



Desarrollo de un algoritmo de calibración para un acelerómetro MEMS utilizando el método LMS

René Corvo Ferreira, Fidel Ernesto Hernández Montero

RESUMEN

Esta investigación propone el desarrollo de un algoritmo de calibración basado en el método LMS para obtener mediciones precisas de un acelerómetro MEMS. El algoritmo consiste en la búsqueda de los parámetros de calibración del sensor mediante el procesamiento iterativo de señales utilizando el método LMS. Para la realización de este trabajo, se construyó una base de datos compuesta por 360 muestras tomadas con un acelerómetro MEMS en tres posiciones distintas. Los datos se incorporaron gradualmente al análisis para evaluar su suficiencia. Se calcularon varias métricas de desempeño, obteniéndose un error absoluto de 0.014 m/s^2 y un RMSE de 0.02 m/s^2 . Los resultados revelaron que el algoritmo desarrollado logra una estimación precisa y confiable de los valores de aceleración sin requerir sistemas de calibración costosos.

Palabras claves: sensores inerciales, algoritmo, calibración, acelerómetro MEMS, método LMS.

ABSTRACT

This research proposes the development of a calibration algorithm based on the LMS method to obtain accurate measurements from a MEMS accelerometer. The algorithm consists of estimating the sensor calibration parameters through the iterative processing of signals using the LMS method. To carry out this work, a database composed of 360 samples acquired using a MEMS accelerometer in three different positions was constructed. The data were gradually incorporated into the analysis to evaluate their sufficiency. Several performance metrics were calculated, yielding an absolute error of 0.014 m/s^2 and an RMSE of 0.02 m/s^2 . The results revealed that the developed algorithm achieves an accurate and reliable estimation of acceleration values without requiring expensive calibration systems.

Keywords: inertial sensors, algorithm, calibration, MEMS accelerometer, LMS method.

Development of a calibration algorithm for a MEMS accelerometer using the LMS method

1. INTRODUCCIÓN

Los sensores inerciales (IMUs, del inglés *Inertial Measurement Units*) con la reciente tecnología MEMS (del inglés *Microelectromechanical Systems*) han permitido la creación de dispositivos portátiles, conocidos como *wearables*, los cuales pueden integrarse en cámaras, ordenadores y dispositivos electrónicos personales, lo que posibilita el análisis de movimientos mecánicos desde un nivel general hasta variaciones mínimas [1]. Dentro del Grupo de Aplicaciones de Procesamiento de Señales (GAPS), vinculado a la Facultad de Ingeniería en Telecomunicaciones y Electrónica de la Universidad Tecnológica de La Habana “José Antonio Echeverría” (CUJAE), existen varios proyectos orientados al monitoreo y diagnóstico de condiciones físicas y enfermedades relacionadas con la motricidad de las personas mediante el uso de este tipo de sensores.

Los componentes más habituales de los IMUs son acelerómetros y giroscopios, siendo acompañados en algunas ocasiones por magnetómetros. De estos elementos, los acelerómetros son los que presentan mayor cantidad de errores, como el *bias* o el error del factor de escala, siendo necesaria su calibración para obtener mayor precisión en las mediciones que se realicen [2].

Con el fin de lograr la precisión deseada, se han desarrollado diversas investigaciones orientadas al desarrollo de algoritmos de calibración. En esa dirección, en [3] se propone una calibración multiposición *offline* con una mesa de velocidad de

Recibido: 03/2026 Aceptado: 05/2026

movimiento, que se combina con una solución de filtrado dinámico (uso del filtro de Kalman). En [4] se presenta un procedimiento de calibración rápido y sin equipo que requiere de condiciones cuasi-estáticas, pero se limita a estimar el *bias* cuando el sujeto está parado derecho o se mueve ligeramente.

En [5] se propone un algoritmo de calibración que aplica un modelo matemático simple, sin equipos especializados, que requiere colocar el acelerómetro en seis ángulos de inclinación muy precisos, para luego emplear un algoritmo iterativo que limita la aplicabilidad en tiempo real. Por otra parte, en [6] se aplica un enfoque de máxima verosimilitud para calibrar, estableciendo una función de verosimilitud que logra estimaciones precisas con bajo cómputo, en este caso se realiza una optimización iterativa que debe asumir determinada distribución de ruido.

En [7] se propone un método de autocalibración a través de un esquema G-óptimo de seis puntos para un modelo de segundo grado, el cual es resuelto utilizando el método de mínimos cuadrados; luego, posee baja carga computacional y es eficiente. Sin embargo, el trabajo parte de suponer formas específicas de modelo que pueden limitar la generalidad y necesita de condiciones estáticas precisas, además de ser potencialmente sensible al ruido si se utilizan sensores de bajo costo.

Asimismo, en [8] se introduce un enfoque de calibración de campo que elimina la necesidad de equipo externo, el cual aplica mínimos cuadrados no lineales generalizados (GNLS) para estimar errores determinísticos para obtener mayor precisión y convergencia más rápida que otros algoritmos. En este trabajo se utilizó un proceso novedoso de recolección de datos, durante el cual el acelerómetro se posiciona a lo largo de los tres ejes, lo cual puede aumentar el tiempo y la complejidad en configuraciones prácticas.

