

**Diseño de prototipo electrónico IoT para el monitoreo biomédico de señales EEG, PPG y
acelerométricas, orientado al estudio de crisis epilépticas**

Yesid Amin Arcón Kalil

Asesor

Estefany María Lancheros Sepulveda

Universidad Nacional Abierta y a Distancia-UNAD

Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI

Ingeniería Electrónica

2026

Nota de Aceptación

Estefany María Lancheros Sepulveda

Director de Trabajo de Grado

Jurado

Jurado

Dedicatoria

Dedico este trabajo a mi familia, cuyo apoyo constante, motivación y confianza han sido fundamentales para superar las dificultades presentadas a lo largo de este proceso, y quienes han sido la fuente de energía que me impulsó a alcanzar este logro académico.

Agradecimientos

Agradezco en primer lugar a Dios, por guiar mis pasos y darme la fortaleza necesaria para superar cada obstáculo presentado a lo largo de este proceso académico.

De manera especial, extiendo mi agradecimiento a mi familia, por su apoyo incondicional, comprensión y paciencia, siendo un pilar fundamental durante el desarrollo de este trabajo.

A mi tutora de trabajo de grado, por su orientación, acompañamiento, disposición y valiosos aportes, los cuales fueron fundamentales para la culminación exitosa de este proyecto.

A la institución universitaria, por ofrecerme una formación integral y las herramientas necesarias para mi crecimiento académico y profesional.

A todas aquellas personas que, de una u otra manera, contribuyeron a la materialización de este trabajo de grado, por su acompañamiento y palabras de ánimo durante todo este proceso, les expreso mi más sincero agradecimiento.

Resumen

El presente proyecto aborda el desarrollo de un prototipo portátil basado en tecnologías IoT, diseñado para la adquisición y procesamiento de señales biomédicas. El dispositivo integra sensores para la detección de señales de electroencefalografía (EEG) mediante electrodos, fotopletismografía (PPG) y acelerometría, permitiendo una evaluación multimodal del estado fisiológico del usuario. El sistema contempla el diseño del hardware y la implementación de software embebido sobre una tarjeta de circuito impreso (PCB), incorporando capacidades de transmisión inalámbrica. Los datos adquiridos son almacenados localmente y visualizados en la nube, facilitando su acceso remoto y el análisis en tiempo real, como soporte para estudios biomédicos asociados a crisis epilépticas.

Palabras clave: Portátil, electroencefalografía (EEG), fotopletismografía (PPG), acelerometría, epilépticas.

Abstract

This project addresses the development of a portable prototype based on IoT technologies, designed for the acquisition and processing of biomedical signals. The device integrates sensors for the detection of electroencephalography (EEG) signals through electrodes, photoplethysmography (PPG), and accelerometry, enabling a multimodal assessment of the user's physiological state. The system includes both hardware design and the implementation of embedded software on a printed circuit board (PCB), incorporating wireless communication capabilities. The acquired data are stored locally and visualized in the cloud, facilitating remote access and real-time analysis, in support of biomedical studies related to epileptic seizures.

Keywords: Portable, electroencephalography (EEG), photoplethysmography (PPG), accelerometry, epileptic.

Tabla de contenido

Introducción	14
Justificación	16
Objetivos.....	18
Objetivo General.....	18
Objetivos Específicos	18
Marco Teórico.....	19
Conceptos Generales	19
Monitorización de Signos Vitales.....	19
Frecuencia Cardíaca.....	19
Saturación de Oxígeno.....	20
Electroencefalografía (EEG).....	20
Señales Biomédicas	20
Dispositivos Biomédicos	21
Principio de Señales Eléctricas, PPG y Acelerómetro.....	21
Dispositivos Portátiles y Bajo Consumo Energético	29
Base de Datos en la Nube y Plataformas Gratuitas	34
Conceptos de Epilepsia.....	39
Soluciones IoT en Salud	48
Metodología	51
Fase 1 – Determinación de Requerimientos y Selección de Componentes.....	52
Fase 2 – Diseño de Hardware e Integración	53
Fase 3 – Implementación de Algoritmos y Transmisión de Datos.....	53

