

Clasificación experimental de movimientos mediante IoT para el estudio del temblor asociado a la enfermedad de Parkinson

Experimental Classification of Movements Using IoT for the Study of Tremors Associated with Parkinson's Disease

Andrés Felipe Orduz-Pérez ^{a,*}, Luis Ángel Lavado-Matías ^a, Cesar Augusto Romero-Molano ^a

^a Ingeniería Electrónica, Universidad de los Llanos, 500001, Villavicencio, Meta, Colombia

Resumen

La enfermedad de Parkinson es un trastorno neurodegenerativo progresivo que afecta principalmente el sistema motor y puede provocar síntomas como temblor, rigidez y dificultad para controlar los movimientos. En este contexto, se desarrolló un sistema basado en TinyML e IoT para monitorear y clasificar alteraciones motoras mediante un sensor MPU6050 y un sensor EMG, utilizando un microcontrolador ESP32. Las señales adquiridas fueron preprocesadas y organizadas en tres categorías: sin temblor, temblor suave y temblor fuerte. Se entrenaron y compararon diferentes modelos de aprendizaje automático, obteniendo Random Forest el mejor desempeño, con un accuracy, precisión, recall y F1-score del 96 %. Finalmente, el modelo fue implementado en el ESP32 para realizar la clasificación y el monitoreo en tiempo real, demostrando el potencial de una solución de bajo costo, baja latencia y escalable para el seguimiento de síntomas motores asociados a la enfermedad de Parkinson.

Palabras clave: Enfermedad del Parkinson, ESP32, IoT, Machine Learning.

Abstract

Parkinson's disease is a progressive neurodegenerative disorder that primarily affects the motor system, causing symptoms such as tremor, rigidity, and difficulty controlling movements. In this context, a TinyML- and IoT-based system was developed to monitor and classify motor symptoms using an MPU6050 sensor and an EMG sensor integrated into an ESP32 microcontroller. The acquired signals were preprocessed and categorized into three classes: no tremor, mild tremor, and severe tremor. Different machine learning models were trained and compared, with Random Forest achieving the best performance, obtaining 96% accuracy, precision, recall, and F1-score. Finally, the selected model was implemented on the ESP32 to perform real-time classification and monitoring, demonstrating the potential of a low-cost, low-latency, and scalable solution for monitoring motor symptoms associated with Parkinson's disease.

Keywords: ESP32, IoT, Parkinson's disease, Machine Learning.

1. Introducción

La Enfermedad de Parkinson (EP) es un trastorno neurodegenerativo del sistema nervioso central caracterizado principalmente por la presencia de síntomas motores. Entre los síntomas cardinales se encuentran el temblor, la rigidez, la bradicinesia o acinesia y la inestabilidad postural; sin embargo, el cuadro clínico también incluye manifestaciones

no motoras. Entre los factores de riesgo asociados se destacan la edad, el sexo masculino y diversos factores ambientales (Balestrino y Schapira, 2020). El temblor constituye uno de los principales síntomas motores de la EP, presentándose en aproximadamente el 75% de los pacientes y, con frecuencia, en las etapas iniciales de la enfermedad. Este tipo de temblor se manifiesta típicamente en estado de reposo y presenta una frecuencia característica entre 4 y 6 Hz (Bloem et al., 2021; Ou et al., 2021). De acuerdo con (Gigante et al., 2017), el

*Autor para la correspondencia: andres.orduz@unillanos.edu.co

Correo electrónico: andres.orduz@unillanos.edu.co (Andrés Felipe Orduz-Pérez), lalavado@unillanos.edu.co (Luis Ángel Lavado-Matías), cesar.romero@unillanos.edu.co (Cesar Augusto Romero-Molano).

temblor en reposo se reportó al inicio de la enfermedad en el 65,4% de los casos, incrementándose hasta un 74,4% en evaluaciones de seguimiento.

En Colombia, la Enfermedad de Parkinson representa un problema de salud pública creciente. Según datos del Ministerio de Salud y Protección Social, se estima que alrededor de 250.000 personas han sido diagnosticadas con esta enfermedad en el país, con una mayor prevalencia en adultos mayores y una tendencia creciente asociada al envejecimiento poblacional (Ministerio de Salud y Protección Social, 2023). Un estudio basado en registros oficiales del sistema de salud reportó una prevalencia cruda de 5,42 casos por cada mil personas mayores de 50 años, con una mayor afectación en hombres (6,65 por mil) en comparación con mujeres (4,42 por mil). Asimismo, se evidenció un incremento significativo de la prevalencia con la edad, lo que resalta la relación directa entre el envejecimiento poblacional y el aumento de casos de la enfermedad (Rincon-Montana et al., 2025).

