



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

“Sistema Inteligente de Alerta ante Caídas de Adultos Mayores”

Guerrero Navarro, Lucía Daniela

Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica e Instrumentación

Trabajo de titulación, previo a la obtención del título de Ingeniera en Electrónica e
Instrumentación

Ing. Guerrón Paredes, Nancy Enriqueta. PhD

Ing. Galarza Zambrano, Eddie Egberto. PhD

29 de agosto del 2023

Reporte de Verificación de Contenidos



Tesis_Daniela_Guerrero_copleaks.do...

Scan details

Scan time:
August 30th, 2023 at 21:56 UTC

Total Pages:
25

Total Words:
6212

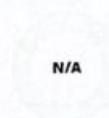
Plagiarism Detection



8.8%

Types of plagiarism		Words
Identical	2.7%	168
Minor Changes	3.5%	216
Paraphrased	2.6%	163
Omitted Words	0%	0

AI Content Detection



Text coverage

- AI text
- Human text

Plagiarism Results: (17)

- Marco Teórico y Conceptual - PROYECTO FIN DE CAR...** 3.1%

<https://1library.co/article/marco-te%C3%B3rico-conceptual-p...>

...

- Raspberry Pi 4: Análisis y valoración de este mini or...** 2.8%

<https://www.redeszone.net/analisis/otros-dispositivos/raspb...>

Sergio De Luz

Menú ASUS QNAP AVM Ordenar por fe...

- Redes Neuronales Recurrentes - Jordi TORRES.AI** 2.7%

<https://torres.ai/redes-neuronales-recurrentes/>

Skip to content Main Menu ...

Ing. Nancy Guerrón
 Ing. Guerrón Paredes, Nancy PhD
 C.C.: 1707886139



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica e Instrumentación

Certificación

Certifico que el trabajo de titulación: **"Sistema Inteligente de Alerta ante Caídas de Adultos Mayores"** fue realizado por la señorita **Guerrero Navarro, Lucía Daniela**; el mismo que cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, además fue revisado y analizado en su totalidad por la herramienta de prevención y/o verificación de similitud de contenidos; razón por la cual me permito acreditar y autorizar para que se lo sustente públicamente.

Latacunga, 29 agosto del 2023

Ing. Guerrón Paredes, Nancy PhD

C.C.: 1707886139

Ing. Galarza Zambrano, Eddie. MSc.

C.C.: 1303128514



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica e Instrumentación

Responsabilidad de Autoría

Yo, **Guerrero Navarro, Lucía Daniela**, con cédula de ciudadanía N°: 0503022907, declaro que el contenido, ideas y criterios del trabajo de titulación: **Sistema Inteligente de Alerta ante Caídas de Adultos Mayores** es de mi autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Latacunga, 29 de agosto del 2023

Guerrero Navarro, Lucía Daniela

C.C.: 0503022907



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica e Instrumentación

Autorización de Publicación

Yo, **Guerrero Navarro, Lucía Daniela**, con cédula de ciudadanía N°: 0503022907, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **Sistema Inteligente de Alerta ante Caídas de Adultos Mayores** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Latacunga, 29 de agosto del 2023

Guerrero Navarro, Lucía Daniela

C.C.: 0503022907

Dedicatoria

A Dios por darme vida, salud y sabiduría a lo largo de la carrera de Ingeniería
Electrónica e Instrumentación.

A mis abuelitos Teresa y Leonardo, quienes nunca me abandonaron por más difíciles
que fueran las circunstancias.

A mi tía Eliana, cuyo ejemplo decidí seguir, quien me orientó en las cátedras
complicadas.

A mi madre Mery, por ser el gran ejemplo de superación y valentía, de quien nunca me
faltó una palabra de aliento para continuar.

A mi hermana Leonela, por motivarme cada día a seguir adelante, y con un abrazo
cargarme de motivación y fuerza.

A mi padre, que desde el cielo me ilumina para continuar con mis proyectos.

A mi sobrino Lucas, que aún sin saberlo llegó para ser mi inspiración.

Lucía Daniela

Agradecimiento

Agradezco a Dios que me ha guiado y brindado la fortaleza para seguir adelante.

A mi familia por su comprensión y apoyo incondicional a lo largo de mi formación.

A mis docentes quienes con su carisma y vocación me inspiraron a realizarme profesionalmente.

A cada una de las personas que me apoyaron y de una u otra forma hicieron posible la realización de este proyecto.

Lucía Daniela

ÍNDICE DE CONTENIDO

Carátula.....	1
Reporte de Verificación de Contenidos.....	2
Dedicatoria	6
Agradecimiento.....	7
Índice de contenido	8
Índice de figuras	11
Índice de tablas	13
Resumen.....	14
Abstract	15
Capítulo I: Introducción.....	16
Planteamiento del Problema	16
Antecedentes	17
Justificación e Importancia	18
Objetivos.....	19
<i>Objetivo General.....</i>	19
<i>Objetivos Específicos</i>	19
Variables de la investigación	19
<i>Variables independientes.....</i>	19
<i>Variable dependiente.....</i>	19
Hipótesis.....	20

Capítulo II: Marco Teórico	21
Importancia del Problema.....	21
Detección de caídas.....	21
Sistemas de Detección de Caídas Basados en Sensores.....	22
Raspberry Pi 4.....	23
<i>Capacidades Técnicas de la Raspberry Pi 4 como Microcomputador</i>	<i>23</i>
Redes Neuronales LSTM (Long Short-Term Memory).....	24
Redes Neuronales Convolucionales 1D	25
Sensores de Tamaño Reducido que se Adaptan al Cuerpo.....	27
<i>Características Principales</i>	<i>28</i>
<i>Especificaciones Técnicas del Acelerómetro.....</i>	<i>28</i>
Colocación del Sensor en la Muñeca de la persona	29
Base de Datos	30
Capítulo III: Desarrollo e Implementación del Sistema.....	31
Entrenamiento de Redes Neuronales	37
Capítulo IV: Análisis y Resultados	46
Modelos de Red Empleadas	46
<i>LSTM</i>	<i>46</i>
<i>Red Convolutiva</i>	<i>47</i>
<i>Red Combinada</i>	<i>48</i>
Comparación Entre los Tipos de Redes Neuronales Implementadas	49

Generación Automática de Mensajes	50
Capítulo V: Conclusiones y Recomendaciones	52
Conclusiones y Recomendaciones	52
Bibliografía	54
Anexos	57

ÍNDICE DE FIGURAS

Figura 1	<i>Celda de una neurona LSTM.....</i>	<i>25</i>
Figura 2	<i>Arquitectura de redes neuronales convolucionales.....</i>	<i>26</i>
Figura 3	<i>Partes constitutivas del sensor MetaMotion.....</i>	<i>27</i>
Figura 4	<i>Diagrama de trabajo del desarrollo del proyecto.....</i>	<i>31</i>
Figura 5	<i>Algoritmo para recuperar datos desde carpetas</i>	<i>32</i>
Figura 6	<i>Algoritmo para la inclusión de una nueva variable en las tablas obtenidas.....</i>	<i>33</i>
Figura 7	<i>Algoritmo de eliminación de datos no válidos</i>	<i>34</i>
Figura 8	<i>Cambio de dimensión de las tablas obtenidas.....</i>	<i>35</i>
Figura 9	<i>Algoritmo de aleatoriedad para la distribución de los datos</i>	<i>36</i>
Figura 10	<i>Ejemplo de datos ante una caída</i>	<i>36</i>
Figura 11	<i>Algoritmo de entrenamiento y validación de la red neuronal LSTM</i>	<i>38</i>
Figura 12	<i>Estructura de la red neuronal LSTM.....</i>	<i>39</i>
Figura 13	<i>Algoritmo de entrenamiento y validación red neuronal Convolucional</i>	<i>40</i>
Figura 14	<i>Estructura básica de la red neuronal convolucional.....</i>	<i>41</i>
Figura 15	<i>Pasos iniciales para la ejecución del script.....</i>	<i>42</i>
Figura 16	<i>Funciones necesarias para el envío de mensajes y detección de caídas</i>	<i>43</i>
Figura 17	<i>Diagrama de flujo para la recolección y procesamiento de datos del acelerómetro .</i>	<i>43</i>
Figura 18	<i>Secuencia de conexión y confirmación del dispositivo.....</i>	<i>44</i>
Figura 19	<i>Lazo de ejecución constante del script implementado</i>	<i>44</i>
Figura 20	<i>Evolución histórica del entrenamiento y validación red neuronal LSTM.....</i>	<i>47</i>
Figura 21	<i>Evolución histórica del entrenamiento y validación red neuronal Convolutiva.....</i>	<i>48</i>
Figura 22	<i>Evolución histórica del entrenamiento y validación red neuronal combinada.....</i>	<i>49</i>
Figura 23	<i>Gráfico comparativo entre las redes neuronales.....</i>	<i>50</i>

Figura 24 <i>Captura de los mensajes automáticos generados</i>	51
---	----

ÍNDICE DE TABLAS

Tabla 1 <i>Características técnicas del acelerómetro</i>	28
---	----

Resumen

El presente trabajo presenta el desarrollo de un sistema de detección de caídas, basado en un dispositivo inteligente, el cual es capaz de recolectar datos en tiempo real y generar alertas ante una caída. El sistema fue implementado mediante la combinación de las redes neuronales Long Short – Term Memory y convolucionales, las mismas que fueron entrenadas con una base de datos compuesta por 3.5 millones de muestras tomadas a través de un acelerómetro, diferenciadas en ventanas de datos, con las etiquetas de 0 y 1 haciendo referencia a “caída” y “no caída”. Mediante las redes neuronales, se logró obtener una buena precisión y disminuir la pérdida de datos. El resultado tangible de esta investigación es el reconocimiento y alerta de caídas mediante un brazalete. El dispositivo de detección consta de dos elementos básicos, un HUB para la concentración de los datos recolectados y posterior procesamiento, a través de una Raspberry Pi 4; como equipo sensor un dispositivo no invasivo, colocado en la muñeca del usuario. El sistema en sí puede ser implementado a larga escala, hasta un máximo de 20 dispositivos recolectores de datos simultáneos, esto con el fin de supervisar varios adultos mayores ubicados en un mismo punto.

