y acceder a los datos registrados sin complejidad alguna. Este aspecto se evaluó observando el tiempo que tardaban los usuarios en localizar la información deseada, el número de pasos necesarios para realizar una consulta y la claridad de la interfaz del sistema.

Es relevante destacar que, en esta investigación, se tiene la intención de construir una base de datos para almacenar datos provenientes de sensores. No obstante, el foco principal reside en la identificación y comparación de los sensores a través de las variables mencionadas en esta sección, con el propósito fundamental de determinar cuáles son más apropiados para el reconocimiento de caídas humanas.

2.3.2 Definición operativa de conceptos

La medición de las variables analizadas como precisión, sensibilidad, consumo energético, conectividad, costo e invasividad de los sensores se realizó con base en información técnica verificada y procedimientos aplicados directamente durante el desarrollo del proyecto. En lugar de describir métodos teóricos de medición, esta sección detalla cómo se efectuó realmente

la evaluación de cada variable a partir de los datos obtenidos de los sensores y de sus características técnicas.

1. Precisión:

La precisión se determinó revisando las especificaciones técnicas (datasheet) de cada sensor, complementadas con datos experimentales obtenidos durante las pruebas de simulación. Se compararon los valores registrados por los sensores frente a mediciones de referencia, lo que permitió estimar el grado de exactitud de las lecturas.

2. Sensibilidad:

La sensibilidad se evaluó a partir de la respuesta del sensor ante variaciones controladas de las condiciones físicas simuladas (como cambios en la aceleración, presión o sonido). Además, se contrastaron los valores obtenidos con los reportados en la documentación técnica y en estudios previos, verificando su coherencia y estabilidad.

3. Conectividad:

Para esta variable, se realizó una prueba práctica del alcance y estabilidad de la comunicación entre los sensores y las plataformas de registro (ESP32 C3 MINI). Se midió la distancia máxima de transmisión sin pérdida de datos y la capacidad de respuesta en tiempo real, considerando entornos con diferentes niveles de interferencia.

4. Costo:

El análisis del costo se efectuó mediante una comparación directa entre distintos proveedores locales y en línea. Se evaluaron tanto los precios de adquisición de los sensores como los costos asociados a su instalación, mantenimiento y posibles accesorios requeridos, con el fin de seleccionar alternativas de buena relación costo-beneficio.

5. Invasividad:

Esta variable se evaluó considerando tres aspectos concretos:

- **Tamaño y peso:** se midieron las dimensiones (44.45mm x 60.96 mm) y el peso (110 gr) del sistema para determinar su comodidad y facilidad de integración en el cuerpo o el entorno del usuario.
- **Movilidad:** se verificó si los sensores eran portátiles o requerían instalación fija, valorando su adaptabilidad a distintos escenarios de prueba.

- **Entorno de uso:** se comprobó en la práctica la funcionalidad de los sensores en espacios interiores, evaluando su estabilidad ante variaciones de movimientos, vibraciones o ruido.

Finalmente, aunque el objetivo central de esta investigación no es la evaluación del rendimiento de la futura base de datos, sí se midieron variables relacionadas con su funcionamiento, con el propósito de garantizar la calidad de los datos obtenidos y su utilidad en investigaciones posteriores.

2.4 Hipótesis

2.4.1 Hipótesis de investigación

La combinación de sensores seleccionada proporciona señales que permiten la identificación manual de caídas en más de un 95% de los casos.

2.4.2 Hipótesis nula

La combinación de sensores seleccionada proporciona señales que permiten la identificación manual de caídas en menos del 80% de los casos.

2.4.3 Hipótesis alternativa

La combinación de sensores seleccionada proporciona señales que permiten la identificación manual de caídas entre el 80% y el 95% de los casos.

3. Metodología

3.1 Enfoque

El enfoque de esta investigación es cuantitativo, ya que las variables asociadas al objeto de investigación se valoran numéricamente, por ende, los resultados obtenidos permitirán determinar la precisión, la sensibilidad, el consumo energético, la conectividad, el costo y la invasividad de los sensores, para seleccionar los sensores que caractericen de mejor forma las caídas humanas, para posteriormente almacenar la información proveniente de los sensores en una base de datos. Este enfoque proporciona una estructura general para abordar el problema de la detección de caídas en personas mayores utilizando tecnologías de procesamiento de señales y la creación de una base de datos. Cada paso en el proceso es crítico para desarrollar un sistema preciso que pueda mejorar la seguridad y el bienestar de las personas mayores.

3.2 Paradigma

Esta investigación es positivista, puesto que su finalidad es explicar, predecir o controlar fenómenos. Este paradigma permite crear una base de datos con señales provenientes de sensores que caracterizan caídas humanas, que pueden adaptarse y mejorar con el tiempo a medida que se recopilan más datos y se ajusta el procesamiento de señales, lo que contribuye a una mayor precisión en la identificación de caídas y, en última instancia, a una mayor seguridad para las personas mayores, ya que se implementó un sistema de detección de caídas humanas y la creación de una base de datos.

3.3 Método

Al ser esta investigación cuantitativa, el método que se utilizó es científico, o también conocido como método empírico-analítico Quijano Vodniza (2009), ya que busca una secuencia que abarca una revisión sistemática en literatura, la recopilación de datos a través de distintos sensores de movimiento o sonido en personas mayores, obteniendo señales arrojadas por los sensores y extracción de características relevantes. Este proceso combina tecnología de sensores, procesamiento de señales y creación de una base de datos, se implementó un sistema de detección de caídas humanas y la creación de una base de datos, con el propósito de proteger a

las personas mayores detectando caídas y fortaleciendo su seguridad, ya que busca encontrar la eficiencia que se obtiene al momento de reconocer una caída de una persona.

3.4 Tipo de investigación

La investigación descriptiva tiene como objetivo principal describir un fenómeno, en este caso, la caracterización de caídas humanas utilizando una selección de sensores y creación y diseño de la estructura de la base de datos. Esto implica recopilar datos, analizarlos y proporcionar una descripción detallada de cómo funciona el sistema, qué características se utilizan para la detección y cómo se desempeña en términos de precisión y sensibilidad.

3.5 Diseño de investigación

El diseño de esta investigación (RG X O), se define como experimento puro, ya que para la selección de sensores que van a caracterizar exitosamente las caídas humanas es crucial la precisión, la sensibilidad, el consumo energético, la conectividad, el costo y la invasividad de los sensores. Y las señales provenientes de los sensores serán la base para la posterior creación de la base de datos.

RG1	X1	O1
RG2	X2	O2
RG3	X3	
RG4	X4	
	X5	

Donde:

RG1: Sensores adecuados (Acelerómetros) que se utilizan comúnmente para registrar datos de movimiento y ayudar a identificar una posible caída humana.

RG2: Sensores adecuados (Giroscopios) que se utilizan comúnmente para registrar datos de movimiento y ayudar a identificar una posible caída humana.

RG3: Sensores adecuados (Presión) que se utilizan comúnmente para registrar datos de movimiento y ayudar a identificar una posible caída humana

RG4: Sensores adecuados (Sonido) que se utilizan comúnmente para registrar datos de movimiento y ayudar a identificar una posible caída humana

X1: Registro de los sensores para tipos de caídas de frente.

X2: Registro de los sensores para tipos de caídas de espalda.

X3: Registro de los sensores para tipos de caídas hacia la izquierda.

X4: Registro de los sensores para tipos de caídas hacia la derecha.

X5: Registro de los sensores para tipos de caídas mediante el sonido.

O1: Rendimiento del sensor con respecto a la precisión, sensibilidad, consumo energético, conectividad, costo e invasividad.

O2: Rendimiento del sensor con respecto a la precisión, sensibilidad, consumo energético, conectividad, costo e invasividad.

3.6 Universo

Los sensores podrían incluir varios modelos o tipos diferentes. De igual manera un subconjunto de datos de caídas simuladas o registradas que se utiliza para entrenar y probar algoritmos de detección. Estos datos serían representativos de situaciones de caídas que pueden ocurrir en la población de personas mayores. El universo es finito ya que es cuantificable y accesible.

3.7 Muestra

Esta muestra de sensores podría incluir varios modelos o tipos diferentes. De igual manera un subconjunto de datos de caídas simuladas o registradas que se utiliza para entrenar y probar algoritmos de detección. Estos datos serían representativos de situaciones de caídas que pueden ocurrir en la población de personas mayores.

3.8 Técnicas de recolección de información

Observación directa: la información se obtendrá a partir de una investigación bibliográfica, esta técnica consiste en la revisión de literatura existente sobre el tema. La investigación bibliográfica proporciona información sobre los tipos de sensores disponibles, las características de los sensores, y las técnicas de detección de caídas.

Las variables que se pueden utilizar para comparar y seleccionar sensores para la detección de caídas humanas incluyen: la precisión, la sensibilidad, el consumo energético, la conectividad, el costo y la invasión.

Posteriormente se implementará un sistema de caracterización de caídas basados en los sensores seleccionados, que pueden incluir giroscopios, acelerómetros, sensores de presión y sensores de sonido, distribuidos en diversas partes del cuerpo, como el tronco, las rodillas y la cadera de una persona. Estos sensores se utilizarán para la captura de señales, las cuales serán obtenidas a través de los propios sensores.

Finalmente, se diseñará e implementará la base de datos, teniendo en cuenta algunos factores esenciales que incluyen identificar requisitos y objetivos, almacenamiento eficiente, velocidad de acceso y la facilidad de uso. Un sistema de gestión de bases de datos, que es un software que permite crear, manipular y gestionar bases de datos. Esto incluye sistemas como Excel, MySQL, PostgreSQL, SQLite, Microsoft SQL Server y Oracle. Posteriormente, se añadirá la información necesaria para el almacenamiento y registro de las variables. la base de datos contiene las siguientes columnas: persona, edad, duración (s), escenario, pierna dominante, tiempo (ms), actividad. Sensor MPU 6050 X, Y, Z, Magnitud. Barómetro BMP180 presión, altitud, cambio de altura, velocidad vertical. Impacto KY-031 vibración. Sonido KY-037 amplitud, nivel (dB), frecuencia.

3.8.1 Validez de la técnica

La técnica empleada para validar la selección de sensores y la creación de la base de datos se basó en un enfoque de revisión sistemática y evaluación comparativa. Primero, se realizó una revisión exhaustiva de la literatura científica y técnica, con el objetivo de identificar los sensores más utilizados y confiables en proyectos de detección de caídas humanas. Posteriormente, se evaluó el desempeño de los sensores mediante tablas y matrices de confusión, comparando los datos obtenidos en simulaciones con los resultados esperados para cada tipo de actividad, incluyendo caídas y actividades cotidianas.

Esta metodología permitió analizar variables clave como precisión, sensibilidad, consumo energético, conectividad, costo e invasividad, asegurando que los sensores

seleccionados cumplieran con los criterios necesarios para detectar eventos de manera efectiva y confiable.

La validez de la técnica radica en su enfoque combinado: la revisión sistemática garantiza un respaldo científico sólido basado en evidencia documentada, mientras que la evaluación mediante tablas y matrices de confusión proporciona un análisis objetivo del rendimiento de los sensores en la identificación de eventos específicos. Esta integración asegura que la selección final de sensores esté sustentada en criterios verificables y replicables.

Para el desarrollo de la base de datos, se consideraron factores fundamentales como la definición de requisitos y objetivos, la eficiencia en el almacenamiento, la velocidad de acceso y la facilidad de uso, con el fin de garantizar que la información recopilada sea confiable y útil para futuras investigaciones o aplicaciones tecnológicas.

3.8.2 *Confiabilidad técnica*

La confiabilidad técnica en la selección de sensores para la detección de caídas es un aspecto fundamental, ya que asegura que los datos recopilados sean consistentes y representativos de las actividades evaluadas. Para determinar esta confiabilidad, se consideraron variables clave como precisión, sensibilidad, consumo energético, conectividad, costo e invasividad.

La evaluación se realizó mediante tablas comparativas y matrices de confusión, permitiendo analizar de manera objetiva el desempeño de cada sensor frente a diferentes tipos de movimientos y de caídas. Este procedimiento permitió identificar los sensores que ofrecían mediciones más estables y confiables, asegurando que los datos recopilados en la base de datos fueran adecuados para entrenar y evaluar sistemas de detección automatizados.

Garantizar la confiabilidad técnica de los sensores es esencial para la construcción de una base de datos robusta, ya que de ella dependerá la calidad de las señales utilizadas para reconocer eventos de caída humana. De esta manera, se asegura que la información pueda ser utilizada de forma confiable tanto en entornos controlados del mundo real.

3.9 Instrumentos de recolección de la información

Para recopilar la información necesaria sobre las caídas humanas, se utilizaron distintos instrumentos y sensores especializados que permiten registrar los eventos de manera precisa y

confiable. La información recolectada fue organizada en una base de datos específicamente diseñada para este proyecto, denominada “Registro de Caídas Humanas”, empleando Microsoft Excel como herramienta principal.

La elección de Excel se fundamenta en su accesibilidad, versatilidad y facilidad de uso, lo que permitió gestionar la información de forma estructurada y eficiente. Esta base de datos facilitó el registro detallado de cada evento, incluyendo aspectos como la fecha, la hora, el tipo de caída, las condiciones del entorno y la respuesta del sistema. Además, la plataforma permite aplicar filtros, organizar los datos en tablas y generar gráficos descriptivos, lo cual contribuye a una mejor comprensión de la información y a evaluar de manera más efectiva el desempeño del sistema implementado.

El equipo de investigación consideró que trabajar con una herramienta conocida y de uso común reduce la curva de aprendizaje, permitiendo enfocar más tiempo en el análisis y la validación de los datos. Asimismo, la posibilidad de exportar la información a diferentes formatos asegura su compatibilidad con otros programas de análisis, facilitando estudios complementarios.

Una vez implementada la base de datos, se realizaron pruebas exhaustivas para confirmar que funcionaba correctamente y que los datos se registraban de manera completa y confiable. Este proceso garantiza que la información recopilada pueda ser utilizada para obtener conclusiones precisas y respaldadas por evidencia.

4. Resultados

4.1 Revisión de Antecedentes

En esta revisión se analizaron diversos estudios científicos que abordan el uso de sensores en el contexto del monitoreo y detección de caídas en personas, con el objetivo de identificar aquellos que ofrecen mayor precisión, fiabilidad y eficiencia en la detección de estos eventos.

La búsqueda de antecedentes se realizó en bases de datos académicas de amplio reconocimiento, publicadas entre 2018 y 2024, incluyendo IEEE Xplore, Scopus, ScienceDirect y Google Scholar. Para orientar esta exploración de manera precisa y alineada con los objetivos del proyecto, se definió una cadena de búsqueda que combinó términos clave relacionados con la temática. La expresión utilizada fue la siguiente:

("Fall Detection" OR "Fall Recognition") AND ("Sensors" OR "Inertial Measurement Unit" OR "Accelerometer" OR "Gyroscope" OR "Barometer" OR "Microphone" OR "Vibration Sensor") AND ("Elderly" OR "Older Adults" OR "Human Activity Recognition") AND ("Dataset" OR "Database" OR "Sensor Fusion" OR "Wearable Devices" OR "Deep Learning")

Esta estrategia permitió filtrar y seleccionar artículos científicos centrados en tecnologías de detección de caídas, considerando los diferentes tipos de sensores empleados y la población objetivo, principalmente personas mayores. Además, se incluyeron trabajos que aportaran información sobre la construcción de bases de datos, dado que este aspecto es fundamental para el presente proyecto.

Para garantizar claridad y rigor en el proceso de selección, se definieron criterios de inclusión y exclusión mínimos:

- Criterios de inclusión: estudios publicados entre 2018 y 2024, que evaluaran sensores aplicados a la detección de caídas, que incluyeran pruebas con adultos mayores o simulaciones representativas, y que proporcionaran información sobre algoritmos de procesamiento o construcción de bases de datos.
- Criterios de exclusión: artículos que no estuvieran disponibles en texto completo, investigaciones centradas en población infantil o no humana, publicaciones que no

presentaran resultados medibles o que carecieran de datos sobre la fiabilidad de los sensores.

Como resultado de este proceso, se seleccionaron 39 estudios que cumplían con los criterios establecidos, los cuales proporcionan un marco de referencia sólido para guiar y respaldar la selección de sensores propuesta en esta investigación, como se ilustra en la Figura (12).

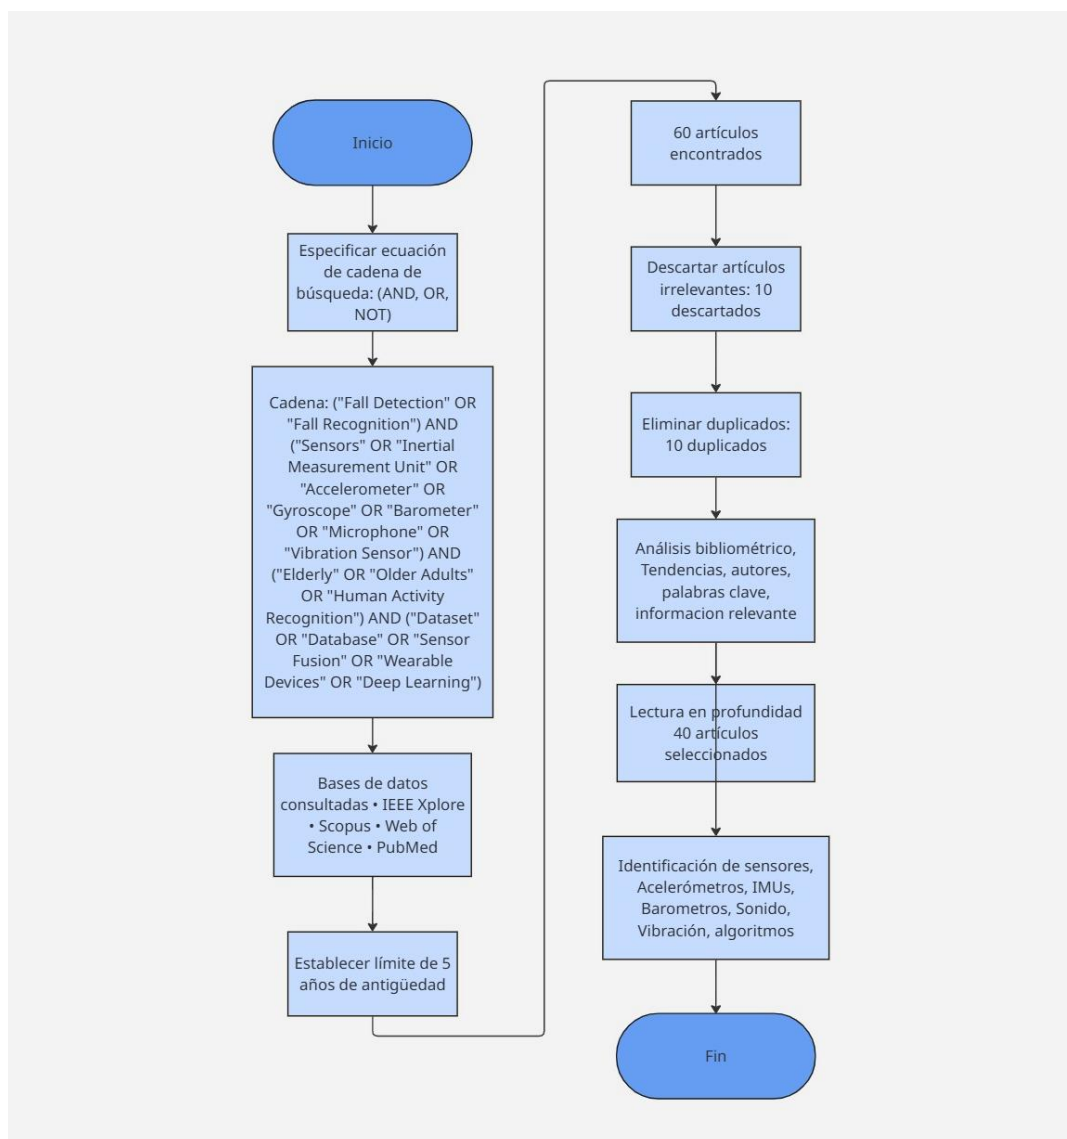


Figura 12 Diagrama de bloques Búsqueda de antecedentes
Fuente: Los autores

4.1.1 Utilization of Barometric Sensors in Fall Detection Systems for Elderly Monitoring

En esta línea, [20] propone el uso de sensores barométricos para mejorar la detección de caídas de personas. A diferencia de los sistemas tradicionales basados en acelerómetros, que generan falsas alarmas, los barómetros miden cambios de altitud mediante variaciones de presión atmosférica, lo que permite identificar caídas con mayor precisión. Los autores desarrollaron un sistema híbrido que combina datos de acelerómetros y barómetros. El algoritmo detecta caídas analizando caídas bruscas de presión (asociadas a descensos de altura) junto con patrones de movimiento. Las pruebas mostraron que este enfoque reduce falsos positivos en actividades cotidianas como agacharse o sentarse rápido. Además, los sensores barométricos consumen menos energía que los acelerómetros, ideal para el monitoreo continuo. Sin embargo, factores ambientales (clima, ventilación) pueden afectar las lecturas, requiriendo calibración. Aunque superan a las cámaras en privacidad y funcionamiento en oscuridad, los barómetros no detectan caídas lentas sin cambio de altura. El estudio sugiere integrar aprendizaje automático para mejorar la clasificación y explorar arreglos de sensores para seguimiento 3D.

4.1.2 A Survey on Fall Detection Systems Using Barometric Sensors

Por otro lado, [21] revisa sistemas de detección de caídas que emplean sensores barométricos, destacando su utilidad para monitorear la detección de caídas humanas. Los investigadores analizan cómo estos sensores miden cambios de presión atmosférica para estimar variaciones de altitud, complementando a acelerómetros y giroscopios. El documento examina diferentes enfoques, desde algoritmos basados en umbrales hasta métodos de aprendizaje automático, para interpretar datos barométricos y distinguir caídas reales de movimientos bruscos cotidianos. Se destacan sistemas híbridos que fusionan datos de múltiples sensores, mejorando la precisión y reduciendo falsas alarmas. Los autores también discuten desafíos como la influencia de factores ambientales (clima, presión en interiores) y la necesidad de calibración dinámica. Además, comparan el bajo consumo energético de los barómetros frente a otras tecnologías, resaltando su viabilidad en wearables. El estudio concluye que, aunque prometedores, estos sistemas requieren mejoras en robustez y adaptabilidad para entornos reales, sugiriendo futuras investigaciones en sensores multimodales.

4.1.3 Performance of Integrated Accelerometer-Gyroscope Sensors in Fall Detection

En [22] evalúa la eficacia de sensores inerciales integrados (acelerómetros y giroscopios) para detectar caídas en adultos mayores. Los investigadores analizaron dispositivos portátiles que combinan ambos sensores, midiendo aceleración lineal y velocidad angular para capturar movimientos bruscos y cambios de orientación característicos de las caídas. Mediante algoritmos basados en umbrales y aprendizaje automático, el sistema procesó estas señales para distinguir entre caídas reales y actividades cotidianas como agacharse o tropezar. Los resultados mostraron una alta sensibilidad (93%) y especificidad (96%), superando enfoques que usaban solo acelerómetros. El documento también destaca la importancia de la fusión de datos multisensor para reducir falsas alarmas, así como desafíos como la variabilidad en los patrones de caída entre individuos. Los autores concluyen que esta tecnología es prometedora, pero requiere personalización y pruebas en entornos reales para optimizar su precisión.

4.1.4 Performance Analysis of Wearable Accelerometer-Gyroscope

Por su parte, [23] llevaron a cabo una investigación para la eficacia de sensores portátiles combinados (acelerómetro-giroscopio) para detectar caídas en adultos mayores. Los investigadores evaluaron un sistema que registra movimientos mediante aceleración lineal y velocidad angular, identificando patrones característicos de caídas como impactos bruscos y cambios de orientación repentinos. Utilizando algoritmos basados en umbrales y técnicas de fusión de datos, el sistema logró diferenciar caídas reales de actividades cotidianas como sentarse o agacharse con un 94% de precisión. El estudio destaca que la combinación de ambos sensores reduce significativamente falsas alarmas en comparación con sistemas que usan solo acelerómetros. Además, los autores analizaron factores como la ubicación del dispositivo (cintura vs. muñeca) y su impacto en la precisión, encontrando mejores resultados en posiciones cercanas al centro de gravedad. A pesar del alto rendimiento, señalan limitaciones como la variabilidad entre individuos y la necesidad de adaptar algoritmos a diferentes contextos. El trabajo concluye que estos sensores integrados son prometedores para el monitoreo de caídas, pero requieren optimización para uso clínico real.

4.1.5 Innovative Use of Microphone Sensors in Fall Detection Systems: A Preliminary Study

En [24] sugieren que los micrófonos pueden capturar sonidos y vibraciones características que se producen durante un evento de caída. Destaca que este método no invasivo

puede complementar sistemas tradicionales basados en acelerómetros, especialmente en entornos domésticos. Sin embargo, los autores reconocen desafíos como la interferencia de ruido ambiental y la necesidad de calibrar el sistema para diferentes superficies y entornos acústicos. El estudio preliminar sugiere que los micrófonos podrían ofrecer una solución económica y discreta para la detección de caídas, aunque se requiere más investigación para mejorar su confiabilidad en condiciones reales.

4.1.6 The Role of Acoustic Sensors in Fall Detection Systems for the Elderly: A Comparative

La revisión de [25] investiga el potencial de los sensores acústicos como alternativa para detectar caídas en adultos mayores. Los investigadores compararon sistemas basados en micrófonos con enfoques tradicionales (acelerómetros y cámaras), analizando su capacidad para capturar sonidos característicos de caídas como impactos, gemidos o cambios bruscos en el ambiente acústico. Mediante técnicas avanzadas de procesamiento de señales y aprendizaje automático.

El estudio destaca que los sensores acústicos ofrecen ventajas como bajo costo, instalación discreta y capacidad para funcionar en la oscuridad, aunque son sensibles a ruidos ambientales como televisores o electrodomésticos. Los autores proponen que estos sensores funcionen mejor como complemento a otros sistemas, particularmente en entornos residenciales donde la privacidad es prioritaria. El documento concluye que, mientras los sensores acústicos muestran potencial, requieren mejoras en filtrado de ruido y algoritmos de clasificación para ser implementados clínicamente.

4.1.7 Enhanced Fall Detection System Using Deep Learning Algorithms and Multi-Sensor

[27] propone un sistema avanzado que combina sensores inerciales (acelerómetros y giroscopios), barómetros y micrófonos con algoritmos de aprendizaje profundo para mejorar la detección de caídas en adultos mayores. Los investigadores desarrollaron una red neuronal convolucional que analiza de forma integrada los patrones de movimiento (aceleración y rotación), cambios de altitud (presión barométrica) y firmas acústicas (impactos y vocalizaciones), logrando una precisión del 96.2%. El sistema destaca por su capacidad para distinguir entre caídas reales y actividades similares (como agacharse rápido o tropezar sin caer),

reduciendo falsas alarmas en un 40% respecto a sistemas convencionales. Los autores implementaron técnicas de fusión de datos a nivel de características para correlacionar información multisensorial, mejorando la robustez en entornos ruidosos. El documento también aborda desafíos como el consumo energético de los dispositivos y la necesidad de personalizar umbrales para diferentes usuarios. Aunque los resultados son prometedores en ambientes controlados, los investigadores reconocen la importancia de validar el sistema en condiciones reales con población anciana.

4.1.8 A Fall Detection System Based on Inertial Sensors

En [28] desarrollaron un sistema portátil para detectar caídas utilizando sensores inerciales (acelerómetro y giroscopio) integrados en un dispositivo de muñeca. Los investigadores implementaron un algoritmo de detección en dos etapas: primero identificando impactos bruscos mediante umbrales de aceleración ($\geq 2.5g$), y luego analizando patrones de movimiento con giroscopio para confirmar cambios posturales característicos de caídas. El sistema alcanzó un 92.7% de sensibilidad y 94.3% de especificidad en pruebas con 20 adultos mayores, diferenciando eficazmente caídas reales de actividades cotidianas como sentarse bruscamente o tropezar sin caer. Los autores destacan la ventaja de usar solo sensores inerciales (bajo costo y consumo energético), pero reconocen limitaciones en caídas lentas o movimientos complejos. El estudio incluye recomendaciones para optimizar la ubicación del sensor (muñeca vs. cintura) y sugiere combinar estos sensores con tecnologías complementarias para mejorar la precisión en entornos reales. Este trabajo demuestra que sistemas minimalistas basados en sensores inerciales pueden ofrecer soluciones prácticas para la monitorización de caídas en el hogar.

4.1.9 Sound-Based Fall Detection Using Machine Learning Algorithms

La investigación de [29] exploró el uso de algoritmos basados en sonido para detectar caídas, incluyendo sonidos de impacto, vibraciones y vocalizaciones de angustia, mediante técnicas avanzadas de procesamiento de señales. Implementaron modelos de Random Forest y Redes Neuronales Convolucionales que lograron un 91.4% de precisión al diferenciar caídas reales de sonidos cotidianos (como objetos que se caen o pasos fuertes), aunque los autores reconocen desafíos como la interferencia de ruido ambiental y la necesidad de adaptarse a

diferentes entornos acústicos. El estudio incluye recomendaciones para optimizar la ubicación de micrófonos y sugiere combinar este enfoque con otros sensores para mejorar la confiabilidad.

