

APLICACIONES DE LOS SENSORES INERCIALES DE RELOJES INTELIGENTES EN PRL Y SALUD

Ignacio Pavón García^{1*}, Carlos Polvorinos-Fernández¹, César Asensio Rivera¹, Juan Manuel López Navarro¹, Luis Francisco Sigcha², Guillermo De Arcas Castro¹

¹ Grupo de Investigación en Instrumentación y Acústica Aplicada. Universidad Politécnica de Madrid, Madrid, España

² Data-Driven Computer Engineering (D2iCE) Group, Department of Electronic and Computer Engineering, University of Limerick, Limerick, V94 T9PX, Ireland

RESUMEN

Los actuales relojes inteligentes incluyen sensores inerciales de tipo MEMS (*microelectromechanical systems*) que permiten medir aceleración y velocidad angular que pueden ser utilizadas para distintas aplicaciones de captura y análisis de movimiento con aplicación en los ámbitos de la salud y la prevención de riesgos laborales (PRL), entre otros.

En esta comunicación se presentan varias experiencias de uso de este tipo de tecnología, como pueden ser la determinación del tipo de máquina utilizada y la tarea ejecutada por un trabajador, o la evaluación y seguimiento de trastornos del movimiento relacionado con enfermedades de tipo neurodegenerativo.

ABSTRACT

Current smartwatches include inertial sensors of the MEMS (*microelectromechanical systems*) type that measure acceleration and angular velocity which can be used for different applications of motion capture and analysis with applications in the fields of health and occupational risk prevention (ORP), among others.

In this communication, several experiences of use of this type of technology are described, such as the determination of the type of machine used and the task performed by a worker, or the evaluation and monitoring of movement disorders related to neurodegenerative diseases.

Palabras Clave— Relojes inteligentes, inteligencia artificial, prevención de riesgos laborales, salud

1. INTRODUCCIÓN

Los *wearables* son dispositivos electrónicos diseñados para ser llevados en el cuerpo, ya sea como accesorios o en la ropa. Estos dispositivos han revolucionado la forma en que interactuamos con la tecnología, ya que se integran perfectamente en nuestra vida cotidiana gracias a los avances en electrónica de consumo, miniaturización y telecomunicaciones de los últimos años.

Este tipo de dispositivos suelen tener incorporados sensores inerciales de tipo MEMS (*microelectromechanical systems*) como los acelerómetros y los giroscopios. [1]

Los acelerómetros permiten registrar la aceleración de un objeto en una o más direcciones. Su funcionamiento se basa en la detección de la aceleración relativa experimentada por la masa suspendida con respecto a la estructura de soporte y, la convierte en una señal eléctrica proporcional, que representa la magnitud y dirección de la aceleración aplicada. Los giroscopios miden la velocidad angular de un objeto, a partir de la orientación o rotación de un objeto en el espacio, basándose en el principio de conservación del momento angular, que establece que un objeto en rotación tiende a mantener su eje de rotación invariable a menos que se aplique un momento externo para cambiar su dirección de rotación.

Con estos sensores, se pueden medir una amplia variedad de datos biométricos y parámetros relacionados con el movimiento, la frecuencia cardíaca o el sueño, entre otros. Por lo que estos datos pueden ser utilizados en multitud de aplicaciones, como puede ser la evaluación de la actividad física o la monitorización de la salud de las personas [2].

En la actualidad, esta tecnología está cada vez más presente en la sociedad [3]. Uno de los *wearables* más utilizados son los relojes inteligentes, ya que combinan las funcionalidades de un dispositivo inteligente en un formato reducido, portable y fácil de utilizar. Una de las grandes ventajas de estos dispositivos, y que potencia la utilidad y precisión de los datos recogidos por los sensores, es su colocación en el cuerpo humano, al situarse en la zona del antebrazo y estar en contacto directo con la piel de los usuarios. Esto facilita la utilización de sensores especializados para medir pulso, temperatura, sudoración, presión y otras muchas variables, que permiten que la información medida sea más variada, amplia, de mejor precisión y de mayor utilidad.

Todo esto, combinado con las características técnicas propias de los relojes inteligentes (velocidad de procesamiento, almacenamiento de datos, conexión inalámbrica o facilidad de uso diario), hacen que estos dispositivos tengan el potencial para el desarrollo de una amplia variedad de funcionalidades como, por ejemplo, la detección de caídas, navegación en entornos de realidad aumentada, o mejorar la seguridad y la toma de decisiones en situaciones de riesgo.