Fase 4 – Evaluación y Pruebas en Escenario Controlado.....	54
Resultados.....	55
Resultados Fase 1 – Determinación de Requerimientos y Selección de Componentes	55
Resultados Fase 2 – Diseño de Hardware e Integración.....	68
Resultados Fase 3 – Implementación de Algoritmos y Transmisión de Datos	96
Almacenamiento en Firebase Realtime Database.....	111
Almacenamiento en Tarjeta MicroSD	112
Resultados Fase 4 – Evaluación y Pruebas en Escenario Controlado	113
Respuesta del Sistema ante Condiciones Críticas.....	115
Pérdida de Señal del Sensor PPG	116
Movimientos Bruscos Detectados por el IMU	116
Alarma de Batería Baja.....	116
Ausencia de Tarjeta SD	116
Análisis y Discusión	122
Conclusiones.....	125
Recomendaciones	127
Referencias Bibliográficas.....	129

Lista de Tablas

Tabla 1 <i>Comparativa de Características Técnicas de Sensores PPG Comerciales.</i>	22
Tabla 2 <i>Comparativa de Características Técnicas de Sensores IMU (Unidad De Medición Inercial) Comerciales.</i>	28
Tabla 3 <i>Elementos Claves para el Diseño de Dispositivos IoT de Bajo Consumo</i>	30
Tabla 4 <i>Comparativas Plataformas en la Nube más Usadas</i>	35
Tabla 5 <i>Tarjetas y Dispositivos de Desarrollo Seleccionados para Pruebas Iniciales.</i>	58
Tabla 6 <i>Asignación de Pines ESP-32</i>	60
Tabla 7 <i>Especificaciones Técnicas y Requerimientos de Integración de los Componentes del Sistema.</i>	65
Tabla 8 <i>Lista de Materiales (BOM) y Especificaciones de Componentes del Sistema.</i>	86

Lista de Figuras

Figura 1 <i>Modelo Mecánico de un Acelerómetro con 2 AXIS</i>	27
Figura 2 <i>Características Para un Diseño Eficiente de Dispositivos Portátiles Biomédicos Basado en el Análisis PESTEL</i>	34
Figura 3 <i>Beneficios de Almacenamiento en la Nube.</i>	39
Figura 4 <i>Concepto e Impacto de las Epilepsias en las Personas</i>	41
Figura 5 <i>Estudios Sobre la Epilepsia</i>	47
Figura 6 <i>Beneficios del Uso de IoT en la Salud</i>	50
Figura 7 <i>Fases del Proyecto</i>	52
Figura 8 <i>Pinout y Distribución de Pines de la Tarjeta de Desarrollo ESP32 C3 Super Mini.</i> ...	59
Figura 9 <i>Configuración de Pines y Funciones del Sensor MAX30102</i>	62
Figura 10 <i>Circuito de Aplicación Típica y Diagrama de Bloques del Sensor MAX30102.</i>	63
Figura 11 <i>Conexiones Recomendadas para Integrado IMU (Bus I2C)</i>	64
Figura 12 <i>Pruebas del ESP-32 C3 con el PPG, IMU Y EEG</i>	68
Figura 13 <i>Diagrama de Bloques del Sistema y Base del Diseño Electrónico</i>	70
Figura 14 <i>Simulación del Circuito de Gestión de Potencia en Estado Desactivado (Off).</i>	73
Figura 15 <i>Simulación del Circuito de Gestión de Potencia en Estado Activado (On).</i>	74
Figura 16 <i>Diseño del Circuito de Adaptación de Impedancia para Antena Wi-Fi Bluetooth.</i>	78
Figura 17 <i>Dimensiones y Diseño de Referencia del Área de Antena en la PCB.</i>	79
Figura 18 <i>Esquema del Circuito de Control y Activación para el Buzzer.</i>	82
Figura 19 <i>Esquema Electrónico del Sistema de Gestión de Energía, Carga y Regulación de Tensión</i>	83