En resumen, los métodos de calibración existentes comparten un enfoque analítico, basado en modelos específicos. Asimismo, suelen requerir de equipos costosos, operar en condiciones experimentales estrictas, depender de la medición de gran cantidad de datos en múltiples orientaciones precisas, o en suposiciones restrictivas, ser sensibles al ruido o no estar orientados desde un enfoque óptimo. Este trabajo propone un algoritmo de calibración con un enfoque óptimo y analítico, de procesamiento relativamente simple, a partir de las muestras de señales de aceleración obtenidas en tres orientaciones simples del acelerómetro.

2. ACELERÓMETROS MEMS

Los sensores MEMS son dispositivos con dimensiones entre 1 μm y 1 mm que integran componentes mecánicos y eléctricos en un mismo sustrato, generalmente de silicio. Esto permite la interacción directa con variables físicas del entorno y las convierten en señales eléctricas [9]. Los acelerómetros basados en esta tecnología son sensores diseñados para medir la aceleración lineal. Estos sensores se caracterizan por su pequeño tamaño, bajo consumo de energía y facilidad de integración con circuitos electrónicos, por lo que su uso se ha generalizado en sistemas donde se requiere el monitoreo de movimiento, orientación o vibración. Esto ha impulsado su incorporación en dispositivos portátiles, sistemas de seguridad, control industrial y aplicaciones biomédicas [10].

Su funcionamiento se basa en la segunda ley de Newton, donde una aceleración aplicada genera una fuerza proporcional sobre una masa suspendida mediante estructuras elásticas. Esta fuerza produce un desplazamiento relativo entre la masa móvil y el marco fijo del dispositivo, el cual puede ser detectado mediante mecanismos de detección, siendo el capacitivo uno de los más comunes. En este caso, el desplazamiento modifica la capacitancia entre electrodos, generando una señal eléctrica proporcional a la aceleración [11].

La arquitectura interna de un acelerómetro MEMS incluye una masa central, estructuras de suspensión que determinan la rigidez mecánica y conjuntos de electrodos para la detección del desplazamiento, como se representa en la Figura 1. La disposición geométrica de estos componentes permite la medición en uno, dos o tres ejes, siendo los sensores triaxiales los más comunes en aplicaciones actuales [10].




Figura 1
Arquitectura interna de un acelerómetro MEMS.

Los acelerómetros se ven afectados por diversos tipos de errores que limitan la exactitud y la confiabilidad de las señales registradas. Estos errores pueden clasificarse en determinísticos y aleatorios. Los errores determinísticos son aquellos que siguen patrones predecibles y reproducibles, por lo que pueden ser modelados matemáticamente y corregidos mediante la calibración. Por otro lado, los errores aleatorios presentan un comportamiento impredecible, asociado principalmente al ruido electrónico y a perturbaciones térmicas, por lo que solo pueden describirse mediante modelos estadísticos y reducirse mediante técnicas de filtrado [2].

Esta investigación busca desarrollar un algoritmo de calibración simple y de fácil implementación que corrija los errores más significativos. Entre los errores determinísticos, los de sesgo y factor de escala tienen un impacto directo en la exactitud de las mediciones de los acelerómetros MEMS, por lo que el proceso de calibración propuesto se orientará a su reducción. El sesgo equivale a un desplazamiento constante en la salida del sensor aun cuando no se aplica ninguna aceleración. Este puede originarse debido a asimetrías estructurales, tensiones residuales del proceso de fabricación y variaciones térmicas. Este error suele considerarse constante o lentamente variable en el tiempo, por lo que puede estimarse mediante mediciones en condiciones conocidas, como reposo estático [12]. El error de sesgo se puede expresar como:

$$\bar{\mathbf{a}} = \begin{bmatrix} \bar{a}_x \\ \bar{a}_y \\ \bar{a}_z \end{bmatrix} = \begin{bmatrix} a_x \\ a_y \\ a_z \end{bmatrix} + \begin{bmatrix} B_x \\ B_y \\ B_z \end{bmatrix} = \mathbf{a} + \mathbf{B} \quad (1)$$

donde $\bar{\mathbf{a}} = [\bar{a}_x \ \bar{a}_y \ \bar{a}_z]^T$ es el vector de aceleración calibrada, $\mathbf{a} = [a_x \ a_y \ a_z]^T$ es el vector de aceleración medida y $\mathbf{B} = [B_x \ B_y \ B_z]^T$ es el sesgo (*bias*).

El factor de escala representa una desviación en la ganancia del sensor, es decir, una diferencia entre la aceleración real y la medida en términos de la pendiente de la respuesta. Las causas del error de escala incluyen tolerancias en las dimensiones de las microestructuras, variaciones en la rigidez de las suspensiones y no idealidades en los circuitos de lectura. La corrección de este error requiere la estimación de coeficientes multiplicativos que ajusten la pendiente de la respuesta del sensor [12]. El error del factor de escala se puede expresar como:

$$\bar{\mathbf{a}} = \begin{bmatrix} S_x & 0 & 0 \\ 0 & S_y & 0 \\ 0 & 0 & S_z \end{bmatrix} \begin{bmatrix} a_x \\ a_y \\ a_z \end{bmatrix} = \mathbf{S} \cdot \mathbf{a} \quad (2)$$

donde $\mathbf{S}$ es una matriz diagonal que representa el factor de escala.