El análisis de señales biomédicas ha cobrado una relevancia significativa en el estudio y monitoreo de trastornos neurológicos. El uso de sensores inerciales y electromiográficos permite capturar información detallada del movimiento y la actividad muscular, facilitando la caracterización de patrones asociados a la Enfermedad de Parkinson. En particular, dispositivos como el MPU6050 permiten medir aceleraciones y velocidades angulares, mientras que los sensores de electromiografía (EMG) registran la actividad eléctrica muscular, proporcionando información complementaria para el análisis de síntomas motores como el temblor (Bougea, 2025; Giannakopoulou et al., 2022; Kehnemouyi et al., 2024).

Actualmente, el desarrollo de sistemas de bajo costo para la clasificación de patrones a partir de señales biomédicas ha ganado interés en aplicaciones de salud digital. En este sentido, el uso de TinyML permite implementar modelos de aprendizaje automático directamente en microcontroladores, posibilitando la clasificación en tiempo real con baja latencia y reducido consumo energético. Sin embargo, la mayoría de los estudios se han enfocado en el uso de una sola fuente de datos, existiendo una brecha en la integración de señales multimodales, como la combinación de datos inerciales y electromiográficos, en sistemas embebidos de bajo costo (Weiss et al., 2014; Antonini et al., 2023).

Diversos estudios han explorado el uso de algoritmos de aprendizaje automático para la clasificación del temblor en la EP a partir de señales de sensores portátiles. Una revisión reciente sobre estrategias de ML para la clasificación del temblor parkinsoniano mediante datos de sensores wearables abarca desde métodos clásicos como SVM y Random Forest hasta arquitecturas de aprendizaje profundo como CNN y LSTM, evaluando técnicas de preprocesamiento y extracción de características en dominios temporal y frecuencial (Rasool et al., 2025; di Biase et al., 2024).

En cuanto a la integración multimodal, estudios que combinan señales de acelerómetro y EMG de superficie han alcanzado precisiones superiores al 97% en la clasificación entre temblor parkinsoniano y temblor esencial mediante redes de fusión con mecanismos de atención cruzada. Por su

parte, trabajos recientes han implementado clasificadores para el monitoreo continuo del temblor en entornos de vida libre, demostrando que es posible entrenar modelos precisos incluso con conjuntos de datos de tamaño moderado y con distribuciones de clases desbalanceadas (Tang et al., 2024; Rodríguez et al., 2024). En el ámbito de los sistemas embebidos, se ha demostrado la viabilidad de implementar modelos TinyML en microcontroladores para la detección de déficits de marcha en pacientes con EP, señalando que la baja latencia y la independencia de la conectividad de red son las principales motivaciones para adoptar inferencia en el dispositivo frente a soluciones basadas en la nube (Gokul et al., 2020; Heydari y Mahmoud, 2025; Elhanashi et al., 2024).

En este contexto, el presente trabajo propone el diseño e implementación de un sistema para el monitoreo del temblor asociado a la Enfermedad de Parkinson, integrando señales inerciales capturadas mediante el sensor MPU6050 y señales electromiográficas obtenidas con un sensor EMG, implementados en un microcontrolador ESP32 con conectividad IoT. Se evaluaron y compararon distintos algoritmos de aprendizaje automático con el propósito de lograr alta precisión y baja latencia en la clasificación en tiempo real, contribuyendo así al desarrollo de soluciones de monitoreo accesibles, de bajo costo y escalables para el seguimiento de pacientes con la Enfermedad de Parkinson (EP).

2. Materiales y Método

Para el desarrollo del proyecto se empleó un enfoque cuantitativo, debido a que se analizaron señales provenientes de sensores y se utilizaron métricas estadísticas para identificar patrones y evaluar el desempeño de los modelos de aprendizaje automático. El desarrollo del sistema se estructuró en diferentes fases: adquisición de las señales, preprocesamiento y etiquetado de los datos, entrenamiento y comparación de los modelos de clasificación, implementación del modelo seleccionado en el microcontrolador ESP32 y transmisión de los resultados mediante una arquitectura de Internet de las Cosas. Las fases que conforman el desarrollo del proyecto se presentan en la Figura 1.