Figura 20 <i>Esquema Electrónico del Sistema de Procesamiento Central y Periféricos de Entrada/Salida.</i>	84
Figura 21 <i>Vista de Diseño de las Capas Superior (Top) e Inferior (Bottom) de la PCB del Sistema Monitor BioIoT.</i>	85
Figura 22 <i>Integración Física de los Módulos de Hardware del Prototipo Monitor BioIoT.</i>	91
Figura 23 <i>Modificaciones para Conexiones hacia Módulo PPG.</i>	92
Figura 24 <i>Medición de Corriente Durante el Proceso de Carga de la Batería Lipo.</i>	93
Figura 25 <i>Medición de Consumo de Corriente del Sistema en Modo de Operación Local Sin Transmisión Inalámbrica.</i>	94
Figura 26 <i>Diagrama de Flujo del Algoritmo Principal del Firmware (Setup Y Loop)</i>	98
Figura 27 <i>Interfaz de Firebase Realtime Database con Estructura JSON para el Registro de Variables Biométricas.</i>	107
Figura 28 <i>Visualización de Registros Históricos Biométricos y Ambientales Exportados a Formato de Hoja de Cálculo.</i>	108
Figura 29 <i>Visualización del Archivo de Registro (Log.Txt) con Datos Estructurados por Delimitadores.</i>	109
Figura 30 <i>Panel de Control (Dashboard) Web para la Monitorización en Tiempo Real de Datos Fisiológicos e Inerciales.</i>	110
Figura 31 <i>Cuotas de Consumo y Almacenamiento para el Plan Spark en la Plataforma Firebase</i>	112
Figura 32 <i>Visualización de Biomarcadores y Métricas de Movimiento en la Interfaz Web del Monitor BioIoT.</i>	114

Figura 33 <i>Estructura de Datos JSON en Firebase Realtime Database para el Monitoreo Multivariable de Biomarcadores.</i>	115
Figura 34 <i>Monitorización de Procesos y Depuración del Firmware Mediante la Terminal Serial de Visual Studio Code.</i>	118
Figura 35 <i>Respuesta del Sistema y Flujo de Datos Capturados Mediante Comunicación Serial.</i>	119
Figura 36 <i>Respuesta del Sistema y Gestión de Excepciones Ante la Desconexión de la Tarjeta SD.</i>	120

Lista de Apéndices

Apéndice A <i>Distribución Pines del SoC ESP32-C3</i>	141
Apéndice B <i>Esquemático Tarjeta de Desarrollo ESP32-C3 Super Mini</i>	142
Apéndice C <i>Característica de Pines del Bus I2C para el MAX30102</i>	143
Apéndice D <i>Hojas de Datos de Componentes Preliminares</i>	144
Apéndice E <i>Listado Tiempos del Sistema</i>	146
Apéndice F <i>Diseño Preliminar de la Carcasa</i>	149

Introducción

La epilepsia es uno de los trastornos neurológicos más frecuentes a nivel mundial, afectando a millones de personas y caracterizándose por la presencia de actividad eléctrica cerebral anómala que da lugar a crisis con diversas manifestaciones clínicas (Organización Mundial de la Salud [OMS], 2024). Debido a esta variabilidad, el diagnóstico y el monitoreo continuo representan un desafío, especialmente fuera del entorno hospitalario, donde la subnotificación y la dependencia de registros manuales por parte de pacientes y cuidadores limitan la precisión del seguimiento clínico (Serrano et al., 2023).

En este contexto, los dispositivos portátiles y el uso de tecnologías basadas en electroencefalografía (EEG), fotopletismografía (PPG) y acelerometría han surgido como alternativas prometedoras para el monitoreo de señales fisiológicas relevantes asociadas a crisis epilépticas (Ingolfsson et al., 2024). Estas tecnologías permiten la adquisición de información multimodal que puede ser utilizada en estudios biomédicos orientados a la comprensión y análisis de este tipo de eventos (Zambrana-Vinaroz et al., 2022).

Bajo esta premisa, el presente documento describe el desarrollo de un proyecto aplicado enfocado en el diseño y la implementación de un prototipo electrónico portátil, abordando las distintas etapas de investigación, selección de componentes, diseño de hardware, programación, adquisición y almacenamiento de señales biomédicas. El sistema desarrollado se concibe como una plataforma tecnológica que permita, a futuro, su utilización en investigaciones orientadas a la detección temprana de epilepsia en población pediátrica, sin constituir un dispositivo de diagnóstico clínico.