Palabras clave: Detector de caídas, adultos mayores, dispositivo inteligente

Abstract

This paper presents the development of a fall detection system based on an intelligent device, which collect data in real time and generate alerts in case of a fall of older people. The system was implemented through the combination of Long Short - Term Memory and Convolutional Neural Networks. The neural networks were trained using a database composed of 3.5 million of samples taken through an accelerometer, differentiated in data windows, with labels of 0 and 1 to define "fall" and "no fall". By means of these neural networks, it was possible to obtain good accuracy and reduce data loss. The tangible result of this research is the recognition and alert of people falls by means of a bracelet. The detection device consists of two basic elements, a HUB for the concentration of the collected data to be processed using a Raspberry Pi 4 board and a sensor equipment considered as a non-invasive device that is placed on the wrist of the user. The system itself can be implemented on a large scale including up to a maximum of 20 simultaneous data collection devices, in order to monitor several older adults located at the same point.

Keywords: Fall detector, older adults, smart device.

Capítulo I

Introducción

Planteamiento del Problema

El envejecimiento de la población es un hecho indudable y tiene importantes implicaciones para la salud; por tanto, los cuidados que se brinden en esta etapa definen el bienestar de este sector de la población. Uno de los problemas más frecuentes a los que se enfrentan los adultos mayores es el riesgo de sufrir caídas. Estas caídas pueden tener graves consecuencias para la salud, incluyendo lesiones peligrosas, hospitalización y, en algunos casos, incluso la muerte

Un sistema inteligente de alerta y prevención ante caídas de los adultos mayores permitiría reducir el riesgo de ocurrencia de caídas en personas de edad avanzada y, en consecuencia, reducir las posibilidades de hospitalización y el estrés que les causa al sufrir una caída. Para ello, se plantea desarrollar un dispositivo inteligente capaz de detectar y alertar del riesgo potencial de la ocurrencia de una caída de un adulto mayor a las personas cercanas o a los servicios de emergencia, para que estos puedan intervenir de manera oportuna.

Uno de los principales desafíos a la hora de implementar un sistema de prevención ante caídas de adultos mayores es garantizar que el dispositivo inteligente sea fácil de usar por personas ancianas y no suponga una carga adicional para ellas. Además, el dispositivo debe ser fiable y capaz de funcionar en diferentes condiciones ambientales y de actividad.

También es importante tener en cuenta que el sistema de prevención ante caídas de adultos mayores debe ser capaz de integrarse en el entorno de vida de las personas de edad avanzada de manera natural, sin interferir en su rutina diaria. De esta manera, se logrará una mayor aceptación por parte de los usuarios y, en consecuencia, una mayor efectividad del sistema.

Antecedentes

Las caídas entre las personas de 65 años o más, son la principal causa de muerte por lesiones a nivel global (CDC, 2020). y son la causa más frecuente de lesiones no mortales y de ingresos hospitalarios por lesiones traumáticas. Las caídas tienen una etiología multifactorial, este síndrome geriátrico es relevante y muchas veces puede ser evitado. Un 22% de las caídas se debe a factores de riesgo extrínsecos (CDC, 2020). En consecuencia, la adaptación de los factores ambientales y el desarrollo de sistemas inteligentes permitirían minimizar estos riesgos.

Las tasas de caídas aumentan considerablemente a medida que avanza la edad (CDC, 2020). En 2002, se produjeron 12.800 muertes relacionadas con caídas de adultos mayores; la tasa global de mortalidad entre los hombres alcanzó un 60% más que entre las mujeres.

En 2002, aproximadamente 1,6 millones de adultos mayores, fueron atendidos en los servicios de urgencias de los hospitales estadounidenses, por lesiones no intencionadas relacionadas con caídas y 388.000 fueron hospitalizados posteriormente (CDC, 2020). Las lesiones por caídas más graves son los traumatismos y las fracturas de cadera. En España, según (Maria Dolores Estrada Sabadell, 2002) “el número anual estimado de personas con nuevas fracturas por fragilidad era de 327.000 (197.000 en mujeres y 130.000 en hombres) con un aumento esperado de un 29% para el año 2030”.

La osteoporosis, enfermedad metabólica que provoca fragilidad ósea, aumenta considerablemente las probabilidades de que una persona que se cae sufra una fractura de cadera. Las caídas también pueden tener importantes consecuencias psicológicas. Muchas personas que se caen sufran o no lesiones, desarrollan miedo a las caídas. Este miedo puede hacer que limiten su actividad, lo que a su vez provoca una reducción de la movilidad, debilidad y un mayor riesgo de caídas (Vellas et al., 1997).

La detección de caídas es un tema ampliamente investigado en los últimos años. Existen revisiones sistemáticas recientes sobre el uso de la tecnología vestible, que han sido reconocidas como el tipo más eficaz para la detección de caídas en adultos mayores. También han sido ampliamente empleadas en la detección de la enfermedad de Parkinson (Chaudhuri et al., 2014; Montesinos et al., 2018; Nguyen et al., 2018; Pang et al., 2019; Rucco et al., 2018; Silva de Lima et al., 2017; Sun & Sosnoff, 2018).

En este proyecto se plantea efectuar una revisión general de los principales sensores miniaturizados y con capacidad de detectar caídas con precisión. A través de la recepción de datos de la posición y orientación del usuario y manejo de cambio de coordenadas espaciales presentadas por estos dispositivos; estos datos podrán ser manipulados y enviados en forma inalámbrica para la generación de alertas y se podrá efectuar el diseño adecuado del dispositivo vestible final. Su estudio y manejo podrá servir de guía para futuras investigaciones en este campo.

Justificación e Importancia

Las caídas son eventos negativos de gran importancia en los adultos mayores, su ocurrencia produce un gran deterioro en la vida funcional del individuo, así como una elevada mortalidad y morbilidad de los ancianos, constituyéndose en un problema de gran magnitud personal, social, sanitaria y económica. La prevención de las caídas de adultos mayores es parte de la solución a los riesgos extrínsecos evitables que sufren las personas mayores, como las fracturas, que pueden requerir hospitalización y tratamientos médicos costosos. Además, las caídas, reducen la independencia de las personas que la sufren, con otras consecuencias socioeconómicas, derivadas de esta dependencia para su movilidad.

Un sistema inteligente puede alertar a las personas cercanas o a los servicios de emergencia elegidos por los familiares ante el caso de riesgo de caída, permitiendo una intervención oportuna y evitando lesiones graves. Además, el dispositivo puede proporcionar

información útil sobre los factores de riesgo de caídas y ayudar a identificar las medidas preventivas adecuadas para cada individuo.

Objetivos

Objetivo General

- Desarrollar un Sistema Inteligente de alerta ante caídas de Adultos Mayores.

Objetivos Específicos

- Realizar una revisión bibliográfica de los tipos de caída relevantes en adultos mayores, su ocurrencia, desarrollo y prevención.
- Desarrollar un prototipo de un sistema inteligente para alertar a los vigilantes, familiares y servicios de emergencia ante posibles caídas de un adulto mayor.
- Desarrollar un instructivo del funcionamiento del prototipo.
- Evaluar el funcionamiento del sistema inteligente de alerta ante caídas en adultos mayores.

Variables de la investigación

Sistema Inteligente de alerta ante caídas de adultos mayores.

Variables independientes

Sistema Inteligente de alerta ante caídas de adultos mayores.

Variable dependiente

Advertencia del riesgo de caídas de un adulto mayor, mediante el envío de alertas a cuidadores y/o servicios de emergencia.

Hipótesis

El uso de un sistema inteligente de alerta ante posibles caídas permite advertir a cuidadores y/o servicios de emergencias ante el riesgo de una caída de un adulto mayor.

Capítulo II

Marco Teórico

Importancia del Problema

Según la Organización Mundial de la Salud, en Estados Unidos, de un 20% a un 30% de las personas mayores que se caen sufren lesiones de moderadas a graves, tales como contusiones, fracturas de cadera y traumatismos craneoencefálicos (*Caídas*, 2021).

Un estudio realizado en el Hogar “Noel Fernández” en la ciudad de Quito, dio como resultado que tres cuartas partes de los ancianos habitantes regulares sufrieron al menos una caída durante el año en estudio, revisando las causas de las caídas, se encuentra que son accidentales, por tropiezos y resbalones. (Díaz Oquendo et al., 1999)

Las caídas involuntarias si bien no pueden ser tomados como factor mortal, debido a su naturaleza, pueden llegar a serlo en adultos mayores sin supervisión, así como también en otros grupos de riesgo, es por ello por lo que los sistemas tecnológicos coadyuvan en la toma de acciones rápidas ante una caída inminente.

La tecnología actual permite desarrollar sistemas de alerta basados en inteligencia artificial, redes neuronales y sistemas de comunicación, que constituyen el eje central de esta investigación.

Detección de caídas

Los adultos mayores, con el paso de los años, pueden llegar a depender de un tercero, para poder movilizarse, sin embargo, no siempre es posible mantener una supervisión, es por ello que un sistema de detección de caídas ayuda al cuidador o a la persona encargada de la supervisión del adulto mayor a verificar el estado del mismo sin tener un contacto permanente.

Un sistema de detección de caídas se puede implementar empleando varios dispositivos, desde cámaras de seguridad hasta dispositivos vestibles “wereables”, como es el caso de este trabajo de investigación.

La detección de caídas mediante el procesamiento de imágenes es una posible solución para la detección temprana de accidentes, dado que en su gran mayoría utiliza reconocimiento de imágenes, sin embargo, este sistema depende de la iluminación, colocación de la cámara, el entorno, y en definitiva de muchos aspectos que no permiten la correcta detección de caídas las 24 horas del día.