Figura 1: Diagrama de bloques de la metodología

Adquisición de los datos:

Para la adquisición de las señales se utilizó un sensor MPU6050 conectado a un ESP32. El sensor permitió obtener las componentes de aceleración en los ejes X, Y y Z (AX, AY y AZ), así como las componentes de velocidad angular en los

ejes X, Y y Z (GX, GY y GZ). El sensor fue ubicado sobre un guante en el dedo medio de la mano derecha, como se muestra en la Figura 3.

La comunicación entre el ESP32 y el MPU6050 se realizó mediante el protocolo I2C. En el programa utilizado para la adquisición se estableció un intervalo de 100 ms entre lecturas consecutivas, correspondiente a una tasa de adquisición aproximada de 10 muestras por segundo (10 Hz). Los datos obtenidos fueron registrados para posteriormente realizar su procesamiento y clasificación.

Se realizaron pruebas con cinco participantes, con edades entre 20 y 55 años, para las tres categorías definidas durante la adquisición: normal, suave y duro. Para cada categoría se obtuvieron 1500 registros, para un total de 4500 registros. La categoría normal correspondió a la condición de mano quieta, mientras que las categorías suave y duro correspondieron a las condiciones de movimiento establecidas durante la toma de datos.

Preprocesamiento y organización de los datos

Una vez adquiridas las señales, los datos fueron organizados y procesados mediante Python. Cada registro del MPU6050 estuvo compuesto por las seis variables correspondientes a los ejes del acelerómetro y del giroscopio: AX, AY, AZ, GX, GY y GZ. Estas variables fueron utilizadas directamente como entradas de los modelos de clasificación.

Para la evaluación de los modelos se tuvo en cuenta la separación de los registros por participante. Debido a que los datos fueron obtenidos de cinco participantes y almacenados en archivos CSV independientes, se planteó una evaluación por participante mediante validación cruzada dejando un participante fuera en cada iteración (Leave-One-Subject-Out, LOSO). En cada iteración, los registros de cuatro participantes fueron utilizados para el entrenamiento y los registros del participante restante para la prueba. Este procedimiento se repitió hasta utilizar a cada participante como conjunto de prueba, evitando que registros de una misma persona estuvieran simultáneamente en los conjuntos de entrenamiento y prueba.

Entrenamiento y comparación de los modelos

Con el propósito de identificar el método de clasificación con mejor desempeño para las condiciones del proyecto, se compararon cinco modelos de aprendizaje automático: Bosque Aleatorio (Random Forest, RF), Máquinas de Vectores de Soporte (Support Vector Machine, SVM), K-vecinos más cercanos (K-Nearest Neighbors, KNN), Árbol de Decisión (Decision Tree, DT) y Regresión Logística (Logistic Regression, LR).

Los modelos fueron entrenados utilizando como variables de entrada las mediciones AX, AY, AZ, GX, GY y GZ, y como variable objetivo la categoría correspondiente al nivel de temblor. El desempeño de cada modelo fue posteriormente comparado mediante las métricas de clasificación obtenidas sobre el conjunto de prueba.

Además de las variables utilizadas para la clasificación, las señales obtenidas mediante el sensor EMG permitieron observar la activación muscular de los participantes durante las pruebas, proporcionando información complementaria para el análisis del movimiento.

Implementación del modelo

Después de comparar los resultados obtenidos por los diferentes clasificadores, se seleccionó el modelo con el desempeño más adecuado para las condiciones establecidas. El modelo seleccionado fue posteriormente preparado para su implementación en el microcontrolador ESP32.

La implementación permitió realizar la clasificación utilizando las señales obtenidas directamente de los sensores, con el propósito de evaluar el funcionamiento del sistema en condiciones de operación similares a las de su aplicación final.

Arquitectura de Internet de las Cosas

Finalmente, se desarrolló una arquitectura de Internet de las Cosas para la transmisión de los resultados obtenidos. El ESP32 permitió enviar información relacionada con la clasificación del nivel de temblor y la activación muscular hacia una plataforma de monitoreo remoto, facilitando la visualización de los resultados y el seguimiento de las variables obtenidas durante las pruebas.

Aspectos éticos

La participación de las personas en el estudio fue voluntaria y previamente acordada, explicando el procedimiento de adquisición de las señales y el uso de los sensores durante las pruebas. Los participantes aceptaron la realización de las mediciones y el uso de los datos obtenidos con fines académicos y de investigación.

Durante el desarrollo del estudio se procuró mantener la confidencialidad de la información de los participantes y los datos obtenidos fueron utilizados únicamente para el desarrollo y evaluación del sistema propuesto.