De esta forma, el modelo de error de los acelerómetros MEMS se puede expresar como:

$$\bar{\mathbf{a}} = \mathbf{S} \cdot \mathbf{a} + \mathbf{B} \quad (3)$$

3. MÉTODO LMS

El método de Mínimos Cuadrados Medios (LMS, por sus siglas en inglés) es un algoritmo de filtrado lineal adaptativo cuya principal ventaja su simplicidad [13]. Este algoritmo consta de dos procesos básicos: un proceso de predicción y un proceso adaptativo. La combinación de ambos procesos simultáneamente crea un lazo de realimentación que le permite ajustar sus parámetros automáticamente [14].

Como se explica en [14,15], el primero de estos procesos, representado en la Figura 2, implica en primer lugar el cálculo de la salida de un filtro lineal y_n a partir de una señal de entrada:

$$y_n = \boldsymbol{\omega}^T \cdot \mathbf{x}_n \quad (4)$$

donde $\mathbf{x}_n$ es el vector de la señal de entrada y $\boldsymbol{\omega}^T$ es traspuesta del vector de pesos, ambos con tamaño n . En segundo lugar, involucra la generación de un error de estimación al comparar esta salida con una medida deseada t :

$$e_n = t_n - y_n \quad (5)$$




Figura 2
Proceso de predicción del filtro lineal.

El segundo proceso involucra el ajuste automático de los pesos del filtro. En este caso, se busca que la diferencia entre un peso y el siguiente vaya encaminada a minimizar el valor de una función de costo:

$$J(\omega) = \frac{1}{2} \cdot \sum_n (e_n)^2 \quad (6)$$

Para esto, se le aplica un gradiente descendente a dicha función:

$$\Delta\omega = -\mu \cdot \nabla J(\omega) \quad (7)$$

de tal forma que, a partir de un valor inicial de los pesos, estos se ajusten buscando el valor mínimo de la función, considerando un valor μ , denominado tamaño de paso o razón de aprendizaje, el cual puede ser constante o variable según se necesite.

Por tanto, al sustituir la ecuación (6) en (7) y derivar, se obtiene la forma en que se actualizan los pesos:

$$\omega_{n+1} = \omega_n + \mu \cdot e_n \cdot x_n \quad (8)$$

Luego, estos procesos se repiten nuevamente siguiendo el procedimiento descrito: calcular la salida del predictor lineal, generar el error de estimación y actualizar los pesos, hasta procesar el total de muestras N de la señal de entrada. Este procedimiento iterativo inicia desde $n = 0$ con un valor de los pesos igual a cero.

4. MATERIALES Y MÉTODOS

4.1. ALGORITMO PROPUESTO

El algoritmo de calibración que se propone se basa en la colocación del IMU en las tres orientaciones básicas, representadas en la Figura 3, para medir la aceleración de la gravedad ($g = 9.8 \text{ m/s}^2$) en cada uno de los tres ejes. Si el dispositivo estuviese calibrado y se encontrara colocado como en la Figura 3(a) el acelerómetro debería medir los valores: $A_x = 9.8 \text{ m/s}^2$, $A_y = 0 \text{ m/s}^2$ y $A_z = 0 \text{ m/s}^2$, siendo estas las variables que representan las mediciones de la aceleración en la dirección de cada eje: A_x , A_y y A_z , correspondiendo a los ejes 'x', 'y' y 'z', respectivamente. A partir de esta posición, si el equipo se rota 90° , en sentido antihorario alrededor del eje 'z', entonces la aceleración de la gravedad debería proyectarse en la variable A_y , de la forma en que se muestra en la Figura 3(b), y si a partir de esta última posición, se rotase 90° , en sentido antihorario, alrededor del eje 'x', la aceleración de la gravedad debería aparecer en la variable A_z , como se muestra en la Figura 3(c).




Figura 3
 Posiciones del IMU donde la gravedad se proyecta sobre el eje x (a), el eje y (b) y el eje z (c).

Por lo general, estos dispositivos no están calibrados, por lo que los valores de las variables no son los esperados.

En esta investigación se propone un método, basado en el algoritmo LMS (por tanto, sigue un enfoque de optimización), para realizar la calibración del sensor. Un diagrama del método propuesto se muestra en la Figura 4. Para la implementación de este método se necesita contar con una base de datos compuesta por mediciones de aceleración en cada una de las posiciones representadas en la Figura 3, manteniéndose el IMU firme e inmóvil. El método propuesto consiste en aplicar los pasos del algoritmo LMS a la base de datos creada anteriormente, de forma iterativa, hasta que el error de estimación promedio sea menor que un umbral predefinido. De esta forma se obtienen los parámetros de calibración del dispositivo, correspondiendo estos a la última actualización de los pesos del LMS.




Figura 4
 Diagrama del algoritmo propuesto.