Los “wereables”, son dispositivos electrónicos que se utilizan en personas con el fin de recoger datos y transmitirlos a otros equipos (*Qué es Wearable - Definición, significado y ejemplos, 2020*).

Con estos dispositivos es posible evaluar el estado de sensores como acelerómetros, barómetros, giroscopios entre otros para realizar el análisis de cambios repentinos en la posición del usuario, buscando así detectar una caída.

En este proyecto de investigación se hace uso enfático de los cambios de aceleración para la toma de datos y posterior identificación de caídas.

Sistemas de Detección de Caídas Basados en Sensores.

Los sistemas basados en sensores permiten una detección más próxima al usuario, dado que en comparación con sistemas que hacen uso de imágenes específicamente visión por computador, dependen de factores externos como la iluminación, distancia a la cámara, estatura, procesamiento dedicado a las imágenes entre otros factores, que si bien pueden ser compensados por un proceso de identificación específico, presentan limitantes, en cuando a la diversidad del usuario que puede hacer uso del sistema. Por otra parte, los sensores toman

datos de la persona, y mediante el proceso de la información recolectada, permite identificar los desplomes de manera más precisa, frente a sistemas que se basan en imágenes.

Una de las ventajas que presentan los sistemas basados en sensores, permiten una generalización del usuario que lo utiliza, dado que el sensor se ubica en una zona en común y la toma de datos es independiente del entorno.

El desafío que se puede encontrar en el uso del sistema es que el usuario lo encuentre algo incómodo, dado que debe estar en contacto con su cuerpo. Existen sensores que pueden ser ubicados en diferentes partes del cuerpo como frente, cintura, muñecas, tobillo, cuello entre otras utilizadas en diferentes estudios (*Qué es Wearable - Definición, significado y ejemplos*, 2020). Dada la facilidad de colocación y habituación del usuario en portar objetos en la muñeca, se definió trabajar con un brazalete portador del sistema de detección.

Raspberry Pi 4

Es un microcontrolador con una gran memoria en el chip, un complejo procesador simétrico de doble núcleo, una estructura de bus determinista y un rico conjunto de periféricos ampliado con nuestro exclusivo subsistema de E/S programables (PIO), el RP2040 proporciona a los usuarios profesionales una potencia y flexibilidad inigualables (Solé, 2021).

Raspberry Pi requiere de un sistema operativo para funcionar. Este es Raspberry Pi OS (anteriormente llamado Raspbian). Para su programación se puede usar los lenguajes de C o C++ o Python.

Capacidades Técnicas de la Raspberry Pi 4 como Microcomputador

La Raspberry Pi 4 incorpora un procesador Broadcom BCM2711 con arquitectura de 64 bits, tiene cuatro núcleos ARM A72, la velocidad del procesador es de 1.5GHz. Otra novedad muy importante es que esta CPU dispone de un bus PCI Express (Peripheral Component Interconnect Express,) que se encarga de interconectar los puertos USB, tanto los dos puertos

USB 2.0 como los dos puertos USB 3.0, y lo hace a una velocidad máxima combinada de 4Gbps. El controlador Ethernet es nativo y dedicado, permite velocidades de más de 900Mbps reales en la red local, algo que anteriormente no era posible porque el bus era compartido. Este procesador dispone de una GPU VideoCore VI 3D potente, capaz de decodificar el códec H.265 con una resolución hasta 4K y 60 FPS, y también el códec H.264 con una resolución de 1080p a 60FPS o a 30 FPS, por último, es compatible con gráficos OpenGL ES 3.0. En cuanto a la conectividad inalámbrica, la tarjeta dispone de Wi-Fi con los estándares 802.11b/g/n/ac y también Bluetooth 5.0 con BLE (*Raspberry Pi 4*, 2019).

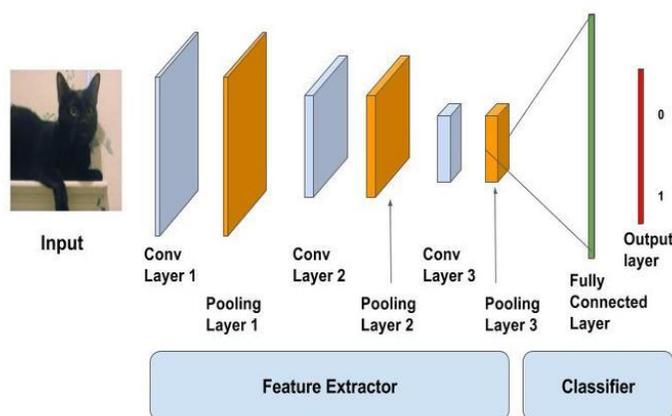
Redes Neuronales LSTM (Long Short-Term Memory)

Long-Short Term Memory(LSTM) son una extensión de las redes neuronales recurrentes (RNN), que extienden su memoria para formarse de experiencias pasadas. Las LSTM admiten a las redes neuronales recurrentes para recordar sus entradas durante un largo período de tiempo. Esto se debe a que LSTM contiene su información en la memoria, que puede considerarse similar a la memoria de un ordenador, en el sentido que una neurona de una LSTM puede leer, escribir y borrar información de su memoria. Esta memoria se puede ver como una “celda” bloqueada, donde “bloqueada” significa que la célula decide si almacenar o eliminar información dentro (abriendo la puerta o no para almacenar), en función de la importancia que asigna a la información que está recibiendo. La asignación por su importancia se decide a través de los pesos, que se aprenden mediante el algoritmo de optimización, que define qué información es importante y cuál no (Gaset, 2022).

Estas redes aprenden de diversas formas y niveles, en la primera capa se identifican colores, formas simples y bordes. En la segunda capa, los colores y bordes se articulan y se pueden tratar como una sola imagen, en la tercera capa se obtiene la forma y se busca descifrar de qué objeto se trata (Machado, 2022). En la figura 2, se presenta la arquitectura típica de una red neuronal convolucional.

Figura 2

Arquitectura de redes neuronales convolucionales



Nota. La figura representa la arquitectura de las redes neuronales convolucionales. Las capas son las encargadas de encontrar los patrones (convoluciones) que más tarde permitirán clasificarla. Tomado de *Arquitectura de redes neuronales convolucionales, CNN Architecture*, Marjolein, s/f

La red inicia su entrenamiento con numerosos objetos y elementos como imágenes que contienen información de entrenamiento. Se utilizan cientos y hasta miles de imágenes, con bordes, colores y formas distintas, pero con características únicas, que la red neuronal podrá generalizar, de esta manera es como aprende a clasificar la información.

La red neuronal convolucional, puede reconocer información anteriormente vista, no solo para hallar información semejante, sino, que también poder estudiar objetos que

desconoce y relacionarlos con elementos semejantes. Para series de tiempo o señales de audio se utilizan convoluciones en 1D y para datos volumétricos se emplea las convoluciones 3D (Machado, 2022).

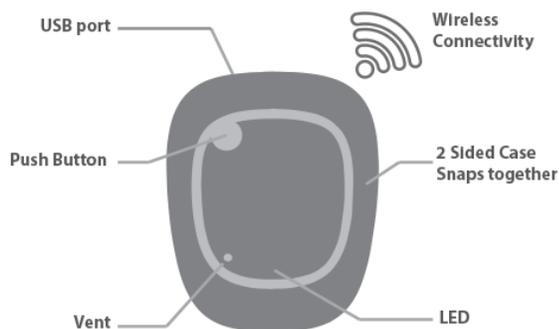
Las redes neuronales convolucionales (CNN) 1D se han convertido recientemente en la técnica más avanzada para aplicaciones de procesamiento de señales, como la clasificación de encefalogramas de pacientes específicos, la monitorización de la salud estructural, la detección de anomalías en circuitos electrónicos de potencia y la detección de fallos en motores.

Sensores de Tamaño Reducido que se Adaptan al Cuerpo

Uno de los sensores que se adapta fácilmente al cuerpo por su tamaño reducido y por las características que presenta es el MetaMotionS+. MetaMotionS+ combina las mediciones del giroscopio de 3 ejes, el sensor geomagnético de 3 ejes y un acelerómetro de 3 ejes, para proporcionar un vector de orientación. Es un dispositivo que puede llevarse en la muñeca y proporciona datos de sensores grabados (registro) o en tiempo real (transmisión). Todos los MetaSensors incluyen: una MCU ARM, Bluetooth Low Energy, memoria, un LED, un pulsador, una batería recargable. En la figura 3 se puede observar las partes constitutivas del sensor MetaMotion.

Figura 3

Partes constitutivas del sensor MetaMotion



Nota. Tomado de MetaMotionS, por MbientLab, 2020, (<https://mbientlab.com/metamotions/>).

Características Principales

- Giroscopio, acelerómetro, magnetómetro y fusión de sensores.
- Sensor de presión barométrica y luz ambiental.
- Comunicación en tiempo real mediante Bluetooth LE.
- Descarga rápida de los datos de los sensores mediante USB.
- Los datos también se pueden registrar en la memoria NAND Flash de 512 MB.
- Se puede añadir una funda resistente al agua a las bandas y más.
- Uso para aplicaciones de movimiento e investigación científica.
- APIs y Apps gratuitas y de código abierto para una rápida adquisición de datos.

En particular en esta investigación se utiliza el acelerómetro del módulo BMI270. Este modelo combina un acelerómetro y un giroscopio, por su bajo consumo, está perfeccionado para wearables que proporcionan una aceleración precisa, medición de la velocidad angular y funciones inteligentes de interrupción activados por movimiento en el chip. El sensor combina un giroscopio triaxial de 16 bits y un acelerómetro triaxial de 16 bits, dispone de una tecnología de giroscopio probada en automoción de Bosch (*Inertial Measurement Unit BMI270, s/f*).

Especificaciones Técnicas del Acelerómetro

En la tabla 1, se presentan las características más relevantes del sensor.