Unos de los campos donde la utilización de relojes inteligentes ha supuesto un gran cambio es en el ámbito del reconocimiento de actividades humanas, sobre todo para la prevención de riesgos laborales (PRL), y la monitorización de la salud de las personas. En este trabajo se presentan varias experiencias de uso de este tipo de tecnología en estos dos ámbitos.

2. MÉTODOS

Para cualquier tipo de uso, el proceso comienza con la adquisición de datos del reloj inteligente que lleva el usuario, ya sea a través de aplicaciones desarrolladas o comerciales preinstaladas en el dispositivo.

En los casos expuestos en este documento, se empleó una aplicación Android desarrollada por el proyecto TECAPARK [4], la cual permite el registro de los datos de los acelerómetros y giroscopios de un reloj inteligente comercial. Tras el registro inicial de los datos, se realiza un preprocesamiento necesario para que los algoritmos y modelos de inteligencia artificial tengan rendimiento adecuado. Posteriormente, se realiza el etiquetado de los datos, de forma manual o automática, según la aplicación. Seguidamente, se procede a la extracción de características que serán utilizados para el entrenamiento de modelos de inteligencia artificial.

Según la aplicación, se requerirán unas características u otras. Existen un amplio abanico de posibilidades en la bibliografía. En la Tabla 1 se muestra un resumen de las principales características para caso de uso.




Figura 1. Flujo de trabajo seguido en los casos de uso

A partir de esta etapa, se puede realizar el desarrollo y entrenamiento de modelos de inteligencia artificial, pudiendo ser algoritmos de aprendizaje automático, aprendizaje profundo, redes neuronales, etc.

En la Figura 1 se muestra el proceso expuesto.

Tabla 1: Características usadas en los casos de uso

Características	Número	Descripción
Estadísticos domino del tiempo	6	Desviación media, media, mediana, percentiles (25-75), oblicuidad
Estadísticos domino de la frecuencia	6	
Líneas espectrales de la FFT	128	128 líneas espectrales
HAR [5]	290	Reconocimiento automático de actividades humanas
Señal Cruda	(Muestras *3)	Señal triaxial bruta enventanada obtenida de los sensores
Específicas para el caso de salud		
MFCCs [6]	36 (12*3)	Coefficientes cepstrales en frecuencias de mel
Mahadevan et al. [7]	64 (8*8)	RMS, rango de la señal, entropía de la señal, frecuencia y magnitud dominantes, relación entre la banda de frecuencia dominante y la energía total, horizontalidad espectral, entropía espectral.
Hssayeni et al. [8]	39	Potencia en dos bandas específicas (4-6Hz y 0,5-15Hz), características de auto correlación, entropía espectral, primeras y segundas frecuencias dominantes y magnitudes, correlaciones cruzadas entre pares del eje.

A continuación, se exponen dos casos de uso. En primer lugar, se expondrá la aplicabilidad al ámbito de la PRL para la identificación de maquinaria utilizada y para la clasificación de tareas llevadas a cabo, y, posteriormente, se tratará el uso en el campo de la salud.

2.1. PRL

La evaluación de riesgos laborales no es ajena a la innovación tecnológica de los relojes inteligentes. Existen varias propuestas para la evaluación de riesgos en el puesto de trabajo gracias a los dispositivos de tipo *wearable* [9] [10]. Toda la información recolectada por los sensores de estos dispositivos proporciona información que puede ser usada para la gestión de riesgos al permitir a los responsables de salud y seguridad: identificar riesgos específicos;

perfeccionar las medidas para reducir las lesiones; crear una cultura de seguridad y educación en los trabajadores en el puesto de trabajo; y garantizar la productividad y la relación coste-beneficio para la empresa [11].

Uno de los riesgos típicos en determinados sectores es la exposición a las vibraciones, donde los trabajadores que utilizan herramientas en su día a día están expuestos a vibraciones transmitidas al sistema mano-brazo, como puede ser al utilizar herramientas manuales vibratorias, maquinaria móvil y fija o al conducir vehículos pesados. La exposición a la vibración transmitida al sistema mano-brazo es una de las principales causas de enfermedades profesionales como trastornos neurológicos o musculoesqueléticos, enfermedades vasculares y trastornos musculares que se manifiestan como dolor, entumecimiento, rigidez y disminución de la fuerza muscular [12]. Los procedimientos técnicos para la medición de la magnitud y la exposición a las vibraciones mano-brazo se definen en la norma ISO 5349 (las partes 1 y 2). Las evaluaciones del riesgo de exposición a las vibraciones suelen realizarse a partir de mediciones durante cortos periodos de tiempo, intentando obtener valores representativos de la exposición del trabajador durante una operación o un ciclo de trabajo.