El algoritmo propuesto se basa en la estrecha similitud que existe entre la expresión de salida del filtro lineal del algoritmo LMS, expresión (4), y la expresión del valor calibrado de aceleración, expresión (3). Por tanto, si se reescribe la expresión (4) a partir de la expresión (3), se obtiene, para cada eje del dispositivo:

$$y_n = \omega_1 x_n + \omega_0 \quad (9)$$

donde ω_1 modela el factor de escala S , y ω_0 , el sesgo presente B . Por su parte, x_n corresponde, para cada eje, el valor promedio de las muestras no calibradas, y y_n sería el valor estimado.

Luego, a partir de la expresión (9) y la base de datos compuesta por mediciones de aceleración en cada una de las posiciones representadas en la Figura 3, se actualizan los pesos, como propone el algoritmo LMS. En esta investigación se emplea una razón de aprendizaje pequeña, como se sugiere en [14], igual a 0.01, mientras que los pesos se inicializan con valor igual a 0. El proceso es iterativo y se repite mientras el error de estimación promedio supere un umbral determinado (en este trabajo, el umbral de error de estimación se definió como 10^{-5} m/s^2). De todas formas, se establece un número máximo de 100000 iteraciones en caso de que no se logre alcanzar el error de estimación.

Los últimos valores de pesos obtenidos se corresponderán con los parámetros de calibración a utilizar.

Para una mejor comprensión de los principales elementos involucrados en el algoritmo propuesto, la Tabla 1 presenta un resumen que recoge los parámetros fundamentales empleados en el proceso de calibración, incluyendo su símbolo, valor de inicialización y función dentro del método de calibración propuesto.

Tabla 1
Parámetros fundamentales empleados en el proceso de calibración.

Parámetro	Símbolo	Valor	Descripción
Aceleración de la gravedad	g	9.8 m/s^2	Valor esperado de aceleración usado como referencia cuando uno de los ejes coincide con la gravedad en las tres orientaciones
Variables de aceleración	A_x, A_y, A_z	—	Mediciones de aceleración en cada eje del acelerómetro (cuando no coinciden con la gravedad se espera un valor de 0 m/s^2)
Señal de entrada	x_n	—	Señal de entrada al método LMS compuesto por los valores promedio de las muestras no calibradas de aceleración de cada eje
Factor de escala	ω_1	Inicialmente 0	Parámetro de calibración que modela el factor de escala del sensor y peso del método LMS
Sesgo	ω_0	Inicialmente 0	Parámetro de calibración que modela el offset del sensor y peso del método LMS
Salida estimada	y_n	—	Valor estimado de aceleración calibrada
Razón de aprendizaje	μ	0.01	Controla la velocidad de convergencia del algoritmo
Error de estimación	e_n	—	Diferencia entre valor esperado y estimado
Umbral de error	—	10^{-5} m/s^2	Condición de parada basada en el error de estimación promedio
Número máximo de iteraciones	—	100000	Límite para evitar iteraciones infinitas

4.2. CONSTRUCCIÓN DE LA BASE DE DATOS

Para la implementación y validación posterior del algoritmo de calibración propuesto en la sección 4.1, se construyó una base de datos conformada por muestras de señales de aceleración provenientes de un IMU, obtenidas a partir de un experimento.

El dispositivo portátil utilizado en la investigación, mostrado en la Figura 5, contiene un sensor inercial y fue desarrollado por el GAPS, en colaboración con el Centro de Neurociencias de Cuba [16]. Este presenta un diseño donde todos los componentes están integrados en el interior de una carcasa que posee 8 cm de largo, 4 cm de ancho y 4.5 cm de altura. Está formado por

un microcontrolador ESP32, el sensor inercial ICM-20948, una batería de 4.5 V y un puerto microSD. Este tipo de sensor inercial es capaz de estimar la aceleración en los tres ejes coordenados, representados en la Figura 5.




Figura 5
Dispositivo usado con los 3 ejes coordenados representados.

Debido a su tamaño, el dispositivo se adapta a la estabilidad de cualquier superficie. Por esta razón, el IMU se fijó a un artefacto con superficie plana que podía ser ajustado fácilmente para realizar las mediciones del experimento, como se observa en la Figura 6.



Figura 6
Sistema de medición.

Este experimento consistió en la colocación del sistema de medición en las diferentes posiciones mostradas en la Figura 3, de tal forma que el dispositivo se encontrase estable y estático. Las posiciones paralelas y perpendiculares a la superficie terrestre se lograron con la ayuda de un nivel de burbuja. A través de una aplicación móvil, desarrollada por GAPS, se controló el proceso de digitalización y registro en memoria SD de las señales de los acelerómetros. Se aplicó una frecuencia de muestreo de 1 kHz.

Para construir la base de datos se tomó como referencia las medidas de 9.8 m/s^2 para cuando uno de los ejes del IMU coincide con la aceleración de la gravedad en las posiciones de la Figura 3, y 0 m/s^2 cuando no coinciden. Se realizó un total de 20 ensayos de 10 s de duración, obteniéndose 20 señales por eje (3 ejes), en cada posición (3 posiciones). Cada señal se dividió en 3 segmentos de la misma duración y se determinó el promedio de cada segmento. Cada valor calculado se consideró como una muestra de aceleración. Se obtuvieron 60 muestras de aceleración por eje, por posición.