Tabla 1

Características técnicas del acelerómetro

Parámetro	Dato técnico
Resolución digital	Acelerómetro (A): 16 bits o 0,06 mg/LSB

Parámetro	Dato técnico
	Giroscopio (G): 16 bits o 0,004 dps/LSB
Rango de medición y sensibilidad programables	(A): ± 2 g: 16384 LSB/g (A): ± 16 g: 2048 LSB/g

Los rangos de medición en conjunto brindan la posibilidad para una detección en los cambios de aceleración, de manera efectiva y precisa.

La fusión de sensores combina las mediciones del giroscopio de 3 ejes, el sensor geomagnético de 3 ejes y un acelerómetro de 3 ejes, para proporcionar un vector de orientación absoluta robusto en forma de Quaternion o ángulos de Euler. El algoritmo fusiona los datos brutos de los sensores de forma inteligente para mejorar los resultados de cada uno de ellos. Esto incluye algoritmos para la calibración offset de cada sensor, la monitorización del estado de calibración y la fusión del filtro de Kalman para proporcionar vectores de orientación refinados y sin distorsiones (*Wrist Band Kit for MMRL or MMS – MBIENTLAB, s/f*).

Colocación del Sensor en la Muñeca de la persona

La colocación del sensor en la muñeca, facilita la accesibilidad y libertad de movimientos por parte del usuario, es fácil colocar y quitar el dispositivo, según (Ordóñez, 2016), “la aceptación por parte del usuario es significativamente mayor, dado que las personas ya están acostumbradas a utilizar un reloj”, además, desde décadas atrás, los relojes son socialmente admitidos, tienen poca probabilidad de que se quede asido en la ropa, en comparación con dispositivos que son ubicados en la cintura o en el tobillo. En conclusión, la ubicación es cómoda, por ende, el usuario no sentirá molestias al usarlo por largos periodos de tiempo. Finalmente, la muñeca es una parte del cuerpo que se mueve considerablemente durante las actividades diarias, lo que brinda datos de movimiento variados para el análisis.

Base de Datos

La base de datos para el presente proyecto fue obtenida de UC Irvine Machine Learning Repository, en este repositorio se encuentran diversas bases de datos donadas por investigadores alrededor del mundo, la base de datos utilizada para este proyecto, lleva como nombre "Simulated Falls and Daily Living Activities Data Set", la cual dispone de información de 17 voluntarios que ejecutaron 20 caídas y 16 actividades de la vida diaria con 5 repeticiones mientras llevaban 6 sensores (3.060 instancias) que se colocaron en la cabeza, el pecho, la cintura, la muñeca, el muslo y el tobillo (Ahmet Zdemir, 2014).

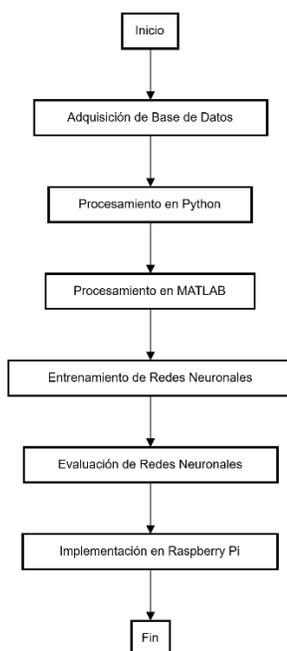
Capítulo III

Desarrollo e Implementación del Sistema

El presente capítulo describe el desarrollo y la implementación del sistema inteligente de alerta ante caídas de adultos mayores, de manera general, el diagrama de flujo del trabajo se presenta en la figura 4.

Figura 4

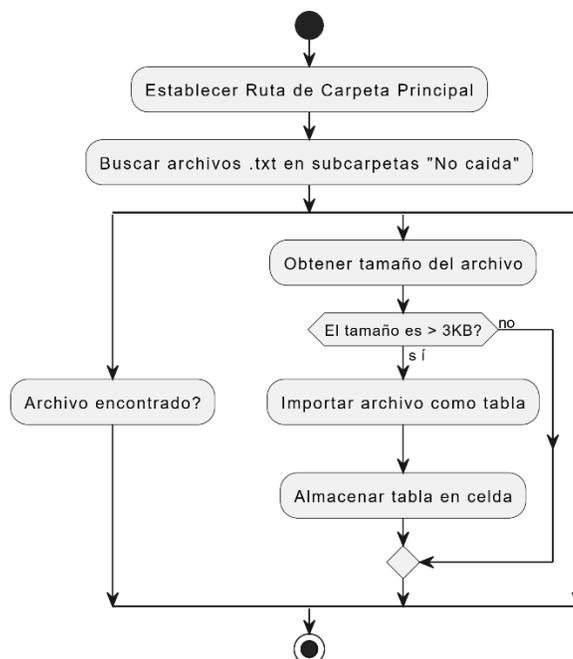
Diagrama de trabajo del desarrollo del proyecto



La base de datos (descrita en el capítulo 2), está dividida en varias carpetas. Se consideran los valores de entrenamiento, los datos de las carpetas “Caídas”, y “No caídas”, teniendo en cuenta la distribución original de ésta. Se implementó el código representado en el diagrama de flujo presentado en la figura 5.

Figura 5

Algoritmo para recuperar datos desde carpetas

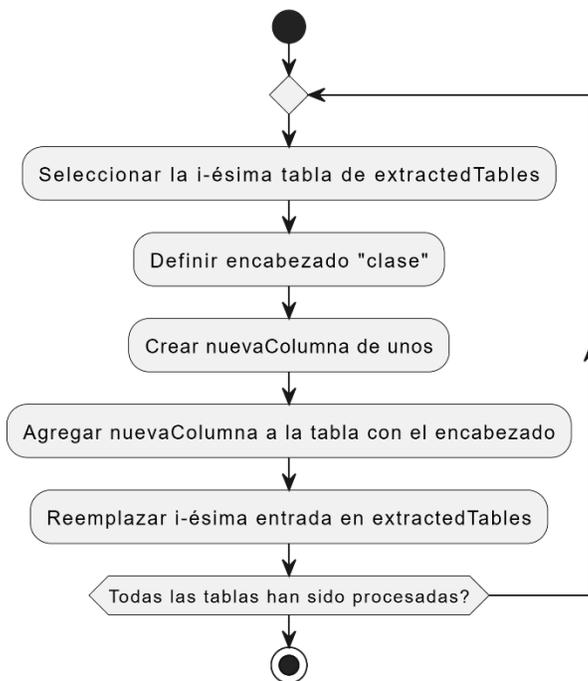


En el diagrama de flujo, presentado en la figura 5, inidca el algoritmo utilizado para recuperar datos a partir de documentos con extensión txt, el algoritmo se repite para las subcarpetas “Caída”. este código está diseñado para escanear una estructura de carpetas específica en busca de archivos de texto dentro de la subcarpeta llamada "No caída". Si encuentra dichos archivos y superan un tamaño determinado, los procesa y almacena su contenido en una estructura específica.

Dado que se trata de una base de datos, no se encuentran los identificadores de caída y no caída, es por ello que mediante el algoritmo presentado en la figura 6, fue añadida esta variable, tomando los valores de 0 y 1 para cada caso.

Figura 6

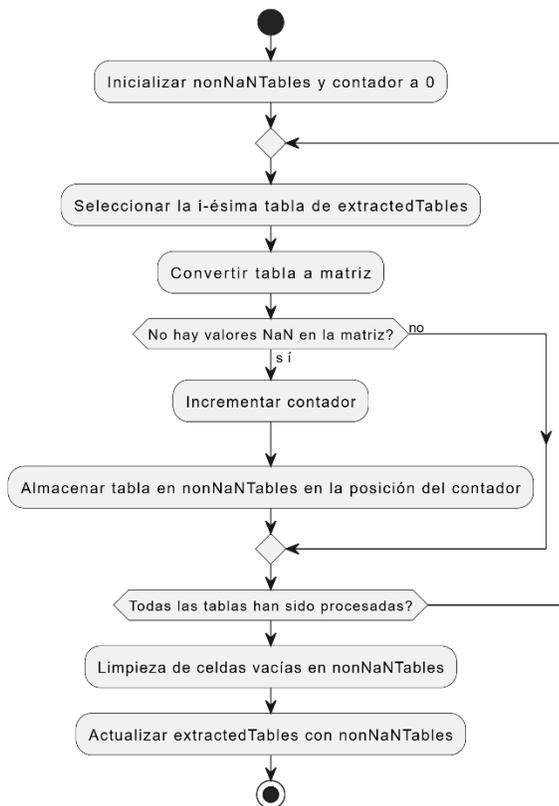
Algoritmo para la inclusión de una nueva variable en las tablas obtenidas



Los datos extraídos de la base de datos tienen características diferentes, entre ellas se encuentran espacios vacíos, que son borrados para evitar conflictos en el procesamiento de los datos en los pasos siguientes, para ello, se implementó el algoritmo presentado en la figura 7 para la eliminación de las tablas que contengan datos "NaN", que no son más que datos perdidos, corruptos, o datos que no pudieron ser importados de manera correcta.

Figura 7

Algoritmo de eliminación de datos no válidos



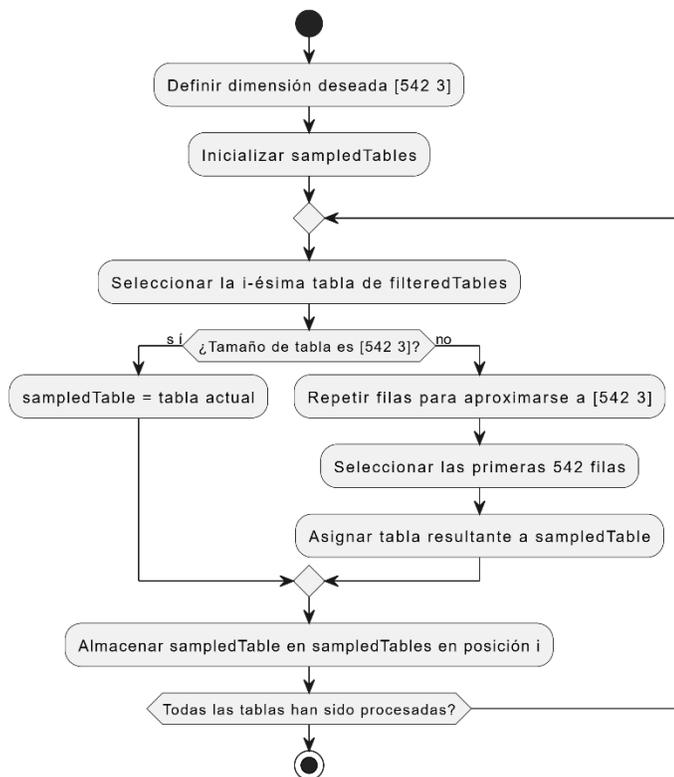
Con este algoritmo, se logra que los datos no tengan espacios vacíos que dificulten el procesamiento, haciendo énfasis en los datos NaN.