En diferentes estudios se ha detectado que las mediciones realizadas siguiendo los procedimientos definidos muestran una gran variabilidad con los valores declarados por los fabricantes de máquinas y herramientas [13].

Por lo tanto, la evaluación de riesgos será más precisa cuando se realice con mediciones reales y se tenga en cuenta los factores que influyen en la incertidumbre de la medición, como las características del acelerómetro, los métodos de fijación y el tiempo de exposición [14].

Con el fin de resolver los problemas encontrados y mejorar los procedimientos de evaluación del riesgo de vibración es posible utilizar tecnología *wearable*. [15]

2.1.1 Identificación de Tareas

Uno de los casos de uso es la identificación de las tareas realizadas por operarios gracias a los datos recolectados por un reloj inteligente. En este caso, se registró la actividad de 2 técnicos de laboratorio durante 7 horas a lo largo de 10 días. En la Figura 2, se ilustran dos de las máquinas empleadas por dichos operarios.



Figura 2. Maquinaria empleada por los operarios de taller.

Durante ese tiempo, cada uno de los técnicos utilizó un reloj inteligente, registrando 3 señales del acelerómetro.

En la Figura 1 se describe el procedimiento seguido. Para este caso de uso, el preprocesado consiste en un filtrado de la señal mediante un filtro de Butterworth, seguido de un enventanado con ventanas de 256 muestras sin solapamiento. De dicha señal se obtuvieron, por un lado, características en el dominio del tiempo, y, por otro, después de aplicar una ventana de Hanning y transformada rápida de Fourier (FFT), características en el dominio de la frecuencia.

Además, a partir de las 3 señales de aceleración, se ha obtenido el valor RMS a partir de los 3 valores de aceleración obtenidos de cada reloj, de acuerdo con la ecuación 1:

$$\Sigma a_{xyz} = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (1)$$

La base de datos estaba compuesta por 420 características (140 por eje) junto a las 290 características obtenidas de la combinación de las 3 señales, según [5], utilizadas para el reconocimiento automático de actividades humanas.

A partir de dicha base de datos, se ha realizado un análisis de componentes principales (PCA) y se desarrollaron los modelos de clasificación de actividad, dividiéndolo en tres niveles. El nivel 0 diferencia entre el tiempo operativo y no operativo. El nivel 1 clasifica las tareas operativas entre mecanizado, programación y trabajo manual. Para la categoría “Trabajo Manual”, se diferencia entre el uso de sierra, taladrado y destornillador eléctrico. La jerarquía de clasificación se muestra en la Figura 3.




Figura 3. Niveles en la identificación de tareas.

En este caso, se han aplicado los siguientes modelos: *logistic regression*, *linear discriminant análisis*, *gradient boosting*, *Ada Boost*, *k-nearest neighbors*, *decision trees*, *SVC*, *linear SVC*, *MLPC*, *Random Forest*, *Gaussian NB*.

Tras el entrenamiento de estos modelos, se obtuvo que, para el nivel 0, el mejor clasificador se obtiene utilizando *Random Forest*, con 150 características, cuyas métricas son AUC de 0,859; F1-score de 0,776; y precisión de 0,777. En cuanto al nivel 1, la mejor precisión la tiene nuevamente el clasificador tipo *Random Forest*, con las métricas de la Tabla 2.

Tabla 2: Resultados del clasificador de Nivel 1 de tareas

Categoría	Precisión	Recall	F1-score	Exactitud
Mecanizado	0,67	0,63	0,65	0,6817
CAD	0,83	0,68	0,75	
Trabajo Man.	0,62	0,75	0,68	

A partir de este clasificador de tareas, se pueden desarrollar numerosos clasificadores de las tareas del nivel 1, como el que se plantea el siguiente apartado.

2.1.2 Identificación de Herramientas

Se desarrollaron clasificadores que permiten diferenciar entre 3 tipos de herramientas: taladros, sierras de calar y destornilladores eléctricos. Este clasificador se integraría dentro de la categoría de trabajo manual del nivel 1 del clasificador propuesto en el apartado anterior.

Además, se utilizaron 3 modelos diferentes de cada una de las categorías a predecir, con el fin de tener una amplia y variada base de datos. Por lo que, se desarrolló un segundo modelo que discriminaba entre el modelo utilizado.