Por cada posición se tomó como referencia (valor esperado) que las muestras de aceleración de uno de los ejes fueran 9.8 m/s^2 , y que las muestras de aceleración de los otros dos ejes fueran 0 m/s^2 . Como se contaría con más muestras (el doble) de aceleración de valor 0 m/s^2 , que de valor 9.8 m/s^2 , lo que daría lugar a una base de datos desbalanceada (el algoritmo se estaría “entrenando” más para un caso que para el otro), se decidió prescindir aleatoriamente de la mitad de las muestras de aceleración correspondientes a 0 m/s^2 . De este modo se logró que la cantidad de elementos de la base de datos correspondientes a 0 m/s^2 coincidiera con la cantidad correspondiente a 9.8 m/s^2 . Finalmente, la base de datos quedó constituida por un total de 360 muestras de aceleración: 120 muestras (60 muestras correspondientes a 0 m/s^2 más 60 muestras correspondientes a 9.8 m/s^2) por cada eje coordenado (3 ejes).

4.3. VALIDACIÓN DEL ALGORITMO

Para la validación del algoritmo se calcularon las siguientes métricas de desempeño:

- El Error Absoluto Medio,

$$E_{abs} = \frac{1}{N} \cdot \sum_{i=1}^N |x_i - \hat{x}_i| \quad (10)$$

- La Raíz del Error Cuadrático Medio,

$$RMSE = \sqrt{\frac{\sum_{i=1}^N |x_i - \hat{x}_i|^2}{N}} \quad (11)$$

- El Error Relativo Medio,

$$E_{rel} = \frac{1}{N} \cdot \sum_{i=1}^N \frac{|x_i - \hat{x}_i|}{x_i} \quad (12)$$

- El coeficiente de determinación,

$$R^2 = 1 - \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{\sum_{i=1}^N (\hat{x}_i - \bar{\hat{x}})^2} \quad (13)$$

donde x_i es el valor de referencia (valor esperado) de aceleración, $\hat{x}_i$ es la aceleración medida, N el número de muestras obtenidas y $\bar{\hat{x}}$ es el valor medio de las N aceleraciones medidas.

A pesar de ser menos convencional, el índice R^2 es empleado debido a que permite una evaluación global de la calidad y consistencia del algoritmo de calibración. Este expresa qué porcentaje de la variabilidad observada en los valores esperados de aceleración es capturada por el algoritmo propuesto. Un valor de R^2 cercano a 1 significa que los valores calibrados de aceleración siguen muy de cerca el comportamiento de los valores esperados [17].

Para determinar la suficiencia de los datos disponibles para aplicar el algoritmo, las métricas se calcularon de forma acumulativa, incorporando gradualmente al análisis una muestra de aceleración a la vez. De este modo, la estabilidad de la tendencia de los valores obtenidos de las métricas a calcular indicaría que la cantidad de datos analizados se puede considerar suficiente y que tales resultados serían confiables.

Para verificar si el algoritmo es efectivo y presenta un desempeño apropiado, se realizó una comparación cualitativa entre métricas como E_{abs} y $RMSE$, antes y después de calibrar.

Para reforzar la validación del algoritmo se decidió acompañar el cálculo de las métricas con pruebas estadísticas y métodos de inferencia estadística. Como durante el desarrollo del trabajo la prueba de Shapiro-Wilk [18] (la cual permite determinar si una muestra aleatoria de datos proviene de una población normal) arrojó que los errores de medición del algoritmo no seguían una distribución normal, se emplearon pruebas no paramétricas para evaluar su desempeño. Las siguientes pruebas estadísticas y métodos de inferencia fueron utilizados:

- Prueba de Rangos con Signo de Wilcoxon [19]: aplicada para detectar si el algoritmo mejora las mediciones de aceleración después de la calibración. Esta prueba evalúa si la mediana de las diferencias entre dos conjuntos de datos difiere significativamente de 0 (H_0 : Mediana = 0), considerando tanto el signo como la magnitud relativa de los errores.
- Análisis de Bland-Altman [20]: aplicado para caracterizar el comportamiento general del error de estimación, incluyendo su magnitud y dispersión. Este análisis usa la mediana como medidor de sesgo y percentiles como límites de acuerdo.
- Intervalos de Confianza de Bootstrap [21]: aplicados para estimar intervalos de confianza del 95 % para las métricas E_{abs} y $RMSE$ usando el procedimiento de remuestreo Bootstrap. Este método permite evaluar la estabilidad de las métricas frente a variaciones muestrales sin asumir ninguna distribución para el error.