Una vez obtenidos los datos correspondientes, es necesario crear tablas con la forma de ventanas, para dividir los datos de cada tipo de caída o no caída obtenidas a raíz del procesamiento anterior.

El algoritmo presentado en la figura 8, se encarga de ajustar la dimensión de las tablas y organizarlas para el procesamiento posterior.

Figura 8

Cambio de dimensión de las tablas obtenidas

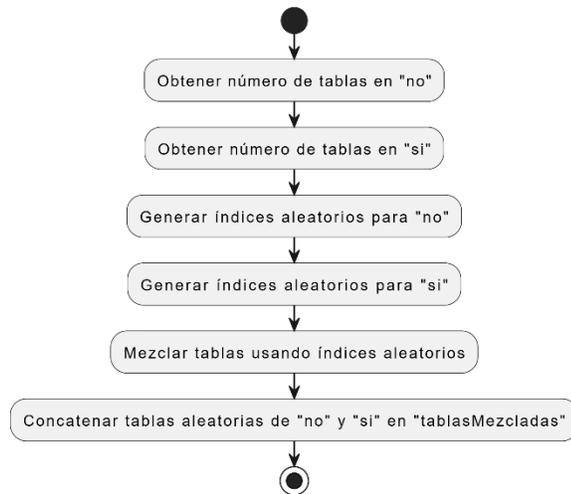


Una vez ejecutado este algoritmo, se obtienen tablas con la dimensión de 542 x 3, que corresponden a los datos de aceleración de los 3 ejes.

Hasta ahora los datos, se han tratado de manera secuencial, es decir que los datos se encuentran ordenados “No caída” y “caída”, esto presenta un problema, para el procesamiento posterior, para solucionar este inconveniente se implementó el algoritmo presentado en la figura 9, para realizar una mezcla aleatoria de las tablas ya obtenidas.

Figura 9

Algoritmo de aleatoriedad para la distribución de los datos

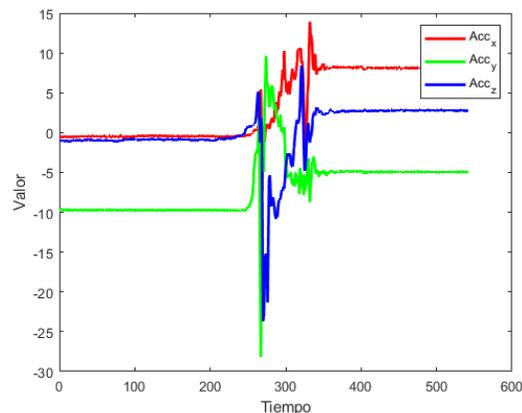


Con este algoritmo se obtiene una matriz totalmente aleatorizada, que permitirá más adelante entrenar de manera correcta las redes neuronales implementadas.

En la figura 10, se presenta una muestra de cómo se ven los datos de una caída, en la misma se presentan las aceleraciones en los ejes x, y, z.

Figura 10

Ejemplo de datos ante una caída



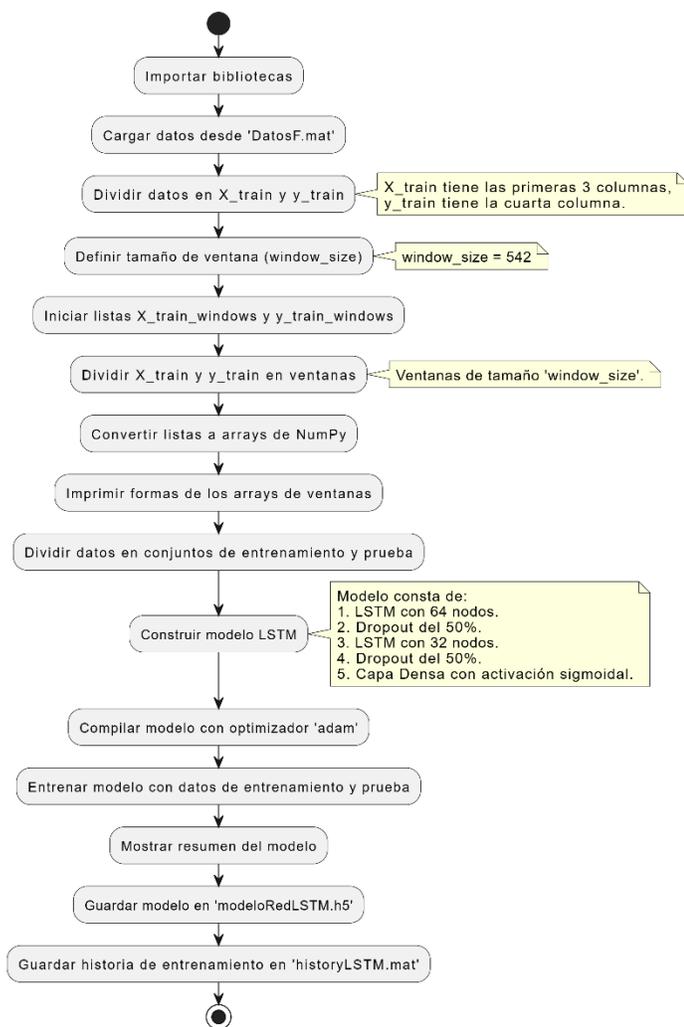
Entrenamiento de Redes Neuronales

Las redes neuronales utilizadas son la red LSTM que significa “Long Short-Term Memory”, este tipo de red neuronal trabaja con secuencias y puede recordar cosas por un periodo, en otras palabras, son equivalentes a la memoria de corto y largo plazo, recordando qué pasó antes para entender lo que está sucediendo en la actualidad. El otro tipo de red neuronal utilizada es una red convolucional 1D, se caracteriza porque busca patrones específicos en los datos, identificando las características claves.

Con este preámbulo, ambas redes hacen uso de los datos antes procesados, la representación del algoritmo completo para la implementación de la red neuronal LSTM se encuentra en el flujo indicado en la figura 11.

Figura 11

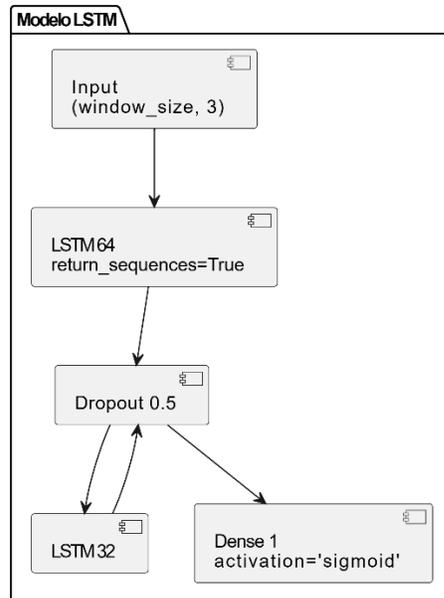
Algoritmo de entrenamiento y validación de la red neuronal LSTM



El diagrama anterior, muestra cuál es el proceso que se sigue, desde importar las librerías necesarias, cargar los datos, preprocesar los datos de entrenamiento, dividir los datos de entrenamiento en un 80% y los de validación en 20%, crear la red LSTM, entrenar el modelo y guardar la red obtenida. La representación simplificada del modelo se encuentra presentada en la figura 12.

Figura 12

Estructura de la red neuronal LSTM



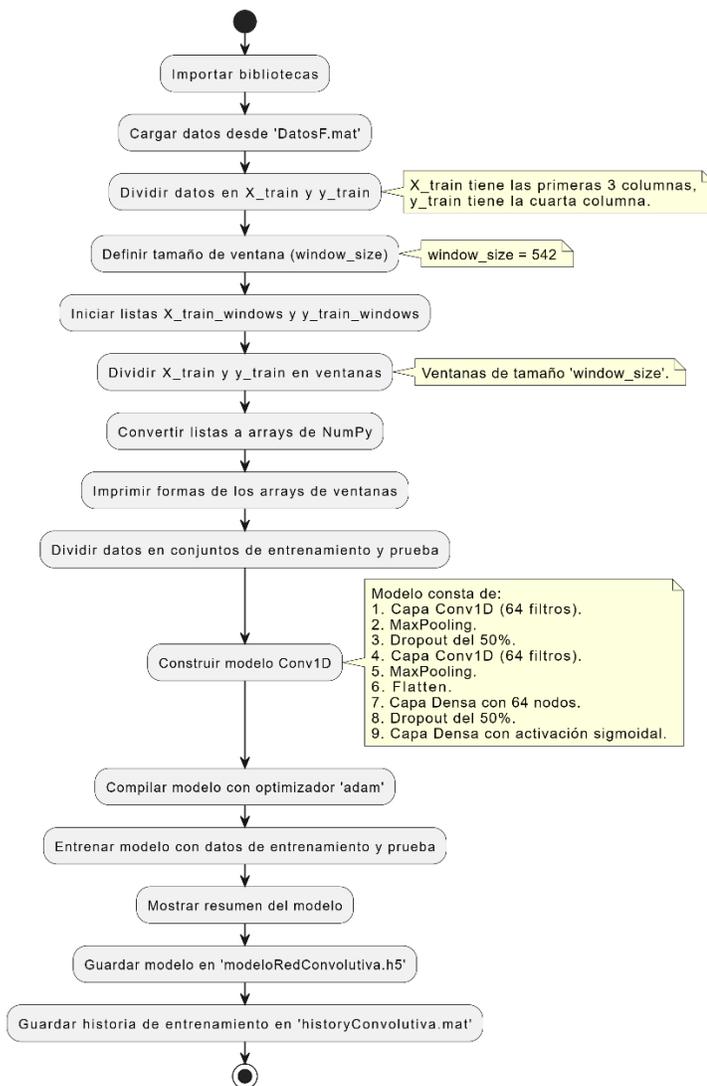
La estructura de la red se encuentra descrita a continuación.