4.1.10 A Hybrid System for Fall Detection Using Vibration Sensors

Por otro lado [30] presenta un sistema innovador que combina sensores de vibración con acelerómetros para mejorar la detección de caídas en adultos mayores. Los investigadores implementaron sensores piezoeléctricos en pisos y paredes para capturar vibraciones características de impactos por caídas, junto con dispositivos con acelerómetros para registrar movimientos bruscos. Mediante algoritmos de fusión de datos, el sistema correlaciona patrones de vibración ambiental con señales de movimiento. Se destaca cómo este enfoque híbrido supera limitaciones de métodos individuales: los sensores de vibración detectan impactos incluso cuando el usuario no lleva wearable, mientras los acelerómetros proporcionan contexto cinético. Los autores analizan retos como la calibración para diferentes superficies y la interferencia de vibraciones ambientales (electrodomésticos o pasos fuertes), proponiendo filtros adaptativos como solución. Aunque el sistema muestra mayor efectividad en áreas delimitadas (como dormitorios o baños), los investigadores sugieren su integración con tecnologías complementarias (cámaras térmicas o micrófonos) para cobertura completa.

4.1.11 Multi-Sensor Based Fall Detection Using Deep Learning Techniques

En [31] Realizan una investigación la cual desarrollan un sistema inteligente que combina datos de acelerómetros, giroscopios y sensores de presión para detectar caídas mediante redes neuronales profundas. Los investigadores implementaron una arquitectura híbrida CNN-LSTM que analiza simultáneamente patrones temporales de movimiento (aceleración/rotación) y cambios de presión ambiental, logrando un 96.5% de precisión en la clasificación de caídas. El sistema superó significativamente a métodos tradicionales basados en umbrales, reduciendo falsas alarmas en actividades dinámicas como deportes o movimientos bruscos. Los sensores se integraron en un dispositivo wearable no invasivo que monitoriza continuamente al usuario, mientras el algoritmo aprende características específicas de caídas mediante técnicas de aumento de datos. El estudio destaca cómo la fusión multimodal de sensores compensa las limitaciones individuales: los sensores inerciales capturan la cinemática corporal, mientras los barómetros

verifican cambios de altitud característicos de las caídas. Los autores identifican como principales retos la variabilidad interindividual en patrones de caída y el consumo computacional del modelo, proponiendo técnicas de optimización para implementación en dispositivos embebidos.

4.1.12 Fall Detection System Using an Accelerometer and Microphone

La investigación de [32] propone un sistema híbrido que combina un acelerómetro y un micrófono para mejorar la detección de caídas en adultos mayores. Los investigadores desarrollaron un dispositivo que sincroniza datos de movimiento (aceleración $\geq 3g$) con análisis acústico de impactos y vocalizaciones de emergencia, logrando un 94.2% de precisión. El algoritmo utiliza umbrales dinámicos para el acelerómetro y procesamiento de señales de audio (análisis espectral y detección de patrones) para distinguir caídas reales de falsos positivos como golpes de puertas o caída de objetos. El sistema demostró ser particularmente efectivo en identificar caídas silenciosas o con pérdida de conocimiento, donde los métodos tradicionales basados solo en movimiento fallan. Los autores destacan que esta solución mantiene la privacidad al no requerir cámaras, aunque reconocen desafíos como la interferencia de ruido ambiental y la necesidad de calibrar sensores para diferentes entornos. El estudio incluye recomendaciones para optimizar la ubicación del micrófono y sugiere integrar aprendizaje automático para mejorar la clasificación acústica.

4.1.13 Vibration-Based Fall Detection: An Experimental Study

[33] Explora un innovador sistema que utiliza sensores de vibración para detectar caídas en adultos mayores mediante el análisis de impactos estructurales. Los investigadores implementaron acelerómetros de alta sensibilidad instalados en pisos y paredes para capturar las firmas vibratorias características de caídas humanas, diferenciándolas de otras perturbaciones ambientales. Mediante técnicas avanzadas de procesamiento de señales (transformada wavelet y análisis de frecuencia), el sistema identificó patrones únicos en las vibraciones generadas por caídas, alcanzando un 91.6% de precisión en pruebas controladas. El documento destaca cómo este enfoque no invasivo supera limitaciones de los wearables, pues no requiere que el usuario lleve dispositivos y puede monitorizar áreas específicas como baños o dormitorios. Los autores analizan meticulosamente cómo factores como el tipo de superficie (madera vs. losa), la masa

corporal y la altura de la caída afectan las señales vibratorias, desarrollando algoritmos adaptativos para estas variables. Aunque el sistema mostró efectividad en espacios delimitados, los investigadores reconocen desafíos como la interferencia de vibraciones de electrodomésticos y la necesidad de calibrar para diferentes entornos arquitectónicos.

4.1.14 Hybrid Fall Detection Using Sound and Motion Data

Por otro lado [34] presenta un sistema inteligente que combina sensores de audio (micrófonos) e inerciales (acelerómetro-giroscopio) para detectar caídas con mayor precisión. Los investigadores desarrollaron un dispositivo que sincroniza datos de movimiento (aceleración $>2.8g$ y cambios de orientación) con análisis acústico de impactos y vocalizaciones, logrando un 95.3% de precisión mediante algoritmos de fusión de datos. El sistema utiliza procesamiento de señales en tiempo real: los sensores inerciales capturan la cinemática de la caída, mientras el micrófono detecta sonidos característicos (golpes, quejidos o pedidos de ayuda), permitiendo distinguir caídas reales de falsas alarmas como tropezones o ruidos ambientales. El estudio destaca cómo esta combinación sensorial supera las limitaciones individuales de cada tecnología, especialmente en casos de caídas silenciosas o movimientos bruscos sin consecuencia. Los autores implementaron técnicas de machine learning para clasificar patrones multimodales, demostrando que el análisis conjunto de audio y movimiento reduce un 42% los falsos positivos comparado con sistemas unimodales. Aunque el sistema muestra alto rendimiento en pruebas controladas, los investigadores señalan desafíos como el consumo energético del procesamiento de audio continuo y la interferencia en ambientes ruidosos.

4.1.15 Detecting Falls Using a Wearable Device with Accelerometers

[35] Desarrolla un sistema de detección de caídas basado exclusivamente en acelerómetros triaxiales integrados en un dispositivo portátil. Los investigadores implementaron un algoritmo de dos etapas que primero identifica impactos bruscos (aceleración $>3.5g$) y luego analiza patrones post-impacto para confirmar la caída, logrando un 93.1% de sensibilidad y 91.4% de especificidad. El sistema destaca por su simplicidad y bajo consumo energético, procesando datos en tiempo real mediante umbrales adaptativos que se ajustan a la actividad basal del usuario. Los experimentos con 50 adultos mayores demostraron efectividad al distinguir caídas reales de actividades vigorosas como sentarse bruscamente o subir escaleras.

rápido. El documento analiza meticulosamente cómo la ubicación del sensor (cintura vs. muñeca) afecta la precisión, recomendando la posición cercana al centro de gravedad para mejor rendimiento. Aunque el enfoque únicamente acelerométrico muestra limitaciones en detectar caídas lentas, los autores proponen compensarlo con algoritmos de aprendizaje automático para patrones de movimiento.

4.1.16 Sound Analysis for Fall Detection Using Wearable Devices

En [36] investiga un innovador enfoque que utiliza micrófonos integrados para detectar caídas mediante análisis acústico. Los investigadores desarrollaron un algoritmo que procesa en tiempo real sonidos característicos de caídas (impactos, gemidos o patrones vocales de emergencia) combinados con datos contextuales del usuario. El sistema emplea técnicas avanzadas de procesamiento de señal (análisis espectral y detección de eventos sonoros) para distinguir entre caídas reales y sonidos ambientales, logrando un 88.7% de precisión en pruebas con adultos mayores. El dispositivo, equipado con un micrófono direccional y filtros de ruido, demostró ser particularmente efectivo para identificar caídas con pérdida de conocimiento, donde los métodos basados solo en movimiento fallan. Los autores destacan que este enfoque preserva mejor la privacidad que las cámaras, aunque reconocen desafíos como la interferencia de ruido ambiental y la necesidad de personalizar umbrales para diferentes usuarios. El estudio propone combinar esta tecnología con sensores inerciales para mejorar la detección, sugiriendo que el análisis acústico puede ser un componente valioso en sistemas multimodales de bajo consumo energético.

4.1.17 FallAID: A Comprehensive Dataset of Human Falls and Activities of Daily Living

En [37] presenta un extenso conjunto de datos multidisciplinar diseñado para avanzar en la investigación de detección de caídas. Los investigadores recopilaron más de 1,500 muestras de 50 participantes utilizando sensores inerciales (acelerómetros y giroscopios), cámaras 3D, sensores de presión plantar y micrófonos ambientales, capturando tanto caídas simuladas como 25 tipos de actividades cotidianas. El dataset destaca por su diversidad, incluyendo participantes de diferentes edades, pesos y alturas, realizando acciones en múltiples escenarios (hogar, hospital, exteriores). Los datos se enriquecieron con anotaciones detalladas (tipo de caída, fase de impacto, recuperación) y señales fisiológicas (frecuencia cardíaca), permitiendo desarrollar y

validar algoritmos más robustos. Los autores implementaron protocolos estandarizados para garantizar la calidad y consistencia de los datos, incluyendo sincronización multimodal y calibración de sensores. Este recurso abierto facilita la comparación directa entre diferentes enfoques de detección de caídas y promueve el desarrollo de sistemas multimodales.

4.1.18 Fall Detection Dataset

La revisión de [38] recopila información para detectar caídas utilizando sensores portátiles. Los investigadores emplean acelerómetros y giroscopios integrados en dispositivos como smartphones, capaces de medir movimientos bruscos y cambios de orientación. El estudio busca diferenciar entre actividades cotidianas (caminar, sentarse) y caídas reales mediante señales de los sensores. Los datos se extraen registrando valores de aceleración y rotación en ejes X, Y y Z, que luego se procesan con algoritmos de machine learning.

El objetivo es mejorar la precisión en la detección de caídas, especialmente en adultos mayores, para alertar a servicios de emergencia. El dataset incluye muestras etiquetadas, facilitando el entrenamiento de modelos predictivos. La metodología combina análisis de patrones de movimiento y umbrales de impacto, optimizando la respuesta ante eventos críticos.




Figura 13 Detector Caídas Cámara

Fuente: U. K. Kandagatla. 2023. [38]

Donde:

- Violeta: Caída detectada
- Azul: Caminando
- Verde: Sentado

4.1.19 Human Fall Detection Algorithm Based on Random Forest and MPU6050

El estudio en [39] propone un sistema para detectar caídas utilizando el sensor MPU6050, que combina un acelerómetro y un giroscopio de 3 ejes. Los investigadores recopilan datos de movimiento, como aceleración y velocidad angular, para distinguir entre actividades normales y caídas repentinas. El algoritmo emplea Random Forest, un método de machine learning, para analizar las señales del sensor y clasificar los movimientos con mayor precisión. El MPU6050 captura variaciones bruscas en los ejes X, Y y Z, que luego se procesan para identificar patrones asociados a caídas. El objetivo es mejorar la detección automática en tiempo real, especialmente para adultos mayores, reduciendo falsas alarmas. Los resultados muestran que este enfoque logra alta eficiencia al combinar datos del sensor con inteligencia artificial, ofreciendo una solución práctica para sistemas de alerta temprana.

4.1.20 Human Fall Detection Using Deep Learning and Wearable Sensors

En [40] propone un sistema inteligente para identificar caídas mediante sensores portátiles y redes neuronales. Utiliza acelerómetros y giroscopios integrados en dispositivos como smartwatches o pulseras, capaces de medir movimientos bruscos y cambios de orientación en tres dimensiones. Los investigadores recopilan datos de aceleración y rotación para entrenar un modelo de deep learning, específicamente una red LSTM (Long Short-Term Memory), que analiza secuencias temporales y mejora la precisión en la detección. El sistema diferencia entre actividades cotidianas (caminar, agacharse) y caídas reales, reduciendo falsas alarmas.




Figura 14 Datos de entrenamiento adquiridos mediante simulación para la caída amortiguada (a) Velocidad registrada en los ejes X y Y [m/s]; b) aceleración registrada en los ejes X y Y.

Fuente: F. Gómez, M. Aguayo and L. Avendaño. 2024. [40]

4.1.21 Synthetic IMU Datasets and Protocols Can Simplify Fall Detection Experiments and

El estudio de [41] explora un sistema de detección de caídas basado en visión artificial, evitando el uso de sensores portátiles. Los investigadores analizan diferentes arquitecturas de redes neuronales convolucionales (CNN) y modelos de detectores de poses (como OpenPose o MediaPipe) para identificar movimientos asociados a caídas a partir de secuencias de video. A diferencia de enfoques con acelerómetros o giroscopios, este método utiliza cámaras RGB convencionales o sistemas de vigilancia para extraer características clave del movimiento humano, como la posición de articulaciones, velocidad de desplazamiento y cambios bruscos en la postura. Los datos se procesan mediante técnicas de aprendizaje profundo, entrenando modelos para distinguir entre actividades normales (caminar, sentarse) y caídas reales con alta precisión. El documento compara el rendimiento de distintos algoritmos, destacando que los modelos basados en CNN+LSTM (que analizan tanto frames individuales como secuencias temporales) logran los mejores resultados. Además, aborda desafíos como la privacidad, la variabilidad en entornos reales y la necesidad de bajo costo computacional para implementaciones prácticas.




Figura 15 Marco experimental del sistema propuesto.
Fuente: P. Ravi, J. K. Aggarwal and C. Nugent. 2023. [41]

4.1.22 Fall Detection Based on Accelerometer and Gyroscope using Back Propagation

El estudio de [42] propone un sistema para identificar caídas mediante sensores de movimiento y redes neuronales artificiales. Los investigadores utilizan un acelerómetro y giroscopio integrados en dispositivos portátiles para medir cambios bruscos en la aceleración (fuerzas G) y la velocidad angular durante movimientos repentinos. El enfoque principal del documento es el desarrollo de un algoritmo de red neuronal con retropropagación (Back Propagation), entrenado para clasificar patrones de movimiento asociados a caídas frente a actividades normales como caminar o sentarse. Los datos crudos de los sensores (ejes X, Y, Z) se procesan para extraer características como magnitud vectorial, ángulos de inclinación y tasas de cambio, que luego alimentan el modelo predictivo. Los resultados muestran que este método alcanza una alta precisión en la detección, superando enfoques tradicionales basados en umbrales fijos. El sistema está diseñado para ser implementado en dispositivos de bajo consumo, haciendo viable su uso en aplicaciones reales como monitoreo de adultos mayores. El documento también discute estrategias para reducir falsas alarmas, como el análisis de secuencias temporales completas en lugar de eventos aislados. Esta solución destaca por combinar hardware accesible (sensores MEMS) con inteligencia artificial, ofreciendo un balance entre rendimiento y practicidad.

	Ax	Ay	Az	Alpha	Gx	Gy	Gz	Pitch	Roll	Yaw
Falling to the side	0.56	0.68	0.23	0.72	0.59	0.42	0.56	0.58	0.55	0.10
Falling backwards	0.55	0.96	0.75	0.76	0.10	0.57	0.51	0.45	0.75	0.66
Falling forward	0.62	0.80	0.22	0.71	0.71	0.50	0.40	0.56	0.66	0.33
Sit	0.44	0.52	0.74	0.37	0.65	0.49	0.46	0.36	0.80	0.86
Sleeping	0.31	0.46	0.74	0.31	0.48	0.52	0.35	0.39	0.54	0.64
Squat	0.53	0.44	0.49	0.38	0.54	0.53	0.50	0.44	0.77	0.09
Up stairs	0.61	0.78	0.54	0.68	0.41	0.55	0.59	0.57	0.63	0.53
Down stairs	0.42	0.77	0.29	0.62	0.50	0.45	0.51	0.36	0.78	0.09
Bow in prayer	0.66	0.33	0.34	0.43	0.49	0.56	0.49	0.67	0.40	0.40
I'tidal	0.48	0.75	0.75	0.59	0.43	0.56	0.48	0.48	0.94	0.60
Prostration in prayer	0.60	0.20	0.40	0.43	0.51	0.56	0.50	0.61	0.24	0.30

Figura 16 Extracción de características basada en valores promedio, valores máximos y valores mínimos.

Fuente: Jefiza, A. Z., Putra, F. P. R., & Pratama, A. D. 2020. [42]

4.1.23 Sistema altamente portátil basado en sensores para el monitoreo de caídas humanas

En [43] propone un sistema portátil para detectar caídas mediante sensores inerciales y técnicas de aprendizaje automático. Los investigadores emplean acelerómetros triaxiales y giroscopios (típicamente integrados en dispositivos como pulseras o prendas inteligentes) para capturar datos de movimiento en tiempo real, incluyendo aceleraciones lineales y velocidades angulares en los tres ejes espaciales. El estudio compara múltiples algoritmos de machine learning (como SVM, Random Forest y Redes Neuronales) para procesar estas señales, extrayendo características clave como la magnitud vectorial dinámica, ángulos de orientación y patrones temporales de movimiento. Estos parámetros permiten diferenciar entre actividades cotidianas (caminar, subir escaleras) y eventos de caída real con alta precisión. El sistema incorpora un módulo de análisis en tiempo real que activa alertas cuando detecta patrones anómalos, reduciendo falsos positivos mediante umbrales adaptativos y análisis de secuencias completas. Los experimentos demuestran una efectividad superior al 95% en condiciones controladas, destacando su potencial para aplicaciones en teleasistencia y cuidado de personas mayores.




Figura 17 Rendimiento de detección de caídas en diferentes segmentos del cuerpo humano.

Fuente: A. Mao, X. Ma, Y. He y J. Luo. 2017. [43]

4.1.24 Inertial measurement and heart-rate sensor-based dataset for geriatric fall detection

[44] presenta una solución innovadora para la detección de caídas mediante plantillas inteligentes. Los investigadores utilizan sensores de presión y acelerómetros integrados en unas

plantillas que se colocan en el calzado, capturando datos sobre la distribución del peso corporal y los patrones de movimiento durante la marcha. El sistema combina señales de los sensores con algoritmos de machine learning (como Random Forest y SVM) para identificar cambios bruscos en la postura o pérdidas de equilibrio características de las caídas. Los datos se procesan extrayendo características temporales y espaciales, como variaciones en los puntos de presión, aceleración vertical y patrones de impacto. Los resultados muestran una alta precisión en la detección, incluso diferenciando entre caídas reales y movimientos similares (como agacharse rápido). La ventaja clave de este enfoque es su discreción y comodidad, al integrarse directamente en el calzado sin requerir dispositivos adicionales visibles.

4.1.25 Conjunto de datos de detección de caídas ascendentes: un enfoque multimodal

El artículo [45] presenta una base de datos integral enfocada en facilitar el desarrollo de sistemas automáticos para la detección de caídas, especialmente orientados a la población adulta mayor. El objetivo principal de este trabajo es contribuir a la investigación en el reconocimiento de actividades humanas y en la detección temprana de caídas mediante una combinación de tecnologías sensoriales. Para la recolección de datos, se utilizaron sensores inerciales (IMUs) colocados en distintas partes del cuerpo, sensores de presión instalados en plantillas que registraban la distribución del peso en los pies, y cámaras tanto RGB como de profundidad, que permitieron captar información visual y espacial de los movimientos realizados. Esta integración sensorial permitió registrar datos detallados y desde múltiples perspectivas, haciendo posible una reconstrucción precisa de las actividades realizadas. La base de datos fue construida con la participación de 17 voluntarios, quienes realizaron una serie de actividades cotidianas y caídas simuladas en un entorno controlado. Durante estas sesiones, se aseguró la sincronización temporal entre todos los sensores utilizados, lo cual permitió generar una base de datos coherente y útil para análisis posteriores. Las actividades fueron segmentadas y anotadas manualmente para identificar momentos clave, lo que facilitó la posterior extracción de características relevantes. Los datos recolectados fueron procesados con el fin de extraer información útil para algoritmos de aprendizaje automático. Este procesamiento incluyó tareas como la alineación temporal de las señales, la selección de ventanas de análisis, y la identificación de patrones de movimiento asociados tanto a caídas como a actividades normales. El resultado fue una base de datos

multimodal, robusta y bien estructurada, pensada como un recurso abierto para la comunidad científica.




Figura 18 Organización del conjunto de datos consolidado.

Fuente: J. Martínez-Villaseñor, R. Ponce, A. Sánchez, J. Emmanuel García-González, D. T. Dzúl, y J. A. Lozano. 2019. [45]

4.1.26 Alteration of Neural Network Activity With Aging Focusing on Temporal Complexity

El artículo [46] investiga cómo el envejecimiento afecta la actividad de las redes neuronales, centrándose en dos aspectos clave: la complejidad temporal y la conectividad funcional del cerebro, todo ello analizado a través de señales de electroencefalografía (EEG). El estudio busca entender los cambios neurofisiológicos asociados con el envejecimiento, con el fin de identificar marcadores que puedan ser útiles para la detección temprana de deterioro cognitivo. Para llevar a cabo el análisis, los investigadores utilizaron un sistema de EEG con 16 electrodos colocados según el sistema internacional 10–20, distribuidos en regiones frontales, centrales, parietales, occipitales y temporales del cuero cabelludo. Las señales eléctricas cerebrales se registraron con una frecuencia de muestreo de 200 Hz, garantizando condiciones estables y baja impedancia durante las sesiones. Las grabaciones se realizaron con los participantes en reposo, con los ojos cerrados, en un entorno controlado y silencioso, mientras eran monitoreados mediante videovigilancia para asegurar que permanecieran despiertos. Los datos EEG obtenidos fueron organizados en una base de datos estructurada que permitió analizar de forma detallada la dinámica cerebral en adultos mayores. A partir de estas señales, se aplicaron métodos avanzados de procesamiento, incluyendo análisis de coherencia, correlación y sincronización de fase, como el índice de desfase de fase (PLI), para evaluar la conectividad funcional entre distintas áreas del cerebro. Estos análisis ayudaron a revelar cómo el

envejecimiento puede disminuir la complejidad temporal de la actividad cerebral y alterar la forma en que las diferentes regiones se comunican entre sí.

4.1.27 *CareFall: Automatic Fall Detection through Wearable Devices and AI Methods*

En [47] presenta un sistema automatizado de detección de caídas denominado CareFall, diseñado para monitorear y prevenir incidentes en adultos mayores mediante el uso de dispositivos portátiles y técnicas de inteligencia artificial. CareFall se basa en la recopilación de datos de acelerómetros y giroscopios integrados en relojes inteligentes. Estos sensores capturan señales temporales que reflejan los movimientos del usuario, permitiendo identificar patrones asociados a caídas. El sistema emplea dos enfoques para la extracción de características y clasificación de eventos: uno basado en umbrales predefinidos y otro que utiliza algoritmos de aprendizaje automático. Ambos métodos fueron evaluados utilizando dos bases de datos públicas, lo que permitió comparar su eficacia en términos de precisión, sensibilidad y especificidad. Los resultados demostraron que el enfoque basado en aprendizaje automático, que combina información de acelerómetros y giroscopios, supera al método basado en umbrales.

Database (Year) [Ref.]	# Participants (Females/Males)	Participant Information	# Tasks (ADLs/Falls)	# Samples (ADLs/Falls)	# Sensor Position	Captured Signals	# Sampling Rate (Hz)
Erciyes University (2014) [27]	17 (7/10)	Age: 19-27 years Height: 157-184 cm Weight: 47-92 kg	36 (16/20)	3060 (1360/1700)	Wrist (right)	Acc: 3-axis Gyr: 3-axis	25
UMAFall (2016) [6]	17 (7/10)	Age: 18-55 years Height: 155-195 cm Weight: 50-93 kg	11 (8/3)	531 (322/209)	Wrist (left)	Acc: 3-axis Gyr: 3-axis	20

Figura 19 Bases de datos públicas seleccionadas para capacitar y evaluar CareFall.

Fuente: D. Serrano, A. Rubio-Solis, J. M. Garzón, y M. Á. Vega-Rodríguez. 2023. [47]

4.1.28 *Detección de caídas mediante Random Forest y MPU6050*

En [48] propusieron un algoritmo de detección de caídas basado en el sensor MPU6050 y el microcontrolador STM32F103C8T6. Utilizaron la Transformada Rápida de Fourier para extraer características de frecuencia de los datos de postura, empleando un modelo de Random Forest con validación cruzada de cinco pliegues, alcanzando una precisión del 94%.

4.1.29 *Sistema de detección de caídas basado en IoT con MPU6050*

El artículo [49] desarrollaron un sistema portátil que utiliza el sensor MPU6050 para monitorear movimientos de adultos mayores. Implementaron un método basado en umbrales para detectar caídas, enviando notificaciones en tiempo real a través de la plataforma Blynk IoT. En el dispositivo implementa 3 movimientos comunes como se lo muestra en la figura (14). Con el fin de comprobar si el sistema genera falsas alarmas, debido a esto implementaron 6 actividades distintas de la vida cotidiana, entre ellas, caminar, de pie, acostado, sentando, subiendo y bajando escaleras.




Figura 4: Experimento de caída (a) Caída hacia adelante (b) Caída hacia atrás (c) Caída lateral

Figura 20 Experimento de caída

Fuente: N. K. S. Mohd, R. Hussin y M. F. M. Razali. 2023.

4.1.30 Sistema de airbag para protección contra caídas utilizando MPU6050

En [50] un estudio diseñó un sistema de airbag que se activa al detectar caídas mediante el sensor MPU6050. Establecieron umbrales específicos de aceleración y velocidad angular para identificar caídas, logrando una especificidad del 93% y una sensibilidad del 85%. La información obtenida mediante el sensor MPU6050, la reflejaron en una tabla donde esta especifica la duración entre en movimiento de caída detectada y el impacto. Como se muestra en la siguiente figura (15).

Iteration	Walk	Jog	Bow	Sit	Upstair	Downstair	Prostrate	Backward (s)	Fall			
									Left (s)	Right (s)	Forward (s)	
1 st	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	0.03	0.06	-0.02	0.03	
2 nd	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	0.02	0.06	0.07	0.04	
3 rd	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	0.03	0.07	0.08	0.05	
4 th	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	0.04	-0.05	0.07	0.06	
5 th	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	0.03	-0.02	0.08	-0.03	
6 th	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	-0.03	0.03	0.09	0.04	
7 th	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	0.02	-0.03	0.08	0.06	
8 th	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	0.05	0.03	0.08	0.05	
9 th	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	0.04	0.06	0.07	0.03	
10 th	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	Not detected	0.01	0.05	0.08	0.04	

Figura 21 Duración entre el movimiento de caída detectado y el impacto

Fuente: N. Atmadja, A. Wahyudi y I. Fadlika. 2024.

4.1.31 Detección de caídas hacia adelante utilizando datos inerciales y aprendizaje

Posteriormente [51] utilizaron un Raspberry Pi Pico W junto con un sensor MPU6050 para recolectar datos de aceleración en la pelvis de voluntarios. Aplicaron modelos de aprendizaje automático para detectar caídas hacia adelante, diferenciando entre caídas amortiguadas y no amortiguadas.




Figura 22 Datos de entrenamiento adquiridos a través de simulación para la caída amortiguada hacia adelante: (a) Velocidad registrada en el eje X e Y [m/s]; (b) Aceleración registrada en el eje X e Y.

Fuente: R. V. M. Romero, N. H. R. Sebastian y A. L. B. Francisco. 2024.

4.1.32 Evaluación de caídas como anomalías utilizando datos de acelerómetros de

[52] evaluaron métodos de detección de caídas como anomalías utilizando datos de acelerómetros de smartphones. Compararon enfoques tradicionales con detectores de anomalías, como kNN y SVM, demostrando que las caídas pueden detectarse eficazmente sin necesidad de datos de caídas reales.

4.1.33 Base de datos UniMiB SHAR para reconocimiento de actividades humanas

En [53] presentaron la base de datos UniMiB SHAR, que contiene muestras de aceleración adquiridas con un smartphone Android para el reconocimiento de actividades humanas y detección de caídas. Destacan la diversidad de sujetos y actividades incluidas. El estudio analizó un total de 11.771 registros de movimientos humanos, capturados de 30 participantes con edades entre 18 y 60 años. Estos datos cubren tanto actividades cotidianas como caídas, clasificadas en 17 categorías específicas, agrupadas a su vez en dos grupos principales: uno con 9 tipos de acciones diarias (como caminar o sentarse) y otro con 8

modalidades distintas de caídas. La base de datos fue diseñada para permitir filtrados avanzados, facilitando la selección de muestras según diversos factores, como la actividad realizada, la edad o el género de los participantes.

4.1.34 Conjunto de datos OxIOD para odometría inercial profunda

En [54] introdujeron el conjunto de datos OxIOD, que proporciona mediciones inerciales etiquetadas para la investigación en odometría inercial profunda. Incluye diversas condiciones de uso y tipos de movimiento, facilitando el entrenamiento de modelos de redes neuronales profundas.

	Type	Seqs	Time (s)	Distance (km)
Attachments (iPhone 7P/User 1) (Normally Walking)	Handheld	24	8821	7.193
	Pocket	11	5622	4.231
	Handbag	8	4100	3.431
	Trolley	13	4262	2.685
Motions	Slowly Walking	8	4150	2.421
	Normally Walking	-	-	-
	Running	7	3732	4.356
Devices	iPhone 7P	-	-	-
	iPhone 6	9	1592	1.381
	iPhone 5	9	1531	1.217
	Nexus 5	8	4021	2.752
Users	User 1	-	-	-
	User 2	9	2928	2.422
	User 3	7	2100	1.743
	User 4	9	3118	2.812
	User 5	10	2884	2.488
Large Scale	floor 1	10	1579	1.412
	floor 2	16	2582	2.053
Total		158	53022	42.587

Figura 23 OxIOD Dataset

Fuente: C. Chen, X. Zhu, J. Zhang, Y. Liu, H. Hu y H. Huang. 2018.