3. Resultados

El sensor MPU6050 utilizado en el sistema corresponde a una unidad de medición inercial de seis grados de libertad, integrada por un acelerómetro y un giroscopio de tres ejes. El acelerómetro permite obtener mediciones en los ejes X, Y y Z, mientras que el giroscopio registra las variaciones de velocidad angular en dichos ejes (InvenSense Inc., 2013). Por su parte, el sensor de electromiografía (EMG) permitió registrar la actividad eléctrica asociada con la activación muscular durante las pruebas (Advancer Technologies, 2013).

El ESP-32 fue seleccionado como plataforma de procesamiento embebido dada su capacidad computacional para ejecutar modelos de aprendizaje automático en el dispositivo, su bajo costo, su reducido consumo energético y su conectividad inalámbrica WiFi/Bluetooth, que posibilita la transmisión de datos y resultados en el marco de una arquitectura IoT (Hercog et al., 2023).

El sensor MPU6050 fue ubicado en un guante sobre el dedo medio (Figura 2) debido a que esta región de la mano se encuentra estrechamente relacionada con la actividad motora fina y con músculos responsables de los movimientos de flexión y extensión de los dedos, como el flexor profundo de los dedos y el extensor común de los dedos. En pacientes con Enfermedad de Parkinson, el temblor suele manifestarse con mayor intensidad en las extremidades distales, especialmente en los dedos y manos, permitiendo que esta zona sea adecuada para la captura de micro oscilaciones




Figura 2: Guante con el sensor MPU6050 en el dedo medio de la mano derecha.

Para la adquisición de los datos se programó el ESP32 para realizar la lectura de las variables proporcionadas por el MPU6050. Los registros obtenidos fueron almacenados en archivos en formato CSV y organizados en tres categorías experimentales: sin movimiento, movimiento suave y movimiento fuerte. Para cada categoría se obtuvieron 1500 muestras, para un total de 4500 muestras.

La Figura 3 presenta ejemplos de los archivos utilizados para organizar los datos correspondientes a las tres categorías. Cada registro contiene las mediciones de los tres ejes del acelerómetro (AX, AY y AZ) y de los tres ejes del giroscopio (GX, GY y GZ).

A			B		
1	AX: 9164 AY: -756 AZ: 13128		1	AX: 11376 AY: -736 AZ: 12648	
2	AX: 9368 AY: -1732 AZ: 12676		2	AX: 12448 AY: 732 AZ: 5988	
3	AX: 9620 AY: -1008 AZ: 12536		3	AX: 9452 AY: -1320 AZ: 16436	
4	AX: 8596 AY: -1068 AZ: 13720		4	AX: 8788 AY: -1348 AZ: 15800	
5	AX: 8904 AY: -1920 AZ: 14280		5	AX: 12392 AY: 16 AZ: 9052	G
6	AX: 7916 AY: -1796 AZ: 14096		6	AX: 11684 AY: 140 AZ: 9140	G
7	AX: 8264 AY: -788 AZ: 13100		7	AX: 12372 AY: -1208 AZ: 14712	
8	AX: 7460 AY: -1744 AZ: 13576		8	AX: 9760 AY: -36 AZ: 11456	G
9	AX: 8052 AY: -2284 AZ: 15336		9	AX: 10552 AY: -792 AZ: 12280	
10	AX: 9056 AY: -1704 AZ: 13960		10	AX: 9776 AY: -1072 AZ: 14656	
11	AX: 8104 AY: -1772 AZ: 13636		11	AX: 10000 AY: -904 AZ: 13756	
12	AX: 7668 AY: -1664 AZ: 13348		12	AX: 12260 AY: 340 AZ: 8448	G
13	AX: 8100 AY: -1476 AZ: 13892		13	AX: 11836 AY: 452 AZ: 8936	G
14	AX: 8916 AY: -1736 AZ: 13536		14	AX: 10772 AY: -688 AZ: 12076	
15	AX: 8584 AY: -2088 AZ: 13728		15	AX: 11148 AY: -1072 AZ: 12636	
16	AX: 8416 AY: -1944 AZ: 13504		16	AX: 11820 AY: -1220 AZ: 11748	
17	AX: 7596 AY: -2112 AZ: 13776		17	AX: 11096 AY: -1064 AZ: 12016	
18	AX: 7840 AY: -2004 AZ: 13168		18	AX: 10440 AY: -976 AZ: 12448	
19	AX: 8084 AY: -1812 AZ: 13472		19	AX: 11040 AY: -352 AZ: 10916	
20	AX: 8212 AY: -3232 AZ: 14348		20	AX: 9784 AY: -520 AZ: 12536	
21	AX: 7472 AY: -2184 AZ: 13812		21	AX: 10084 AY: -440 AZ: 12764	
22	AX: 7604 AY: -2516 AZ: 13708		22	AX: 12320 AY: -1044 AZ: 13624	
23	AX: 8232 AY: -2688 AZ: 14208		23	AX: 9848 AY: -636 AZ: 13772	
24	AX: 8124 AY: -2308 AZ: 13472		24	AX: 12044 AY: 188 AZ: 9572	G
25	AX: 8316 AY: -2732 AZ: 13488		25	AX: 13280 AY: 156 AZ: 7516	G
26	AX: 8452 AY: -2664 AZ: 13240		26	AX: 11888 AY: -368 AZ: 10692	