Figura 4. Modelos usados en el desarrollo del clasificador

Cada herramienta se utilizó sobre la superficie adecuada para su uso: la taladradora se empleó sobre una pieza de mármol, y la sierra de calar y el destornillador se usaron sobre madera. La toma de datos se realizó llevando a cabo 3 registros de 90 segundos empleando las 9 herramientas.

Además, para aumentar la diversidad de la base de datos, se recopilaban datos de los sensores con 2 relojes diferentes.

Por lo tanto, la base de datos generada en este trabajo está compuesta por la señal de los 3 sensores de 2 relojes inteligentes diferentes utilizando 3 tipos de herramientas distintas y para cada tipo, 3 modelos diferentes (9 unidades).

A partir de dicha base de datos, se generó una segunda base de datos utilizando el valor RMS según la ecuación 1.

Con esto, se pudo trabajar con 2 bases de datos diferentes obtenidas a partir de la misma medida. Partiendo de estas, se ha seguido el procedimiento explicado en la Figura 1.

Particularizando el proceso, la extracción de características de la señal se llevó a cabo mediante un inventariado, con un tamaño de la ventana de 256 muestras y un solapamiento del 50%. Después, se usó una ventana Hanning antes de aplicar a la señal la transformada rápida de Fourier (FFT) con el objetivo obtener datos en el dominio de la frecuencia. Tras esto, se expresaron los resultados utilizando el nivel de aceleración (L_a) definido en la ecuación 2.

$$L_a = 20 \log \left(\frac{a}{10^{-6}} \right) \quad (2)$$

Además, para cada ventana, se obtuvieron características estadísticas en el dominio del tiempo y de la frecuencia.

Después, tras un análisis PCA, se desarrollaron los algoritmos de clasificación de tipo *Decision tree*, *Naive Bayes*, *K-nearest neighbor*, *Parzen classifier*, y los modelos no lineales *Fisher's Least Square Linear Discriminant*, *Logistic Linear*, *Nearest Mean*, *Polynomial classifier*.

En primer lugar, se ha desarrollado el clasificador del tipo de herramienta utilizada (taladro, sierra de calar o destornillador eléctrico). Se han planteado dos clasificadores diferentes en función de la base de datos: uno a partir de la señal de cada uno de los 3 ejes del acelerómetro, y otro a partir de la obtenida a partir del valor RMS de aceleración en los 3 ejes.

En segundo lugar, se ha plantado el clasificador de modelos de herramienta entre los 3 utilizados. En este caso, de igual manera que en el anterior clasificador, se han planteado dos clasificadores a partir de cada base de datos.

Una vez entrenados y validados, se pudo evaluar qué modelos y/o bases de datos ofrecían un mejor rendimiento en la clasificación de las herramientas.

Tabla 3. Resultados del clasificador de herramientas

Categoría	Extracción	Modelo	Precisión
Tipo de Herramienta	Señal Cruda	<i>Polynomial classifier</i>	95,5%
Modelo de Herramienta			
Taladros	Señal Cruda	<i>Parzen classifier</i>	91,0%
Sierra de Calar	Señal Cruda	<i>Parzen classifier</i>	90,4%
Destornillador	Señal Cruda	<i>Parzen classifier</i>	97,8%

2.2. Salud

En el ámbito de la salud, el uso de relojes inteligentes ha experimentado un crecimiento significativo en los últimos años. Son numerosos los autores que han realizado estudios médicos gracias al uso de este tipo de dispositivos: en [16] han desarrollado una aplicación que permite detectar paro cardíaco extrahospitalario; en [17] han estudiado la posibilidad de sustituir el diario de sueño por un reloj inteligente en las personas con trastornos del sueño; en [18] ha propuesto un sistema que predice caídas.

Se presenta el planteamiento para la evaluación y seguimiento de trastornos del movimiento relacionados con enfermedades de tipo neurodegenerativo. Concretamente, se ha trabajado en la evaluación de la constancia y amplitud del temblor de pacientes de Parkinson.

Para ello, se tomaron datos de 18 pacientes a lo largo de 2 a 8 semanas [4]. Mediante una serie de ejercicios pautados, se registraron los valores del acelerómetro del reloj inteligente de los pacientes.

Según la guía UPDRS sección 3.17, la amplitud del temblor se evalúa entre 0 (sin presencia de temblor) a 2 (temblor leve). Según la sección 3.18 de la misma guía, la constancia se califica como 0 (sin presencia temblor) a 4 (existe temblor en más del 75% del examen).