- Capa de entrada con forma (window_size, 3).
- Una capa LSTM con 64 nodos que retorna secuencias.
- Una capa de Dropout al 50%.
- Otra capa LSTM, esta vez con 32 nodos.
- Otra capa de Dropout al 50%.
- Una capa densa de salida con 1 nodo y una activación sigmoideal.

El algoritmo para la implementación de la red neuronal convolucional 1D, inicialmente tiene la misma estructura que la anterior, con breves cambios en la implementación de la red como se describe a continuación:

Figura 13

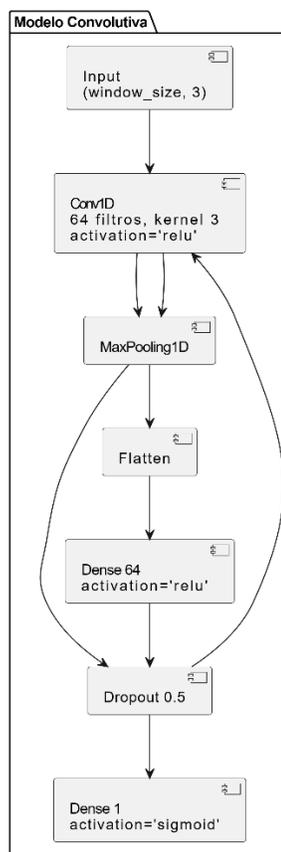
Algoritmo de entrenamiento y validación red neuronal Convolutacional



El diagrama anterior presentado en la figura 13, difiere con la red LSTM en la construcción del modelo, la que claramente posee otras características, las mismas que de manera general, se encuentran indicadas en la figura 14.

Figura 14

Estructura básica de la red neuronal convolucional



La estructura general de la red convolucional 1D se compone por:

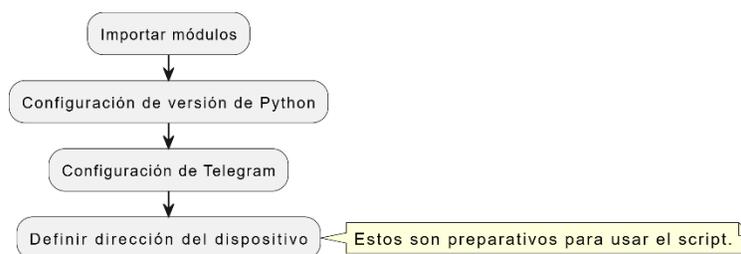
- Capa de entrada con forma (window_size, 3).
- Una capa Conv1D con 64 filtros y tamaño de kernel de 3.
- Capa de MaxPooling1D.
- Capa de Dropout al 50%.
- Otra capa Conv1D con 64 filtros y tamaño de kernel de 3.
- Otra capa de MaxPooling1D.
- Una capa Flatten.
- Capa densa con 64 nodos y activación ReLU.

- Capa de Dropout al 50%.
- Capa densa de salida con 1 nodo y activación sigmoïdal.

La implementación del código para identificar caídas en ejecución se desarrolla sobre una Raspberry Pi, la misma que es capaz de ejecutar scripts en Python. Dado que el algoritmo es complejo, se encuentra dividido en varios flujos, iniciando con la configuración e importación de librerías.

Figura 15

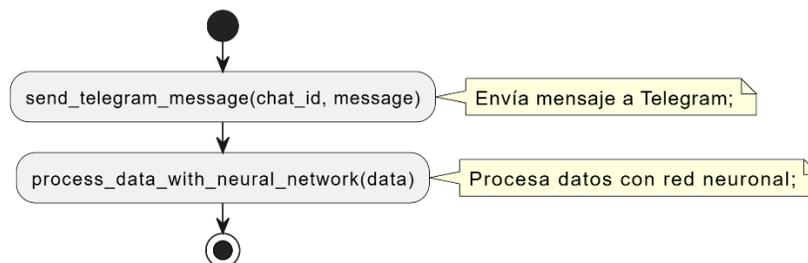
Pasos iniciales para la ejecución del script



Las librerías necesarias son scipy, numpy, tensorflow, que permiten el manejo de matrices de datos, fue necesario la configuración del “Token” de Telegram que es un identificador para el API del servicio de mensajes, pasando por crear y configurar un bot que permite la comunicación de las alertas de caídas y que se muestra en la figura 16.

Figura 16

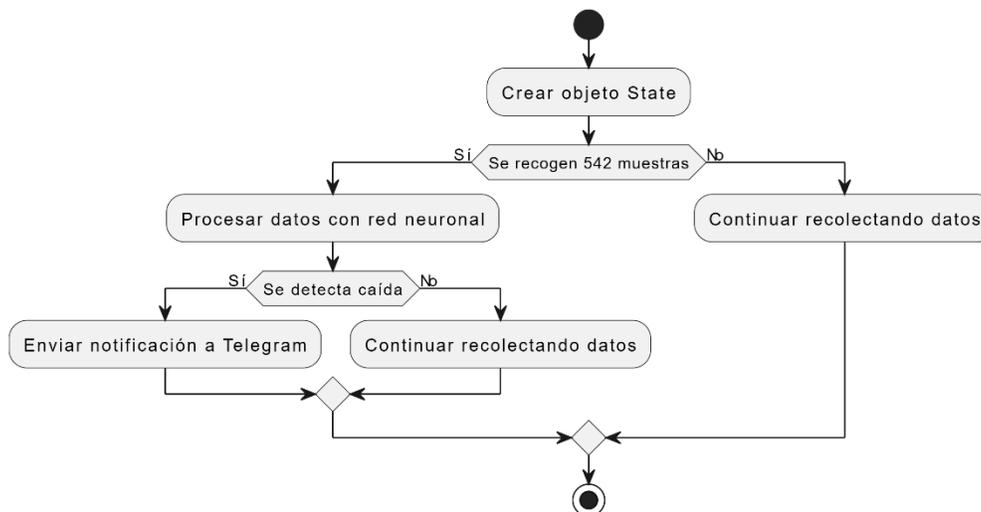
Funciones necesarias para el envío de mensajes y detección de caídas



El paso siguiente es configurar las funciones tanto para el envío de mensajes a Telegram como para el procesamiento de los datos con la red neuronal.

Figura 17

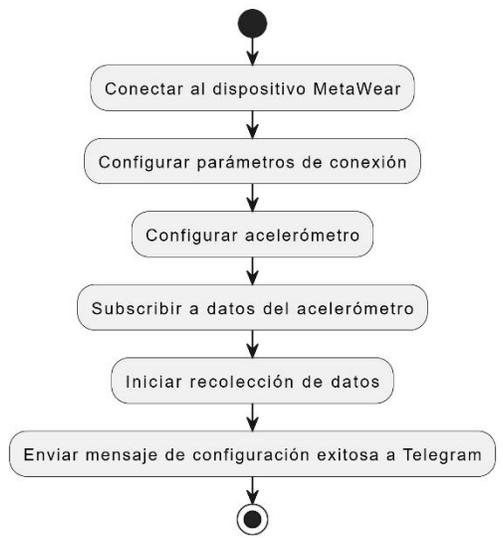
Diagrama de flujo para la recolección y procesamiento de datos del acelerómetro



La manera en la que se recolectan los datos es a través de ventanas de 542 muestras, dato que representa la forma en la que los datos de entrenamiento fueron estructurados, los datos son recolectados por el script hasta tener la forma adecuada, una vez que se cumple con esta condición se envía el mensaje de alerta a Telegram, y se evalúa con la red neuronal.

Figura 18

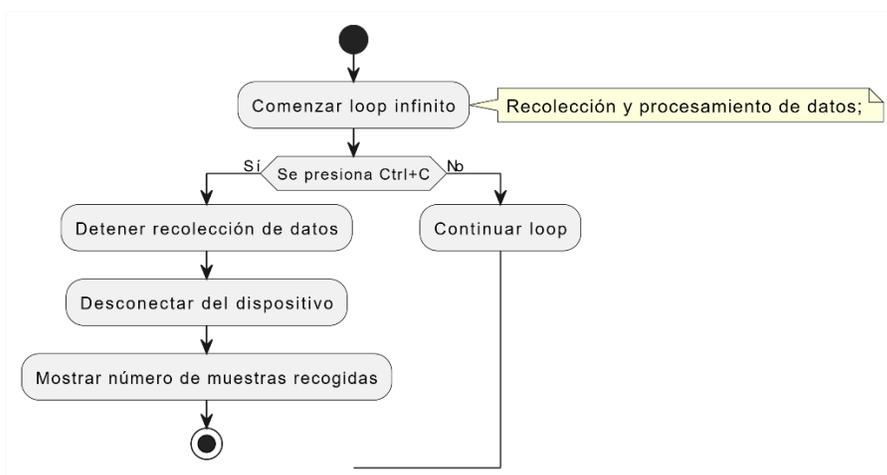
Secuencia de conexión y confirmación del dispositivo



El siguiente paso, como se presenta en la figura 18, es conectar el dispositivo MetaWear e iniciar la recolección de datos. Una que vez la configuración del dispositivo esté completa, se envía una notificación a Telegram.