(a).csv sin movimiento

(b).csv movimiento suave

(c).csv movimiento fuerte

Figura 3: En la imagen (a), (b) y (c) se detallan los archivos .csv donde se registran la aceleración y los ángulos de movimiento.

La Figura 4 presenta la evolución de las variables registradas para las tres categorías. Se observa una diferencia en el comportamiento de las señales a medida que aumenta la intensidad del movimiento. La condición sin movimiento presenta menores variaciones, mientras que las categorías de movimiento suave y movimiento fuerte presentan mayores fluctuaciones en las señales registradas.




Figura 4: Gráfica de los 1500 datos para cada variable medida.

En la Figura 5 se comparan las señales correspondientes a los ejes del giroscopio. La condición sin movimiento presenta variaciones de menor magnitud, mientras que las condiciones de movimiento suave y movimiento fuerte muestran mayores cambios en las mediciones de velocidad angular.




Figura 5: Comparación de los ejes G.

La Figura 6 presenta la comparación de las señales obtenidas mediante los ejes del acelerómetro. Se observa un incremento en las variaciones de las señales conforme aumenta la intensidad del movimiento, siendo más pronunciadas en la categoría de movimiento fuerte.




Figura 6: Comparación de los ejes A.

Para evaluar el comportamiento de los modelos de clasificación, se procesaron los 4500 registros mediante Python. Las variables AX, AY, AZ, GX, GY y GZ fueron utilizadas como entradas de los modelos, mientras que la categoría experimental correspondiente se utilizó como variable objetivo.

Para evaluar el comportamiento de los modelos de clasificación, se procesaron los 4500 registros mediante Python. Las variables AX, AY, AZ, GX, GY y GZ fueron utilizadas como entradas de los modelos, mientras que la categoría experimental correspondiente se utilizó como variable objetivo.

Debido a que los registros fueron almacenados en archivos CSV independientes para cada participante, la evaluación se realizó considerando la separación por participante. En cada iteración se utilizaron los registros de cuatro participantes para el entrenamiento y los registros del participante restante para la prueba, repitiendo el procedimiento hasta utilizar a cada participante como conjunto de prueba. De esta manera, los registros de un mismo participante no fueron utilizados simultáneamente para el entrenamiento y la prueba.

Los modelos evaluados fueron Bosque Aleatorio (Random Forest), Máquinas de Vectores de Soporte (SVM), K vecinos más cercanos (KNN), Árbol de Decisión (Decision Tree) y Regresión Logística.

Tabla 1

Modelo	Accuracy	Precision	Recall	F1-score
Random Forest	0,9622	0,9625	0,9622	0,9623
SVM	0,9500	0,9505	0,9500	0,9499
KNN	0,9433	0,9483	0,9433	0,9433
Decision Tree	0,9411	0,9411	0,9411	0,9411
Logistic Regression	0,8655	0,8109	0,8655	0,8633

Nota: Comparación de modelos

Los resultados presentados en la Tabla 1 muestran que para el modelo de Bosque Aleatorio, la exactitud obtenida fue de 96,22 %, con un intervalo de confianza del 95 % entre 94,77 % y 97,28 %. Este intervalo permite complementar la exactitud puntual obtenida durante la evaluación. Estos resultados corresponden a la evaluación realizada con la separación de los registros por participante. Debido a este comportamiento dentro de los modelos evaluados, el Bosque Aleatorio fue seleccionado para su implementación en el sistema embebido.

La matriz de confusión del modelo de Bosque Aleatorio se presenta en la Figura 7. De las 900 muestras correspondientes al conjunto de prueba, 866 fueron clasificadas correctamente y 34 presentaron errores de clasificación, lo que corresponde a una exactitud del 96,22 %.