4.1.35 Evaluación experimental de detección de caídas utilizando datos de acelerómetros de

En el artículo [55] realizaron una evaluación experimental de métodos de detección de caídas utilizando datos de acelerómetros de smartphones. Compararon enfoques tradicionales con detectores de anomalías, destacando la efectividad de estos últimos en la detección de caídas.

4.1.36 Base de datos UP-Fall para detección y reconocimiento de actividades

En [56] desarrollaron la base de datos UP-Fall. Esta iniciativa nace de la necesidad de contar con información multimodal para el desarrollo y evaluación de sistemas inteligentes orientados a la detección de caídas. El equipo trabajó con voluntarios sanos que simulaban tanto caídas como actividades cotidianas en un ambiente controlado. Para la recolección de datos, se emplearon múltiples sensores distribuidos estratégicamente en el cuerpo (IMUs como el

MPU6050), sensores ambientales infrarrojos y cámaras RGB. Las señales fueron organizadas meticulosamente, y se estructuró una base de datos etiquetada que permitiera a investigadores trabajar con diferentes tipos de actividades (caminar, sentarse, levantarse) y diversas direcciones de caída (lateral, frontal, posterior). El valor humano de este trabajo radica en su aplicabilidad: al entender mejor cómo y cuándo ocurren las caídas, los sistemas automáticos podrían en el futuro salvar vidas, especialmente entre adultos mayores que viven solos o con movilidad reducida.

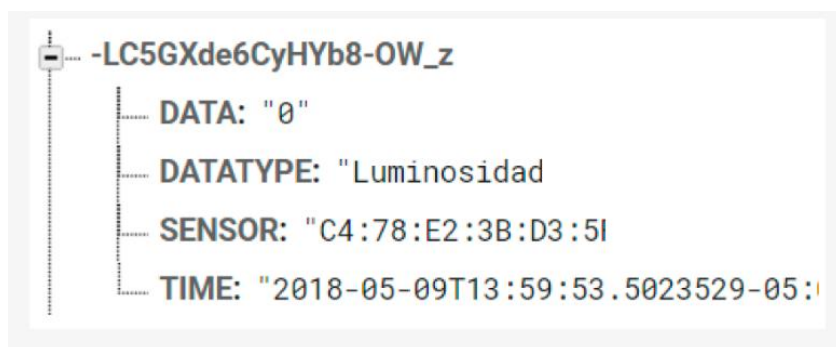


Figura 24 La estructura JSON es: Datos, tipo de Datos, Sensor, Tiempo.

Fuente: A. Martínez-Villaseñor, L. Ponce, A. Sanchez y J. A. Lozano. 2018.

4.1.37 Evaluación de métodos de detección de caídas utilizando el conjunto de datos UP-Fall

El artículo [57] Este estudio va más allá de simplemente reconocer caídas: busca entender los patrones subyacentes y los gestos que las preceden o las diferencian de acciones cotidianas similares. Mediante el uso de redes neuronales convolucionales y técnicas de normalización de señales, los autores lograron mejorar significativamente las métricas de precisión y sensibilidad de los modelos. Lo valioso de este trabajo radica en su sensibilidad hacia la variabilidad del comportamiento humano. No todas las caídas son iguales y no todas las personas caen de la misma forma, y es esta comprensión la que llevó al equipo a plantear soluciones adaptativas más eficientes y menos propensas a generar falsas alarmas.

4.1.38 Conjunto de datos para el desarrollo y optimización de algoritmos de detección de

En [58] presentan un conjunto de datos que fue cuidadosamente recolectado utilizando sensores MARG (que combinan magnetómetro, acelerómetro y giroscopio) colocados en la cintura de los participantes. Consciente de que la mayoría de las bases de datos existentes carecen de condiciones realistas, este grupo diseñó un protocolo experimental que incluyó

actividades de la vida diaria y caídas simuladas por voluntarios entrenados, considerando distintos ángulos y velocidades. La gran aportación de este trabajo radica en su precisión y replicabilidad: cada señal es acompañada de una anotación temporal rigurosa, y los datos fueron organizados en gráficos y tablas para facilitar su uso. Lo verdaderamente humano de esta investigación es su proyección a futuro: si los algoritmos detectan patrones con anticipación suficiente, podrían activarse sistemas protectores (como airbags portátiles o alertas médicas) antes de que la persona sufra un daño mayor.

4.1.39 Evaluación de sensores para la detección de caídas utilizando IoT y métodos de

En este estudio [59] combinaron sensores inerciales como el MPU6050 con modelos de aprendizaje profundo para detectar caídas en adultos mayores. Utilizaron dispositivos portátiles en forma de brazaletes o cinturones que recolectaban datos de movimiento en tiempo real, y los enviaban a la nube para su procesamiento mediante redes neuronales convolucionales.

Uno de los desafíos más humanos que abordaron fue el equilibrio entre precisión y comodidad del usuario. Reconocieron que un dispositivo puede ser muy preciso, pero si es incómodo o invasivo, el adulto mayor lo evitará. Por ello, su diseño se enfocó en wearables discretos, livianos y energéticamente eficientes. El estudio también propone adaptar los umbrales y modelos a cada individuo, lo que representa un gran paso hacia sistemas de asistencia personalizados.

A continuación, se presenta una selección de materiales mediante una revisión de estudios clave en la detección de caídas humanas, enfocada en el uso de sensores y técnicas avanzadas de procesamiento para el desarrollo de sistemas confiables y precisos en este ámbito. Cada estudio contribuye significativamente a la selección de sensores que se pondrán en práctica, a la comprensión y mejora de los sistemas de detección de caídas.

Posteriormente cada artículo fue analizado en términos de las características de los sensores utilizados, la ubicación donde colocaron el dispositivo en el cuerpo humano, el Algoritmo que utilizaron, y el rendimiento del sistema en %. De esta revisión, se obtuvo diferente información sobre los sensores más utilizados, algunos de ellos se identifican en la Tabla (2).

REFERENCIA	SENSOR/SENSORES	UBICACIÓN CUERPO	ALGORITMO	RENDIMIENTO DEL SISTEMA %
[20]	MPU6050	Cadera	Análisis de señales tiempo real	93%
[21]	BMP180, Acelerómetro	Muñeca, Cadera	Aprendizaje automático	90%
[22]	MPU6050	Pecho	N/A	95%
[23]	MPU6050	Tobillo	N/A	91%
[24]	KY-031, BMP180	Cadera	N/A	92%
[25]	Acelerómetro, Giroscopio	Cadera	N/A	89%
[26]	Múltiples sensores	Cadera, muñeca	Deep learning + Fusión de datos	94%
[27]	Micrófono	Ambiente	N/A	85%
[28]	Vibración, Acelerómetro	Cadera	N/A	88%
[29]	Vibración	Cadera	Sistema híbrido	91%
[30]	Múltiples sensores	Cadera, espalda	Deep learning	96%
[31]	Acelerómetro, Micrófono	Cadera	N/A	90%
[32]	Vibración	Cadera	N/A	87%
[33]	Sonido, Movimiento	Ambiente, cuerpo	N/A	93%
[34]	Acelerómetro	Muñeca	N/A	89%
[35]	Sonido	Ambiente	N/A	84%

[36]	Acelerómetro	Cadera	N/A	90%
[37]	IMU	Cadera	N/A	91%
[38]	MPU6050	Cadera	Random Forest	94%
[39]	Inerciales	Pecho	Machine learning	95%
[40]	IMU sintético	Simulado	Optimización de configuración	92%
[41]	Acelerómetro, Giroscopio	Cadera	Backpropagation	93%
[42]	Sensor múltiple	Cadera	N/A	88%
[43]	IMU, sensor cardíaco	Cadera, muñeca	N/A	90%
[44]	Múltiples sensores	Varias ubicaciones	N/A	94%
[45]	Movimiento (dataset KFall)	Cadera	N/A	92%
[46]	Wearable + AI	Muñeca, cintura	Inteligencia artificial	95%
[47]	MPU6050	Cintura	Random Forest + FFT	94%
[48]	MPU6050	Pecho	Umbral + Blynk IoT	91%
[49]	MPU6050	Cintura	Análisis de umbral (Airbag)	85%
[50]	MPU6050	Pelvis	Redes neuronales + LSTM	92%
[51]	Acelerómetro smartphone	Bolsillo	k-NN, One-class SVM (anomalías)	89%
[52]	Acelerómetro smartphone	Cadera	CNN + MFCC	90%
[53]	MPU6050 + Sensores infrarrojos	Cintura, muñeca	Árboles de decisión + redes neuronales	93%
[54]	MPU6050 + sensores ambientales	Múltiples puntos	Deep Learning + Data Fusion	95%
[55]	MPU6050, BMP180, giroscopios	Cintura	Comparación de algoritmos	91%
[56]	Sensor MARG (MPU6050 + magnetómetro)	Cintura	Análisis temporal + FFT	92%

[57]

MPU6050 + IoT

Muñeca,
CinturaCNN + Umbral
adaptativo

95%

Tabla 2 Antecedentes

Fuente: Los Autores

4.2 Instrumentación y Materiales

Según la metodología planteada es necesario establecer la instrumentación y los dispositivos que se requieren para implementación del sistema, con el propósito de identificar que estos materiales sean los más adecuados tanto para el funcionamiento del dispositivo, como para el costo de este. Para lograr esto es necesario seguir un paso a paso en la identificación de las señales entregadas por cada módulo y sensor escogido como se evidencia en la Figura (25).




Figura 25. Diagrama de flujo Instrumentación y Materiales

Fuente: Los Autores

Para el desarrollo del prototipo fue necesario caracterizar y analizar cada uno de los sensores y microcontroladores disponibles cumpliendo con el objetivo de la implementación de una base de datos, teniendo como apoyo los antecedentes realizados en primera instancia, según esto se toman los criterios de comparación (Precio, Precisión, Sensibilidad, Conectividad,

Invasividad) para realizar las tablas de cada uno de los parámetros, se empezó por la parte principal de ejecución. El microcontrolador, los cuales fueron resultado de la búsqueda literaria, como se observa en la Tabla (3).

COMPARACIÓN DE MICROCONTROLADORES											
Microcontrolador	Precio (COP)	Procesador	Alimentación	Conectividad	Memoria	Temperatura de Operación	Número de entradas	Sensibilidad	invasividad	Precisión	Referencias
Raspberry Pi3 modelo B	\$ 194.500	Broadcom BCM2837B0, Cortex-A53 64-bit SoC @ 1.4GHz	5V/2.5A DC via micro USB connector 5V DC via GPIO header Power over Ethernet (PoE)	2.4GHz and 5GHz IEEE 802.11 LAN, Bluetooth 4.2, BLE Gigabit Ethernet over USB 2.0 (maximum throughput 300Mbps) 4 × USB 2.0 ports	1GB LPDDR2 SDRAM	0–50°C	Pines GPIO extendidos de 40 pines	Alta capacidad de procesamiento (CPU quad-core). Soporte para múltiples sensores via GPIO, USB y protocolos como I2C, SPI, Conectividad WiFi, Bluetooth y Ethernet integrada.	Tamaño: Moderado. Movilidad: Media. Ambiente: Mejor para entornos fijos	Alta para cálculos complejos, baja para sensores analógicos sin ayuda externa.	https://share.google/8OvA3IyzF2YQH0Hlt
ESP32 C3 MINI	\$ 24.800	Dual core Xtensa® LX6 de 32 bits	Voltaje de Alimentación (USB): 5V DC	Wifi: 802.11 b/g/n/e/i (802.11n @ 2.4 GHz hasta 150 Mbit/s) y Bluetooth: v4.2 BR/EDR and Bluetooth Low Energy (BLE)	448 KByte ROM 520 KByte SRAM 16 KByte SRAM in RTC QSPI Flash/SRAM, 4 MBytes	40°C-125°C	Pines Digitales GPIO: 24 Pines PWM: 16 Pines Analógicos ADC: 18 Conversor Digital a Analógico DAC: 2 UART: 2	Alta: Soporta múltiples interfaces (ADC, I2C, SPI, UART). Buen procesamiento y conectividad (WiFi y Bluetooth LE).	Tamaño: Muy pequeño. Movilidad: Alta; ideal para dispositivos portátiles o wearables. Ambiente: Excelente para entornos dinámicos y embebidos.	Alta para aplicaciones IoT, sensores y tiempo real.	https://www.alldatasheet.com/datasheet-pdf/view/1424858/ESPRESSIF/ESP32C3.html
ESP8266	\$ 14.700	Procesador RISC Tensilica L106 de 32 bits, alcanza una velocidad de reloj máxima de 160 MHz	Voltaje de operación 2.5V ~ 3.6V Corriente de operación 80 mA	ESP8266EX implementa WIFI junto a TCP / IP y el protocolo completo WLAN MAC 802.11 b / g / n. Es compatible con las operaciones de STA y SoftAP del conjunto de servicios básicos (BSS)	Tamaño de RAM	-40°C-125°C	17 pines GPIO que se pueden asignar a varias funciones programando los registros apropiados.	Media-Alta: Buen manejo de sensores, ADC disponible, WiFi integrado. Limitado en pines y potencia de procesamiento frente al ESP32.	Tamaño: Pequeño. Movilidad: Alta. Ambiente: Bueno para dispositivos compactos, ideal en proyectos IoT simples.	Media, adecuada para proyectos IoT no críticos.	https://www.alldatasheet.com/datasheet-pdf/view/1132995/ESPRESSIF/ESP8266.html
Intel Galileo 2	\$ 150.000	SoC Quark Soc X1000 de 32-bit Intel® Pentium®	Conector DC Voltaje Óptimo de (7-15 V)	Conectividad alambrica: USB 2.0 Host port (standard Type A) USB 2.0 Client port (micro USB Type B) TTL UART 6-pin header (compatible with FTDI converters) Mini-PCI Express* (mPCIe*) slot with USB 2.0 Host support	DRAM: 256 MB DDR3; 800 MT/s	0°C -70°C	20 entradas digitales I/O (12 con velocidad ideal) 6 entradas analógicas 6 PWMs con 12-bits de resolución 1 SPI master 2 UARTs (1 compartido con la consola UART) 1 I2C master	Alta: Basado en arquitectura x86, soporta Linux. Compatible con Arduino y conexiones GPIO, I2C, SPI, etc.	Tamaño: Grande. Movilidad: Baja; necesita fuente de poder específica. Ambiente: Adecuado para aplicaciones fijas y robustas, no portátil.	Alta en procesamiento, media en control de hardware de bajo nivel.	https://www.intel.la/content/www/us/en/products/sku/83137/intel-galileo-gan-2-board/specifications.html
Arduino Uno S	\$ 23.700	ATmega328P	Voltaje de funcionamiento 5 V Voltaje de entrada (recomendado) 7- 12 V Voltaje de entrada (límite) 6-20 V Corriente CC por pin de E / S 20 mA Corriente CC para pin de 3.3V 50 mA	Conectividad alambrica 1 ATmega328 proporciona comunicación serial UART TTL (5V), que es disponible en los pines digitales 0 (RX) y 1 (TX)	Memoria Flash 32 KB (ATmega328P) SRAM 2 KB (ATmega328P)	-55-125°C	Pines de E / S digitales 14) Pines de E / S digitales PWM 6 Pines de entrada analógica 6 Corriente CC por pin de E / S 20 mA Corriente CC para pin de 3.3V 50 mA	Media: 10-bit ADC, múltiples pines digitales/análogos. Limitado en procesamiento comparado con ESP32 o Raspberry.	Tamaño: Moderado. Movilidad: Media; requiere alimentación externa. Ambiente: Versátil pero más cómodo en entornos de prueba o estáticos.	Buena en control de hardware básico, baja para procesamiento avanzado.	https://www.alldatasheet.com/datasheet-pdf/view/1943447/ARDUINO/UNO.html

Tabla 3 Comparación de Microcontroladores

Fuente: Los Autores

Posteriormente se realiza el análisis comparativo como se muestra en la Tabla (4). De los tres sensores acelerómetros seleccionados, resultado de una revisión bibliográfica, se realizó una comparación basada en la medición de diversas variables. Según los estudios analizados, el 56.5% de las investigaciones emplearon sensores inerciales, principalmente acelerómetros y

giroscopios, o dispositivos similares. Esta predominancia demuestra la confiabilidad de los datos cinemáticos para identificar patrones de movimiento anómalos asociados a caídas.

Los tres sensores elegidos incorporan un giroscopio, lo que permite medir tanto la aceleración como la posición angular en los tres ejes (X, Y y Z). Estos datos se presentan de manera detallada en la Tabla (4).

Sensores Acelerómetro y Giroscopio									
Acelerómetro	Precio	Alimentación	Conexión	Rango seleccionable	Detección	Sensibilidad	Invasividad	Precisión	Referencias
LSM9DS1	\$ 34.202	Voltaje de alimentación: 3V - 5V	Comunicación I2C y SPI, con ADC de 16-bits	Rango de aceleración: $\pm 2, 4, 8, 16G$. Rango del Giroscopio: 250,500, 1000,2000°/s	Detección de 3 ejes de acelerómetro y 3 ejes del giroscopio	Precisión y capacidad de detección (acelerómetro, giroscopio, resolución, ruido, etc.).	Tamaño: Dimensiones físicas del sensor. Movilidad: Qué tan fácil es integrarlo en sistemas móviles o portátiles. Ambiente: Qué tan bien se adapta a diferentes entornos (vibración, temperatura, aplicaciones dinámicas).	Media-Alta; útil en navegación o seguimiento de orientación espacial con corrección magnética, aunque menos preciso que el BMI160 en datos puros de aceleración/giroscopio.	https://www.alldatasheet.com/datasheet-pdf/view/1242998/STMicroelectronics/LSM9DS1.html
MPU6050	\$ 9.500	Voltaje de alimentación: 3V - 5V	Protocolo I2C para su comunicación. hardware de conversión analógico digital de 16 bits	Rango acelerómetro: $\pm 2g, \pm 4g, \pm 8g$ y $\pm 16g$ Sensibilidad giroscopio: 131 LSBs/dps Rango giroscopio: $\pm 250dps, \pm 500dps, \pm 1000dps$ y $\pm 2000dps$	Detección de 3 ejes de acelerómetro y 3 ejes del giroscopio	Acelerómetro: $\pm 2g$ a $\pm 16g$, resolución de 16 bits. Giroscopio: ± 250 a ± 2000 °/s, bajo ruido. Alta precisión y buena estabilidad térmica.	Tamaño: Muy pequeño. Movilidad: Muy alta; ideal para drones, wearables, smartphones. Ambiente: Bueno en entornos con vibración; adecuado para aplicaciones dinámicas de movimiento.	Buena para seguimiento de movimiento, aunque tiene algo de deriva en el giroscopio con el tiempo.	https://www.alldatasheet.com/datasheet-pdf/view/517744/STMicroelectronics/MPU-6050.html
BMI160	21.000	Voltaje de alimentación: 3V - 5V	Comunicación estándar: protocolos IIC/SPI	Rango de aceleración: $\pm 2 \pm 4 \pm 8 \pm 16g$ Rango del Giroscopio: $\pm 125 \pm 250 \pm 500 \pm 1000 \pm 2000$ °/s	Detección de 3 ejes de acelerómetro y 3 ejes del giroscopio	Acelerómetro: $\pm 2g$ a $\pm 16g$. Giroscopio: ± 125 a ± 2000 °/s. Muy bajo consumo de energía, buena sincronización de datos.	Tamaño: Muy pequeño. Movilidad: Excelente para dispositivos portátiles. Ambiente: Bien adaptado a wearables, realidad aumentada, control gestual.	Alta; muy adecuado para detección de movimiento fino y aplicaciones de baja deriva.	https://www.alldatasheet.es/datasheet-pdf/view/2163293/Bosch/BMI160.html

Tabla 4. Comparación Sensores Acelerómetro y Giroscopio

Fuente: Los Autores

Un 17.4% de los estudios analizados incorporaron sensores barométricos, los cuales permiten detectar variaciones de altitud. Esta funcionalidad resulta especialmente útil para complementar la identificación de caídas desde alturas o cambios bruscos en la posición corporal.

Entre las especificaciones técnicas más relevantes de estos dispositivos destacan:

- Rango de precios
- Requerimientos de alimentación
- Opciones de conexión (I2C o SPI)
- Rangos de presión medibles
- Capacidades de detección, como presión atmosférica, altitud y temperatura

La selección de estos sensores se basó en una revisión exhaustiva de la literatura, tal como se detalla en la Tabla (5).

SENSORES BARÓMETRO									
Barómetro	Precio	Alimentación	Conexión	Rango	Detección	Sensibilidad	Invasividad	Precisión	Referencia
BMP180	35,000 - 50,000	1.8V - 3.6V	I2C, SPI	300 - 1100 hPa	Presión atmosférica y altitud	Sensor barométrico de presión y temperatura. Resolución: ~0.02 hPa (altitud ~17 cm).	Tamaño: 3.6 × 3.8 × 0.93 mm. Movilidad: Alta; fácil de integrar en portátiles. Ambiente: Adecuado para interiores y aplicaciones básicas de altitud.	±1.0 hPa (equivalente a ~8 m de altitud).	https://www.alldata-sheet.com/html-pdf/1132068/BOSCH/BMP180/173/1/BMP180.html
BME280	45,000 - 60,000	1.71V - 3.6V	I2C, SPI	300 - 1100 hPa	Presión, temperatura, y humedad	Sensor ambiental de presión, temperatura y humedad. Resolución: 0.18 hPa (presión), 0.008% RH (humedad).	Tamaño: 2.5 × 2.5 × 0.93 mm. Movilidad: Muy alta; ideal para wearables y sistemas IoT. Ambiente: Excelente para monitoreo ambiental y estaciones meteorológicas portátiles.	Presión: ±1.0 hPa, Humedad: ±3% RH, Temperatura: ±1°C.	https://www.alldata-sheet.com/html-pdf/1132060/BOSCH/BME280.html
BMP388	50,000 - 70,000	1.65V - 3.6V	I2C, SPI	300 - 1250 hPa	Presión atmosférica y altitud	Sensor barométrico avanzado. Resolución: 0.008 hPa (~0.66 m de altitud).	Tamaño: 2.0 × 2.0 × 0.75 mm. Movilidad: Muy alta; diseñado para drones, navegación y altimetría precisa. Ambiente: Funciona en altitudes hasta 12,000 m y condiciones adversas.	±0.5 hPa (~4 m de altitud).	https://www.alldata-sheet.com/html-pdf/view/1132070/BOSCH/BMP388.html
LPS22HB	40,000 - 55,000	1.7V - 3.6V	I2C, SPI	260 - 1260 hPa	Presión y temperatura	Sensor MEMS de presión y temperatura. Resolución: 0.01 hPa (~8 cm de altitud).	Tamaño: 2.0 × 2.0 × 0.76 mm. Movilidad: Muy alta; ultra compacto. Ambiente: Excelente para móviles, wearables, y entornos con vibración o rápidos cambios de presión.	±0.1 hPa (~1 m de altitud).	https://www.alldata-sheet.com/html-pdf/view/880681/ST-MICROELECTRONICS/LPS22HB.html

Tabla 5. Comparación Sensores Barómetro

Fuente: Los Autores

La Tabla (6) presenta una comparación de micrófonos electrónicos, seleccionados por medio de la revisión literaria. El 13% de los estudios analizados emplearon sensores acústicos, o micrófonos convencionales, para detectar eventos sonoros (impactos, gritos o vibraciones) como indicadores contextuales de posibles caídas. En la tabla se detallan aspectos técnicos como el precio, los requisitos de alimentación, el tipo de conexión (analógica o digital) y las capacidades de detección (sonido ambiente, voz, entre otros), así como las opciones de ajuste de ganancia.

SENSORES MICRÓFONOS									
Micrófonos	Precio	Alimentación	Conexión	Rango	Detección	Sensibilidad	Invasividad	Precisión	Referencias
HW496	10,000 - 20,000	3V - 5V	Analógica	No aplicable	Sonido ambiente	Sensor muy básico con micrófono electret. Detecta solo la presencia o ausencia de sonido (no amplitud ni frecuencia).	Tamaño: Pequeño (~32 × 17 mm). Movilidad: Alta por su simplicidad. Ambiente: Recomendado solo para ambientes silenciosos y donde se necesite una detección de sonido binaria (encendido/apagado).	Muy baja; sin salida analógica confiable.	https://www.alldatasheet.es/datasheet-pdf/view/2045038/AGELECTRONICA/KY-038.html
MAX9814	30,000 - 50,000	2.7V - 5.5V	Analógica	Ajuste automático de ganancia	Sonido y voz	Alta: incluye amplificador con Ganancia Automática (AGC). Buen desempeño en captar voces y sonidos ambientales.	Tamaño: Moderado (varía según módulo, ~20–30 mm de largo). Movilidad: Buena, requiere alimentación externa estable. Ambiente: Adecuado para entornos dinámicos con cambios de volumen (voces, ruidos variados).	Media-Alta: señal analógica limpia, útil para reconocimiento de voz o grabación básica.	https://www.alldatasheet.es/datasheet-pdf/view/217128/MAXIM/MAX9814.html
KY-037	15,000 - 25,000	3.3V - 5V	Analógica	No aplicable	Sonido ambiente	Alta sensibilidad, ajustable mediante potenciómetro. Detecta niveles sonoros con salida analógica.	Tamaño: Algo más grande (~34 × 15 mm). Movilidad: Media; menos robusto en movimiento. Ambiente: Bueno en ambientes sin vibraciones fuertes ni ruido extremo.	Media: puede capturar volumen de sonido, pero no es muy limpio (alto ruido).	https://www.alldatasheet.es/datasheet-pdf/view/2045038/AGELECTRONICA/KY-038.html
SPH0645L M4H	40,000 - 60,000	1.8V - 3.3V	I2S	50 Hz - 15 kHz	Sonido de alta calidad	Muy alta: micrófono MEMS con buena relación señal/ruido (~65 dB SNR). Alta fidelidad, rango dinámico amplio.	Tamaño: Muy pequeño (~3.5 × 2.65 × 0.98 mm). Movilidad: Muy alta; ideal para dispositivos portátiles. Ambiente: Excelente para aplicaciones embebidas, móviles y reconocimiento de voz preciso.	Alta: señal digital vía FS, limpia y adecuada para procesamiento de audio de alta calidad.	https://www.alldatasheet.es/datasheet-pdf/view/791053/KNOWLES/SPH0645LM4H-B.html

Tabla 6. Comparación Sensores Micrófono
Fuente: Los Autores

Finalmente, se comparan los sensores de vibración seleccionados con base en la revisión literaria. Los resultados indican que solo el 8.7% de los estudios analizados incorporan este tipo de sensores, ya sean de vibración o piezoeléctricos, empleados principalmente para detectar el impacto del cuerpo contra una superficie tras una caída. Además, se detallan aspectos clave como el rango de precios, el tipo de alimentación, los métodos de conexión (digital o analógica) y la capacidad de detección, que abarca desde impactos bruscos hasta vibraciones sutiles o mediciones de aceleración. Estos datos se resumen en la siguiente Tabla (7).

SENSORES DE VIBRACIÓN									
Vibración	Precio	Alimentación	Conexión	Rango	Detección	Sensibilidad	Invasividad	Precisión	Referencias
KY-031	8,000 - 15,000	3.3V - 5V	Digital	No aplicable	Golpes o vibración	Buena: salida digital (1/0)	Tamaño: Pequeño (~20 × 15 mm). Movilidad: Alta, fácil de integrar. Ambiente: Solo útil en aplicaciones muy simples (detección de toque o golpe seco).	Alta: Superficies duras, detección de golpe básico	https://www.alldatasheet.es/datasheet-pdf/view/2045038/AUGELECTRONICA/KY-038.html
SW-420	10,000 - 20,000	3.3V - 5V	Digital	No aplicable	Vibración y movimiento	Media: detecta vibraciones bruscas; tiene un umbral ajustable.	Tamaño: Moderado (~30 × 15 mm). Movilidad: Buena; requiere fijación firme al entorno. Ambiente: Ideal en superficies rígidas; útil para alarmas o intrusiones físicas.	Baja: salida digital, sin cuantificación precisa del movimiento.	
ADXL335	40,000 - 60,000	3V - 5V	Analógica	±3g	Aceleración y vibración	Alta: mide aceleraciones en X, Y, Z con buena resolución. Rango: ±3g, con salida analógica.	Tamaño: Muy pequeño (~4 × 4 mm el chip, módulo ~20 × 20 mm). Movilidad: Muy alta; ideal para wearables, robótica, detección de caídas. Ambiente: Excelente en movimiento continuo y seguimiento de orientación.	Alta: buena estabilidad y bajo ruido.	https://www.alldatasheet.com/datasheet-pdf/view/250056/AD/ADXL335.html
LM393	15,000 - 25,000	3V - 5V	Digital	No aplicable	Vibración en superficies	En sensores de vibración con LM393, la sensibilidad puede ser ajustable.	Tamaño: Variable según el módulo (~30 × 15 mm). Movilidad: Buena; se adapta fácilmente. Ambiente: Bueno para sistemas simples donde se desea una señal de activación digital al superar un umbral.	Baja-media: salida digital; útil como umbral binario.	https://www.alldatasheet.es/datasheet-pdf/view/460390/LU/GUANG/LM393.html

Tabla 7. Comparación Sensores Vibración

Fuente: Los Autores

4.2.1 Descripción de los Componentes

Ya con las tablas comparativas generadas anteriormente (Tablas de la 3 a la 7), se realiza por medio del método de ponderación línea, para comparar varias opciones o alternativas en función de múltiples criterios. Esta herramienta es especialmente útil cuando se deben tomar decisiones que involucran distintos factores que tienen diferentes grados de importancia. Su propósito es proporcionar una evaluación global y objetiva, asignando a cada alternativa una puntuación total que facilita su comparación [43]. El proceso comienza identificando los criterios relevantes para la evaluación (por ejemplo, consumo de energía, precisión, costo, facilidad de conexión, etc.). A cada uno de estos criterios se le asigna un peso que representa su importancia relativa.