Figura 19

Lazo de ejecución constante del script implementado



La ejecución del script está enfocada a ser de forma indefinida, para ello se encuentra implementado un lazo infinito.

Con la ejecución de los pasos anteriores, se logró la implementación del sistema, para la posterior evaluación del funcionamiento.

Capítulo IV

Análisis y Resultados

En esta sección se presentan los resultados obtenidos a partir de los algoritmos implementados, redes neuronales entrenadas y los resultados conseguidos de las alertas generadas.

Modelos de Red Empleadas

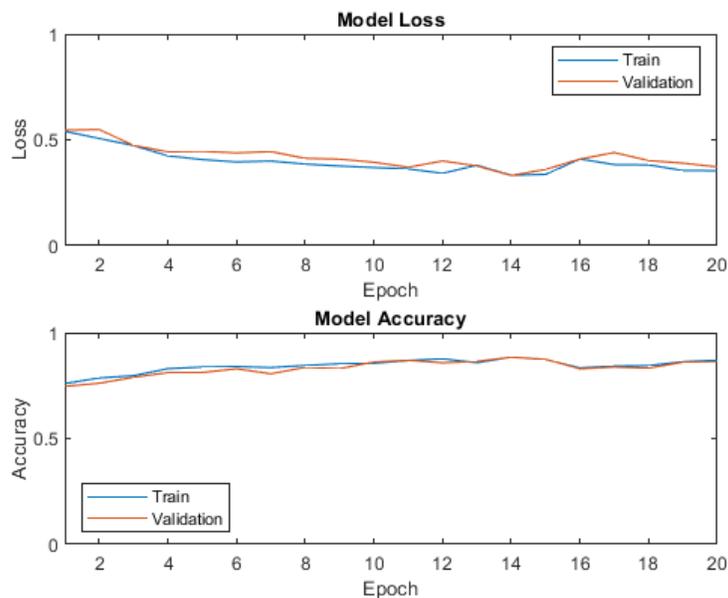
Cada una de las redes neuronales planteadas fueron entrenadas en ventanas de 542 x 3 datos, esto corresponde a los datos de aceleración en los ejes X, Y, Z. Con esta distribución de datos se consideró evaluar y seleccionar el modelo de red a ser utilizada en el proyecto. Para ello, se muestreó la base de datos y se separaron los datos que son más representativos para el entrenamiento. Las épocas seleccionadas en un principio fueron de diez, sin embargo, las redes neuronales tuvieron un margen de evolución mejorable, por lo que se consideró mejorar la evolución las épocas y se establecieron en cada caso, veinte; obteniendo los siguientes resultados.

LSTM

Después de aplicar el algoritmo correspondiente para crear el modelo de red neuronal LSTM, se obtuvo una precisión del 86.45 % y una pérdida de 0.35, valores que se ven reflejados en la figura 20, además se obtuvo el desarrollo del entrenamiento a través de veinte épocas planteadas. Dado que las curvas históricas del entrenamiento tienen una tendencia de convergencia, es decir las líneas de entrenamiento y validación se encuentran descendiendo y estabilizando el entrenamiento es efectivo, para el entrenamiento de esta red neuronal con un procesador de 4.4Ghz se tomó aproximadamente 10 minutos, dada la magnitud de los datos y las épocas anteriormente definidas.

Figura 20

Evolución histórica del entrenamiento y validación red neuronal LSTM

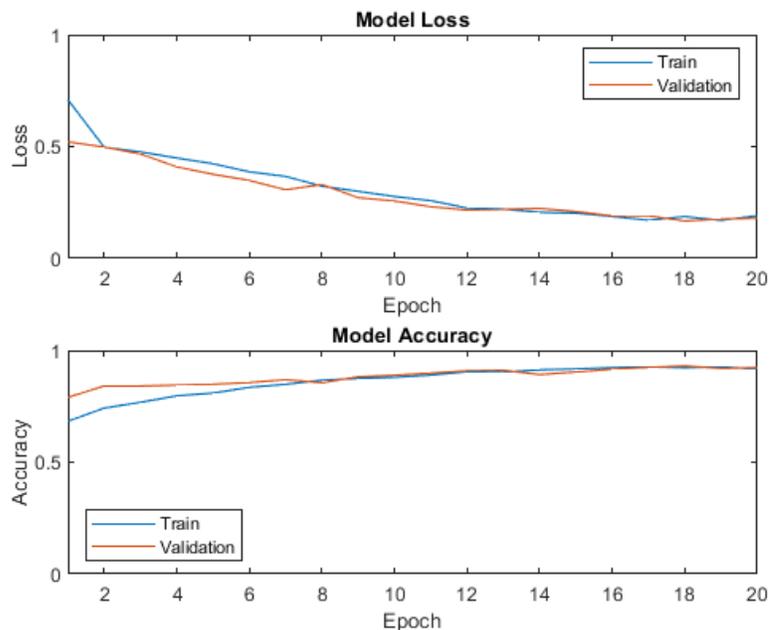


Red Convolutiva

En el caso de la red neuronal convolutiva 1D, el proceso fue similar, pero el tiempo de entrenamiento se vio reducido a aproximadamente en 5 minutos, manteniendo el mismo procesador utilizado para la red anterior. Este modelo de red neuronal obtuvo un 92.31% de precisión y una pérdida de 0.17 obteniendo valores más precisos con respecto a la red anterior. Finalmente, en la figura 21, se aprecia claramente que no existe un sobreajuste ni un desajuste dado que la línea de entrenamiento y validación se encuentran en convergencia durante el paso de las épocas.

Figura 21

Evolución histórica del entrenamiento y validación red neuronal Convolutiva



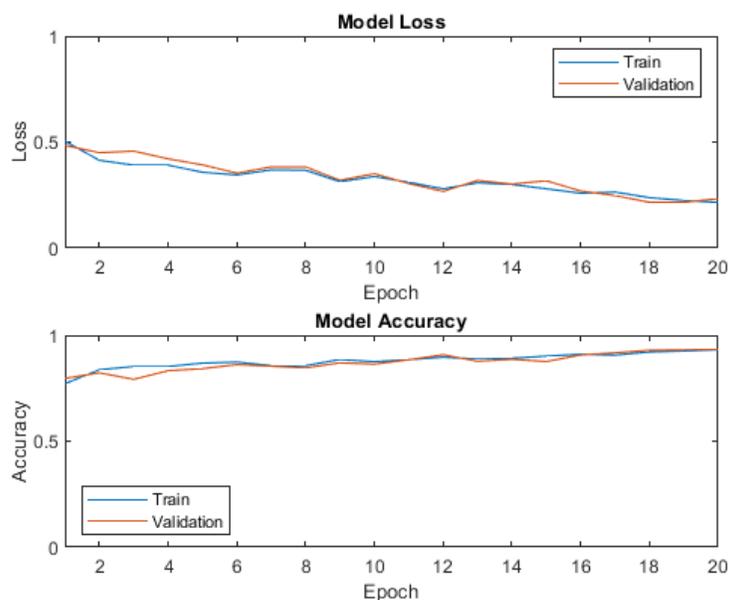
Con el fin de obtener una mejora se planteó la combinación de ambas redes neuronales esto en busca de un valor de precisión mayor y una pérdida menor, obteniendo el modelo combinado de ambas redes.

Red Combinada

El modelo de red neuronal que une lo mejor de ambas redes, obtuvo una precisión de 93.45% y una pérdida 0.21 y al considerar la gráfica histórica del entrenamiento se encontró nuevamente un comportamiento convergente, con esto se generaron 3 redes neuronales aceptables para ponerse en marcha sobre el algoritmo de reconocimiento de caídas.

Figura 22

Evolución histórica del entrenamiento y validación red neuronal combinada

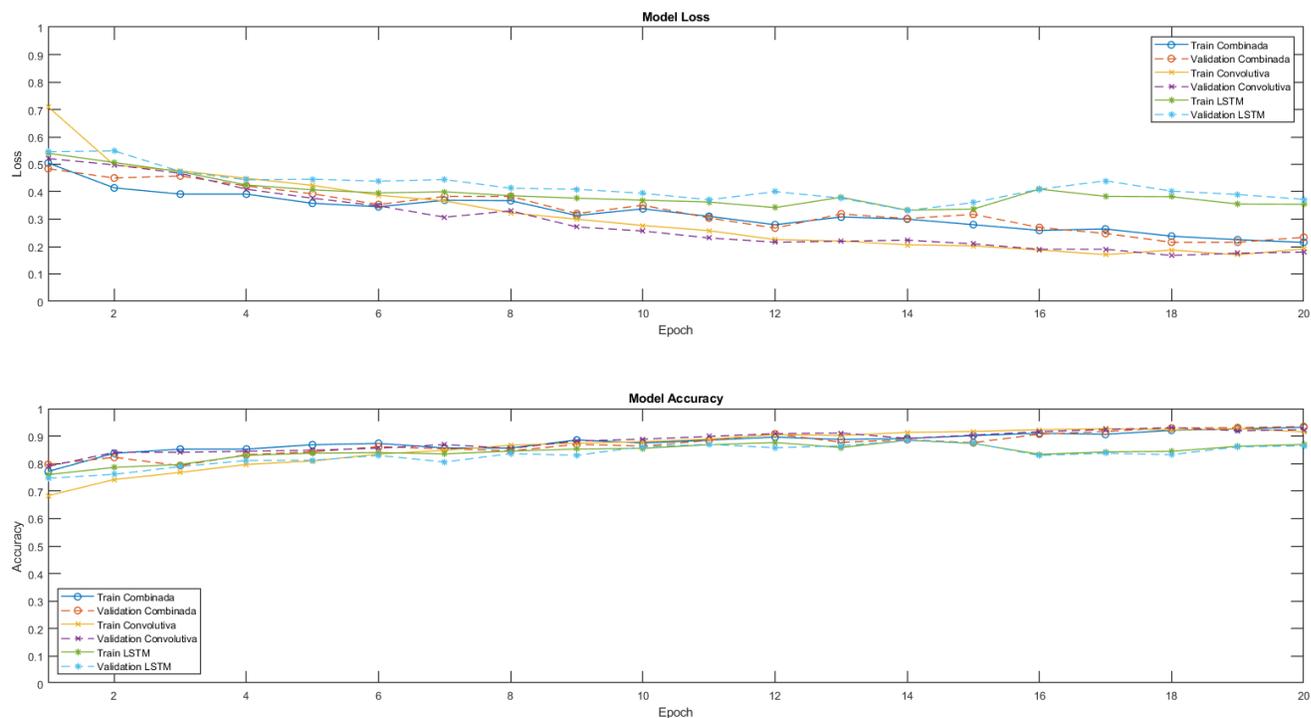


Comparación Entre los Tipos de Redes Neuronales Implementadas

Al comparar los tres modelos de redes neuronales se aprecia en el histórico, que en todos los casos se encuentra un modelo convergente, sin sobreajuste, además con los tres modelos se aprecia que al cotejar los valores de precisión y pérdida, la mejor red neuronal es la red convolucional pura, ya que tiene una precisión final de 92.31% de precisión y una pérdida de 0.17, el razonamiento detrás de esta elección se debe al valor de pérdida, buscando que el valor sea el mínimo, ya que en el entrenamiento de una red se busca maximizar la precisión y minimizar la pérdida.