Como se observa en la Figura 5, se desarrollaron 3 modelos: un clasificador para saber si el paciente estaba en reposo, un detector de temblor, y, a partir de ambos, un evaluador de la amplitud y constancia del temblor.



Figura 5. Enfoque para la evaluación del temblor en reposo

Para el clasificador de contexto, se plantearon algoritmos diferentes, cada uno con una extracción de características particular, expuestas en la Tabla 1. En la Tabla 4 se muestran los resultados obtenidos. Se puede observar que el mejor clasificador de contexto se obtiene de la combinación de un modelo CNN multitarea entrenado con la señal medida.

Tabla 4. Resultados del clasificador de contexto

Características	Modelo	Sensibilidad	Especificidad	AUC
HAR [5]	<i>AdaBoost</i>	88.5%	88.6%	0.953
Señal cruda	CNN multitarea	92.9%	93.0%	0.981
FFT	CNN multitarea	89.0%	89.1%	0.960

Para el detector de temblor, de igual manera, se han propuesto varios algoritmos de inteligencia artificial y diferentes tipos de características, expuestas en la Tabla 1. El mejor clasificador se obtiene usando un modelo CNN con características de la FFT de la señal como se puede observar en la Tabla 5.

Tabla 5. Resultados del detector de temblores

Características	Modelo	Sensibilidad	Especificidad	AUC
MFCCs [6]	<i>AdaBoost</i>	82.6%	82.2%	0.905
Mahade van et al. [7]	<i>Random Forest</i>	82.3%	84.0%	0.893
Hssayeni et al. [8]	<i>Gradient Boost</i>	84.1%	84.0%	0.922
FFT	CNN multitarea	86.1%	86.1%	0.936

Por último, se evaluó de la amplitud y constancia del temblor en reposo en aquellas ventanas temporales en las que se detecta que el paciente está en reposo y se identifica la presencia de temblores.

Por un lado, se planteó un análisis espectral de las señales inerciales para realizar la evaluación de la amplitud del temblor, ya que, de acuerdo con la literatura, este presenta un aumento en el rango de frecuencia 3,5 a 7,5 Hz cuando el paciente presenta temblores en reposo.

Para proporcionar un indicador de amplitud se calculó el nivel de aceleración (L_a) de la amplitud RMS en la banda de temblor para cada ventana de análisis, según la ecuación 2. Siguiendo la metodología propuesta en [7], se ha comprobado que, utilizando el nivel L_a como indicador de magnitud del temblor en reposo, el percentil 75 logra una gran correspondencia con la evaluación clínica que se realiza según la guía UPDRS sección 3.17.

En la Figura 6, se muestra la concordancia entre el nivel de aceleración obtenido a partir de los modelos CNN multitarea (con FFT y con señal cruda) y la evaluación clínica UPDRS.




Figura 6. Concordancia entre los resultados del modelo CNN multitarea y la evaluación clínica

Por otro lado, para la evaluación de la constancia del temblor, se analizaron los datos de una visita semanal. Se compararon los segmentos en los que se detectaba que paciente estaba temblando con los segmentos en los que el paciente realmente lo hacía. En este caso, la comparación de los resultados de la constancia del temblor en reposo entre ambos segmentos se hizo en forma de porcentaje.

Como se muestra en la Figura 7, se encontró una fuerte correlación entre la constancia obtenida mediante la evaluación de video y los enfoques CNN multitarea.




Figura 7. Correlación del temblor medido y obtenido con el modelo CNN multitarea.

3. CONCLUSIONES

En este documento, se presentan dos casos de uso en los que se han utilizado los sensores inerciales de los relojes inteligentes. Estos sensores permiten registrar la aceleración y velocidad angular que pueden ser utilizadas para aplicaciones de captura y análisis de movimiento con aplicación en diferentes ámbitos.

Por un lado, se expone el uso de estos dispositivos en el ámbito de la prevención de riesgos laborales, mediante el desarrollo de clasificadores mediante técnicas de inteligencia artificial que permite diferenciar la tarea que está ejecutando un trabajador, además del tipo de herramienta que utiliza.

Los resultados obtenidos demuestran que es posible reconocer diferentes actividades en entornos laborales aplicando técnicas de inteligencia artificial mediante señales vibratorias. Además, se puede identificar el uso de tres máquinas vibratorias del tipo manual diferentes con una exactitud de hasta un 98%.