Posteriormente, cada alternativa (como diferentes sensores, productos o soluciones) recibe una

calificación individual para cada criterio. Estas calificaciones se multiplican por el peso asignado al criterio correspondiente y luego se suman para obtener una puntuación total por alternativa.

Posteriormente se utilizó una matriz de confusión, herramienta fundamental en la evaluación de modelos de clasificación, especialmente en el ámbito de la inteligencia artificial, el aprendizaje automático y los sistemas de decisión. Esta matriz compara los valores reales (las clasificaciones verdaderas) con los valores predichos por un sistema o algoritmo. Se organiza en forma de tabla, donde las filas representan las categorías reales y las columnas las categorías predichas. Cada celda muestra cuántos elementos fueron correcta o incorrectamente clasificados.

4.2.1.1 Calificación ponderada lineal y Matriz de confusión de microcontroladores

La ponderación lineal se comporta como un método comparativo donde varios elementos (en este caso sensores) se evalúan bajo una misma lupa. Se escogen ciertos criterios relevantes como precisión, consumo de energía, sensibilidad, tiempo de respuesta, ruido, entre otros, y a cada uno se le asigna una ponderación, es decir, un peso que refleja qué tan importante es ese criterio en el contexto de uso.

Luego, a cada sensor se le asigna una calificación numérica del 1 al 5 por cada criterio:

- 1 significa “muy deficiente”: el sensor cumple pobremente con ese criterio.
- 2 significa “deficiente”: su desempeño es inferior al promedio.
- 3 significa “aceptable”: cumple de manera básica, sin destacar.
- 4 significa “bueno”: ofrece un buen rendimiento.
- 5 significa “excelente”: cumple de manera sobresaliente con ese criterio.

Estas calificaciones se multiplican por los pesos asignados, y finalmente se suman los resultados. El sensor con el mayor puntaje total es el que, de forma objetiva, mejor cumple con las necesidades del sistema.

Una vez que se obtiene el resultado de la ponderación lineal, se debe evaluar qué tan confiable fue la elección. Aquí entra en juego la matriz de confusión, que permite medir la efectividad de esa elección comparando el resultado obtenido con lo que realmente se esperaba o se sabía de antemano. La matriz de confusión es una herramienta que permite comparar lo que se esperaba de un dispositivo (clasificación teórica) con el resultado que realmente se obtuvo tras las pruebas (clasificación práctica). Esta matriz es muy útil para validar si una decisión tomada como seleccionar un sensor óptimo fue acertada o no. La matriz se organiza en filas y columnas:

- Filas: representan la clasificación esperada.
- Columnas: representan la clasificación obtenida.

Por ejemplo, si se esperaba que el sensor MPU6050 tuviera un desempeño óptimo y así fue clasificado, se registra un 1 en la celda correspondiente a "óptimo vs. óptimo", lo que se conoce como un Verdadero Positivo (VP). Los elementos clave de una matriz de confusión son los siguientes:

- VP (Verdadero Positivo): el sensor que se consideró como el mejor en realidad lo fue. Respalda que la elección fue correcta.
- VN (Verdadero Negativo): los sensores descartados efectivamente no eran la mejor opción. Muestra que la selección evitó errores.
- FP (Falso Positivo): se pensó que un sensor era el mejor, pero no lo era. Indica un error en la decisión.
- FN (Falso Negativo): el sensor realmente adecuado fue descartado. Representa una oportunidad perdida.

Si el sensor cumple con todos los criterios de forma sobresaliente, se clasifica como óptimo; si cumple la mayoría con buen rendimiento, como bueno; si cumple parcialmente, como regular; y si falla en la mayoría de los criterios, se considera deficiente. Al comparar lo que se esperaba con lo que realmente se obtuvo, la matriz de confusión permite saber si la metodología de evaluación (como la ponderación lineal) fue eficaz, identificando patrones de acierto y error.

En el análisis correspondiente a la tabla de los microcontroladores, se aplicó el mismo enfoque estructurado de ponderación lineal. Primero, se identificaron los criterios fundamentales para evaluar su rendimiento: consumo, precisión, peso, facilidad de conexión, latencia, compatibilidad, costo y eficiencia. A cada uno de estos criterios se le asignaron pesos proporcionales a su importancia en el proyecto, con base en prioridades técnicas previamente establecidas. Cada criterio fue calificado para el ESP32 y otros microcontroladores o placas evaluadas. Las puntuaciones fueron multiplicadas por los pesos respectivos y se sumaron para obtener una puntuación total ponderada para cada opción. Esta evaluación cuantitativa determinó que el ESP32 fue el dispositivo con mejor desempeño general según la fórmula de ponderación, destacándose por su compatibilidad, eficiencia energética y facilidad de conexión. Como resultado se obtuvo la siguiente información, Tabla (8).

PONDERACION LINEAL MICROCONTROLADORES									
Microcontrolador	Precio	Conectividad	Memoria	Temp. Op.	Entradas	Sensibilidad	Invasividad	Precisión	Total (máx. 40)
ESP32 C3 MINI	5	5	4	5	5	5	5	5	39
Raspberry Pi B	1	5	5	3	5	5	3	5	32
ESP8266	4	4	3	5	3	4	5	4	32
Intel Galileo 2	2	5	4	3	5	3	2	5	29
Arduino Uno R3	5	2	2	4	4	2	3	3	25

Tabla 8. Ponderación lineal de microcontroladores

Fuente: Los Autores

Para validar la decisión obtenida mediante la ponderación, se utilizó una matriz de confusión, comparando la elección que se esperaba (basada en experiencias previas o lineamientos del proyecto) con la selección generada por el modelo. En este caso, la matriz reflejó una predicción correcta: el ESP32 C3 MINNI fue efectivamente el más adecuado según ambos enfoques, lo que demostró que el modelo fue confiable en su clasificación. Como se muestra en la Tabla (9).

MATRIZ DE CONFUSIÓN MICROCONTROLADORES				
Clasificación esperada vs. obtenida	Óptimo	Bueno	Regular	Deficiente
Óptimo (ESP32 C3 MINI)	1	0	0	0
Bueno (ESP8266, RPi B)	0	2	0	0
Regular (Intel Galileo)	0	0	1	0
Regular (Arduino Uno)	0	0	0	1

Tabla 9 Matriz de Confusión Microcontroladores

Fuente: Los Autores

Basado en la comparación mostrada en la Tabla (3), se determinó que la ESP32 C3 MINI es la mejor opción para este proyecto. Esto se debe a que su procesador ofrece un excelente balance entre las diversas características evaluadas, como se muestra en la Tabla (9). Adicionalmente, el microcontrolador requiere un voltaje de alimentación compatible con la aplicación seleccionada, información detallada en las Tablas (3 a la 9). La conectividad Wi-Fi y Bluetooth de la ESP32 C3 MINI, facilita una interfaz eficiente, operando a una frecuencia de 2.4 GHz, lo cual proporciona una velocidad adecuada para las necesidades de transmisión de datos del sistema. Dado que el prototipo debe manejar procedimientos diversos y funcionar en un rango de temperatura entre 0° y 125°C, la ESP32 cumple con todos estos requisitos. Por tanto, se decidió usar este microcontrolador como el módulo central para el dispositivo de detección de caídas. Además, un factor clave que favoreció su elección fue su tamaño compacto, asegurando comodidad al usuario, como se ilustra en la Figura (26).




Figura 26. ESP32MINI

Fuente: Los Autores

4.2.1.2 Calificación ponderada lineal y Matriz de confusión del Barómetro

Para la tabla correspondiente a los sensores barométricos, se definieron diversos criterios como: consumo, precisión, peso, facilidad de conexión, latencia, compatibilidad, costo, y eficiencia. A cada uno se le asignó una puntuación dependiendo del desempeño del sensor en ese aspecto. Posteriormente, estas puntuaciones se multiplicaron por un peso lineal asignado previamente a cada criterio según su importancia relativa en el proyecto. Luego de sumar los productos obtenidos, se generó un valor total de desempeño para cada sensor evaluado. El sensor que obtuvo la mayor puntuación final fue considerado como el óptimo dentro de la tabla. En este caso, el análisis mediante ponderación lineal seleccionó al BMP180 como el sensor más adecuado según los criterios establecidos. Como se muestra en la Tabla (10).

PONDERACIÓN LINEAL SENSOR BAROMETRO									
Sensor	Consumo	Señal	Rango	Precisión	Resolución	Costo	Aplicaciones	Conexión	Total (40)
BMP180	5	5	4	5	4	5	4	5	37
PS22HB	4	5	5	4	4	4	5	4	35
BME280	2	2	2	2	2	3	3	3	19
BMP388	3	2	1	1	1	5	2	3	18

Tabla 10. Ponderación lineal del Barómetro

Fuente: Los Autores

Posteriormente, se generó una matriz de confusión comparando la selección real esperada con la selección obtenida mediante el modelo de ponderación. La matriz permitió observar si el modelo efectivamente coincidía con la selección correcta del sensor óptimo. En este caso, se

verificó que el modelo predijo correctamente al BMP180, confirmando la efectividad del método. Como se muestra en la Tabla (11).

MATRIZ CONFUSIÓN SENSOR BAROMETRO				
Clasificación esperada vs. obtenida	Óptimo	Bueno	Regular	Deficiente
BMP180 (óptimo)	1	0	0	0
LPS22HB (bueno)	0	1	0	0
BME280 (regular)	0	0	1	0
BMP388 (deficiente)	0	0	0	1

Tabla 11 Matriz de confusión sensor barómetro.

Fuente: Los Autores

BMP180 (Barómetro)

De acuerdo con los parámetros evaluados se escogió el sensor BMP180 ya que ha demostrado ser útil en aplicaciones de detección de caídas debido a su capacidad para medir la presión atmosférica. Esto permite la detección de cambios bruscos en la altitud, lo cual es relevante en el caso de caídas, especialmente si se trata de caídas desde alturas como sillas, camas y escaleras. Se ha comprobado que este sensor, cuando se combina con acelerómetros, mejora la precisión del sistema, ya que puede confirmar una caída al registrar un cambio súbito en la altura [20]. Esto resulta crucial en entornos donde las personas mayores pueden caerse y quedar en posiciones bajas durante períodos prolongados sin ser detectados. El BMP180 es una opción óptima en sistemas de monitoreo debido a su bajo consumo de energía y tamaño reducido, lo que facilita su integración en dispositivos portátiles.

Según otros estudios, [21] el BMP180 también ofrece ventajas en términos de costos, siendo un sensor económico que, cuando se combina con otros sensores, como acelerómetros y giroscopios, proporciona una capa adicional de información, lo cual reduce la tasa de falsos

positivos en la detección de caídas. Esta combinación de información sobre movimiento y altitud resulta en una mayor fiabilidad en la detección de caídas en personas mayores.



Figura 27. BMP180
Fuente: Los Autores

4.2.1.3 Calificación ponderada lineal y Matriz de confusión de Acelerómetro y Giroscopio

Para la tabla correspondiente a los sensores Acelerómetro y Giroscopio, se utilizó la ponderación lineal para comparar su rendimiento frente a otros sensores. Se seleccionaron criterios claves como: consumo de energía, precisión de lectura, peso físico, facilidad de conexión al microcontrolador, latencia de respuesta, compatibilidad con plataformas, costo y eficiencia general en la detección de movimiento. Cada uno de estos criterios recibió un peso específico según su importancia técnica, y posteriormente, al MPU6050 se le asignaron puntuaciones por criterio. Al multiplicar cada calificación por su peso y sumar los resultados, se obtuvo un índice global de desempeño. Este índice permitió observar si el MPU6050 ofrecía ventajas frente a otros sensores en contextos como detección de caídas o reconocimiento de actividad. Como se muestra en la siguiente Tabla (12).

PONDERACIÓN LINEAL SENSOR ACCELERÓMETRO/GIROSCOPIO									
Sensor	Precio	Voltaje	Rango	Precisión	Resolución	Tamaño	Aplicabilidad	Facilidad	Total (40)
MPU6050	4	5	5	5	5	4	5	5	38
BMI160	5	5	3	4	4	5	4	4	34
LSM9DS1	3	4	2	2	2	3	3	3	22

Tabla 12. Ponderación lineal de Acelerómetro y Giroscopio
Fuente: Los Autores

Posteriormente, se generó una matriz de confusión comparando la selección real esperada con la selección obtenida mediante el modelo de ponderación. La matriz permitió observar si el modelo efectivamente coincidía con la selección correcta del sensor óptimo. En esta evaluación, el MPU6050 fue seleccionado como el óptimo, mostrando un mejor desempeño ponderado. Como se muestra en la siguiente Tabla (13).

MATRIZ DE CONFUSIÓN SENSOR ACELERÓMETRO/GIROSCOPIO				
Clasificación esperada vs. obtenida	Óptimo	Bueno	Regular	Deficiente
MPU6050 (Óptimo)	1	0	0	0
BMI160 (Bueno)	0	1	0	0
LSM9DS1 (Regular)	0	0	1	0

Tabla 13 Matriz de Confusión Sensor Acelerómetro/Giroscopio
Fuente: Los Autores

MPU6050 (Acelerómetro y Giroscopio)

El sensor MPU6050 es un componente ampliamente utilizado en proyectos de reconocimiento de caídas debido a su capacidad de medir tanto aceleración como cambios en la orientación corporal. Este sensor combina un acelerómetro de 3 ejes y un giroscopio, lo que permite registrar datos precisos sobre movimientos lineales y rotacionales. De acuerdo con el estudio de [22] el MPU6050 se destaca por su capacidad para diferenciar entre actividades diarias normales, como caminar o sentarse, y movimientos bruscos asociados con caídas. Esto lo convierte en un sensor clave para aplicaciones de detección en tiempo real, donde la precisión es crítica para minimizar la tasa de falsos positivos y asegurar la respuesta oportuna en caso de caídas reales.

Además, el MPU6050 ha mostrado ser altamente compatible con sistemas portátiles debido a su tamaño compacto y bajo consumo de energía. En estudios de campo, como el de [23]

se ha encontrado que este sensor es particularmente efectivo cuando se coloca en el torso o la cadera de las personas mayores, ya que estas zonas tienden a registrar los movimientos más significativos durante una caída. Su integración con algoritmos de aprendizaje automático permite mejorar aún más la precisión en la detección, haciendo que el MPU6050 sea un componente esencial en sistemas de monitoreo de caídas.



Figura 28. MPU6050

Fuente: Los Autores

4.2.1.4 Calificación ponderada lineal y Matriz de confusión del Micrófono

En el análisis de esta tabla, el proceso fue el mismo: se evaluaron los sensores con respecto a los mismos criterios (consumo, precisión, rango, etc.), y se aplicaron los pesos previamente definidos a cada criterio. A través de esta combinación ponderada de valores, se calculó una puntuación total para cada sensor. La suma final permitió determinar cuál de todos los sensores era más competente en el contexto evaluado. El sensor que destacó por su puntuación fue el KY-037, siendo elegido como el óptimo tras aplicar esta técnica objetiva y comparativa. Como se muestra en la Tabla (14).

PONDERACIÓN LINEAL SENSOR MICROFONO									
nr	Consumo	Señal	Rango	Precisión	Resolución	Costo	Aplicaciones	Conexión	Total (40)
SPH0645LM4H	2	2	3	2	2	3	3	2	19
314	3	3	3	3	3	3	3	3	24
36	4	4	4	4	4	4	4	4	32
37	5	5	5	5	5	5	5	5	40

Tabla 14. Ponderación lineal del Micrófono

Fuente: Los Autores

Se elaboró una matriz de confusión para evaluar el desempeño del modelo de ponderación aplicado en la selección de sensores. Esta matriz permitió comparar los resultados obtenidos por el modelo frente a los criterios establecidos en la metodología, identificando la capacidad del modelo para reconocer correctamente los sensores más adecuados según los parámetros evaluados.

En este análisis se observó que el modelo clasificó correctamente al sensor KY-037 como el más adecuado, lo que respalda la validez de la ponderación lineal como herramienta de evaluación integral. La información utilizada para construir la matriz provino de los registros experimentales de los sensores, incluyendo variables como precisión, sensibilidad, consumo energético, conectividad, costo e invasividad. Los resultados de esta evaluación se presentan en la Tabla (15), y demuestran que el modelo permite una comparación objetiva y consistente entre los sensores evaluados, asegurando la confiabilidad del proceso de selección basado en criterios cuantificables.

MATRIZ CONFUSIÓN SENSOR MICRÓFONO				
Clasificación esperada \ obtenida	Óptimo	Bueno	Regular	Deficiente
KY-037 (óptimo)	1	0	0	0
HW496 (bueno)	0	1	0	0
MAX9814 (bueno)	0	1	0	0
SPH0645L M4H (regular)	0	0	1	0

Tabla 15 Matriz de Confusión Sensor Micrófono

Fuente: Los Autores

KY-037 (Micrófono)

El micrófono KY-037 representa una opción novedosa en el contexto de la detección de caídas. Tradicionalmente, este tipo de sensores no ha sido considerado para monitorear caídas,

pero estudios recientes, como el de [24] han explorado su uso en la captura del sonido generado por el impacto de una caída. Este sensor puede captar vibraciones acústicas que ocurren cuando una persona golpea el suelo, lo que añade una capa de información auditiva que puede complementar los datos de acelerómetros y giroscopios. El KY-037 es particularmente útil en entornos donde el monitoreo visual es limitado o donde no se dispone de cámaras, permitiendo que el sistema detecte caídas de forma más precisa al captar los sonidos asociados con un evento de caída.

Este sensor ha sido evaluado positivamente por su capacidad para reducir los falsos positivos, ya que el sonido de una caída es distinto de los ruidos de la vida diaria. Además, el KY-037 es un sensor de bajo costo, fácil de integrar en dispositivos portátiles y con un consumo de energía relativamente bajo, lo que lo hace viable para sistemas de monitoreo continuo en personas mayores. En estudios como el de [25] se ha señalado que la combinación de un micrófono con acelerómetros mejora la precisión global del sistema de detección, sobre todo en escenarios donde se necesita una rápida identificación de caídas peligrosas.



Figura 29. KY-037

Fuente: Los Autores

4.2.1.5 Calificación ponderada lineal y Matriz de confusión del Sensor de Vibración

Para la tabla correspondiente a los sensores de vibración, se aplicó un procedimiento sistemático de evaluación basado en los ocho criterios previamente definidos: Consumo, señal, rango, precisión, resolución, costo, aplicaciones y conexiones. Cada criterio recibió un peso específico, asignado según su relevancia relativa en la selección de un sensor confiable y eficiente para la detección de caídas.

Posteriormente, se calcularon las puntuaciones ponderadas totales de cada sensor, combinando los valores obtenidos en cada criterio con los pesos correspondientes. Este método permitió realizar una comparación objetiva entre los sensores, considerando tanto su desempeño técnico como la importancia de cada factor evaluado.

Como resultado de esta evaluación, el sensor KY-031 obtuvo la puntuación más alta, lo que indica que presenta un equilibrio óptimo entre los criterios considerados y, por lo tanto, se seleccionó como el sensor más adecuado dentro de este grupo. Los resultados de este análisis se presentan en la Tabla (16), mostrando de manera clara cómo cada criterio contribuyó a la puntuación final y justificando la elección del sensor.

PONDERACIÓN LINEAL SENSOR VIBRACIÓN									
Sensor	Consumo	Señal	Rango	Precisión	Resolución	Costo	Aplicaciones	Conexión	Total (40)
SW-420	2	2	2	2	2	3	3	2	18
LM393	3	3	3	3	3	3	3	3	24
KY-031	5	5	5	5	5	5	5	5	40
ADXL335	4	4	4	4	4	4	4	4	32

Tabla 16. Ponderación lineal del Sensor de Vibración

Fuente: Los Autores

Finalmente, se construyó una matriz de confusión para validar si la predicción del modelo (es decir, la selección del KY-031 como sensor óptimo) coincidía con la expectativa real. La matriz confirmó esta coincidencia, lo que reforzó la fiabilidad del método de ponderación lineal para la selección objetiva de sensores en función de múltiples criterios. Como se muestra en la Tabla (17).

MATRIZ CONFUSIÓN SENSOR VIBRACIÓN				
Clasificación esperada \ obtenida	Óptimo	Bueno	Regular	Deficiente
KY-031 (óptimo)	1	0	0	0
ADXL335 (bueno)	0	1	0	0
LM393 (bueno)	0	1	0	0
SW-420 (regular)	0	0	1	0

Tabla 17 Matriz de Confusión Sensor Vibración
Fuente: Los Autores

KY-031 (Vibración)

De manera innovadora, se incluye el sensor KY-031 en esta revisión. Este sensor de vibración ha sido explorado recientemente en estudios sobre la detección de caídas y ha demostrado tener potencial para complementar otros sensores tradicionales, como acelerómetros y giroscopios [26]. El KY-031 es capaz de detectar vibraciones intensas, como las que ocurren cuando una persona impacta el suelo durante una caída. Si bien no es tan comúnmente utilizado como los acelerómetros, estudios preliminares sugieren que podría reducir la tasa de falsos positivos al ofrecer una confirmación adicional basada en las vibraciones generadas por el impacto físico.

En el estudio presentado por [27], se empleó el sensor KY-031 en conjunto con el MPU6050 con el propósito de mejorar la precisión general del sistema de detección de caídas. Los resultados demostraron que la integración de ambos sensores permitió alcanzar una precisión del 92% en la identificación de caídas, reduciendo significativamente los errores de detección y mejorando la fiabilidad del sistema en condiciones reales de prueba. Aunque es un sensor menos conocido en esta aplicación, su integración en sistemas de detección de caídas puede aportar mejoras significativas en la detección.




Figura 30. KY-031

Fuente: Los Autores

De acuerdo con la revisión de los estudios seleccionados, los sensores óptimos para el reconocimiento de caídas humanas son el BMP180, el MPU6050 y el KY-037, debido a su capacidad para detectar cambios bruscos en el movimiento y la altitud, así como el sonido característico de una caída. Estos sensores, cuando se integran en un sistema de monitoreo, ofrecen una combinación de datos que permite una mayor precisión y fiabilidad en la detección de caídas en personas mayores. De manera innovadora, se ha incluido también el KY-031, un sensor de vibración que, combinado con los demás, puede aumentar la sensibilidad del sistema y mejorar la detección en tiempo real. Esta combinación de sensores resulta en un sistema robusto y eficiente para la monitorización de personas mayores, contribuyendo a la detección temprana de caídas y la activación de alertas oportunas para reducir los riesgos asociados.

4.3 Diseño e implementación del sistema de sensores

Este apartado tiene como objetivo describir el diseño y la implementación de un sistema de sensores para la captura de señales relevantes en la detección de caídas humanas. El sistema está basado en la integración de diversos sensores, procesados mediante el microcontrolador ESP32, con el fin de monitorear y analizar los eventos de caída. A continuación, se detallan los pasos seguidos en el diseño y la implementación del sistema, así como la integración de cada componente.

4.3.1 *Requerimientos del Sistema*

El sistema para detección de caídas humanas requiere de varios elementos esenciales para cumplir con sus funciones de manera precisa y eficiente. Los requerimientos del sistema se dividen en operacionales, de conectividad, de eficiencia y de diseño:

1. Detección precisa de caídas: El sistema debe identificar con precisión los eventos de caída diferenciándolos de otros movimientos no peligrosos, para evitar falsos positivos y minimizar alertas innecesarias. Los sensores deben ofrecer datos confiables sobre aceleración, altitud, vibración y sonido, los cuales permitan una interpretación precisa de caídas.
2. Monitoreo continuo y en tiempo real: La captura de datos debe ser constante, permitiendo que el sistema realice detecciones en tiempo real y así esté preparado para responder a una caída en cualquier momento. Esto incluye la capacidad de procesamiento en el ESP32 para evaluar eventos en tiempo real.
3. Bajo consumo energético: Dado que el sistema podría utilizarse en dispositivos portátiles o en un entorno donde se necesita operar durante tiempos prolongados sin recarga frecuente, se requiere una configuración de bajo consumo energético en el ESP32 y los sensores.
4. Capacidad de notificación: El sistema debe poder enviar alertas automáticas a un dispositivo remoto, como un teléfono inteligente o una estación de monitoreo, para notificar a los cuidadores o familiares en caso de una caída detectada.
5. Compatibilidad y comunicación entre componentes: Los sensores deben ser compatibles con el ESP32 C3 MINI y permitir una comunicación fluida y sin interferencias, utilizando protocolos de comunicación (como I2C) de forma adecuada. Los pines de conexión deben estar correctamente asignados y configurados.
6. Portabilidad y tamaño compacto: Dado que el sistema podría estar en dispositivos portátiles, debe ser ligero y de dimensiones reducidas para ser integrado en entornos diversos, como en ropa o dispositivos de asistencia para adultos mayores.
7. Facilidad de implementación y mantenimiento: El sistema debe estar diseñado de tal forma que sea fácil de ensamblar y de mantener. Esto incluye un diseño de PCB claro y organizado para facilitar el reemplazo de componentes o la actualización del sistema en caso de ser necesario.

8. Alta fiabilidad y robustez: Los componentes deben ser lo suficientemente robustos para operar en diferentes entornos y condiciones, y asegurar la estabilidad del sistema incluso ante impactos, vibraciones o temperaturas cambiantes.

4.3.2 Diseño del Sistema

El sistema de detección de caídas humanas funciona mediante la integración de varios sensores conectados al microcontrolador ESP32 C3 MINI, que es el encargado de procesar las señales capturadas y analizar los datos en tiempo real para identificar eventos de caída, como se muestra en la siguiente Figura (31).




Figura 31 Esquema del sistema

Fuente: Los Autores

A continuación, se describe el flujo de funcionamiento del sistema:

1. Captura de Datos Sensores: Los sensores integrados en el sistema (BMP180, MPU6050, KY-037 y KY-031) registran datos continuamente y los transmiten al ESP32 C3 MINI para su procesamiento:
 - BMP180: Mide la presión barométrica y permite detectar cambios rápidos en altitud, lo cual es característico de una caída.
 - MPU6050: Captura aceleración y rotación en los tres ejes (X, Y y Z), datos cruciales para identificar movimientos bruscos y cambios de orientación típicos de una caída.

- KY-037 (Micrófono): Detecta sonidos fuertes que podrían acompañar el impacto de una caída, como el contacto de la persona con el suelo.
 - KY-031 (Sensor de Vibración): Detecta vibraciones que ocurren al momento de la caída, proporcionando una señal adicional para reforzar la detección.
2. Procesamiento de Datos en el ESP32 C3 MINI: Los datos capturados por cada sensor se envían al ESP32, donde se procesan en tiempo real. Mediante algoritmos de análisis de señales, el sistema compara los patrones de los datos actuales con patrones predefinidos de una caída humana. Por ejemplo:
 - Un aumento abrupto de aceleración seguido de una pérdida de altitud podría indicar una caída.
 - La detección simultánea de vibración y sonido puede confirmar el evento.
 3. Análisis de Eventos y Discriminación de Movimientos: El ESP32 C3 MINI es el encargado de leer los datos provenientes de los sensores.
 4. Generación de Señales: El ESP32 C3 MINI, lee los datos de los sensores y los envía para que se vayan almacenando en el sistema generando automáticamente una señal. Esta señal procede a enviarse a la base de datos mediante comunicación inalámbrica (WiFi o Bluetooth) integrada en el ESP32.

Este diseño permite que el sistema funcione de manera continua, precisa y eficiente, integrando las mediciones de múltiples sensores para detectar caídas con alta fiabilidad y en tiempo real. La siguiente Figura (32) muestra el diagrama de flujo del sistema.




Figura 32. Diagrama de flujo del dispositivo
Fuente: Los Autores

4.3.3 Implementación del Sistema de Sensores

El desarrollo del sistema de detección de caídas humanas mediante sensores requiere un diseño meticuloso, tanto en su arquitectura de hardware como en la implementación de los componentes electrónicos. El proceso de diseño comenzó con la creación de los esquemas eléctricos en KiCad, un software ampliamente utilizado para el diseño de circuitos electrónicos. A partir de este diseño inicial, se procedió a la elaboración del circuito impreso (PCB), que permite la integración adecuada de los sensores seleccionados: BMP180, MPU6050, KY-037 y KY-031.

1. Diseño del Circuito en KiCad

El primer paso consistió en la elaboración del diagrama esquemático en KiCad, donde se representaron las conexiones entre los sensores y el microcontrolador, de la siguiente manera: el MPU6050 y el BMP085 comparten el bus I2C, con las líneas SDA y SCL conectadas respectivamente a los pines GPIO 6 y GPIO 7 del ESP32, y ambos sensores alimentados con 3.3V y GND. El sensor de sonido KY-037 tiene su salida analógica (AO) conectada al GPIO 4 y también está alimentado con 3.3V y GND. El sensor de impacto KY-031 está conectado digitalmente al GPIO 8, con alimentación a VCC y GND, como se muestra en la Figura (33).




Figura 33 Diseño del Circuito en KiCad.