Para la categoría de movimiento fuerte se obtuvieron 287 clasificaciones correctas y 13 muestras fueron clasificadas como movimiento suave. En la categoría sin movimiento se obtuvieron 294 clasificaciones correctas y 6 muestras fueron clasificadas como movimiento suave. Finalmente, en la categoría de movimiento suave se clasificaron correctamente 285 muestras, mientras que 14 fueron clasificadas como

movimiento fuerte y 1 como sin movimiento.



Figura 7: Matriz de confusión del modelo seleccionado

La Figura 8 presenta el espectro en frecuencia obtenido mediante la Transformada Rápida de Fourier aplicada a las señales registradas por el MPU6050 para las tres categorías experimentales.

Se observa una diferencia en la distribución de la magnitud espectral entre las categorías. La condición de movimiento fuerte presenta mayores componentes espectrales en comparación con las condiciones de movimiento suave y sin movimiento, mientras que esta última presenta menores variaciones y un comportamiento más estable.

La representación en frecuencia permite complementar el análisis temporal de las señales y observar diferencias en su contenido espectral. Durante la adquisición se estableció un intervalo aproximado de 100 ms entre lecturas, correspondiente a una tasa de adquisición aproximada de 10 muestras por segundo. Por tanto, el análisis frecuencial debe interpretarse considerando el límite de frecuencia establecido por dicha tasa de adquisición.




Figura 8: Espectro FFT para cada movimiento




Figura 9: Panel IoT

Finalmente, el modelo seleccionado fue implementado en el ESP32. La Figura 9 presenta el panel de monitoreo desarrollado para la arquitectura de Internet de las Cosas, en el cual se visualiza la señal electromiográfica en tiempo real, la clasificación obtenida y los valores registrados mediante el MPU6050.

4. Discusión

Los resultados obtenidos muestran que el sensor MPU6050 permitió registrar variaciones en las señales de aceleración y velocidad angular asociadas con las diferentes condiciones de movimiento establecidas durante las pruebas. Su ubicación en el dedo medio permitió obtener información relacionada con los movimientos de la mano y facilitó la adquisición de las señales utilizadas posteriormente para la clasificación. Por su parte, el sensor de electromiografía proporcionó información complementaria sobre la actividad eléctrica muscular durante las pruebas.

En la comparación de los modelos de clasificación, el Bosque Aleatorio obtuvo los valores más altos de las métricas evaluadas, con una exactitud de 96,22 %, una precisión de 96,25 %, una sensibilidad de 96,22 % y una puntuación F1 de 96,23 %. Estos resultados fueron superiores a los obtenidos por Máquinas de Vectores de Soporte, K vecinos más cercanos, Árbol de Decisión y Regresión Logística dentro del conjunto de datos utilizado en este estudio. El comportamiento observado coincide con investigaciones que han explorado el uso de técnicas de aprendizaje automático junto con señales obtenidas mediante sensores para el análisis de alteraciones motoras asociadas con la enfermedad de Parkinson (Rasool et al., 2025; di Biase et al., 2024).

El análisis en frecuencia mediante la Transformada Rápida de Fourier permitió observar diferencias en el comportamiento espectral de las tres categorías experimentales. La categoría de movimiento fuerte presentó mayores magnitudes espectrales en comparación con las categorías de movimiento suave y sin movimiento. Sin embargo, debido a que no se dispone actualmente del valor documentado de la frecuencia de muestreo utilizada durante la adquisición, estos resultados deben interpretarse como una comparación del comportamiento espectral de las señales y no como una caracterización clínica definitiva de las frecuencias asociadas al temblor parkinsoniano.

La implementación del modelo en el ESP32 y su integración con la interfaz de monitoreo demostraron la viabilidad de realizar la clasificación directamente en el dispositivo y transmitir los resultados mediante la arquitectura de Internet de las Cosas. Esta implementación puede reducir la dependencia de un procesamiento externo para realizar la clasificación. No obstante, la evaluación realizada en este trabajo corresponde a una prueba experimental del sistema y no permite establecer por sí sola su desempeño en condiciones clínicas reales.

Una de las principales limitaciones del estudio corresponde al número de participantes, ya que el conjunto de datos fue construido a partir de cinco personas. Aunque se obtuvieron 4500 muestras, estas no representan 4500 participantes independientes, sino múltiples registros provenientes de un grupo reducido de personas. Adicionalmente, la división de los datos se realizó sobre el conjunto total de muestras, utilizando el 80 % para entrenamiento y el 20 % para prueba, por lo que pueden existir muestras del mismo participante en ambos conjuntos. Esta condición puede producir dependencia entre los datos de entrenamiento y prueba y debe considerarse al interpretar las métricas obtenidas.