Este proyecto aplicado forma parte de una iniciativa de investigación de mayor alcance desarrollada en el marco del semillero de investigación SINERGIA de la universidad (UNAD),

la cual se encuentra estructurada en distintas fases con el objetivo de abordar de manera progresiva los requerimientos técnicos y científicos asociados a la temática. En este contexto, el presente trabajo corresponde a la primera etapa del proyecto, centrada principalmente en el diseño, desarrollo y validación funcional del hardware del sistema propuesto.

En esta fase se aborda el desarrollo del prototipo electrónico y la evaluación de sus capacidades básicas, tales como la adquisición de señales biomédicas, el almacenamiento de datos y la transmisión de la información hacia una plataforma en la nube. Las pruebas realizadas se presentan como validaciones preliminares del funcionamiento del sistema electrónico, orientadas a verificar la operatividad del hardware y del prototipo en condiciones controladas.

Se espera contemplar en etapas posteriores procesos de calibración y validación utilizando equipos certificados, así como la participación de personal biomédico y médico especializado, con miras a realizar estudios más completos que permitan evaluar la viabilidad clínica del sistema desarrollado, sujeto a la disponibilidad de recursos y al establecimiento de colaboraciones interdisciplinarias.

Justificación

En la actualidad, el monitoreo de las crisis epilépticas se basa principalmente en la observación realizada por pacientes, y cuidadores, complementada por evaluaciones clínicas de corta duración efectuadas en entornos hospitalarios (Brinkmann et al., 2021). Dado que las crisis epilépticas son eventos poco frecuentes y presentan una alta variabilidad temporal y fisiológica, los profesionales de la salud rara vez pueden observarlas de manera directa durante las consultas o estudios clínicos puntuales. En consecuencia, el diagnóstico y seguimiento clínico dependen de reportes subjetivos que carecen de precisión (Serrano et al., 2023), lo que limita la detección de eventos que ocurren fuera del entorno clínico y dificulta la obtención de información precisa sobre la frecuencia y características reales de las crisis en la vida cotidiana del paciente (Beniczky & Ryvlin, 2018).

Para abordar esta limitación, el análisis de señales biomédicas ofrece una ventana objetiva a la fisiología del paciente. La electroencefalografía (EEG) proporcionan información directa sobre la actividad cerebral y se utilizan ampliamente en el estudio de condiciones neurológicas como la epilepsia, permitiendo incluso la identificación de eventos subclínicos que no presentan manifestaciones evidentes durante evaluaciones breves (Maganti & Rutecki, 2013), (Ortiz & Lanau, 2021). Complementariamente, la fotopletismografía (PPG) permite medir variaciones en el flujo sanguíneo, reflejando parámetros como la frecuencia cardíaca y la oxigenación, parámetros que presentan una alta correlación con la actividad de crisis epilépticas (Ingolfsson et al., 2024). Asimismo, la integración de acelerómetros facilita la identificación del movimiento corporal, permitiendo la clasificación de crisis convulsiva con manifestaciones motoras.

Ante este escenario, el desarrollo de un prototipo electrónico portátil con capacidades IoT se presenta como una alternativa tecnológica viable para mejorar el seguimiento ambulatorio. Este sistema permite la captura continua, objetiva y sincronizada de señales biomédicas, facilitando su almacenamiento y transmisión para un posterior análisis clínico o computacional. La integración de conectividad IoT no solo optimiza el seguimiento en tiempo real, sino que posibilita la creación de conjuntos de datos estructurados, fundamentales para el desarrollo futuro de algoritmos de detección automática. Aunque el enfoque principal de este prototipo es la población pediátrica, su arquitectura multimodal posee un amplio espectro de aplicación en trastornos del sueño, enfermedades cardiovasculares y otras condiciones neurológicas (Johansson et al., 2018).