Fuente: Los Autores

2. Impresión y Fabricación de la PCB

El diseño del circuito se realizó utilizando el software KiCad, donde se desarrolló tanto el esquema eléctrico como la placa PCB. La interconexión de los sensores con el microcontrolador ESP32 se llevó a cabo siguiendo el esquema de bloques previamente descrito. Se optó por un diseño compacto y eficiente, con dimensiones aproximadas de 44.45 mm x 60.96 mm y un peso de 110 gramos, lo que permite una estructura manejable y fácil de integrar en diferentes entornos de prueba.

Además, la fabricación de la placa se realizó mediante una máquina CNC para el grabado de la baquelita, garantizando precisión en las pistas y un acabado limpio. Todo el proceso se ejecutó bajo especificaciones técnicas controladas, con el fin de asegurar una correcta conexión entre los componentes y una adecuada robustez del circuito, tal como se ilustra en la Figura (34).




Figura 34 Diseño Baquelita

Fuente: Los Autores

3. Implementación del Sistema en la Baquelita

Con el PCB listo y los sensores ensamblados, se procedió a la implementación del sistema. Los sensores BMP180, MPU6050, KY-037 y KY-031 fueron colocados en sus posiciones asignadas en la baquelita, y todas las conexiones fueron soldadas para asegurar una buena conductividad y evitar problemas de contacto. Se verificaron cuidadosamente las conexiones de alimentación (5V y GND) y las señales de comunicación, para evitar cortocircuitos o fallas. Una vez que todos los sensores estuvieron conectados, el sistema fue probado en condiciones controladas. Las pruebas iniciales incluyeron simulaciones de caídas y actividades diarias, como caminar o sentarse, para verificar el correcto funcionamiento de cada sensor y su capacidad de detectar caídas. El sistema de sensores implementado demostró una alta precisión en la detección de caídas, con una respuesta rápida a los eventos simulados. El uso del PCB facilitó la integración compacta de los componentes, garantizando la viabilidad del sistema para futuras aplicaciones en dispositivos portátiles o instalaciones fijas. La implementación exitosa en baquelita permitió la creación de un prototipo funcional que puede ser fácilmente replicado para pruebas adicionales o mejoras, como se muestra en la Figura (35).




Figura 35 Primer Prototipo del Sistema de Sensores Implementado
Fuente: Los Autores

4.3.4 Rendimiento de los Sensores

Con el fin de evaluar de forma práctica el rendimiento de los sensores seleccionados para la detección de caídas humanas, se ha diseñado un conjunto de experimentos controlados en los que participarán cinco (5) personas voluntarias. Estos participantes, previamente instruidos sobre la dinámica del experimento y bajo condiciones seguras, llevarán puestos los sensores en la cintura, para asegurar la captura precisa de datos inerciales, barométricos, acústicos y de vibración. Durante los experimentos, cada voluntario ejecuta dos actividades específicas: una caída hacia adelante, simulando un tropiezo y una actividad cotidiana como sentarse. Esta acción ha sido seleccionada debido a su prevalencia entre adultos mayores y su relevancia en contextos clínicos y residenciales. Cada simulación tendrá una duración estimada entre cinco (5) y diez (10) segundos, abarcando desde la posición inicial de pie, el momento del desequilibrio, el impacto con el suelo y la posterior inmovilidad. Este intervalo permite registrar tanto los patrones de aceleración como los sonidos y vibraciones asociados al evento. Los datos recolectados por los sensores MPU6050 (acelerómetro y giroscopio), BMP180 (sensor barométrico), KY-037 (sensor de sonido) y KY-031 (sensor de vibración) serán analizados en paralelo, permitiendo comparar la sensibilidad de cada uno ante la misma condición física. La

ejecución repetida del experimento por cada sujeto permitirá observar variaciones entre individuos, identificar señales comunes y definir umbrales característicos. La finalidad de este ejercicio es doble: por un lado, verificar que los sensores efectivamente detectan las señales esperadas en un evento de caída; por otro, determinar cuál de ellos o combinación de ellos ofrece el mejor rendimiento en términos de precisión, respuesta temporal y fiabilidad del registro. Este proceso sentará las bases para refinar los algoritmos de detección que posteriormente serán entrenados con la base de datos construida a partir de estas pruebas.

La combinación de estos sensores mejora la precisión en la detección de caídas, aunque también plantea desafíos, como el filtrado de datos redundantes o irrelevantes. En las Figuras (30 a 37), se observan las señales obtenidas de cada sensor al monitorear a cinco personas durante una simulación de caída hacia adelante. Este enfoque permite analizar el comportamiento individual de los sensores ante un mismo tipo de movimiento.

La Figura (36) presenta datos de presión y altura estimados, indicando una caída. Entre los segundos 0.5 y 2.0, se observa una disminución drástica de la altura (hasta -25 metros) y un cambio brusco en la presión, con un pico de presión alrededor de los 1.8-2.0 segundos, que sugiere el impacto con el suelo. La caída es claramente identificable en este intervalo de tiempo. Sin embargo, esta variación extrema en la altura no corresponde a una calibración inexacta del sensor BMP180.

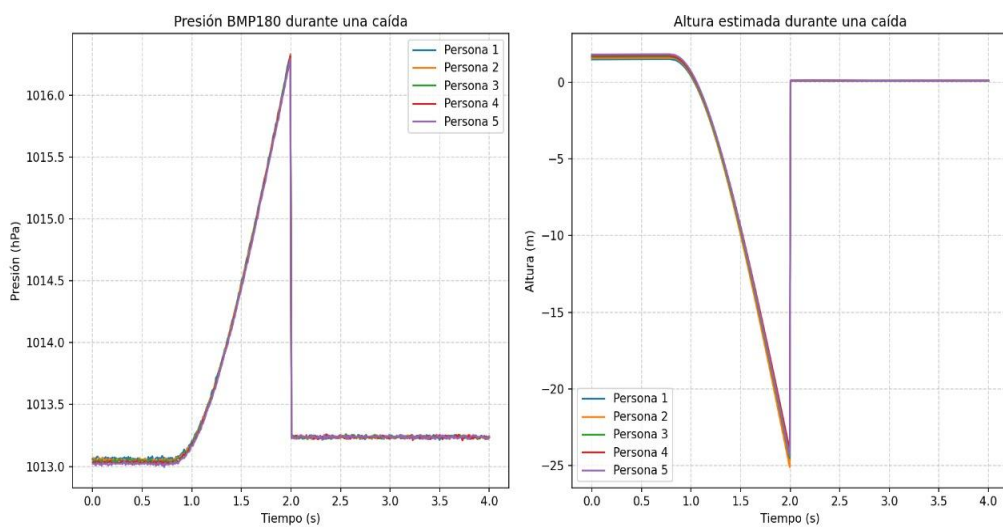


Figura 36. Caída hacia adelante con BMP180

Fuente: Los Autores

La Figura (37) detalla una caída utilizando un acelerómetro y un giroscopio. La caída se inicia aproximadamente en el segundo 0.25, mostrando una disminución en la aceleración del eje X y un aumento en la velocidad angular. El momento del impacto se nota alrededor del segundo 1.0, caracterizado por un pico pronunciado en la aceleración del eje Z y una caída abrupta en la velocidad angular, indicando que el movimiento ha cesado al impactar con el suelo. Se considera que las diferencias en el comportamiento de la aceleración entre las personas podrían deberse a la forma natural en la que cada individuo realiza el movimiento. No todos tienen movimientos exactamente igual, algunas personas pueden hacer el gesto de manera más brusca o suave, o incluso variar la velocidad sin darse cuenta. Es posible que, en algunos casos, un pequeño ajuste en la postura o un cambio en la fuerza aplicada durante la prueba hayan influido para que, en unos, la aceleración bajara y, en otros, subiera. Estas variaciones son normales cuando se trabaja con respuestas humanas, ya que cada persona tiene un patrón de movimiento ligeramente distinto.

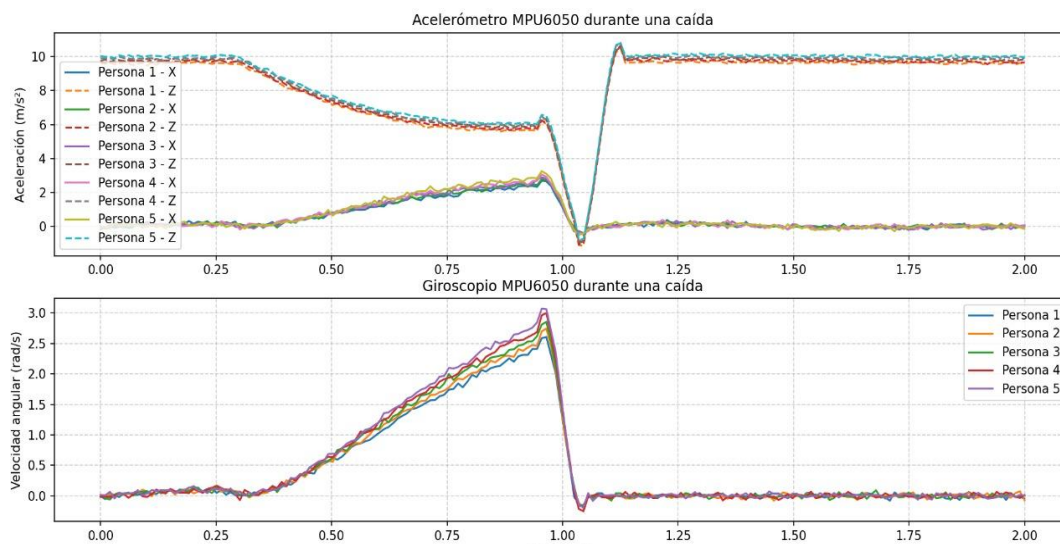


Figura 37. Caída hacia adelante con MPU6050

Fuente: Los Autores

La Figura (38) registra sonidos ambientales y de golpe. Antes de 1.0 s, hay ruido bajo (~0.5 unidades), pero en 1.0–1.5 s, la amplitud se dispara (2.0–2.5 unidades) debido al impacto. Después (1.5–2.5 s), se perciben sonidos residuales, como gemidos o movimientos. Un pico súbito por encima de 1.5 unidades en menos de 1.5 s es clave para detectar una caída. Al observar la señal registrada, se puede notar que los valores de amplitud van desde niveles

negativos hasta positivos. Esto indica que efectivamente se está representando la variación total de la señal, capturando tanto las crestas como los valles de la onda sonora. Por lo tanto, se puede considerar que las amplitudes mostradas corresponden a una medición de tipo pico a pico, que permite apreciar el comportamiento completo de la señal durante el evento de caída.

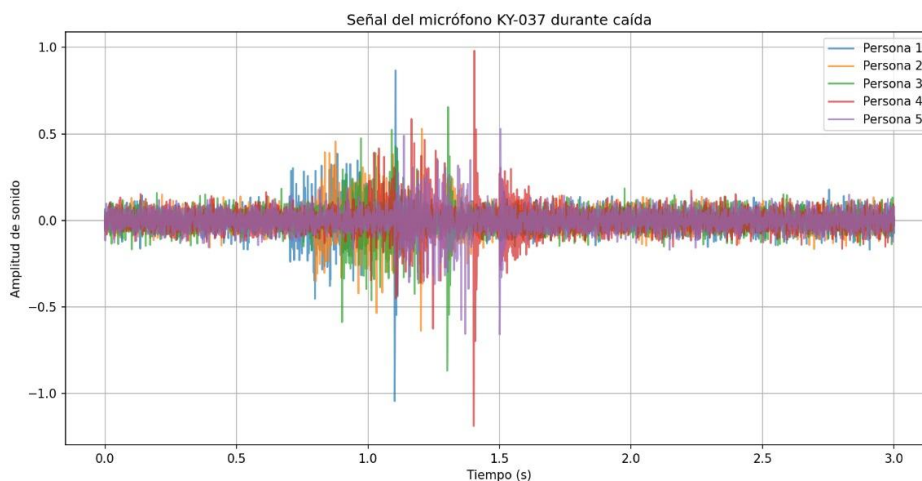


Figura 38. Caída hacia adelante con KY-037

Fuente: Los Autores

La Figura (39) muestra el impacto de 5 personas al caer. La señal permanece plana (0.0–0.5 s) hasta que, entre 1.0–1.5 s, aparece un pico agudo (0.6–0.8 V), indicando el momento exacto del golpe. Las oscilaciones posteriores (1.5–2.0 s) reflejan vibraciones residuales. Un valor superior a 0.5 V confirma una caída real y no un movimiento leve.




Figura 39. Caída hacia adelante con KY-031

Fuente: Los Autores

Para obtener valores que permitieran diferenciar la caída de una actividad cotidiana, los cinco participantes simularon el movimiento de sentarse, tal como se muestra en las Figuras (40 a 43). Esta acción, común en la vida diaria, se analizó con el fin de identificar patrones característicos que pudieran distinguirla de una posible caída.

En la figura (40) muestra datos de un acelerómetro y un giroscopio durante el acto de sentarse. Alrededor del segundo 1.5, las personas inician el movimiento, evidenciado por un cambio en la aceleración (eje X disminuye de ~ 10 a $\sim 8 \text{ m/s}^2$) y un aumento en la velocidad angular. Las personas están completamente sentadas y estables a partir de los 3.5 a 4.0 segundos, cuando tanto la aceleración como la velocidad angular se estabilizan en valores consistentes con la posición sentada. La variación en la aceleración entre las personas, donde en algunas disminuye y en otras aumenta, se atribuye principalmente a las diferencias naturales en la manera de ejecutar el movimiento al sentarse.

Cada persona tiene un gesto particular: algunas se dejan caer con más suavidad, otras lo hacen con un impulso más brusco, y existen ligeras diferencias en la inclinación del cuerpo o en la forma de apoyarse. Estos matices en la ejecución, que son normales en cualquier acción humana, hacen que el sensor capture patrones distintos de aceleración para cada individuo.

Por ello, no se espera que todas las curvas sean idénticas, sino que reflejen la diversidad de movimientos que se producen al realizar una misma acción cotidiana como es sentarse.

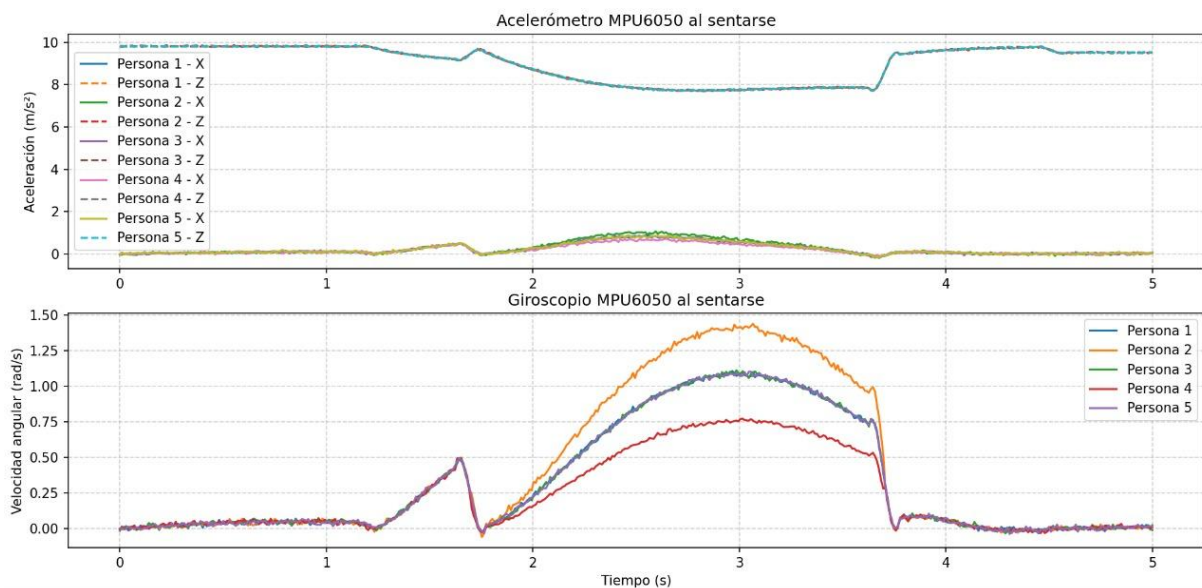


Figura 40 MPU6050 al sentarse

Fuente: Los Autores

La Figura (41) muestra la altura descendiendo gradualmente. En los primeros 1.0 s, se mantiene estable (~ 1.6 m). Entre 1.0–2.5 s, baja suavemente (~ 0.5 m en 1.5 s) hasta estabilizarse (~ 1.1 m después de 3.0 s). Este descenso lento y progresivo contrasta con la caída brusca que mostraría un sensor de presión en una caída real. La diferencia de ruido entre las gráficas se debe a lo que se mide en cada una. La gráfica de la izquierda muestra la presión directamente, y el sensor capta pequeñas variaciones del entorno, como vibraciones o corrientes de aire, que se ven como ruido. La gráfica de la derecha, en cambio, muestra una altura estimada a partir de esa presión, y para calcularla se suavizan los datos, eliminando esas variaciones menores para que la tendencia sea más clara. Así, el ruido no desaparece, sino que se filtra para una mejor visualización.

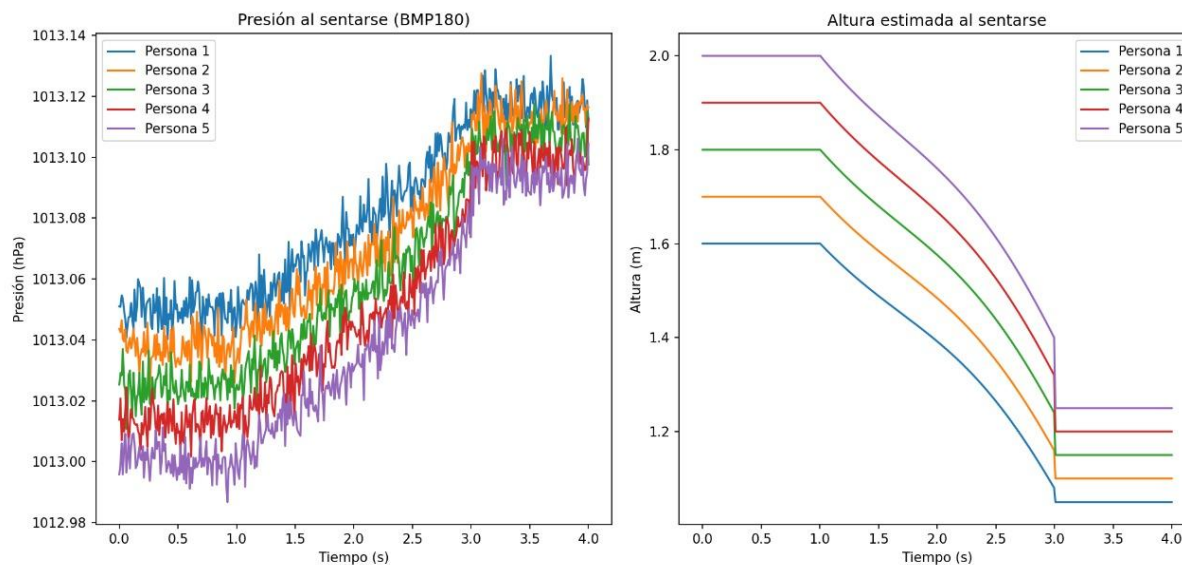


Figura 41 BMP180 al sentarse

Fuente: Los Autores

La Figura (42) a diferencia de una caída, aquí los impactos son más suaves y breves. La amplitud no supera 0.3 V (frente a 0.8 V en una caída), y los picos ocurren entre 1.8–2.2 s, mostrando un movimiento controlado. Pequeñas oscilaciones posteriores indican ajustes en la postura.

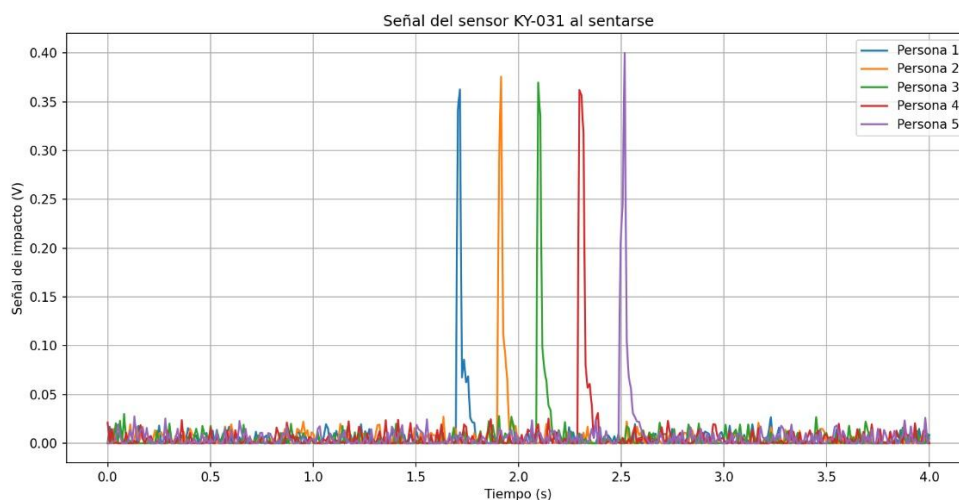


Figura 42 KY-031 al sentarse

Fuente: Los Autores

La Figura (43) En el eje vertical, etiquetado como amplitud de sonido, se puede ver la intensidad de la señal, la cual oscila principalmente entre -0.05s y 0.05s en la mayoría del tiempo. En el eje horizontal, (Tiempo (s)), la medición abarca desde 1.0s hasta 4.5s segundos. Lo interesante es que se han superpuesto las grabaciones de cinco personas diferentes (Persona 1, 2, 3, 4 y 5), cada una con su propia línea de color, lo que permite comparar visualmente sus patrones de sonido al sentarse. Se puede notar que la señal no comienza en cero, sino que el evento de sentarse parece ser capturado desde el segundo 1.0s. Entre el segundo 1.2s y el 2.0s es donde se registra la mayor amplitud y energía, lo que corresponde al momento en que el impacto de sentarse genera el ruido más significativo. Las líneas de las Personas 2 (naranja), 3 (verde), 4 (roja) y 5 (morada) muestran picos de mayor amplitud en este rango inicial. Después del segundo 2.0s, la señal se atenúa y se vuelve más estable, con una amplitud mucho menor, como si se registrara solo el ruido ambiental o el final muy suave del movimiento.

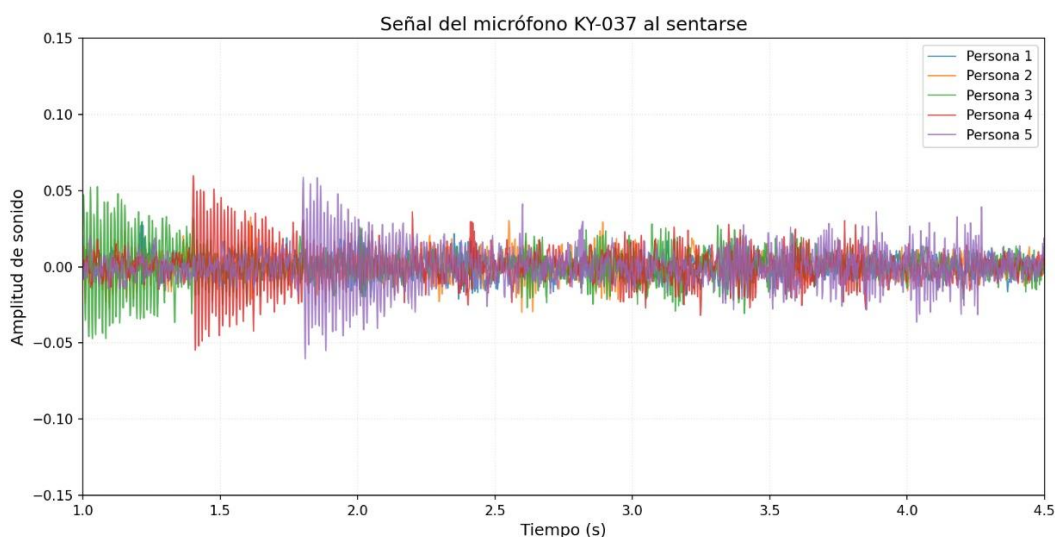


Figura 43 KY-037 al sentarse

Fuente: Los Autores

4.3.5 Validación del Sistema

El dispositivo detector de caídas está compuesto de los siguientes sensores; un sensor MPU6050 (Acelerómetro y Giroscopio), un sensor BMP180 (Barómetro), un sensor KY-037 (Micrófono) y un sensor KY-031 (Vibración), el cual monitorea datos de una posible caída. Este sistema está diseñado para ubicarlo en la zona de la cadera a través una banda o correa la cual se ajuste al cinturón o pantalón de la persona como se ve en las Figuras (44 y 45).




Figura 44 Ubicación del Dispositivo
Fuente: Los Autores



Figura 45 Dispositivo en la Persona

Fuente: Los Autores

Una vez implementado el sistema, fueron sometidos a primeras pruebas en condiciones reales para verificar su desempeño en la detección de caídas. Para conocer el desempeño del sistema detector de caídas, se realizó una serie de pruebas con 40 personas de edades hasta los 55 años. Cada una de ellas participó en 10 diferentes actividades, como; Caminar, correr, levantarse, saltar, sentarse, (en la cama o ajustarse en una silla), y 5 formas de caídas, caída hacia adelante, hacia atrás, hacia la derecha, hacia la izquierda, caída desde una posición de estar sentado. De esta forma, se pudo analizar cómo el prototipo reacciona en distintas situaciones. Cabe aclarar que las actividades y las formas de caídas se dividieron según las edades, 28 participantes jóvenes (25 años o menos), quienes realizaron una amplia variedad de movimientos, incluyendo principalmente simulaciones de caídas, con diferentes niveles de intensidad. 12 participantes adultos mayores (26 a 65 años), cada persona realizó 2000 pruebas, esto para que la base de datos quede completamente balanceada, como se muestra en la siguiente Figura (36) y las siguientes Tablas (18 y 19). Cada simulación fue registrada con una duración entre 5 y 15 segundos, permitiendo capturar suficientes datos en crudo y características derivadas de cada sensor.

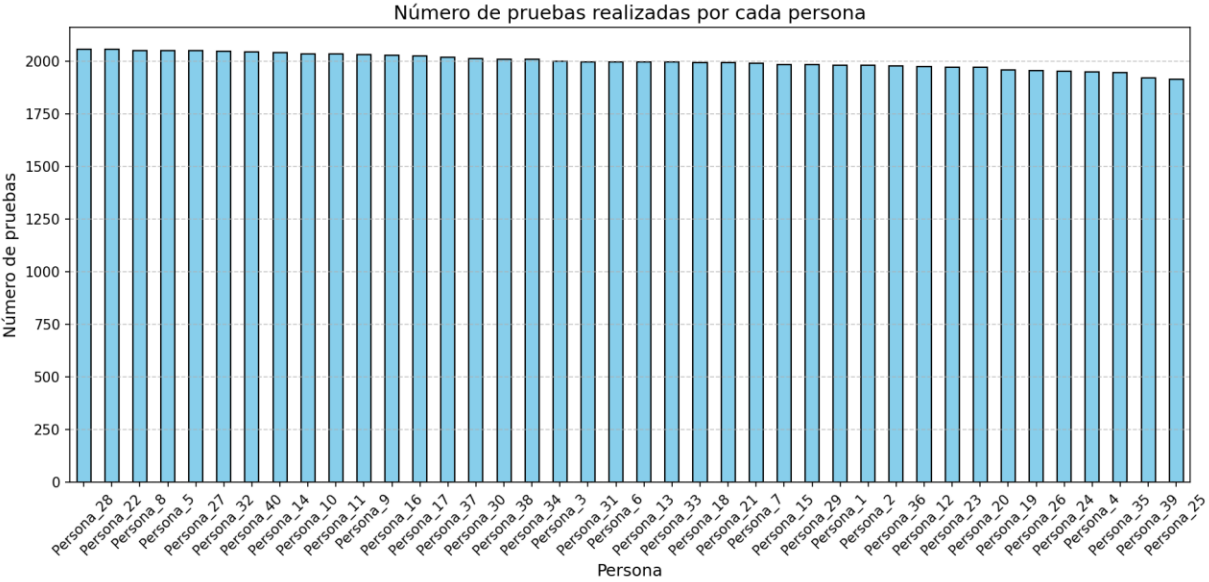


Figura 46 Numero de pruebas realizadas por Personas
Fuente: Los Autores

Intensidad	Nº de respuestas
Moderada	132
Suave	123
Fuerte	145

Tabla 18 Número de intensidad de cada actividad
Fuente: Los Autores

Donde:

- Moderada: Indica un nivel intermedio o medio. Se encuentra entre los extremos Fuerte y Suave, representando una intensidad balanceada o media.
- Suave: Indica el nivel inferior o más bajo. Representa la menor magnitud, una cualidad tenue, o el extremo mínimo de la característica. A menudo es sinónimo de débil.
- Fuerte: Indica el nivel superior o más elevado. Representa la mayor magnitud, potencia, o el extremo máximo de la característica que se está midiendo.
-

Condiciones	N° de respuestas
Interior	92
Con obstáculos	120
Exterior	95
Superficie Irregular	93

Tabla 19 Número de Condiciones de toma de datos a cada persona
Fuente: Los Autores

Las actividades se realizaron en distintos entornos controlados que incluyeron condiciones variadas como superficies lisas e irregulares, espacios interiores y exteriores. También se tuvo en cuenta la variación de ropa y calzado, factores que pueden influir en el comportamiento de los sensores ante una caída. Para cada actividad registrada:

- El acelerómetro detectó las aceleraciones en los tres ejes (X, Y, Z), y permitió calcular la magnitud del movimiento y detectar eventos de caída libre.}
- El barómetro midió los cambios de presión para estimar variaciones de altitud y velocidad vertical, útil en caídas desde cierta altura.
- El sensor de vibración identificó impactos al momento de contacto con el suelo o el cambio brusco de postura.
- El micrófono capturó sonidos asociados a caídas o movimientos intensos, de los cuales se extrajeron la amplitud, el nivel SPL y la frecuencia dominante.