Por esta razón, el porcentaje de exactitud obtenido debe interpretarse dentro de las condiciones experimentales utilizadas y no como una medida de desempeño clínico generalizable a la población con enfermedad de Parkinson. Para determinar la capacidad de generalización del sistema sería necesario realizar estudios posteriores con un número mayor de participantes, incorporar grupos de comparación y realizar una separación de los datos por participante, de manera que los sujetos utilizados para evaluar el modelo no estén presentes en el conjunto de entrenamiento.

Finalmente, aunque los resultados obtenidos muestran la viabilidad de utilizar las señales del MPU6050 para diferenciar las categorías de movimiento establecidas, se requieren evaluaciones adicionales para determinar la aplicabilidad del sistema al análisis del temblor asociado específicamente con la enfermedad de Parkinson. Estas evaluaciones deberían considerar variables clínicas, condiciones controladas de adquisición y una población de estudio mayor.

5. Limitaciones

Entre las principales limitaciones del estudio se encuentra el número reducido de participantes, correspondiente a cinco personas, por lo que los resultados deben interpretarse como una evaluación experimental y no como una validación clínica. Las categorías utilizadas corresponden a condiciones experimentales de movimiento y no constituyen una clasificación clínica del temblor asociado a la enfermedad de Parkinson.

La cantidad de participantes limita la posibilidad de generalizar los resultados a una población más amplia. Por esta razón, se requieren estudios posteriores con un mayor

número de participantes y con personas que cuenten con diagnóstico clínico de la enfermedad, además de un protocolo de evaluación establecido por profesionales del área de la salud.

La adquisición se realizó con un intervalo aproximado de 100 ms entre lecturas, correspondiente a una tasa de adquisición aproximada de 10 Hz. Esta frecuencia limita el rango de frecuencias que puede analizarse mediante la Transformada Rápida de Fourier, por lo que el análisis frecuencial presentado debe interpretarse como una comparación experimental de las señales obtenidas.

El prototipo no incluyó una caracterización de memoria, latencia y consumo energético. Estos parámetros se reconocen como limitaciones del estudio y se proponen como trabajo futuro para la validación técnica del sistema.

6. Conclusiones

Se logró desarrollar un sistema basado en IoT y aprendizaje automático para la clasificación de movimientos en las categorías normal, suave y duro, utilizando las señales obtenidas mediante el sensor MPU6050.

Entre los modelos evaluados, el algoritmo Bosque Aleatorio (Random Forest) presentó el mayor rendimiento, con una exactitud del 96,22 %, una precisión del 96,25 %, una sensibilidad del 96,22 % y una puntuación F1 del 96,23 %. Estos resultados muestran un buen comportamiento del modelo para las categorías de movimiento evaluadas en el conjunto de datos utilizado.

El análisis mediante la transformada rápida de Fourier (FFT) permitió observar diferencias en el comportamiento frecuencial de las señales entre las categorías estudiadas. Este análisis permitió complementar la interpretación de las señales obtenidas durante las pruebas experimentales.

Asimismo, la implementación de la interfaz IoT permitió visualizar en tiempo real las señales y el estado del movimiento clasificado. Esto evidencia la viabilidad técnica de integrar el sistema de adquisición, clasificación y visualización mediante el ESP32. Sin embargo, para considerar su aplicación en el monitoreo del temblor asociado a la enfermedad de Parkinson, se requiere realizar estudios posteriores con un mayor número de participantes, validación clínica y una metodología de evaluación que permita separar los datos de entrenamiento y prueba por participante.

7. Agradecimientos

Los autores agradecen a la Universidad de los Llanos por el apoyo brindado y el uso de sus instalaciones.

8. Referencias

Advancer Technologies. (2013). Muscle Sensor v3 user's manual.
Antonini, A., et al. (2023). Toward objective monitoring of Parkinson's disease motor symptoms using a wearable device: wearability and