Por otro lado, en el ámbito de la salud, se ha presentado una herramienta que permite la evaluación y seguimiento de trastornos del movimiento relacionado con síntomas motores en pacientes de Parkinson.

Se ha demostrado que se puede identificar si un paciente presenta temblor y/o si está en reposo, con una precisión entre el 85 y 90%. Además, se puede realizar una evaluación de amplitud y constancia de dicho temblor en reposo, obteniendo una gran correlación entre los datos medidos por el especialista y los extraídos de los datos medidos, sentando las bases para el desarrollo futuro de un biomarcador digital.

Esta publicación es parte del Proyecto BIOCLITE PID2021-123708OB-I00, financiado por MCIN/AEI/10.13039/501100011033/FEDER, UE; y por las “Ayudas para contratos predoctorales para la realización del doctorado con mención internacional en sus escuelas, facultad, centros e institutos de I+D+i”, financiada por el Programa Propio I+D+i 2022 de la Universidad Politécnica de Madrid

4. REFERENCIAS

- [1] Jean-Michael, S., et al., «Market opportunities for advanced MEMS accelerometers and overview of actual capabilities vs. required specifications,» de *PLANS 2004. Position Location and Navigation Symposium*, Monterey, CA, USA, 2004.
- [2] Wright, R., et al., «Wearable Technology: If the Tech Fits, Wear It,» *Journal of Electronic Resources in Medical Libraries*, vol. 11, pp. 204-216, 2014.
- [3] Page, T., «A Forecast of the Adoption of Wearable Technology,» *International Journal of Technology Diffusion*, vol. 6, n° 2, pp. 12-19, 2015.
- [4] TECAPARK, «<https://www.i2a2.upm.es/tecapark/>».
- [5] San-Segundo, R., et al., «Robust Human Activity Recognition using smartwatches and smartphones,» *Engineering Applications of Artificial Intelligence*, vol. 72, pp. 190-202, 2018.
- [6] Zhang A., et al., «Automated Tremor Detection in Parkinson's Disease Using Accelerometer Signals,» de *Proceedings of the 2018 IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies*, New York, NY, USA, 2020.
- [7] Mahadevan, N, et al., «Development of digital biomarkers for resting tremor and bradykinesia using a wrist-worn wearable device,» *NPJ Digit Med*, 2020.
- [8] Hssayeni, M.D., et al., «Wearable Sensors for Estimation of Parkinsonian Tremor Severity during Free Body Movements,» *Sensors*, 2019.
- [9] Pavón, I., et al., «Wearable technology for occupational risk assessment: Potential avenues for applications,» de *Inter. Symposium Occupational Safety and Hygiene*, Guimarães, 2018.
- [10] Pavón, I., et al., «Wearable technology for occupational risk,» de *Occupational Safety and Hygiene VI, Proceedings of the 6th International Symposium on Occupation Safety and Hygiene (SHO 2018)*, Guimarães, Portugal, 2018.
- [11] Kritzler, M., et al., «Wearable technology as a solution for workplace safety,» *MUM 15: Proceedings of the 14th Int. Conference on Mobile and Ubiquitous Multimedia*, pp. 213-217, 2015.
- [12] South, T., *Managing noise and vibration at work*, London: Routledge, 2004.
- [13] Moschioni, G., et al., «Prediction of data variability in hand-arm vibration measurements,» *Measurement*, vol. 44, n° 9, pp. 1679-1690, 2011.
- [14] Ainsa, I., et al., «Experimental evaluation of uncertainty in hand-arm vibration measurements,» *International Journal of Industrial Ergonomics*, vol. 41, n° 2, pp. 167-179, 2011.
- [15] Sigcha, L., et al., «Occupational risk prevention through smartwatches: Precision and uncertainty effects of the built-in accelerometer,» *Sensors*, vol. 18, n° 11, 2018.
- [16] Schober, P., et al., «Smartwatch based automatic detection of out-of-hospital cardiac arrest: Study rationale and protocol of the HEART-SAFE project,» *Resuscitation Plus*, vol. 12, 2022.
- [17] Gaiduk, M, et al., «Initial evaluation of substituting a sleep diary by smartwatch measurement,» *Procedia Computer Science*, vol. 207, pp. 3376-3383, 2022.
- [18] Şengül, G., et al., «Deep learning based fall detection using smartwatches for healthcare applications,» *Biomedical Signal Processing and Control*, 2022.