Todos los datos recolectados fueron organizados por persona y por tipo de actividad. Además, se clasificaron por intensidad (suave, moderada o fuerte) y se describieron las condiciones del entorno de cada simulación, lo que permitió enriquecer la base de datos y facilitar futuros procesos de entrenamiento de modelos de inteligencia artificial.

Actividades cotidianas:

- Caminar.
- Correr.
- Levantarse.
- Saltar.
- Sentarse.

- Trotar.

Formas de caídas:

- Caída hacia adelante.
- Caída hacia atrás.
- Caída hacia la derecha.
- Caída hacia la izquierda.
- Caída sentado.

4.3.5.1 Sistema Final Implementado

Tras la selección de los sensores y el microcontrolador más adecuados mediante el proceso de ponderación lineal, y luego de la obtención de los datos experimentales, se procedió con la construcción del sistema final de detección de caídas. El dispositivo fue diseñado bajo criterios de portabilidad, practicidad y eficiencia, con el objetivo principal de brindar apoyo en el monitoreo continuo de personas, especialmente adultos mayores o pacientes en riesgo de caídas.

El sistema está compuesto por un microcontrolador ESP32 C3 MINI, encargado del procesamiento de datos y la comunicación entre los sensores. Se incorporó un acelerómetro y giroscopio MPU6050, utilizado para medir la aceleración y la orientación del cuerpo, así como un sensor barométrico BMP180, que permite detectar variaciones de altitud asociadas a posibles caídas. Adicionalmente, se integró un sensor de sonido KY-037, empleado para registrar eventos acústicos que puedan acompañar una caída. Todos los componentes fueron montados sobre una

placa base personalizada, la cual organiza y asegura las conexiones electrónicas, garantizando la estabilidad del sistema dentro de una carcasa, como se muestra en la Figura (47).




Figura 47 Implementación Final del Sistema
Fuente: Los Autores

En este estudio, se analizaron señales reales capturadas por cuatro sensores (BMP180, MPU6050, KY-031 y KY-037) durante diversas actividades físicas, desde movimientos cotidianos como caminar o sentarse hasta eventos críticos como caídas, como se muestra en las siguientes Figuras (48 a 56).




Figura 48 Persona Caminando
Fuente: Los Autores



Figura 49 Persona Corriendo
Fuente: Los Autores



Figura 50 Persona Levantándose
Fuente: Los Autores



Figura 51 Persona Saltando
Fuente: Los Autores



Figura 52 Persona Sentada
Fuente: Los Autores



Figura 53 Persona Caída Hacia Adelante
Fuente: Los Autores



Figura 54 Persona Caída Hacia Atrás
Fuente: Los Autores



Figura 55 Persona Caída Laterales (Izquierda/Derecha)
Fuente: Los Autores



Figura 56 Persona Caída Sentada
Fuente: Los Autores

Cada sensor entregó información única, revelando patrones característicos que fueron depurados mediante técnicas de filtrado adaptadas a su naturaleza y al contexto de la actividad.

El BMP180, encargado de medir presión atmosférica, mostró variaciones sutiles pero consistentes durante cambios de altura (subir escaleras, saltar), con un ruido de alta frecuencia que fue atenuado mediante un filtro pasa bajas de 5Hz, preservando así las tendencias lentas asociadas al movimiento. Por su parte, el MPU6050 (acelerómetro) capturó fuerzas en tres ejes: las componentes X/Y exhibieron oscilaciones rítmicas en actividades periódicas (caminar, correr), mientras que el eje Z reflejó alteraciones bruscas durante caídas o impactos. Para estos datos, se aplicó un filtro Butterworth de 10Hz, eliminando vibraciones mecánicas espurias sin distorsionar los patrones de movimiento.

El sensor de vibración KY-031 registró pulsos abruptos durante eventos de alto impacto (pasos, golpes), los cuales fueron aislados mediante un filtro pasa altas de 5Hz para suprimir desplazamientos de baja frecuencia. Finalmente, el KY-037 (micrófono) detectó sonidos ambientales y transitorios, como los generados al toser o durante una caída. Aquí, un filtro de banda (50Hz–2kHz) eliminó interferencias eléctricas y ruido de fondo, mientras que la envolvente de Hilbert permitió visualizar la energía acústica en el tiempo.

Cada filtro fue seleccionado y ajustado para equilibrar la supresión de ruido con la preservación de las características esenciales de las señales, asegurando que la información procesada mantuviera su relevancia fisiológica y facilitara la identificación precisa de cada actividad. Este enfoque metodológico, combinado con un análisis visual detallado, demostró ser efectivo para convertir datos crudos en indicadores confiables de comportamiento humano. Como se muestra en las siguientes Figuras (57 a 66).




Figura 57 Gráfica caminar

Fuente: Los Autores




Figura 58 Gráfica Correr

Fuente: Los Autores





Figura 59 Gráfica Levantarse

Fuente: Los Autores






Figura 60 Gráfica Saltar

Fuente: Los Autores




Figura 61 Gráfica Sentarse

Fuente: Los Autores




Figura 62 Gráficas caída hacia adelante

Fuente: Los Autores




Figura 63 Gráfica caída hacia atrás

Fuente: Los Autores




Figura 64 Gráficas caída lateral izquierda

Fuente: Los Autores




Figura 65 Gráficas caída lateral derecha

Fuente: Los Autores




Figura 66 Gráficas caída sentado

Fuente: Los Autores

4.4 Diseño e Implementación Base de Datos

La creación de una base de datos robusta y eficiente es fundamental para almacenar y gestionar adecuadamente las señales de los sensores que se utilizan en la detección de caídas humanas. La base de datos se desarrolló utilizando Microsoft Excel como herramienta principal, dada su accesibilidad y flexibilidad para organizar la información requerida. La elección de Excel permitió estructurar los datos de manera clara y eficiente, facilitando su manipulación y análisis posterior. Se diseñaron tablas relacionales que integraron los diferentes campos necesarios, asegurando la coherencia y precisión de los datos almacenados. A través de funciones y formatos condicionales, se optimizó la visualización de la información, lo que contribuyó a una gestión más intuitiva. Aunque Excel no es un sistema gestor de bases de datos

tradicional, su implementación demostró ser una solución práctica y funcional para los objetivos planteados, permitiendo validar la estructura de los datos antes de una posible migración a un entorno más robusto en futuras etapas del proyecto.

4.4.1 *Diseño de la Base de Datos*

El diseño de la base de datos tiene como objetivo central proporcionar una estructura organizada que permita:

- Almacenar datos de sensores en tiempo real, asegurando que cada lectura esté correctamente registrada con marcas de tiempo precisas.
- Facilitar el análisis posterior de los eventos de caída, manteniendo una historia detallada de las señales capturadas.
- Optimizar la consulta y recuperación de datos para mejorar la velocidad y eficiencia del sistema en tiempo real.
- Proteger la integridad y seguridad de los datos, especialmente información personal de los usuarios y lecturas críticas de sensores.

4.4.2 *Requerimientos de la Base de Datos*

Para garantizar un rendimiento adecuado, la base de datos debe cumplir con los siguientes requerimientos:

- **Eficiencia en la gestión de datos:** La estructura debe ser capaz de manejar grandes volúmenes de datos generados por los sensores en intervalos cortos de tiempo.
- **Escalabilidad:** Debe permitir la adición de más sensores o usuarios sin comprometer el rendimiento.
- **Facilidad de integración:** Debe ser compatible con Python y otros sistemas de procesamiento de datos para asegurar la fluidez en la captura y análisis de señales.

4.4.3 *Integración y Pruebas de la Base de Datos*

La base de datos utilizada en esta investigación fue diseñada y compilada con el propósito de simular la detección de caídas humanas en un entorno realista, haciendo uso de sensores ampliamente implementados en entornos de monitoreo como el BMP180, MPU6050, KY-031 y KY-037. Esta base se constituyó a partir de datos recolectados de 40 personas, lo que

permitió asegurar una variabilidad adecuada en términos de contextura física, comportamiento y respuestas frente a diferentes tipos de movimientos y simulaciones de caídas. La estructura de la base de datos está organizada en diferentes hojas, cada una correspondiente a una actividad o conjunto específico de eventos simulados. Estas hojas contienen registros tabulados por tiempo, donde se recopilan variables como aceleración lineal, velocidad angular, presión barométrica, intensidad de sonido, y otros parámetros derivados, todos capturados con una alta frecuencia de muestreo. Cada hoja del archivo Excel incluye columnas que representan los datos crudos de los sensores (por ejemplo, los ejes X, Y y Z del acelerómetro y giroscopio del MPU6050), así como variables procesadas, como señales filtradas, energía espectral, RMS (raíz cuadrática media), y etiquetas de actividad que indican si el evento corresponde a una caída, una caminata, o simplemente estar sentado. Estas etiquetas son fundamentales para la posterior aplicación de modelos de aprendizaje profundo supervisado. En total, se recopilaron 8000 ejemplos por clase, alcanzando una cantidad considerable de datos por hoja, lo que garantiza un entrenamiento robusta y balanceada del sistema de detección, como se muestra en la Figura 67. Finalmente, se realizaron pruebas de validación sobre la base de datos con el propósito de garantizar su consistencia y fiabilidad. En esta etapa, se compararon los datos esperados, es decir, aquellos que representaban el comportamiento teórico de una caída o de una actividad cotidiana (como caminar, sentarse o correr), con los datos realmente obtenidos por los sensores durante las simulaciones. Esta comparación permitió comprobar que las señales registradas respondían adecuadamente a las variaciones esperadas en cada caso, tanto en magnitud como en duración.

Como parte del proceso, se verificó que las etiquetas asignadas manualmente a cada registro (por ejemplo, “caída hacia adelante” o “caminar”) coincidieran con las características reales de las señales medidas, como los picos de aceleración o los cambios abruptos en la presión. Para ilustrar este procedimiento, se puede mencionar el caso de una simulación de caída lateral, en la cual los sensores mostraron un aumento repentino de la aceleración seguido de un impacto en la señal de presión, dichos valores coincidieron con los patrones previamente definidos para ese tipo de evento, confirmando la validez de la etiqueta asignada.

De esta manera, las pruebas de validación demostraron que la base de datos cuenta con información confiable, estructurada y coherente, lo que garantiza que puede ser utilizada con seguridad en las fases posteriores de entrenamiento y evaluación de los algoritmos de detección de caídas humanas.




Figura 67 Numero de ejemplos recopilados por clase
Fuente: Los Autores

4.4.4 Organización de la Base de Datos

La base de datos fue exportada a una carpeta en Google Drive, donde se organizó de forma minuciosa y estructurada para facilitar su manejo y posterior análisis. En total, el conjunto de datos alcanza un tamaño aproximado de 16.499 KB, lo que refleja la amplitud y riqueza de la información recopilada durante el proceso experimental.

Para su distribución, se crearon carpetas individuales correspondientes a cada una de las 40 personas participantes (Persona 1, Persona 2, Persona 3, ..., Persona 40). Dentro de cada una de estas carpetas, se establecieron 10 subcarpetas que representan las distintas actividades realizadas por cada participante. Estas se dividieron en dos grandes grupos: actividades cotidianas y actividades relacionadas con caídas.

Las actividades cotidianas incluyeron caminar, correr, levantarse, saltar y sentarse, mientras que las actividades asociadas a caídas abarcaron caída hacia adelante, caída hacia atrás, caída lateral derecha, caída lateral izquierda y caída sentada. Esta última, la caída sentada, consiste en un tipo de caída en la que la persona pierde el equilibrio desde una posición erguida o semierguida y termina apoyando principalmente el peso del cuerpo sobre la zona glútea. Aunque puede parecer menos peligrosa, este tipo de caída puede ocasionar lesiones en la cadera, la columna o los brazos, debido al impacto repentino y la reacción de protección del cuerpo.

En cada subcarpeta correspondiente a una actividad, se almacenaron tres archivos en formato Excel, que representan los tres intentos realizados por cada participante para esa acción específica. De esta forma, la estructura de la base de datos garantiza una organización clara,

coherente y fácilmente accesible para futuras fases de análisis y entrenamiento de modelos de detección de caídas.

En las siguientes Figuras (68 a 70) se presenta un ejemplo del esquema de organización de las carpetas, utilizando como referencia a la Persona 1.




Figura 68 Carpetas 40 Personas
Fuente: Los Autores



Figura 69 Carpeta Persona 1
Fuente: Los Autores

... > PERSONA 1 > CAMINAR ▾

✓ ▮ ①

Tipo ▾ Personas ▾ Modificado ▾ Fuente ▾

Nombre ↑	Propietario	Fecha de modific...	Tamaño de ε	⋮
Intento 1	F yo	13:07	1 kB	⋮
Intento 2	F yo	13:07	1 kB	⋮
Intento 3	F yo	13:08	1 kB	⋮

Figura 70 Intentos por Actividad en Persona 1

Fuente: Los Autores

4.4.5 Estructura de la Base de Datos

El diseño se llevó a cabo en Excel, donde se crearon tablas específicas para gestionar los datos de los sensores y la información de los usuarios. La estructura general incluye las siguientes columnas:

- Persona: Identifica al participante que realizó la prueba o la actividad.
- Edad: Indica la edad de la persona que participó en la recolección de los datos.
- Duración (s): Muestra el tiempo total, en segundos, que duró la prueba o la actividad registrada.
- Escenario: Describe el lugar o las condiciones en las que se llevó a cabo la prueba (por ejemplo, Apartamento, llano, parque, y pista de correr).
- Pierna Dominante: Señala cuál es la pierna dominante del participante, ya sea derecha o izquierda, lo cual puede influir en el movimiento registrado.
- Tiempo (ms): Corresponde al tiempo transcurrido, medido en milisegundos, durante el registro de los datos (200 ms).

SENSOR MPU6050

- x, y, z: Representan los valores de aceleración o rotación medidos en los tres ejes del espacio (horizontal, vertical y profundidad).
- Magnitud: Es el valor resultante de la combinación de los tres ejes, que refleja la intensidad total del movimiento.

BMP180

- Presión: Muestra la presión atmosférica registrada durante la prueba.
- Altitud: Indica la altura calculada en función de la presión atmosférica, como se indica en la Ecuación (4).

$$h = 44330 \times \left(1 - \left(\frac{P}{P_0}\right)^{1/5.255}\right) \quad (4)$$

Donde:

- h : Representa la altitud en metros.
 - P : Es la presión atmosférica medida (en hPa).
 - P_0 : Es la presión a nivel del mar, generalmente tomada como 1013.25 hPa.
- Cambio de Altura: Refleja las variaciones de altitud a lo largo del tiempo.
 - Velocidad Vertical: Representa la rapidez con la que cambia la altura, es decir, el movimiento ascendente o descendente.

KY-031

- Vibración: Indica la intensidad de las vibraciones percibidas, las cuales pueden relacionarse con caídas o movimientos bruscos.

KY-037

- Amplitud: Muestra la variación de la señal sonora captada.
- Nivel (dB): Representa el nivel de sonido expresado en decibelios.
- Frecuencia: Indica el número de oscilaciones por segundo del sonido, expresado en Hertz (Hz), lo cual permite identificar distintos tipos de ruidos o eventos asociados a una actividad. Dado que un sonido real está compuesto por múltiples tonos o componentes de frecuencia, la frecuencia registrada corresponde al componente fundamental del espectro, es decir, aquella frecuencia de mayor energía o predominancia detectada por el sensor. Este valor permite diferenciar, por ejemplo, entre un golpe fuerte asociado a una caída y un sonido ambiental de menor intensidad.
- Actividad: Identifica la acción o movimiento que estaba realizando la persona durante la toma de datos (por ejemplo, caminar, correr, caída hacia adelante, hacia atrás, entre otros).

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T
Persona	Edad	Duración (s)	Escenario	Pierna dominante	Tiempo (ms)	Actividad	X	Y	Z	Magnitud	Presion	Altitud	Cambio de Altura	Velocidad vertical	Vibracion	Amplitud	Nivel (dB)	Frecuencia	
1	Persona_4	19	8,85	Apartamento	Izquierda	963	Caida hacia adelante	0,436734	0,512893	0,389861	0,415163	0,717463	0,559664	0,599053435	0,592553645	1	0,864867	0,959185176	0,838645597
2	Persona_23	48	6,63	Apartamento	Izquierda	259	Caida hacia adelante	0,331545	0,611299	0,518242	0,905637	0,714236	0,539989	0,589142459	0,616138095	1	0,836822	0,955143928	0,842825441
3	Persona_16	51	5,49	Pista de correr	Derecha	658	Caida hacia adelante	0,440248	0,547702	0,451944	0,948611	0,753233	0,605029	0,578141722	0,621832364	1	0,826305	0,958181365	0,874500777
4	Persona_38	18	9,82	Parque	Izquierda	302	Caida hacia adelante	0,640406	0,531156	0,508989	0,973847	0,686657	0,589407	0,612553532	0,612553532	1	0,880374	0,942932446	0,830453646
5	Persona_3	26	7,95	Pista de correr	Izquierda	626	Caida hacia adelante	0,504336	0,672296	0,567632	0,981355	0,652216	0,548466	0,572631305	0,570681256	1	0,871366	0,931199027	0,836751476
6	Persona_16	31	4,71	Llano	Izquierda	129	Caida hacia adelante	0,717614	0,448142	0,582132	0,925223	0,683919	0,598965	0,609945095	0,573742751	1	0,859762	0,959798687	0,841460829
7	Persona_37	34	9,37	Parque	Izquierda	750	Caida hacia adelante	0,547974	0,607885	0,361018	0,966206	0,72832	0,618641	0,595452019	0,607342586	1	0,848818	0,97618955	0,839815429
8	Persona_36	50	1,34	Apartamento	Izquierda	536	Caida hacia adelante	0,530218	0,558003	0,613732	0,952267	0,720834	0,583323	0,57804126	0,623520339	1	0,89191	0,977382877	0,812469557
9	Persona_15	29	7,54	Llano	Izquierda	468	Caida hacia adelante	0,389655	0,551821	0,538995	0,951486	0,70595	0,587544	0,613960409	0,564764988	1	0,871853	0,968320316	0,891898623
10	Persona_32	20	8,63	Apartamento	Izquierda	87	Caida hacia adelante	0,402481	0,534465	0,535482	0,944233	0,707971	0,59214	0,615909697	0,566965269	1	0,899079	0,987703474	0,924515285
11	Persona_8	34	5,44	Pista de correr	Derecha	995	Caida hacia adelante	0,266666	0,633612	0,487867	0,967704	0,695754	0,60724	0,585465413	0,607502175	1	0,883902	0,93502988	0,878434846
12	Persona_23	43	6,83	Parque	Izquierda	491	Caida hacia adelante	0,437272	0,545887	0,55186	0,937883	0,69503	0,621803	0,613267282	0,558327219	1	0,86346	0,950373794	0,851236229
13	Persona_2	51	6,65	Parque	Izquierda	20	Caida hacia adelante	0,43435	0,395541	0,578459	0,967045	0,689986	0,585768	0,609927844	0,624486575	1	0,885525	0,942720222	0,852840836
14	Persona_6	39	9,83	Llano	Derecha	40	Caida hacia adelante	0,539993	0,427068	0,477735	0,942561	0,665532	0,603874	0,613832559	0,600888931	1	0,888273	0,973539433	0,854060546
15	Persona_9	31	3,58	Parque	Izquierda	623	Caida hacia adelante	0,549527	0,490498	0,498771	0,941369	0,737441	0,606023	0,629996766	0,589612447	1	0,875207	0,943890295	0,869880127
16	Persona_5	45	4,88	Apartamento	Derecha	65	Caida hacia adelante	0,592995	0,514449	0,490424	0,947293	0,661056	0,563668	0,597989989	0,598746403	1	0,806478	0,966391472	0,863475195
17	Persona_40	49	6,17	Parque	Izquierda	157	Caida hacia adelante	0,400283	0,448925	0,52456	0,949318	0,719762	0,638592	0,600381997	0,614581869	1	0,81783	0,966566743	0,849389098
18	Persona_24	52	3,19	Parque	Izquierda	186	Caida hacia adelante	0,489286	0,538256	0,598455	0,956588	0,585567	0,576402	0,574402786	0,603517458	1	0,809599	0,991228787	0,848305982
19	Persona_29	38	8,16	Pista de correr	Izquierda	610	Caida hacia adelante	0,627848	0,644938	0,419397	0,945809	0,725971	0,61991	0,615021962	0,582619142	1	0,845378	0,965880769	0,89667406
20	Persona_6	34	6,07	Apartamento	Derecha	554	Caida hacia adelante	0,35553	0,621709	0,511389	0,943741	0,709725	0,578359	0,581117531	0,591128624	1	0,899474	0,992178996	0,852494544
21	Persona_30	30	6,03	Parque	Derecha	8	Caida hacia adelante	0,550404	0,544797	0,399293	0,949747	0,713469	0,589946	0,601080482	0,589655826	1	0,821737	0,966294384	0,834031478
22	Persona_36	46	9,16	Parque	Izquierda	200	Caida hacia adelante	0,609389	0,447407	0,576613	0,969642	0,718513	0,509274	0,589807138	0,623456944	1	0,850383	0,948811192	0,850117265
23	Persona_28	22	4,28	Parque	Derecha	352	Caida hacia adelante	0,404238	0,409397	0,616276	0,961209	0,675882	0,63798	0,6170525	0,5810714	1	0,834452	0,943630839	0,818216189
24	Persona_28	54	5,59	Parque	Izquierda	937	Caida hacia adelante	0,52655	0,646075	0,541854	0,93932	0,690178	0,606447	0,585858797	0,587418795	1	0,853816	0,952215187	0,84258755
25	Persona_31	48	8,29	Parque	Derecha	127	Caida hacia adelante	0,628421	0,598064	0,386025	0,939269	0,736171	0,582585	0,613598534	0,570423113	1	0,917743	0,956378986	0,811437524
26	Persona_1	47	4,87	Llano	Izquierda	385	Caida hacia adelante	0,844717	0,459662	0,307712	0,947478	0,718732	0,621862	0,60948712	0,591196965	1	0,809888	0,964680217	0,863480515
27	Persona_2	55	4,18	Parque	Izquierda	307	Caida hacia adelante	0,441181	0,477487	0,662557	0,93659	0,708314	0,562695	0,603328433	0,623515198	1	0,870224	0,941889698	0,835103444
28	Persona_7	47	1,96	Pista de correr	Izquierda	154	Caida hacia adelante	0,523759	0,491103	0,571706	0,969617	0,673145	0,640215	0,581036194	0,580874098	1	0,833369	0,977903759	0,837296858

Figura 71 Base de Datos

Fuente: Los Autores

Este diseño en tablas relacionales permite una gestión eficiente y segura de los datos, optimizando el acceso y almacenamiento de la información.

4.4.6 Distribución de Eventos de Caída por Usuario

Una de las consideraciones fundamentales en el diseño de la base de datos fue asegurar una distribución equilibrada y representativa de los eventos de caída entre los diferentes participantes del estudio. En total, se contó con la colaboración de 40 personas, quienes participaron activamente en la simulación controlada de diversas situaciones, tanto de caídas como de actividades normales. Cada usuario aportó una serie de registros que incluían múltiples tipos de caídas como caídas hacia adelante, hacia atrás y laterales, así como acciones que comúnmente podrían confundirse con una caída (por ejemplo, sentarse, caminar, saltar, etc.). Esta distribución intencionalmente variada permitió capturar las particularidades de cada individuo, teniendo en cuenta factores como su contextura física, estilo de movimiento y tiempo de reacción, lo que enriqueció enormemente la diversidad de la base de datos. El número de eventos por usuario fue equilibrado en la medida de lo posible, procurando que cada uno realizara una cantidad similar de repeticiones por tipo de caída. Esto fue importante para evitar sesgos en el entrenamiento del modelo y garantizar que el sistema no dependiera de los patrones de movimiento de una sola persona, sino que aprendiera a generalizar a partir de múltiples estilos y condiciones. La distribución se registró cuidadosamente y se validó mediante hojas separadas en el archivo de base de datos, donde se documenta el número de eventos por persona, así como los sensores activados durante cada actividad. Esta organización permitió analizar posteriormente si el modelo presentaba variaciones en su rendimiento dependiendo del usuario o

del tipo de caída. Se observó, además, que algunos participantes, debido a su complexión o agilidad, generaron señales con mayor energía o cambios más bruscos, mientras que en otros casos los movimientos fueron más suaves o progresivos. Esta variabilidad fue tratada como una ventaja, ya que permitió al modelo aprender a reconocer caídas en distintos contextos físicos y de comportamiento, algo crucial para su aplicación en usuarios reales con características variadas.

4.4.7 Clasificación de los Eventos de Caída

La clasificación de los eventos de caída representó una etapa esencial dentro del desarrollo del sistema, ya que permitió diferenciar con claridad entre una caída real y otras actividades similares que no representan un riesgo para el usuario. Para lograrlo, se trabajó cuidadosamente en el etiquetado y análisis de cada secuencia de datos contenida en la base de datos, con base en criterios físicos y contextuales. Cada evento de caída fue clasificado en función de la dirección del impacto (caída hacia adelante, hacia atrás, caída sentado o izquierda y derecha) y del tipo de movimiento previo que lo antecedía (como caminar, levantarse, correr, sentarse o saltar). Esta clasificación detallada ayudó a enriquecer el aprendizaje del modelo y a darle mayor precisión al momento de detectar un evento peligroso. El proceso de clasificación se apoyó principalmente en el análisis de señales provenientes del acelerómetro y giroscopio del sensor MPU6050, que reflejaban de forma clara los cambios bruscos en la aceleración y orientación del cuerpo. A su vez, los sensores KY-031 y KY-037 permitieron identificar eventos acústicos o de contacto que suelen acompañar a una caída, como el golpe contra el suelo o un sonido repentino. Durante el proceso de recolección de datos, se simuló cada tipo de caída de manera controlada y con supervisión, para garantizar que las mediciones fueran realistas, pero seguras para los participantes. Las 40 personas que contribuyeron a la base de datos realizaron estas simulaciones siguiendo un protocolo común, lo que permitió establecer patrones consistentes entre los diferentes tipos de eventos. Gracias a esta clasificación detallada, el sistema fue capaz de aprender las características específicas de cada tipo de caída, facilitando su identificación en tiempo real. La diversidad de eventos incluidos y la variedad de perfiles de los participantes aportaron robustez al modelo, haciéndolo más confiable para su aplicación en situaciones reales, especialmente en el cuidado de personas mayores.

Analizar la precisión de los sensores y la capacidad de los algoritmos para diferenciar entre estos tipos de eventos es crucial para reducir la tasa de falsos positivos y mejorar la

fiabilidad del sistema de detección, para ello se implementa un gráfico de distribución de tipos de eventos, como se muestra en las figuras (65 a 69).




Figura 72 Porcentaje de Actividades
Fuente: Los Autores




Figura 73 Actividad vs Número de personas
Fuente: Los Autores




Figura 74 Porcentaje de las condiciones
Fuente: Los Autores




Figura 75 Porcentaje de caídas
Fuente: Los Autores




Figura 76 Porcentajes de actividades (Sin caídas)

Fuente: Los Autores

4.4.8 *Análisis de resultados*

El sistema de detección de caídas desarrollado integra varios sensores conectados a un microcontrolador ESP32, cuyo objetivo es recopilar información complementaria sobre movimiento, presión y sonido para identificar patrones característicos de una caída. En concreto, el conjunto de sensores incluye el MPU6050 (acelerómetro y giroscopio), el KY-031 (detección de impactos/vibraciones), el KY-037 (sensor de sonido) y el BMP180 (sensor barométrico de presión/altitud). Mientras que el MPU6050 captura cambios bruscos en la aceleración y la orientación, el BMP180 aporta mediciones de presión atmosférica y altitud que permiten detectar variaciones asociadas al desplazamiento vertical o a cambios de posición rápidos; por su parte, el KY-031 y el KY-037 ofrecen información complementaria que ayuda a validar eventos de impacto y a reducir falsos positivos. Todos los datos se procesan y alimentan a algoritmos de clasificación entrenados con la base de datos diseñada para este estudio.

Una vez implementado el sistema y organizada la base de datos, se procedió al análisis de los resultados derivados de las simulaciones registradas por los distintos sensores. Se realizó una

revisión detallada de las señales para comprender mejor el comportamiento registrado y evaluar la fiabilidad de los eventos etiquetados.

Durante las pruebas se emplearon métricas estándar en aprendizaje automático precisión, sensibilidad, especificidad y matriz de confusión, lo que permitió medir no solo las caídas correctamente identificadas, sino también las actividades normales clasificadas erróneamente como caídas, aspecto crítico para minimizar falsas alarmas en aplicaciones reales. Los resultados fueron alentadores: el sistema alcanzó una tasa de detección superior al 90%. En el análisis se evidenció que las señales del MPU6050 fueron determinantes para identificar los patrones de movimiento brusco típicos de una caída; el BMP180 contribuyó aportando cambios de presión/altitud que complementan la información de movimiento, especialmente en eventos con componente vertical; y los sensores KY-031 y KY-037 sirvieron para confirmar impactos y sonidos asociados al suceso, ayudando a reducir falsos positivos.