5. RESULTADOS Y DISCUSIÓN

Al implementar el algoritmo descrito en esta investigación se logró una mejora significativa en las muestras de aceleración de la base de datos, al obtener valores más cercanos a los valores esperados (ver Figura 7). Asimismo, se determinaron los parámetros de las tres expresiones correspondientes a cada eje coordenado, los cuales permiten calibrar el dispositivo utilizado de forma directa:

$$A_{x,calibrada} = 0.999981A_{x,medida} + 0.085123 \quad (14)$$

$$A_{y,calibrada} = 0.994464A_{y,medida} + 0.226049 \quad (15)$$

$$A_{z,calibrada} = 0.995765A_{z,medida} + 0.138918 \quad (16)$$

Estas expresiones evidencian que la corrección requerida es predominantemente lineal, lo cual resulta especialmente ventajoso desde el punto de vista práctico, ya que su implementación computacional es sencilla y de bajo costo, permitiendo su integración en sistemas embebidos o aplicaciones en tiempo real sin requerimientos significativos de procesamiento.




Figura 7
Muestras de aceleración esperada y calibrada.

Las ecuaciones obtenidas fueron aplicadas a las señales de aceleración que componen la base de datos, y los resultados para tres ejemplos representativos, uno por cada posición descrita en la Sección 4.1, se muestran en la Figura 8. En esta figura se observa que la aplicación de los parámetros de calibración permite obtener mediciones considerablemente más precisas, alineándose con los valores esperados (línea discontinua azul). Las Figuras 8(a), 8(b) y 8(c) corresponden a las señales adquiridas por el IMU en las posiciones ilustradas en las Figuras 3(a), 3(b) y 3(c), respectivamente. Este comportamiento confirma la capacidad del algoritmo para mejorar la calidad de la señal independientemente de la orientación del sensor, lo que amplía su aplicabilidad en escenarios reales donde la orientación puede variar.




Figura 8
Ejemplos de resultados de calibración de señales de aceleración en las tres posiciones.

El algoritmo propuesto fue validado utilizando la base de datos de muestras de aceleración mediante métricas de desempeño, comparaciones cualitativas, métodos de inferencia y pruebas estadísticas, definidos en la Sección 4.3.

Las métricas se calcularon inicialmente con una única muestra de aceleración, incrementando progresivamente la cantidad de datos. La tendencia de los resultados se presenta en la Figura 9 para E_{abs} y $RMSE$, y en la Figura 10 para E_{rel} y R^2 . En ambos casos se observa una convergencia clara hacia valores estables a medida que aumenta el número de muestras. Este comportamiento no solo evidencia la consistencia del algoritmo, sino que también sugiere que el número de muestras utilizado es suficiente para garantizar una calibración confiable, lo cual es relevante en aplicaciones prácticas donde el tiempo o la cantidad de datos disponibles pueden ser limitados.

Los resultados finales alcanzados fueron: $E_{abs} = 0.014 \text{ m/s}^2$, $RMSE = 0.02 \text{ m/s}^2$, $E_{rel} = 0.04 \%$ (relativo a 9.8 m/s^2) y $R^2 = 99.998 \%$. Estos valores reflejan un nivel de error muy bajo, lo que implica que el algoritmo puede ser empleado en aplicaciones que requieran alta precisión, como sistemas de navegación inercial, monitoreo de movimiento o control de dispositivos electrónicos sensibles.




Figura 9
 Tendencia de los resultados de E_{abs} y $RMSE$.




Figura 10
 Tendencia de los resultados de E_{rel} y R^2 .

En la Tabla 2 se presentan los valores de E_{abs} y $RMSE$ antes y después de aplicar el algoritmo, así como el porcentaje de mejora alcanzado.

Tabla 2
 Comparación de las métricas de desempeño obtenidas antes de calibrar con las obtenidas después de aplicar el algoritmo de calibración.

Métrica	Antes	Después	Mejora
E_{abs}	0.134 m/s ²	0.014 m/s ²	89.27 %
$RMSE$	0.146 m/s ²	0.02 m/s ²	86.27 %

Los resultados muestran reducciones superiores al 80 % en los errores de estimación, lo que en términos prácticos se traduce en una mejora sustancial en la confiabilidad de las mediciones. Esto resulta especialmente relevante en aplicaciones donde pequeñas desviaciones pueden acumularse con el tiempo, como en sistemas de integración de aceleración para estimación de velocidad o posición.

Como se describió en la Sección 4.3, se emplearon métodos de inferencia y pruebas estadísticas no paramétricas para reforzar la validación del algoritmo. La prueba de rangos con signo de Wilcoxon, aplicada a los errores de estimación, arrojó un valor de $p = 0.66$, lo que indica ausencia de diferencias significativas respecto a cero y, por tanto, ausencia de sesgo sistemático. Este resultado es clave desde el punto de vista práctico, ya que garantiza que el algoritmo no introduce errores sistemáticos que puedan degradar el desempeño del sistema a largo plazo.

El análisis de Bland-Altman identificó una mediana de las diferencias de -0.0003 m/s^2 y límites de acuerdo de -0.0429 m/s^2 y 0.0401 m/s^2 (Figura 11). La distribución aproximadamente simétrica y acotada de las diferencias alrededor de cero confirma la alta precisión y estabilidad del algoritmo. En aplicaciones reales, esto implica que las mediciones calibradas se mantienen dentro de márgenes de error predecibles y controlados.




Figura 11
Análisis de Bland-Altman.