Figura 23

Gráfico comparativo entre las redes neuronales



Generación Automática de Mensajes.

Para la verificación del funcionamiento del dispositivo, tanto en su etapa de conexión con el hub basado en una Raspberry Pi 4, cada vez que el dispositivo se conecta y se encuentra listo para el funcionamiento, envía un mensaje de confirmación y su dirección MAC a Telegram. Este servicio de mensajería fue elegido en base a su compatibilidad con los “bots”, esto se trata como un beneficio dado que los mensajes se envían mediante un script de Python, como se muestra en el diagrama de flujo de la sección de implementación.

En el caso de detectarse una caída del mensaje, se distribuye a los usuarios registrados en el script, los mismos que son registrados mediante el bot de telegram. Con esto se obtiene un mensaje de ayuda a diversos usuarios sin importar el sistema operativo que tengan en su

equipo móvil, incluso telegram tiene una versión para computadoras, por ende, el mensaje puede ser administrado por varios interesados del adulto mayor que lleva el dispositivo.

Figura 24

Captura de los mensajes automáticos generados



Capítulo V

Conclusiones y Recomendaciones

Conclusiones y Recomendaciones

- El uso de redes neuronales para la detección de caídas fue factible de implementarlo a partir de una base de datos externos. La red neuronal convolucional desarrollada fue la más rápida y requirió menos épocas, trabajando con los datos del sensor metawear.
- En este estudio, se probaron tres tipos de redes neuronales para los datos del sensor, la que obtuvo mayor rendimiento fue la red convolucional 1D, ya que tiene una precisión final del 92.31% y una pérdida datos de 0.17.
- Para el tratamiento de los datos, es importante la forma en la que estos sean recogidos, la frecuencia de muestreo y la magnitud de la escala de aceleración, lo cual se debe considerar para obtener predicciones aceptables.
- El tiempo de entrenamiento de las redes neuronales depende de la magnitud de la base de datos usada y del equipo informático usado, así como también de las características de la red neuronal, por ello, antes de iniciar con el entrenamiento de una red neuronal, es importante estudiar el dispositivo sobre el cual se va a realizar.
- Los dispositivos wereables, además de ser no invasivos, facilitaron la toma de datos en tiempo real. Estos dispositivos poseen diversos sensores que podrían ser empleados para ampliar y complementar este estudio.
- El método de detección de caídas desarrollado en este estudio permitiría atender emergencias de manera rápida, bajando así el tiempo de respuesta tanto de cuidadores como de usuarios a cargo de adultos mayores ante una alerta de caída.
- Debido a la estructura de conexión Bluetooth, el sistema permite conectar hasta un máximo de 20 dispositivos al mismo tiempo.

- El presente proyecto abre un camino para investigaciones posteriores y aplicaciones en campo, dado que la estructura de conexión no se limita a un solo dispositivo de toma de datos.
- Si se busca mejorar la precisión de la red neuronal es de vital importancia aumentar el número de datos con el que se entrenan las redes neuronales o en su defecto variar los parámetros como número de neuronas, función de activación, y demás aspectos configurables en cada tipo de red.

Bibliografía

- Ahmet Zdemir, B. B. (2014). *Simulated Falls and Daily Living Activities Data Set* [dataset]. UCI Machine Learning Repository. <https://doi.org/10.24432/C52028>
- Arquitectura de redes neuronales convolucionales | CNN Architecture | Marjolein.* (s/f). Recuperado el 20 de agosto de 2023, de <https://marjolein-teeppen.com/es/que-es-la-arquitectura-de-redes-neuronales-convolucionales/>
- Caídas.* (2021, abril 26). <https://www.who.int/es/news-room/fact-sheets/detail/falls>
- CDC.* (2020, noviembre 23). <https://www.cdc.gov/falls/data/index.html>
- Chaudhuri, S., Thompson, H., & Demiris, G. (2014). Fall Detection Devices and Their Use With Older Adults: A Systematic Review. *Journal of Geriatric Physical Therapy*, 37(4), 178. <https://doi.org/10.1519/JPT.0b013e3182abe779>
- Díaz Oquendo, D., Barrera García, A. C., & Pacheco Infante, A. (1999). Incidencia de las caídas en el adulto mayor institucionalizado. *Revista Cubana de enfermería*, 15(1), 34–38.
- Ferro, C., Celis Mayorga, N., & Casallas García, A. (2020). *Llenado de series de datos de 2014 a 2019 de PM2.5 por medio de una red neuronal y una regresión lineal.* <https://doi.org/10.13140/RG.2.2.35092.53126>
- Inertial Measurement Unit BMI270.* (s/f). Bosch Sensortec. Recuperado el 20 de agosto de 2023, de <https://www.bosch-sensortec.com/products/motion-sensors/imus/bmi270/>
- Kudo, M., Toyama, J., & Shimbo, M. (1999). Multidimensional curve classification using passing-through regions. *Pattern Recognition Letters*, 20(11–13), 1103–1111. [https://doi.org/10.1016/S0167-8655\(99\)00077-X](https://doi.org/10.1016/S0167-8655(99)00077-X)
- Machado, B. (2022, octubre 7). Redes Neuronales Convolucionales: ¿Qué son? *Signos Comunicación Visual.* <https://signoscvc.com/redes-neuronales-convolucionales-que-son/>

MetaMotionS – MbientLab. (s/f). Recuperado el 20 de agosto de 2023, de <https://mbientlab.com/tutorials/MetaMotionS.html>

Montesinos, L., Castaldo, R., & Pecchia, L. (2018). Wearable Inertial Sensors for Fall Risk Assessment and Prediction in Older Adults: A Systematic Review and Meta-Analysis. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(3), 573–582. <https://doi.org/10.1109/TNSRE.2017.2771383>

Nguyen, H., Mirza, F., Naeem, M. A., & Baig, M. M. (2018). Falls management framework for supporting an independent lifestyle for older adults: A systematic review. *Aging Clinical and Experimental Research*, 30(11), 1275–1286. <https://doi.org/10.1007/s40520-018-1026-6>

Ordóñez, J. L. (2016). Dispositivos y tecnologías wearables. *ACTA. Recuperado de: <https://s3.amazonaws.com/academia.edu/documents/56040178/FundamentosWearables.pdf>*

Pang, I., Okubo, Y., Sturnieks, D., Lord, S. R., & Brodie, M. A. (2019). Detection of Near Falls Using Wearable Devices: A Systematic Review. *Journal of Geriatric Physical Therapy*, 42(1), 48. <https://doi.org/10.1519/JPT.0000000000000181>

Qué es Wearable—Definición, significado y ejemplos. (2020, enero 28). <https://www.arimetrics.com/glosario-digital/wearable>

Raspberry Pi 4: Análisis y valoración de este mini ordenador. (2019, julio 30). RedesZone. <https://www.redeszone.net/analisis/otros-dispositivos/raspberry-pi-4-analisis/>

Rucco, R., Sorriso, A., Liparoti, M., Ferraioli, G., Sorrentino, P., Ambrosanio, M., & Baseliace, F. (2018). Type and Location of Wearable Sensors for Monitoring Falls during Static

and Dynamic Tasks in Healthy Elderly: A Review. *Sensors*, 18(5), Article 5.

<https://doi.org/10.3390/s18051613>

Silva de Lima, A. L., Evers, L. J. W., Hahn, T., Bataille, L., Hamilton, J. L., Little, M. A., Okuma, Y., Bloem, B. R., & Faber, M. J. (2017). Freezing of gait and fall detection in Parkinson's disease using wearable sensors: A systematic review. *Journal of Neurology*, 264(8), 1642–1654. <https://doi.org/10.1007/s00415-017-8424-0>

Solé, R. (2021, julio 18). Raspberry Pi: Qué es, para qué sirve y qué podemos hacer. *Profesional Review*. <https://www.profesionalreview.com/2021/07/18/que-es-raspberry-pi/>

Sun, R., & Sosnoff, J. J. (2018). Novel sensing technology in fall risk assessment in older adults: A systematic review. *BMC Geriatrics*, 18(1), 14. <https://doi.org/10.1186/s12877-018-0706-6>

Vellas, B. J., Wayne, S. J., Romero, L. J., Baumgartner, R. N., & Garry, P. J. (1997). Fear of falling and restriction of mobility in elderly fallers. *Age and Ageing*, 26(3), 189–193. <https://doi.org/10.1093/ageing/26.3.189>

Wrist Band Kit for MMRL or MMS – MBIENTLAB. (s/f). Recuperado el 20 de agosto de 2023, de <https://mbientlab.com/store/wrist-band-kit-for-mmrl/>

Anexos