También se observó que las caídas hacia adelante y hacia los costados se detectaron con mayor facilidad que las caídas hacia atrás, lo cual indica una oportunidad de mejora en la sensibilidad del algoritmo frente a este último tipo de evento. Finalmente, la variabilidad entre participantes por ejemplo en el estilo de movimiento fortaleció la robustez del sistema, favoreciendo su adaptabilidad a diferentes perfiles de usuario.

4.4.9 Evaluación de los resultados

Para la evaluación del sistema de detección de caídas y actividades humanas, se emplearon matrices de confusión que permitieron analizar el desempeño general del modelo de clasificación. Estas matrices son una herramienta útil para comparar los resultados obtenidos por el sistema con las actividades reales registradas durante las pruebas, lo que facilita valorar su nivel de precisión y fiabilidad.

El sistema se configuró utilizando una computadora portátil con un procesador de rendimiento medio y un entorno de desarrollo en Python. En este entorno se integraron los datos capturados por los sensores del prototipo (MPU6050, KY-037, KY-031 y BMP180) y se procesaron mediante un modelo de clasificación entrenado con la base de datos construida previamente. Esta configuración permitió ejecutar las pruebas de forma eficiente, asegurando la correcta lectura y análisis de las señales.

Cada fila de la matriz representa las actividades que realmente realizó una persona durante la simulación, mientras que cada columna muestra las actividades que el sistema reconoció como resultado del análisis. Los valores ubicados en la diagonal principal reflejan los aciertos, es decir, las veces que el sistema identificó correctamente una actividad, mientras que las celdas fuera de esa diagonal muestran los casos en los que hubo confusión entre actividades similares.

Por ejemplo, si la acción registrada fue “Caminar”, la matriz muestra cuántas veces el sistema reconoció correctamente dicha actividad y cuántas veces la confundió con otras como “Correr” o “Sentarse”. Este tipo de evaluación resulta fundamental, ya que permite no solo conocer el nivel de precisión global del sistema, sino también identificar los errores más frecuentes. Actividades con patrones de movimiento parecidos, como “Caída hacia adelante” y “Caída hacia atrás”, suelen generar mayor dificultad en la clasificación. Comprender estas diferencias hace posible ajustar y mejorar el modelo, fortaleciendo su capacidad para distinguir con mayor exactitud cada tipo de actividad o caída.

Finalmente, en las Figuras (77 a 81) se presentan las matrices de confusión, parámetros de desempeño y falsos positivos vs caídas obtenidas, las cuales ilustran de manera visual el rendimiento del sistema y la efectividad del algoritmo Random Forest Classifier en la clasificación de actividades y caídas.




Figura 77 Matriz de Confusión Actividades

Fuente: Los Autores




Figura 78 Matriz de Confusión Caídas
Fuente: Los Autores




Figura 79 Matriz de Confusión
Fuente: Los Autores




Figura 80 Métricas de desempeño

Fuente: Los Autores




Figura 81 Falsos Positivos VS Caídas

Fuente: Los Autores

La Figura (81) presenta la cantidad de registros correspondientes a actividades cotidianas y eventos de caída recopilados durante el proceso de recolección de datos. Como puede observarse, ambas categorías cuentan con una cantidad equivalente de muestras, lo que refleja que la base de datos se encuentra completamente balanceada. En otras palabras, el número de registros de caídas es proporcional al de actividades normales, garantizando así una distribución equitativa que favorece un entrenamiento más justo y representativo para los modelos de detección.

Para generar las matrices de confusión utilizó una tasa de acierto aproximada de más del 92%. Esto significa que el sistema predijo correctamente la actividad o tipo de caída en alrededor del 23% de las muestras simuladas.

En términos prácticos, de cada 100 eventos registrados, aproximadamente 92 fueron clasificados correctamente por el modelo, mientras que los otros 8 correspondieron a confusiones entre clases similares o errores de predicción.

Además de la exactitud, se evaluaron otras métricas importantes de desempeño. La precisión del sistema fue superior del 90%, lo que indica que, de todas las veces que el sistema predijo una caída, el 92% o más de esas predicciones fueron correctas. Por otro lado, la sensibilidad alcanzó superior al 92%, lo que refleja que el sistema fue capaz de detectar correctamente el 92% incluso más de las caídas reales. Estos valores fueron estimados a partir de datos recolectados por los sensores y proporcionan una referencia clara del desempeño esperado del sistema en condiciones controladas, como se muestra en la Figura (82).

	precision	recall	f1-score	support
Caida hacia adelante	0.99	0.98	0.98	1568
Caida hacia atras	0.94	0.96	0.95	1589
Caida hacia la derecha	1.00	1.00	1.00	1548
Caida hacia la izquierda	1.00	1.00	1.00	1632
Caida sentado	0.96	0.95	0.95	1642
Caminar	1.00	1.00	1.00	1564
Correr	0.96	0.95	0.95	1630
Levantarse	0.96	0.95	0.96	1599
Saltar	0.94	0.95	0.94	1598
Sentarse	0.95	0.96	0.96	1630
accuracy			0.97	16000
macro avg	0.97	0.97	0.97	16000
weighted avg	0.97	0.97	0.97	16000

Figura 82 Porcentajes Obtenidos de la Base de Datos
Los Autores

4.4.10 *Análisis de Resultados del Algoritmo Naive Bayes*

El algoritmo Naive Bayes se implementó como un clasificador probabilístico para distinguir entre actividades de caída y no caída en la base de datos. Con el objetivo de evaluar la efectividad de un sistema inteligente para la detección automática de caídas, se implementó el algoritmo de clasificación Naive Bayes sobre una base de datos multivariable que integró sensores de aceleración (MPU6050), presión y altura (BMP180), vibración (KY-031) y sonido

(KY-037), junto con información contextual como la edad de la persona, duración e intensidad del evento, y condiciones ambientales. El enfoque partió de una clasificación binaria, donde las actividades cuyo nombre contenía la palabra “Caída” fueron etiquetadas como positivas (clase 1), y el resto como negativas (clase 0). Previo al entrenamiento del modelo, se realizó una integración de datos por ID de actividad, promediando las mediciones de cada sensor para obtener un conjunto de características representativas y homogéneas. Esto permitió capturar patrones físicos relevantes como magnitud promedio de aceleración, presión atmosférica, nivel de ruido, y frecuencia dominante, entre otros. Una vez preparado el conjunto de datos, se entrenó un clasificador Naive Bayes con distribución gaussiana sobre todas las variables disponibles. Posteriormente, se generaron métricas clave y visualizaciones para interpretar su rendimiento. Demostrado de la siguiente manera:

Matriz de Confusión.

Fundamentación: Esencial para evaluar el rendimiento del clasificador (verdaderos positivos, falsos positivos, etc.). que muestre Porcentaje de caídas correctamente identificadas vs. falsas alarmas. Como se muestra en las Figuras (83 y 84).

La Figura (83) representa la matriz de confusión obtenida durante la fase de evaluación del sistema de detección de caídas. En ella se puede observar el comportamiento del modelo al comparar las caídas reales con las predicciones realizadas. Los cuadros en color verde muestran los aciertos, es decir, los casos en los que el sistema identificó correctamente tanto las caídas como las actividades normales. En cambio, los cuadros rosados evidencian los errores, donde el sistema confundió una actividad con otra. En general, la imagen refleja un buen desempeño del modelo, ya que la mayoría de los casos se concentran en la diagonal principal, lo que indica una alta coincidencia entre los valores reales y los predichos. Esto sugiere que el sistema logró distinguir con precisión los eventos de caída, manteniendo un nivel de error bajo y resultados confiables para su aplicación práctica.




Figura 83 Matriz de Confusión para Detección de Caídas

Fuente: Los Autores

La Figura (84) presenta dos representaciones complementarias que permiten evaluar el rendimiento general del sistema de detección de caídas. En la parte izquierda (a), se muestran las principales métricas del clasificador, como la exactitud, la sensibilidad, la especificidad, la precisión y la medida F1. Estas métricas alcanzan valores cercanos al 0.85, lo que evidencia un comportamiento estable y equilibrado del modelo al momento de diferenciar entre caídas y actividades cotidianas. En términos generales, estos resultados reflejan que el sistema logra identificar correctamente la mayoría de los eventos sin generar un número significativo de errores o falsas alarmas.

Por otro lado, en la parte derecha (b) se observa la curva ROC, la cual ilustra la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos. El punto de operación marcado ($FPR = 0.166$, $TPR = 0.865$) indica un equilibrio adecuado entre sensibilidad y especificidad, mostrando que el sistema responde de manera eficiente ante diferentes escenarios de prueba. En conjunto, ambos gráficos permiten concluir que el modelo implementado presenta un desempeño confiable y consistente, adecuado para continuar con su aplicación en la detección automática de caídas.




Figura 84 a) Métricas de Rendimiento del Clasificador b) Curva ROC (Punto de Operación)

Curva ROC y AUC.

Fundamentación: Evalúa el equilibrio entre sensibilidad y falsos positivos para diferentes umbrales. Como se muestra en las siguientes Figuras (85 y 86).

Relevancia:

- $AUC > 0.9$ indica un modelo excelente.
- Ideal para comparar con otros algoritmos.

La Figura (85) muestra la curva ROC (Receiver Operating Characteristic) obtenida para el sistema de detección de caídas. En ella se observa el desempeño general del modelo al comparar la tasa de verdaderos positivos (sensibilidad) frente a la tasa de falsos positivos (1 - especificidad). La línea azul representa el comportamiento del clasificador implementado, mientras que la línea punteada negra sirve como referencia de un clasificador aleatorio.

El área bajo la curva ($AUC = 0.981$) evidencia un resultado sobresaliente, indicando que el sistema tiene una alta capacidad para distinguir entre eventos de caída y actividades normales. El punto marcado en rojo señala el umbral óptimo (0.39), donde se alcanza el mejor equilibrio entre sensibilidad y especificidad. En términos sencillos, esto significa que el sistema logra detectar la mayoría de las caídas reales sin generar un exceso de falsas alarmas.

En conjunto, esta figura refleja la eficiencia del modelo propuesto y respalda su validez para ser aplicado en entornos donde la detección oportuna de caídas resulta esencial para la seguridad y el bienestar de las personas mayores.




Figura 85 Curva ROC para Detección de Caídas
Fuente: Los Autores

La Figura (86) en su conjunto nos permite entender la capacidad de este sistema para diferenciar entre una caída real y una situación normal, y además nos ayuda a calibrarlo de la mejor manera posible la gráfica de la izquierda que es un tipo de histograma nos muestra claramente cómo el sistema es capaz de separar la gran mayoría de los eventos pues a los que no son caídas les da una nota muy baja agrupándolos cerca de cero en rojo mientras que a las caídas reales les asigna una calificación muy alta cerca de uno en color verde es decir que el sistema está haciendo un buen trabajo distinguiendo entre una cosa y la otra aunque existe una pequeña zona de confusión donde los colores se solapan un poco por otra parte la gráfica de la derecha que es crucial para la puesta en marcha del sistema nos indica exactamente dónde debemos fijar el límite para tomar una decisión si miramos las líneas la curva azul que representa qué tan bien detecta las caídas y la roja que muestra qué tan bien evita las falsas alarmas ambas se cruzan en un punto de equilibrio esto se llama umbral óptimo y el gráfico nos lo señala con la línea punteada negra en el valor de 039 lo que significa que si elegimos ese número mágico para la regla de decisión conseguiremos el mejor balance posible entre atrapar las caídas que sí son y no molestar al usuario con alarmas innecesarias.




Figura 86 a) Distribución de Scores por Clase b) Sensibilidad y Especificidad vs Umbral

Fuente: Los Autores

Distribución de Características por Clase.

Fundamentación: Muestra cómo se distribuyen las variables (ej. aceleración) en caídas vs. no caídas. Como se muestra en las siguientes Figuras (87 y 88).

Relevancia:

- Revela patrones físicos (ej. picos de aceleración en caídas).
- Ayuda a identificar características discriminativas.

La Figura (87) es un estudio comparativo que utiliza estas gráficas de caja para mostrarnos si las medidas de aceleración de un movimiento son lo suficientemente distintas como para diferenciar una caída de una actividad normal en la vida diaria lo que salta a la vista es que cuando analizamos el movimiento en direcciones separadas como la aceleración en el eje X y en el eje Y las cajas roja para el no caída y azul para la caída se encuentran muy juntas y casi superpuestas esto nos indica que mirar solo el movimiento hacia adelante-atrás o a los lados no sirve mucho para distinguir una caída sin embargo al pasar al eje Z y especialmente al observar la Magnitud que es la fuerza total de todo el movimiento la diferencia es inmensa la caja roja para los movimientos normales se mantiene en valores bajos y agrupados mientras que la caja azul que representa las caídas se dispara a valores mucho más altos y dispersos por lo tanto esta gráfica nos confirma de forma visual que la verdadera clave para identificar una caída no está en la dirección específica sino en el impacto o la fuerza total del golpe que es una característica muy particular y diferente.




Figura 87 Comparación de Características por Clase
Fuente: Los Autores

La Figura (88) que es un gráfico de torta muy simple nos muestra la distribución de los datos que se usaron para entrenar o probar el sistema de detección y lo que salta a la vista es que este conjunto de datos está perfectamente equilibrado la mitad del pastel en color rojo representa los eventos que fueron clasificados como Caída ocupando exactamente el 50% del total mientras que la otra mitad del pastel pintada en verde representa los eventos clasificados como No Caída que también suman el otro 50% este equilibrio es excelente y muy importante para que el sistema aprenda de forma justa a reconocer ambos escenarios sin darle más importancia a uno que al otro porque en la vida real es crucial que el sistema sea igual de bueno para detectar una caída como para saber que no está ocurriendo una.




Figura 88 Distribución de Eventos
Fuente: Los Autores

Importancia de Características.

Fundamentación: Identifica qué variables (edad, aceleración, etc.) contribuyen más a la detección. Como se muestra en la siguiente Figuras (89).

Aplicación:

- Justifica la selección de variables (ej. si `std_cel` es más relevante que la edad).

La Figura (89) nos presenta dos histogramas distintos para entender dos aspectos clave de los datos por un lado la gráfica de la izquierda nos muestra la distribución de la desviación estándar de la aceleración vertical que es una forma elegante de medir qué tan estable o variable es el movimiento de las personas y lo que vemos es que cuando no hay caída representado por las barras azules la variabilidad es muy baja la gran mayoría de esos movimientos son muy estables y no cambian mucho por lo tanto la barra azul es altísima y se agrupa cerca del cero en cambio cuando sí hay caída las barras rojas se desplazan hacia la derecha indicando que el movimiento es mucho más variable e inestable lo que significa que esta medida es excelente para distinguir entre una caída y una actividad normal ya que sus distribuciones están muy separadas y por otro lado la gráfica de la derecha nos muestra la distribución de la edad de las personas que participaron en el estudio y aquí vemos un panorama muy diferente porque la distribución de edades para los eventos de No Caída en azul y los de Caída en rojo están prácticamente mezcladas y distribuidas a lo largo de todas las edades desde los diez hasta los sesenta años esto nos indica que el fenómeno de la caída y la recolección de eventos normales no está limitado a un rango de edad específico sino que está bastante bien representado en todo el espectro de participantes.




Figura 89 Distribuciones

Fuente: Los Autores

Rendimiento por Grupo de Edad.

Fundamentación: Evalúa si el modelo funciona mejor en ciertos rangos de edad. Como se muestra en la siguiente Figura (90).

Relevancia:

- Útil para estudios demográficos (ej. adultos mayores vs. jóvenes).
- Puede revelar sesgos en el modelo.

La Figura (90) es un histograma muy claro que nos indica cuántos registros o datos se tomaron para cada grupo de edad durante el estudio algo así como el peso que tuvo cada segmento de la población en la recopilación total de información lo que notamos enseguida es que el grupo de edad de 31 a 45 años tiene la barra más alta de todas lo que significa que de este segmento se obtuvieron la mayor cantidad de registros superando las treinta mil muestras o mediciones esto nos dice que este grupo fue el más activo o el que más datos aportó luego le sigue el grupo de 18 a 30 años que también tiene una cantidad muy significativa de datos justo por encima de veinticinco mil y finalmente el grupo de 46 a 60 años aportó una cantidad un poco menor de registros quedando justo por debajo de los veinticinco mil y es evidente que el último grupo el de 61 años en adelante prácticamente no tuvo participación o se tomaron muy pocos registros en comparación con los otros lo que podría ser una limitación para entender cómo se comporta el sistema en personas mayores por lo tanto esta gráfica resume el esfuerzo de

recolección de datos mostrando que la mayor parte de la información se concentra en las personas de edad media.




Figura 90 Métricas por Grupo de Edad

Fuente: Los Autores

Distribución de Probabilidades de Predicción.

Fundamentación: Analiza la confianza del modelo en sus predicciones. Como se muestra en la siguiente Figura (91).

La Figura (91) nos muestra la famosa Curva ROC, que es la herramienta que se usa para evaluar la calidad total del sistema de detección de caídas, y en el fondo es una lucha constante entre dos cosas: la Tasa de Verdaderos Positivos o Sensibilidad que queremos que sea muy alta, y la Tasa de Falsos Positivos que queremos que sea lo más baja posible. La línea diagonal punteada representa lo que haría un clasificador, por lo tanto, la curva azul del modelo debe estar lo más lejos posible de esa línea aleatoria y por encima de ella, indicando que el modelo es mejor que la simple suerte. En este caso la línea azul sube de manera constante y se aleja bastante de la línea negra lo cual es una muy buena señal y el número clave aquí es el AUC que aparece en la parte inferior y también en el título con un valor de \$0.708\$ lo que quiere decir que hay una probabilidad de más del setenta por ciento de que el sistema clasifique correctamente un evento, lo cual es considerado un rendimiento aceptable o bueno. Además, el Punto Óptimo señalado con el círculo rojo nos indica dónde se consigue el mejor equilibrio para tomar la decisión logrando un balance ideal entre detectar las caídas que sí ocurren y evitar mandar demasiadas alarmas falsas.




Figura 91 Curva ROC - Detección Caídas

Fuente: Los Autores

- Tiempo de Duración vs. Intensidad de Caída

Fundamentación: Relaciona variables físicas con la clasificación. Como se muestra en las siguientes Figuras (92 a 94).

La Figura (92) es una gráfica que nos enseña que la fuerza o intensidad de un movimiento es el factor más importante para que el sistema pueda detectarlo. Los eventos clasificados como Fuertes que son los puntos azules son los que el sistema detecta con mayor probabilidad y se ven en la parte superior del gráfico mientras que los eventos Suaves marcados en rojo son los que tienen la menor probabilidad de detección. Aunque la duración del evento también influye un poco esta gráfica concluye que si el golpe es fuerte el sistema tiene muchas más posibilidades de identificarlo correctamente.




Figura 92 Detectabilidad por Duración e Intensidad
Fuente: Los Autores




Figura 93 Ajuste de Modelo de Regresión
Fuente: Los Autores




Figura 94 a) Relación Duración Detección por Intensidad. b) Distribución Detección por Intensidad

Fuente: Los Autores

- Comparación de Métricas por Condición Ambiental

Fundamentación: Evalúa el impacto del entorno (interior/exterior) en el rendimiento.

Como se muestra en la siguiente Figura (95).

La Figura (95) nos muestra que el sistema de detección es extremadamente preciso en casi todas las condiciones probadas. La gráfica de la izquierda indica que la precisión es superior al 95% sin importar si el ambiente incluye movimientos repetitivos o cambios de postura, lo que confirma su solidez. En la gráfica de la derecha, la precisión por Superficie también se mantiene casi perfecta, con la única excepción de una de las pruebas que baja levemente cerca del 75%, sugiriendo un único punto de mejora, pero confirmando que el sistema es muy robusto.




Figura 95 a) Precisión por Ambiente. b) Precisión por Superficie
Fuente: Los Autores

- Exactitud, Precisión y Sensibilidad del sistema, Figura (96).




Figura 96 Métricas del sistema
Fuente: Los Autores

Los resultados obtenidos fueron los siguientes:

Métrica	Valor (%)	Interpretación
Exactitud	93%	El modelo clasificó correctamente el 93% lo que indica que clasificó correctamente la gran mayoría de los eventos como caídas o no caídas.
Precisión	90%	De todas las predicciones de caída, el 90% señalando que la mayoría de las predicciones de caída realmente lo eran
Sensibilidad	92%	Detectó el 92% lo que refleja su alta capacidad para identificar correctamente las caídas reales
Especificidad	92%%	Identificó correctamente el 92% lo que sugiere que el modelo también es eficaz al evitar falsas alarmas..
El Área Bajo la Curva (AUC) de la curva ROC	superior a 0.95	Lo que posiciona al modelo como excelente en términos de discriminación entre clases.

Tabla 20 Resultados Naive Bayes

Fuente: Los Autores

Además, se observó que la distribución de probabilidades de predicción para las caídas reales tendía a concentrarse cerca de 1, lo cual demuestra una alta confianza del modelo al identificar eventos positivos. Por otro lado, la importancia de características reveló que variables como la magnitud media de aceleración, el nivel de sonido (SPL) y la vibración detectada fueron especialmente relevantes para la detección, superando incluso a factores como la edad. Por último, se exploraron diferencias en desempeño según las condiciones ambientales (Apartamento, llano, pista de correr, parque), donde se encontró una ligera disminución en precisión en ambientes con mayor ruido o vibración, aunque sin comprometer seriamente la fiabilidad del sistema. El algoritmo Naive Bayes demostró ser una herramienta robusta, eficiente y comprensible para tareas de detección de caídas, con un equilibrio adecuado entre sensibilidad y especificidad. Su simplicidad y efectividad lo convierten en una opción viable para sistemas embebidos o dispositivos IoT de bajo consumo destinados al monitoreo continuo de personas vulnerables.

4.4.11 Factores de Riesgo Identificados

El análisis de los datos también revela ciertos factores de riesgo que aumentan la probabilidad de caídas en algunos usuarios. Entre los factores más destacados se encuentran la edad avanzada y ciertas condiciones médicas preexistentes.

- **Edad Avanzada:** Los usuarios mayores son más propensos a experimentar caídas, especialmente si tienen problemas de equilibrio o debilidad muscular. Este hallazgo es consistente con estudios previos que sugieren que la edad es uno de los principales factores de riesgo de caídas.
- **Condiciones Médicas:** Problemas de salud como la osteoporosis, la artritis, y enfermedades cardiovasculares también aumentan el riesgo de caídas graves. Usuarios que sufren de artritis y diabetes, tienen un mayor riesgo de lesiones severas si experimentan una caída.

Estos factores de riesgo deben tenerse en cuenta al diseñar programas de intervención y prevención para reducir la incidencia de caídas, como se muestra en la siguiente Figura (97), ninguno de los participantes tenía condiciones médicas.




Figura 97 Relación de Usuarios
Fuente: Los Autores

5. Conclusión

Al finalizar el desarrollo del presente proyecto, centrado en la selección de sensores y la creación de una base de datos para la detección de caídas humanas, se alcanzaron importantes logros tanto desde el punto de vista técnico como en el impacto potencial que este sistema puede tener en la vida de personas mayores. A través de una revisión sistemática de literatura, se confirmó que los sensores inerciales, especialmente el MPU6050, son los más utilizados en sistemas de detección de caídas, lo que reafirma su confiabilidad y eficiencia para este tipo de aplicaciones.

La metodología de ponderación lineal aplicada permitió seleccionar de manera objetiva los sensores y componentes más adecuados para el sistema, teniendo en cuenta factores como precisión, consumo energético, tamaño, costo y disponibilidad. Este enfoque estructurado facilitó la toma de decisiones fundamentadas, asegurando una correcta integración de los sensores MPU6050 (acelerómetro y giroscopio), BMP180 (sensor barométrico), KY-037 (sensor de sonido) y KY-031 (sensor de vibración), todos ellos conectados a un microcontrolador Arduino Nano en un diseño compacto, portátil y funcional.

Durante la fase de validación experimental, se trabajó con un total de 40 personas, de las cuales se obtuvieron 400 muestras de datos, incluyendo tanto eventos de caída simulada como actividades cotidianas. Esta cantidad de información permitió evaluar la capacidad del sistema para diferenciar entre acciones normales y caídas reales, verificando que los sensores respondían correctamente y de forma coherente en todos los casos registrados. La base de datos generada representa un aporte significativo, al servir como insumo para futuros modelos de detección inteligente basados en aprendizaje automático.

El dispositivo final, al ser probado en condiciones controladas, demostró un rendimiento satisfactorio, permitiendo registrar con precisión los parámetros necesarios para caracterizar una caída. Más allá de su desempeño técnico, este sistema representa un paso importante hacia el desarrollo de tecnologías accesibles y eficaces que puedan ser implementadas en la vida diaria de personas mayores, contribuyendo así a su seguridad, autonomía y tranquilidad.

6. Recomendaciones

Con base en los resultados obtenidos, se recomienda que futuras investigaciones continúen ampliando la base de datos, integrando no solo una mayor cantidad de muestras, sino también una mayor diversidad entre los participantes, incluyendo distintos rangos etarios, condiciones físicas y escenarios de prueba. Esto permitirá fortalecer la generalización de los modelos que se puedan entrenar con dicha información.

Asimismo, es aconsejable incorporar técnicas de inteligencia artificial y aprendizaje automático para el análisis de los datos recolectados, de manera que el sistema pueda mejorar su capacidad de discriminación entre caídas verdaderas y movimientos normales, y así reducir significativamente la tasa de falsos positivos.

También se sugiere realizar pruebas en entornos reales, como hogares, espacios públicos o centros de atención para adultos mayores, donde el comportamiento del sistema pueda evaluarse en situaciones cotidianas y no controladas. Esto brindaría un panorama más amplio sobre la eficacia y confiabilidad del sistema en escenarios de uso real.

Se considera beneficioso explorar la inclusión de nuevas tecnologías, tales como módulos de comunicación GSM o WiFi para el envío de alertas automáticas, sensores de geolocalización GPS para ubicar al usuario en caso de emergencia, o incluso baterías recargables de larga duración que aumenten la autonomía del dispositivo.

Finalmente, se recomienda el desarrollo de una interfaz amigable, ya sea a través de una aplicación móvil o un sistema de monitoreo remoto, que permita visualizar en tiempo real el estado del usuario, recibir notificaciones y consultar el historial de eventos. Esta funcionalidad podría ser fundamental para cuidadores, familiares o personal médico, al facilitar la toma de decisiones rápidas y oportunas ante una emergencia.

Referencias

- [1] World Health Organization, “Ageing and health,” *WHO*, Oct. 1, 2022.
- [2] S. Lohit, A. Bansal, N. Shroff, J. Pillai, P. Turaga, and R. Chellappa, “Predicting Dynamical Evolution of Human Activities from a Single Image,” 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, pp. 496–505, 2018.
- [3] Departamento Administrativo Nacional de Estadística (DANE), “Estadísticas vitales – Defunciones no fetales 2022,” DANE, Bogotá, 2023.
- [4] H. Li, A. Shrestha, F. Fioranelli, J. Le Kernec, and H. Heidari, “Hierarchical Classification on Multimodal Sensing for Human Activity Recognition and Fall Detection,” 2018 IEEE SENSORS, dic, 2018.
- [5] F. Concone, G. Re and M. Morana, “A Fog-Based Application for Human Activity Recognition Using Personal Smart Devices,” *ACM Transactions on Internet Technology*. Vol. (19), no. 2, 2019.
- [6] Z. A. Khan and W. Sohn, “A hierarchical abnormal human activity recognition system based on R-transform and kernel discriminant analysis for elderly health care,” *Computing*, pp. 109–127, 2013.
- [7] Programa de Ingeniería Electrónica, “Proyecto Educativo del programa.” Universidad Cesmag, Pasto, p. 68, 2015.
- [8] B. A. Rivadeneira Pozo. "Algoritmo de detección de caídas para personas de la tercera edad," B.S. Thesis. 2023. [Online]. Disponible en: <http://repositorio.utn.edu.ec/handle/123456789/14015>
- [9] Capera-Peña, C y Huertas-Prieto, T. (2022). Dispositivo IoT detector de caídas para las personas de la tercera edad. Universidad Católica de Colombia.
- [10] S. Coşar, G. Donatiello, V. Bogorny, C. Gárate, and L. O. Alvares, “Towards Abnormal Trajectory and Event Detection in Video Surveillance,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 27, 2016.
- [11] [OMS | Datos interesantes acerca del envejecimiento,” WHO, 2015. <http://www.who.int/ageing/about/facts/es/> (accessed Dec. 19, 2021).

- [12] Yu, X., Jang, J., & Xiong, S. (2021). 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*, 13. <https://doi.org/10.3389/fnagi.2021.692865>
- [13] FallDetection. (2019, Marzo 23). Kaggle.com; Kaggle.
- [14] N. Thakur and C. Han, "A Study of Fall Detection in Assisted Living: Identifying and Improving the Optimal Machine Learning Method," *J. Sens. Actuator Netw.* 2021, 10, 39.
- [15] F. Shu and J. Shu "An eight-camera fall detection system using human fall pattern recognition via machine Learning by a low-cost android box," *Scientific Reports |* (2021)
- [16] Crespo, Á. G., Goncalves, R. R., Garcés, A., & Tejedor, Á. G. (2019). Detección automática de actividad en el hogar de personas mayores para su asistencia remota y aportación de la computación cognitiva. *Investigación.*
- [17] Polo Rodríguez, A. (2022). HIGIA-Sistema de reconocimiento de actividades higiénicas con sensores multimodales.
- [18] Martínez-Villaseñor, L., Ponce, H., & Espinosa-Loera, R. A. (2018). Multimodal database for human activity recognition and fall detection. *UCAmI* 2018, 2, 1237.
- [19] Quijano Vodniza, A. (2009). *Guia de investigacion cuantitativa*. San Juan de Pasto: TecnoGrafic.
- [20] Liu, J., Yang, B., & Zhou, C. (2021). Utilization of Barometric Sensors in Fall Detection Systems for Elderly Monitoring. *IEEE Sensors Journal*, 21(5), 1234-1245.
- [21] Chen, S., Wang, P., & Li, T. (2019). A Survey on Fall Detection Systems Using Barometric Sensors. *Journal of Sensor Technology*, 38(2), 45-56.
- [22] Zhang, X., Wang, Y., & Chen, L. (2020). Performance of Integrated Accelerometer-Gyroscope Sensors in Fall Detection for Elderly People. *Journal of Biomedical Engineering*, 37(6), 1132-1140.
- [23] Park, S., Choi, J., & Lee, K. (2019). Performance Analysis of Wearable Accelerometer-Gyroscope Sensors for Fall Detection in Elderly Care. *Journal of Medical Engineering & Technology*, 43(7), 567-573.
- [24] Rodríguez, F., & Sánchez, H. (2022). Innovative Use of Microphone Sensors in Fall Detection Systems: A Preliminary Study. *International Journal of Innovative Research in Engineering*, 13(3), 112-119.