Finalmente, se calcularon intervalos de confianza del 95 % mediante remuestreo Bootstrap para E_{abs} y RMSE, obteniéndose $[0.013 \text{ m/s}^2, 0.016 \text{ m/s}^2]$ y $[0.018 \text{ m/s}^2, 0.022 \text{ m/s}^2]$, respectivamente. La estrechez de estos intervalos, junto con la inclusión de las métricas dentro de los mismos, evidencia la robustez y reproducibilidad del método. En términos prácticos, esto sugiere que el algoritmo puede mantener su desempeño bajo diferentes conjuntos de datos, lo que favorece su implementación en entornos reales con variabilidad en las condiciones de medición.

6. CONCLUSIONES

Esta investigación presentó el desarrollo y validación de un algoritmo de calibración para un acelerómetro MEMS. Este algoritmo se basa en la búsqueda de los parámetros de calibración del dispositivo mediante la aplicación del método LMS, trabajando sobre una base de datos compuesta por señales de aceleración medidas por un IMU. El algoritmo propuesto se caracteriza por su practicidad, facilidad de implementación y replicabilidad, así como por su enfoque de optimización adaptativa, lo que lo convierte en una alternativa eficiente frente a métodos de calibración tradicionales.

Los resultados obtenidos evidencian que la implementación del algoritmo permite alcanzar estimaciones precisas y confiables de la aceleración calibrada sin requerir sistemas de calibración costosos o complejos, favoreciendo su aplicabilidad en entornos reales. Este algoritmo fue validado de manera exhaustiva con el cálculo de varias métricas de desempeño. Las métricas de desempeño obtenidas: $E_{abs} = 0.014 \text{ m/s}^2$, $RMSE = 0.02 \text{ m/s}^2$, $E_{rel} = 0.04 \%$ (relativo a 9.8 m/s^2) y $R^2 = 99.998 \%$, demuestran un alto nivel de exactitud en el proceso de calibración.

Adicionalmente, la aplicación de pruebas de hipótesis respalda la validez de los resultados, evidenciando la ausencia de sesgo sistemático y una mejora estadísticamente significativa en las mediciones. El análisis de Bland-Altman confirma una adecuada concordancia entre las mediciones, con diferencias centradas alrededor de cero e intervalos de confianza estrechos, lo que refuerza la robustez y reproducibilidad del método propuesto.

En este contexto, la calibración precisa de acelerómetros MEMS se consolida como un elemento fundamental para garantizar la calidad de las señales utilizadas en diversas aplicaciones de estimación y análisis de movimiento. El algoritmo desarrollado constituye una solución efectiva, robusta y de bajo costo, capaz de generar señales calibradas con alta precisión.

Como líneas de trabajo futuro, se plantea extender la aplicación del algoritmo a otros sensores inerciales del IMU, como el magnetómetro y el giroscopio, con el fin de lograr una calibración integral del sistema. Asimismo, se recomienda incrementar

el número de ensayos en cada orientación y aumentar la cantidad de segmentos utilizados en la generación de la base de datos, lo que permitiría mejorar la estabilidad y el desempeño de las métricas obtenidas. De igual forma, la incorporación de ajustes en los parámetros del algoritmo, tales como la implementación de una razón de aprendizaje variable, la optimización del número de iteraciones y la modificación del umbral de error, podría contribuir a reducir aún más los errores de estimación y aumentar la precisión del modelo. Finalmente, se propone avanzar hacia el desarrollo de una solución de software integrada en el dispositivo, que permita automatizar y optimizar el proceso de calibración en aplicaciones prácticas.