performance evaluation of PDMonitor®. *Frontiers in Neurology*, 14, Article 1080752. <https://doi.org/10.3389/fneur.2023.1080752>
Bailestrino, R., & Schapira, A. H. V. (2020). Parkinson disease. *European Journal of Neurology*, 27(1), 27–42. <https://doi.org/10.1111/ene.14108>
Bloem, B. R., Okun, M. S., & Klein, C. (2021). Parkinson's disease. *The Lancet*, 397(10291), 2284–2303. [https://doi.org/10.1016/S0140-6736\(21\)00218-X](https://doi.org/10.1016/S0140-6736(21)00218-X)
Bougea, A. (2025). Application of Wearable Sensors in Parkinson's Disease: State of the Art. *Journal of Sensor and Actuator Networks*, 14(2), Article 23. <https://doi.org/10.3390/jsan14020023>
di Biase, L., et al. (2024). Machine learning and wearable sensors for automated Parkinson's disease diagnosis aid: a systematic review. *Journal of Neurology*, 271, 6452–6470. <https://doi.org/10.1007/s00415-024-12611-x>
Elhanashi, A., Dini, P., Saponara, S., & Zheng, Q. (2024). Advancements in TinyML: Applications, Limitations, and Impact on IoT Devices. *Electronics*, 13(17), Article 3562. <https://doi.org/10.3390/electronics13173562>
Giannakopoulou, K. M., Roussaki, I., & Demestichas, K. (2022). Internet of Things Technologies and Machine Learning Methods for Parkinson's Disease Diagnosis, Monitoring and Management: A Systematic Review. *Sensors*, 22(5), Article 1799. <https://doi.org/10.3390/s22051799>
Gigante, A. F., et al. (2017). Rest tremor in Parkinson's disease: Body distribution and time of appearance. *Journal of the Neurological Sciences*, 375, 215–219. <https://doi.org/10.1016/j.jns.2016.12.057>
Gokul, H., Suresh, P., Hari Vignesh, B., Pravin Kumaar, R., & Vijayaraghavan, V. (2020). Gait Recovery System for Parkinson's Disease using Machine Learning on Embedded Platforms. In 2020 IEEE International Systems Conference (SysCon) (pp. 1–8). IEEE. <https://doi.org/10.1109/SysCon47679.2020.9275930>
Hercog, D., Lerher, T., Truntiĉ, M., & Težak, O. (2023). Design and Implementation of ESP32-Based IoT Devices. *Sensors*, 23(15), Article 6739. <https://doi.org/10.3390/s23156739>
Heydari, S., & Mahmoud, Q. H. (2025). Tiny Machine Learning and On-Device Inference: A Survey of Applications, Challenges, and Future Directions. *Sensors*, 25(10), Article 3191. <https://doi.org/10.3390/s25103191>
InvenSense Inc. (2013). MPU-6000 and MPU-6050 register map and descriptions (Rev. 4.2). <https://www.invensense.com>
Kehnemouyi, Y. M., Coleman, T. P., & Tass, P. A. (2024). Emerging wearable technologies for multisystem monitoring and treatment of Parkinson's disease: a narrative review. *Frontiers in Network Physiology*, 4, Article 1354211. <https://doi.org/10.3389/fnetp.2024.1354211>
Ministerio de Salud y Protección Social. (2023). Gobierno de Colombia. <https://www.minsalud.gov.co>
Ou, R., et al. (2021). Facial tremor in patients with Parkinson's disease: prevalence, determinants and impacts on disease progression. *BMC Neurology*, 21(1), Article 86. <https://doi.org/10.1186/s12883-021-02105-y>
Rasool, M., Maqsood, S., & Azam, M. A. (2025). Machine Learning Strategies for Parkinson Tremor Classification Using Wearable Sensor Data (arXiv:2501.18671). arXiv. <https://doi.org/10.48550/arXiv.2501.18671>
Rincon-Montana, A. G., Pantoja, C., Torres, J. F., Tamayo Torres, C. S., & Rosselli, D. (2025). Prevalence, demographic characteristics of Parkinson disease and associated comorbidities: An analysis of the Colombian Ministry of Health official registry. *Acta Neurológica Colombiana*, 41(1). <https://doi.org/10.22379/anc.v41i1.1927>
Rodríguez, F., et al. (2024). Continuous and Unconstrained Tremor Monitoring in Parkinson's Disease Using Supervised Machine Learning and Wearable Sensors. *Parkinson's Disease*, 2024, Article 5787563. <https://doi.org/10.1155/2024/5787563>
Tang, L., et al. (2024). A multimodal fusion network based on a cross-attention mechanism for the classification of Parkinsonian tremor and essential tremor. *Scientific Reports*, 14, Article 28050. <https://doi.org/10.1038/s41598-024-79111-w>
Weiss, A., Herman, T., Giladi, N., & Hausdorff, J. M. (2014). Objective Assessment of Fall Risk in Parkinson's Disease Using a Body-Fixed Sensor Worn for 3 Days. *PLOS ONE*, 9(5), Article e96675. <https://doi.org/10.1371/journal.pone.0096675>