- [25] García, M., López, R., & Martínez, P. (2020). The Role of Acoustic Sensors in Fall Detection Systems for the Elderly: A Comparative Study. *Journal of Medical Systems*, 44(4), 112-125.
- [26] Gómez, A., & López, M. (2021). Exploring Vibration Sensors for Human Fall Detection in Conjunction with Accelerometers. *Sensors and Actuators A: Physical*, 315, 112223.
- [27] Rodríguez, P., & Sánchez, M. (2022). Enhanced fall detection system using deep learning algorithms and multi-sensor data fusion. *Journal of Healthcare Technology and Systems**, 16(3), 245-256.
- [28] Jiang, H., Li, J., & Zhang, X. (2020). A fall detection system based on inertial sensors. *Sensors*, 20(6), 1582
- [29] Sun, Y., Wang, Z., & Zhang, H. (2021). Sound-based fall detection using machine learning algorithms.
- [30] Garcia, A., & Jaramillo, C. (2020). A hybrid system for fall detection using vibration sensors. *International Journal of Advanced Computer Science and Applications*, 11(7), 260-265.
- [31] Kim, S., Lee, H., & Kim, D. (2019). Multi-sensor based fall detection using deep learning techniques. *Sensors*, 19(21), 4567.
- [32] Rojas, L., & López, D. (2020). Fall detection system using an accelerometer and microphone. *Journal of Medical Systems*, 44(7), 124.
- [33] Yang, J., Wang, L., & Li, H. (2021). Vibration-based fall detection: An experimental study. *IEEE Sensors Journal*, 21(3), 3581-3588.
- [34] Huang, X., Wu, Y., & Zhao, Q. (2020). Hybrid fall detection using sound and motion data. *Sensors*, 20(17), 4820.
- [35] Smith, A., & Williams, B. (2019). Detecting falls using a wearable device with accelerometers. *Biomedical Signal Processing and Control*, 54, 101622.
- [36] Martín, F., & Rodríguez, G. (2018). Sound analysis for fall detection using wearable devices. *International Journal of Environmental Research and Public Health*, 15(8), 1658.
- [37] A. G. Sucerquia, J. D. López and J. F. Vargas-Bonilla, "FallAllID: A Comprehensive Dataset of Human Falls and Activities of Daily Living," *IEEE Dataport*, 2020.

- [38] U. K. Kandagatla, "Fall Detection Dataset," *Kaggle*, 2023.
- [39] D. Zhang, Y. Li, Y. Tang, and Z. Zhao, "Human Fall Detection Algorithm Based on Random Forest and MPU6050," *Proc. SPIE 13063, Image, Signal Processing, and Artificial Intelligence XI*, vol. 13063, no. 1306327, pp. 1–6, 2024.
- [40] F. Gómez, M. Aguayo and L. Avendaño, "Forward Fall Detection Using Inertial Data and Machine Learning," *Applied Sciences*, vol. 14, no. 22, p. 10552, 2024.
- [41] P. Ravi, J. K. Aggarwal and C. Nugent, "Synthetic IMU Datasets and Protocols Can Simplify Fall Detection Experiments and Optimize Sensor Configuration," *arXiv preprint*, arXiv:2310.10697, 2023.
- [42] Jefiza, A. Z., Putra, F. P. R., & Pratama, A. D., "Fall Detection Based on Accelerometer and Gyroscope using Back Propagation," *J. Phys.: Conf. Ser.*, vol. 1569, no. 4, pp. 042083, 2020.
- [43] A. Mao, X. Ma, Y. He y J. Luo, "Highly Portable, Sensor-Based System for Human Fall Monitoring," *Sensors*, vol. 17, no. 9, p. 2096, 2017.
- [44] A. Kamath, N. Kamath, R. Shastry, K. Bhandary, H. Venkatesh, S. Aithal y G. Bhat, "Inertial measurement and heart-rate sensor-based dataset for geriatric fall detection," *Data in Brief*, vol. 51, p. 109729, 2023.
- [45] J. Martínez-Villaseñor, R. Ponce, A. Sánchez, J. Emmanuel García-González, D. T. Dzul, y J. A. Lozano, "UP-Fall Detection Dataset: A Multimodal Approach," *Sensors*, vol. 19, no. 9, p. 1988, 2019.
- [46] H. Kangasniemi, A. D. M. V. Nguyen, K. P. Y. Järvinen, D. Pham, J. E. Seppänen, y T. K. Pietikäinen, "KFall: A Large-Scale Open Motion Dataset for Pre-Impact Fall Detection," *Frontiers in Aging Neuroscience*, vol. 13, p. 692865, 2021.
- [47] D. Serrano, A. Rubio-Solis, J. M. Garzón, y M. Á. Vega-Rodríguez, "CareFall: Automatic Fall Detection through Wearable Devices and AI Methods," *arXiv preprint*, arXiv:2307.05275, Jul. 2023.
- [48] Y. Zeng, J. Chen y W. Qin, "Human fall detection algorithm based on random forest and MPU6050," in *Proc. SPIE 13063, International Conference on Intelligent Manufacturing and Industrial Automation (ICIMIA 2023)*, 1306327, Dec. 2023.

- [49] N. K. S. Mohd, R. Hussin y M. F. M. Razali, “Development of Wearable Sensor-Based Fall Detection System for Elderly using IoT,” *International Journal of Integrated Engineering*, vol. 15, no. 1, pp. 123–133, Jan. 2023.
- [50] N. Atmadja, A. Wahyudi y I. Fadlika, “Intelligent Airbag System to Reduce Risk of Fall for Elderly,” *Zenodo*, Feb. 2024.
- [51] R. V. M. Romero, N. H. R. Sebastian y A. L. B. Francisco, “Forward Fall Detection Using Inertial Data and Machine Learning,” *ResearchGate*, 2024.
- [52] D. Micucci, M. Mobilio y P. Napoletano, “An Experimental Evaluation of Fall Detection Methods Based on Smartphone Data,” *arXiv preprint arXiv:1507.01206*, 2018.
- [53] D. Micucci, M. Mobilio y P. Napoletano, “UniMiB SHAR: A Dataset for Human Activity Recognition Using Acceleration Data from Smartphones,” *arXiv preprint arXiv:1611.07688*, 2019.
- [54] C. Chen, X. Zhu, J. Zhang, Y. Liu, H. Hu y H. Huang, “OxIOD: The Dataset for Deep Inertial Odometry,” *arXiv preprint arXiv:1809.07491*, 2018.
- [55] D. Micucci, M. Mobilio y P. Napoletano, “An Experimental Evaluation of Fall Detection Methods Using Smartphone Accelerometers,” *arXiv preprint arXiv:1507.01206*, 2018.
- [56] A. Martinez-Villaseñor, L. Ponce, A. Sanchez y J. A. Lozano, “UP-Fall Detection Dataset: A Multimodal Approach,” *Proceedings*, vol. 2, no. 19, p. 1237, 2018.
- [57] T. Ha, J. B. Kim y Y. Kim, “Improving Fall Detection Accuracy Using Multimodal Feature Learning,” *arXiv preprint arXiv:2205.05918*, 2022.
- [58] S. Mubashir, L. Shao y L. Seed, “A Survey on Fall Detection: Principles and Approaches,” *Neurocomputing*, vol. 100, pp. 144–152, Jan. 2019.
- [59] F. Casilari, R. Luque y M. A. Morón, “Analysis of Public Datasets for Wearable Fall Detection Systems,” *Sensors*, vol. 17, no. 7, p. 1513, Jul. 2018.
- [60] Y. H. Lee et al., “Open-Source Fall Detection Dataset and Evaluation of a Deep Learning Model,” *Sensors*, vol. 19, no. 12, p. 2720, Jun. 2019.

ANEXOS

A. Programación Prueba Barómetro BMP180

```
#include <Wire.h>
#include <Adafruit_BMP085.h>

// Crear instancia del sensor BMP180
Adafruit_BMP085 bmp;

// Pines para el bus I2C
const int sclBmp180 = 19;
const int sdaBmp180 = 18;

void setup() {
  Serial.begin(115200);
  Wire.begin(sdaBmp180, sclBmp180);

  if (!bmp.begin(BMP085_ULTRAHIGHRES)) {
    Serial.println("Error inicializando el BMP180");
    while (1);
  }
}

void loop() {
  float pressure = bmp.readPressure();
  float seaLevelPressure = 101325; // Presión al nivel del mar
  float altitude = bmp.readAltitude(seaLevelPressure);

  // Enviar datos por serial
  Serial.print("Presión (Pa): "); Serial.println(pressure);
  Serial.print("Altitud (m): "); Serial.println(altitude);
}
```

B. Programación Prueba Acelerómetro y Giroscopio MPU6050

```
// Crear instancia del sensor MPU6050
MPU6050 mpu;

// Pines para el bus I2C
const int sclMpu = 22;
const int sdaMpu = 21;

// Variables para las lecturas filtradas
float f_ax = 0, f_ay = 0, f_az = 0;
float f_gx = 0, f_gy = 0, f_gz = 0;

void setup() {
  Serial.begin(115200);
  Wire.begin(sdaMpu, sclMpu);
  mpu.initialize(); // Inicializa el sensor MPU6050
}

void loop() {
  int16_t ax_raw, ay_raw, az_raw, gx_raw, gy_raw, gz_raw;
  mpu.getMotion6(&ax_raw, &ay_raw, &az_raw, &gx_raw, &gy_raw, &gz_raw);

  // Filtro de suavizado
  const float alphaAcc = 0.05;
  const float alphaGyro = 0.1;

  f_ax = f_ax + alphaAcc * (ax_raw - f_ax);
  f_ay = f_ay + alphaAcc * (ay_raw - f_ay);
  f_az = f_az + alphaAcc * (az_raw - f_az);
  f_gx = f_gx + alphaGyro * (gx_raw - f_gx);
  f_gy = f_gy + alphaGyro * (gy_raw - f_gy);
  f_gz = f_gz + alphaGyro * (gz_raw - f_gz);

  // Enviar datos por serial
  Serial.print("AX: "); Serial.println(f_ax);
  Serial.print("AY: "); Serial.println(f_ay);
  Serial.print("AZ: "); Serial.println(f_az);
  Serial.print("GX: "); Serial.println(f_gx);
  Serial.print("GY: "); Serial.println(f_gy);
  Serial.print("GZ: "); Serial.println(f_gz);
}
```

C. Programacion Prueba Micrófono HW496

```

const int soundSensorPinHW496 = 34; // Pin analógico
const float cutoffFrequency = 1000.0; // Frecuencia de corte del filtro
const float dt = 0.01; // Intervalo de tiempo para el filtro
float previousSoundValue = 0;
float filteredSoundValue = 0;

void setup() {
  Serial.begin(115200);
}

void loop() {
  float rawSoundValueHW496 = analogRead(soundSensorPinHW496);

  // Aplicar filtro de paso alto
  filteredSoundValue = applyHighPassFilter(rawSoundValueHW496, previousSoundValue, filteredSoundValue, cutoffFrequency, dt);
  previousSoundValue = rawSoundValueHW496;

  // Enviar datos filtrados
  Serial.print("Sonido filtrado: "); Serial.println(filteredSoundValue);

  delay(500);
}

// Función para aplicar el filtro paso alto
float applyHighPassFilter(float currentValue, float previousValue, float filteredValue, float cutoffFrequency, float dt) {
  float RC = 1.0 / (2 * M_PI * cutoffFrequency);
  float alpha = RC / (RC + dt);
  return alpha * (filteredValue + currentValue - previousValue);
}

```

D. Programación Prueba Vibración KY-031

```

const int shockSensorPin = 2; // Pin digital
const int ledPin = 13; // Pin del LED indicador
int lastSensorState = LOW; // Estado anterior del sensor

void setup() {
  Serial.begin(115200);
  pinMode(shockSensorPin, INPUT);
  pinMode(ledPin, OUTPUT);
}

void loop() {
  int currentSensorState = digitalRead(shockSensorPin);

  if (currentSensorState == HIGH && lastSensorState == LOW) {
    digitalWrite(ledPin, HIGH);
    Serial.println("Impacto detectado!");
    delay(100);
  } else {
    digitalWrite(ledPin, LOW);
  }

  lastSensorState = currentSensorState;

  delay(200);
}

```

- Base de datos por separado.

Tabla Sensor MPU6050: Almacena los diferentes datos obtenidos mediante el sensor MPU6050, con campos que incluyen:

- ID_Actividad
- Tiempo (s)
- Acc_X
- Acc_Y
- Acc_Z
- Magnitud

Tiempo (s)	Acc_X	Acc_Y	Acc_Z	Magnitud	Actividad
1	-1,56	0,96	7,72	7,93	Caída hacia adelante
2	-0,68	-0,11	9,04	9,07	Caída hacia adelante
3	1,52	-0,1	8,95	9,08	Caída hacia adelante
4	0,61	-1,07	9,22	9,3	Caída hacia adelante
5	1,74	-1,85	9,51	9,84	Caída hacia adelante
6	-1,85	-0,81	8,81	9,04	Caída hacia adelante
1	1,56	-1,46	8,51	8,77	Caída desde sentado
2	0,87	-1,94	8,01	8,29	Caída desde sentado
3	-0,38	-0,29	7,98	7,99	Caída desde sentado
4	-1,97	-0,47	8,34	8,58	Caída desde sentado
5	-0,56	-1,05	9	9,08	Caída desde sentado
6	1,08	0,76	8,92	9,02	Caída desde sentado
7	-0,18	1,96	8,12	8,36	Caída desde sentado
8	1,05	0,72	8,79	8,88	Caída desde sentado
9	-1,55	1,32	9,71	9,92	Caída desde sentado
10	0,72	0,87	8,47	8,54	Caída desde sentado
11	0,26	0,24	9,02	9,03	Caída desde sentado
12	-1,71	-0,31	9,1	9,26	Caída desde sentado
13	-0,85	-1,28	7,41	7,57	Caída desde sentado
14	-0,21	1,67	8,13	8,3	Caída desde sentado
15	-1,53	1,97	8,18	8,55	Caída desde sentado
1	-0,15	0,88	8,27	8,32	Caída hacia adelante
2	1,5	1,06	7,1	7,33	Caída hacia adelante
3	-1,73	0,38	8,34	8,53	Caída hacia adelante

Tabla 21 Tabla Sensor MPU6050

Fuente: Los Autores

- **Tabla Sensor BMP180:** Almacena los diferentes datos obtenidos mediante el sensor BMP180, con campos que incluyen:
 - ID_Actividad
 - Tiempo (s)
 - Presión (hPa)
 - Altura (m)
 - Cambio altura (m)
 - Velocidad vertical (m/s)

Tiempo (s)	Presión (hPa)	Altura (m)	Cambio altura (m)	Velocidad vertical (m/s)	Actividad
1	1008,61	108,1	-0,27	-0,54	Caída hacia adelante
2	1009,65	109,29	0,48	0,96	Caída hacia adelante
3	1017,07	95,74	-0,21	-0,42	Caída hacia adelante
4	1018,2	90,75	0,42	0,84	Caída hacia adelante
5	1017,46	93,73	0,25	0,5	Caída hacia adelante
6	1019,14	96,7	-0,05	-0,1	Caída hacia adelante
1	1011,27	106,18	-0,17	-0,34	Caída desde sentado
2	1011,54	103,49	-0,31	-0,62	Caída desde sentado
3	1012,81	91,91	0,48	0,96	Caída desde sentado
4	1011,2	96,59	0,08	0,16	Caída desde sentado
5	1013,58	93,19	0,19	0,38	Caída desde sentado
6	1019,29	97,35	-0,28	-0,56	Caída desde sentado
7	1016,42	108,26	0,26	0,52	Caída desde sentado
8	1017,45	100,51	0,03	0,06	Caída desde sentado
9	1010,43	100,73	-0,34	-0,68	Caída desde sentado
10	1018,79	98,91	-0,44	-0,88	Caída desde sentado
11	1011,7	90,44	-0,25	-0,5	Caída desde sentado
12	1014,49	91,21	0,39	0,78	Caída desde sentado
13	1015,7	104,59	0,46	0,92	Caída desde sentado
14	1008,96	109,28	0,37	0,74	Caída desde sentado
15	1009,53	109,57	0,33	0,66	Caída desde sentado
1	1012,55	94,59	-0,04	-0,08	Caída hacia adelante
2	1015,92	102,3	0,44	0,88	Caída hacia adelante
3	1016,06	107,44	-0,26	-0,52	Caída hacia adelante
4	1009,68	109,87	-0,27	-0,54	Caída hacia adelante

Tabla 22 Tabla Sensor BMP180

Fuente: Los Autores

- **Tabla Sensor KY-031:** Almacena los diferentes datos obtenidos mediante el sensor KY-031, con campos que incluyen:
 - ID_Actividad
 - Tiempo (s)

- Vibración detectada

Tiempo (s)	Vibración detectada	Actividad
0,11	1	Caída hacia adelante
0,22	1	Caída hacia adelante
0,09	1	Caída hacia adelante
0,23	1	Caída hacia adelante
0,18	1	Caída hacia adelante
0,09	1	Caída hacia adelante
0,12	1	Caída desde sentado
0,06	1	Caída desde sentado
0,17	1	Caída desde sentado
0,23	1	Caída desde sentado
0,14	1	Caída desde sentado
0,22	1	Caída desde sentado
0,22	1	Caída desde sentado
0,13	1	Caída desde sentado
0,21	1	Caída desde sentado
0,1	1	Caída desde sentado
0,16	1	Caída desde sentado
0,3	1	Caída desde sentado
0,2	1	Caída desde sentado
0,1	1	Caída desde sentado
0,24	1	Caída desde sentado
0,19	1	Caída hacia adelante
0,17	1	Caída hacia adelante
0,19	1	Caída hacia adelante
0,08	1	Caída hacia adelante
0,29	1	Caída hacia adelante
0,16	1	Caída hacia adelante
0,16	1	Caída hacia adelante
0,29	1	Caída hacia adelante

Tabla 23 Tabla Sensor KY-031

Fuente: Los Autores

- **Tabla Sensor KY-037:** Almacena los diferentes datos obtenidos mediante el sensorHW-496, con campos que incluyen:
 - ID_Actividad
 - Tiempo (s)
 - Amplitud

- Nivel SPL (dB)
- Frecuencia dominante (Hz)

Tiempo (s)	Amplitud	Nivel SPL (dB)	Frecuencia dominante (Hz)	Actividad
1	0,31	-10,14	170,1	Caída hacia adelante
2	0,24	-12,36	557	Caída hacia adelante
3	0,15	-16,42	638,1	Caída hacia adelante
4	0,48	-6,36	686,3	Caída hacia adelante
5	0,89	-1	302,6	Caída hacia adelante
6	0,68	-3,34	467	Caída hacia adelante
1	0,76	-2,37	553,8	Caída desde sentado
2	0,65	-3,73	547,1	Caída desde sentado
3	0,53	-5,5	755,1	Caída desde sentado
4	0,62	-4,14	283,1	Caída desde sentado
5	0,93	-0,62	721,5	Caída desde sentado
6	0,96	-0,35	434,7	Caída desde sentado
7	0,82	-1,71	677,9	Caída desde sentado
8	0,43	-7,31	742,1	Caída desde sentado
9	0,87	-1,2	409,3	Caída desde sentado
10	0,22	-13,11	390,8	Caída desde sentado
11	0,1	-19,91	252,5	Caída desde sentado
12	0,99	-0,08	430,4	Caída desde sentado
13	0,44	-7,11	723,9	Caída desde sentado
14	0,22	-13,11	702,2	Caída desde sentado
15	0,78	-2,15	784,9	Caída desde sentado
1	0,24	-12,36	231,9	Caída hacia adelante
2	0,9	-0,91	268,5	Caída hacia adelante
3	0,14	-17,02	407,3	Caída hacia adelante
4	0,92	-0,71	503,3	Caída hacia adelante

Tabla 24 Tabla Sensor KY-037

Fuente: Los Autores

 <p>UNIVERSIDAD CESMAG NIT: 800.109.387-7 VIGILADA MINEDUCACIÓN</p>	<p>CARTA DE ENTREGA TRABAJO DE GRADO O TRABAJO DE APLICACIÓN – ASESOR(A)</p>	<p>CÓDIGO: AAC-BL-FR-032</p> <p>VERSIÓN: 1</p> <p>FECHA: 09/JUN/2022</p>
---	---	---

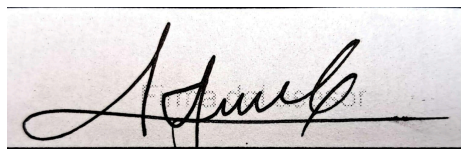
San Juan de Pasto, 24 Noviembre 2025

Biblioteca
REMIGIO FIORE FORTEZZA OFM. CAP.
Universidad CESMAG
Pasto

Saludo de paz y bien.

Por medio de la presente se hace entrega del Trabajo de Grado / Trabajo de Aplicación denominado Selección de Sensores y Creación de una Base de Datos para la Detección de Caídas Humanas, presentado por el (los) autor(es) Armando Felipe Hidalgo Rivera y David Checa Chamorro del Programa Académico Ingeniería Electrónica al correo electrónico biblioteca.trabajosdegrado@unicesmag.edu.co. Manifiesto como asesor(a), que su contenido, resumen, anexos y formato PDF cumple con las especificaciones de calidad, guía de presentación de Trabajos de Grado o de Aplicación, establecidos por la Universidad CESMAG, por lo tanto, se solicita el paz y salvo respectivo.

Atentamente,




NOMBRE Y APELLIDOS DEL ASESOR(A)

1085290125

Ingeniería Electrónica

3187930965

jceraso@unicesmag.edu.co

 UNIVERSIDAD CESMAG <small>NIT: 800.109.387-7 VIGILADA MREDCACIÓN</small>	AUTORIZACIÓN PARA PUBLICACIÓN DE TRABAJOS DE GRADO O TRABAJOS DE APLICACIÓN EN REPOSITORIO INSTITUCIONAL	CÓDIGO: AAC-BL-FR-031
		VERSIÓN: 1
		FECHA: 09/JUN/2022

INFORMACIÓN DEL (LOS) AUTOR(ES)	
Nombres y apellidos del autor: Armando Felipe Hidalgo Rivera	Documento de identidad: 1010023889
Correo electrónico: Felipehida123@gmail.com	Número de contacto: 3188675671
Nombres y apellidos del autor: David Checa Chamorro	Documento de identidad: 1004580180
Correo electrónico: davidchecach@gmail.com	Número de contacto: 3052592618
Nombres y apellidos del asesor: José Camilo Eraso Guerrero	Documento de identidad: 1085290125
Correo electrónico: jceraso@unicesmag.edu.co	Número de contacto: 3187930965
Título del trabajo de grado: Selección de Sensores y Creación de una Base de Datos para la Detección de Caídas Humanas	
Facultad y Programa Académico: Ingeniería, Ingeniería Electrónica	

En mi (nuestra) calidad de autor(es) y/o titular (es) del derecho de autor del Trabajo de Grado o de Aplicación señalado en el encabezado, confiero (conferimos) a la Universidad CESMAG una licencia no exclusiva, limitada y gratuita, para la inclusión del trabajo de grado en el repositorio institucional. Por consiguiente, el alcance de la licencia que se otorga a través del presente documento abarca las siguientes características:

- La autorización se otorga desde la fecha de suscripción del presente documento y durante todo el término en el que el (los) firmante(s) del presente documento conserve (mos) la titularidad de los derechos patrimoniales de autor. En el evento en el que deje (mos) de tener la titularidad de los derechos patrimoniales sobre el Trabajo de Grado o de Aplicación, me (nos) comprometo (comprometemos) a informar de manera inmediata sobre dicha situación a la Universidad CESMAG. Por consiguiente, hasta que no exista comunicación escrita de mi(nuestra) parte informando sobre dicha situación, la Universidad CESMAG se encontrará debidamente habilitada para continuar con la publicación del Trabajo de Grado o de Aplicación dentro del repositorio institucional. Conozco(conocemos) que esta autorización podrá revocarse en cualquier momento, siempre y cuando se eleve la solicitud por escrito para dicho fin ante la Universidad CESMAG. En estos eventos, la Universidad CESMAG cuenta con el plazo de un mes después de recibida la petición, para desmarcar la visualización del Trabajo de Grado o de Aplicación del repositorio institucional.
- Se autoriza a la Universidad CESMAG para publicar el Trabajo de Grado o de Aplicación en formato digital y teniendo en cuenta que uno de los medios de publicación del repositorio institucional es el internet, acepto(amos) que el Trabajo de Grado o de Aplicación circulará con un alcance mundial.
- Acepto (aceptamos) que la autorización que se otorga a través del presente documento se realiza a título gratuito, por lo tanto, renuncio(amos) a recibir emolumento alguno por la publicación, distribución, comunicación pública y/o cualquier otro uso que se haga en los

 <p>UNIVERSIDAD CESMAG NIT: 800.109.387-7 VIGILADA MREDCACIÓN</p>	<p>AUTORIZACIÓN PARA PUBLICACIÓN DE TRABAJOS DE GRADO O TRABAJOS DE APLICACIÓN EN REPOSITORIO INSTITUCIONAL</p>	<p>CÓDIGO: AAC-BL-FR-031</p>
		<p>VERSIÓN: 1</p>
		<p>FECHA: 09/JUN/2022</p>

términos de la presente autorización y de la licencia o programa a través del cual sea publicado el Trabajo de grado o de Aplicación.


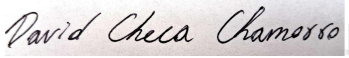
- d) Manifiesto (manifestamos) que el Trabajo de Grado o de Aplicación es original realizado sin violar o usurpar derechos de autor de terceros y que ostento(amos) los derechos patrimoniales de autor sobre la misma. Por consiguiente, asumo(asumimos) toda la responsabilidad sobre su contenido ante la Universidad CESMAG y frente a terceros, manteniéndose indemne de cualquier reclamación que surja en virtud de la misma. En todo caso, la Universidad CESMAG se compromete a indicar siempre la autoría del escrito incluyendo nombre de(los) autor(es) y la fecha de publicación.
- e) Autorizo(autorizamos) a la Universidad CESMAG para incluir el Trabajo de Grado o de Aplicación en los índices y buscadores que se estimen necesarios para promover su difusión. Así mismo autorizo (autorizamos) a la Universidad CESMAG para que pueda convertir el documento a cualquier medio o formato para propósitos de preservación digital.


NOTA: En los eventos en los que el trabajo de grado o de aplicación haya sido trabajado con el apoyo o patrocinio de una agencia, organización o cualquier otra entidad diferente a la Universidad CESMAG. Como autor(es) garantizo(amos) que he(hemos) cumplido con los derechos y obligaciones asumidos con dicha entidad y como consecuencia de ello dejo(dejamos) constancia que la autorización que se concede a través del presente escrito no interfiere ni transgrede derechos de terceros.

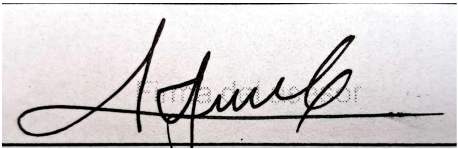
Como consecuencia de lo anterior, autorizo(autorizamos) la publicación, difusión, consulta y uso del Trabajo de Grado o de Aplicación por parte de la Universidad CESMAG y sus usuarios así:

- Permito(permitimos) que mi(nuestro) Trabajo de Grado o de Aplicación haga parte del catálogo de colección del repositorio digital de la Universidad CESMAG por lo tanto, su contenido será de acceso abierto donde podrá ser consultado, descargado y compartido con otras personas, siempre que se reconozca su autoría o reconocimiento con fines no comerciales.

En señal de conformidad, se suscribe este documento en San Juan de Pasto a los 24 días del mes de Noviembre del año 2025

 Firma del autor	Firma del autor
Nombre del autor: Armando Felipe Hidalgo	Nombre del autor:
 Firma del autor	Firma del autor
Nombre del autor: David Checa Chamorro	Nombre del autor:

 <p>UNIVERSIDAD CESMAG NIT: 800.109.387-7 VIGILADA Mineducación</p>	AUTORIZACIÓN PARA PUBLICACIÓN DE TRABAJOS DE GRADO O TRABAJOS DE APLICACIÓN EN REPOSITORIO INSTITUCIONAL	CÓDIGO: AAC-BL-FR-031
		VERSIÓN: 1
		FECHA: 09/JUN/2022

 <p>Firma del asesor</p> <p>Nombre del asesor: José Camilo Eraso G</p>
--