REFERENCIAS

1. Hernández Gonzales-Monje M., Sánchez Ferro Á. Sensores inerciales: evaluación objetiva del movimiento. In: Manual SEN de nuevas tecnologías en trastornos del movimiento. Ediciones SEN; 2021. p. 25–34.
2. Poddar S., Kumar V., Kumar A. A comprehensive overview of inertial sensor calibration techniques. *J Dyn Syst Meas Control* [Internet]. 2016 Sep 26 [cited 2025 Sept 29];139:011006. Available from: <https://doi.org/10.1115/1.4034419>
3. Batista P., Silvestre C., Oliveira P., Cardeira B. Accelerometer calibration and dynamic bias and gravity estimation: analysis, design, and experimental evaluation. *IEEE Trans Control Syst Technol*. 2011 Sep;19(5):1128–37.
4. Lötters J.C., Schipper J., Veltink P.H., Olthuis W., Bergveld P. Procedure for in-use calibration of triaxial accelerometers in medical applications. *Sens Actuators A: Phys*. 1998 Jun 15;68(1):221–8.
5. Won S.P., Golnaraghi F. A triaxial accelerometer calibration method using a mathematical model. *IEEE Trans Instrum Meas*. 2010 Aug;59(8):2144–53.
6. Lu X., Liu Z., He J. Maximum likelihood approach for low-cost MEMS triaxial accelerometer calibration. In: 2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC) [Internet]. 2016 [cited 2025 Sep 29]. p. 179–82. Available from: <https://ieeexplore.ieee.org/abstract/document/7783587>
7. Ye L., Guo Y., Su S.W. An efficient autocalibration method for triaxial accelerometer. *IEEE Trans Instrum Meas*. 2017 Sep;66(9):2380–90.
8. Hassan M., Bao Q. A field calibration method for low-cost MEMS accelerometer based on the generalized nonlinear least square method. *Multiscale Sci Eng*. 2020 Sep 1;2(2):135–42.
9. Becerra-Paniagua D.K., Chávez-Granados C., Oropeza-Ramos L. El gran mundo de la tecnología miniatura. *Rev CienciaUANL*. 2024 Mar 1;27(124):16–23.
10. Akbaba C.E., Tanrikulu Y. MEMS capacitive accelerometer: a review. *Artibilim Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi Fen Bilimleri Dergisi*. 2023 Dec 31;6(2):41–58.
11. Gutiérrez García J.F. Giroscopios y acelerómetros electrónicos para medición de velocidad angular de mecanismos [Internet] [tesis de maestría]. 2020 [cited 2025 Sep 29]. Available from: <http://cicese.repositorioinstitucional.mx/jspui/handle/1007/3287>
12. Ru X., Gu N., Shang H., Zhang H. MEMS inertial sensor calibration technology: current status and future trends. *Micromachines*. 2022 Jun;13(6):879.
13. Hernandez W., De Vicente J., Sergiyenko O., Fernández E. Improving the response of accelerometers for automotive applications by using LMS adaptive filters. *Sensors*. 2010 Jan;10(1):313–29.
14. Haykin S.S. Adaptive filter theory. Pearson Education; 2002. 940 p.
15. Widrow B., Stearns S.D. Adaptive signal processing. Prentice-Hall; 1985. 504 p.
16. Calzadilla S.C., Orihuela O.A.G., Alvaredo E.O.G., Pérez M.B., Castellanos G.A., Montero F.E.H.. Wearable device basado en sensor inercial con capacidad de almacenamiento en memoria SD. *Telemática*. 2024;23:54–64.
17. Chicco D., Warrens M.J., Jurman G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Comput Sci*. 2021 Jul 5;7:e623.
18. Panchi P.A.M., Panchi D.F.M.. Pruebas estadísticas de normalidad: un análisis comparativo entre Kolmogórov-Smirnov, Shapiro-Wilk, Anderson-Darling, Ryan-Joiner y Jarque-Bera. *Ciencia UNEMI* [Internet]. 2025 Sep 8 [cited 2025 Dec 13];18(49). Available from: <https://ojs.unemi.edu.ec/index.php/cienciaunemi/article/view/152-171>
19. Kesgin T., İlayda R. Revisiting trend stability using Mann-Kendall and Wilcoxon signed-rank tests through innovative method comparisons. *Sustainability*. 2025 Jan;17(23):10454.
20. Haghayegh S., Kang H.A., Khoshnevis S., Smolensky M.H., Diller K.R. A comprehensive guideline for Bland–Altman and intra class correlation calculations to properly compare two methods of measurement and interpret findings. *Physiol Meas*. 2020 Jun;41(5):055012.
21. Mokhtar S.F., Yusof Z.M., Sapiri H. Confidence intervals by bootstrapping approach: a significance review. *Malaysian J Fundam Appl Sci*. 2023 Feb 25;19(1):30–42.

DECLARACIÓN DE CONFLICTO DE INTERESES Y RESPONSABILIDAD DE LOS AUTORES

Los autores declaran no tener conflictos de intereses con ninguna institución, organización o entidad que pudiera influir o sesgar el trabajo presentado en este manuscrito. La investigación se realizó en ausencia de cualquier relación comercial o financiera que pudiera ser interpretada como un posible conflicto de intereses.

Las opiniones y puntos de vista expresados en este artículo son únicamente los de los autores y no reflejan necesariamente la política o posición oficial de ninguna institución afiliada o agencia financiadora.

CONTRIBUCIONES DE LOS AUTORES

René Corvo Ferreiro: Conceptualización, Metodología, Investigación, Redacción — preparación del borrador original, Software, Curación de datos, Validación. **Fidel Ernesto Hernández Montero:** Conceptualización, Metodología, Investigación, Redacción — revisión y edición, Recursos, Administración del proyecto.

AUTORES

René Corvo Ferreiro: Ingeniero en Telecomunicaciones y Electrónica, Facultad de Ingeniería en Telecomunicaciones y Electrónica, Universidad Tecnológica de La Habana, Cuba; recorvo02@gmail.com, ORCID: 0009-0000-2973-8779. Sus intereses de investigación incluyen dispositivos portables basados en sensores inerciales para el monitoreo de la actividad humana.

Fidel Ernesto Hernández Montero: Ingeniero en Telecomunicaciones y Electrónica, Doctor en Ciencias, Facultad de Ingeniería en Telecomunicaciones y Electrónica, Universidad Tecnológica de La Habana, Cuba; fherandez@tele.cujae.edu.cu, ORCID: 0000-0002-5003-2807. Sus intereses de investigación incluyen el monitoreo y diagnóstico de condiciones en maquinaria, y dispositivos portables basados en sensores inerciales para el monitoreo de la actividad humana.



Esta revista se publica bajo una [Licencia Creative Commons Atribución-No Comercial-Sin Derivar 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)