Desde una perspectiva de impacto social, el desarrollo de este prototipo se alinea con el Objetivo de Desarrollo Sostenible 3 (Salud y Bienestar), al fortalecer las estrategias de monitoreo preventivo. Al proporcionar información fisiológica objetiva y prolongada, el dispositivo sirve como un insumo confiable para la toma de decisiones médicas, mejorando el bienestar de la población infantil sin pretender sustituir los procedimientos clínicos estándar. Por lo tanto, se justifica el desarrollo de un prototipo portátil, no invasivo y de bajo costo que, además de ser una herramienta práctica y accesible, sienta las bases para futuras investigaciones en el ámbito de la salud digital y la telemedicina.

Objetivos

Objetivo General

Desarrollar un prototipo electrónico portátil con capacidades IoT para la adquisición, y almacenamiento de señales EEG, PPG y acelerométricas, orientado al monitoreo biomédico continuo y al estudio de patrones fisiológicos asociados a crisis epilépticas.

Objetivos Específicos

Determinar los requerimientos del sistema mediante la selección de componentes electrónicos y la realización de pruebas experimentales con tarjetas de desarrollo y sensores disponibles en el mercado, con el fin de evaluar su viabilidad de integración en un prototipo portátil optimizado para bajo consumo energético.

Diseñar el hardware del sistema portátil de monitoreo biomédico, integrando sensores EEG, PPG y acelerométricos, junto con los módulos de procesamiento, almacenamiento y comunicación necesarios para la adquisición continua de señales fisiológicas.

Implementar algoritmos de adquisición, y filtrado de señales biomédicas, mediante técnicas de procesamiento digital de señales, con el fin de garantizar la integridad de los datos en sistemas de almacenamiento local y su transmisión eficiente a través de protocolos IoT para el monitoreo remoto.

Evaluar el funcionamiento del prototipo en escenarios controlados, verificando la correcta interacción entre hardware y software, la estabilidad del sistema y la consistencia de los datos adquiridos, almacenados y transmitidos tanto en memoria local como en la nube.

Marco Teórico

Conceptos Generales

Monitorización de Signos Vitales

La monitorización de signos vitales consiste en la medición continua o periódica de parámetros fisiológicos esenciales tales como: frecuencia cardíaca, saturación de oxígeno y frecuencia respiratoria, para detectar cambios en el estado de salud de un paciente. El uso de dispositivos portátiles e inalámbricos permite registrar estos datos en tiempo real, facilitando intervenciones tempranas ante deterioros clínicos (Reijmers et al., 2025). Estudios recientes demuestran que estos sistemas reducen las complicaciones hospitalarias y el tiempo de estancia, al proporcionar alertas inmediatas y seguimiento remoto del paciente, especialmente en entornos posquirúrgicos. Este enfoque mejora la calidad del cuidado al reducir la carga manual del personal médico y anticipar eventos críticos (Joshi et al., 2025).

Frecuencia Cardíaca

La frecuencia cardíaca indica el número de latidos del corazón por minuto y constituye un parámetro esencial para evaluar la actividad cardiovascular y el estado funcional del sistema circulatorio. En el monitoreo clínico moderno, se considera un biomarcador clave para detectar condiciones cardíacas, estrés fisiológico o cambios en el sistema nervioso autónomo. Los dispositivos portátiles permiten medirla de forma continua y remota, lo que facilita el seguimiento en tiempo real y mejora la detección temprana de anomalías. Esta capacidad es esencial para cuidados críticos, atención domiciliaria y seguimiento postoperatorio durante largos periodos (Lee et al., 2023).

Saturación de Oxígeno

La saturación de oxígeno en sangre o SpO₂, representa el porcentaje de hemoglobina que transporta oxígeno, proporcionando una medición directa de la eficacia respiratoria y la perfusión tisular. Su monitorización continua es crucial, ya que permite identificar episodios de hipoxia, aún en pacientes asintomáticos, y supervisar enfermedades pulmonares o disfunciones vasculares. Los sensores ópticos modernos incorporados en *wearables* están diseñados para uso en tiempo real y en distintos entornos, lo que mejora la capacidad de intervención clínica rápida (Kim & Baek, 2023).

Electroencefalografía (EEG)

Permite medir y registrar la actividad eléctrica del cerebro mediante pequeños electrodos colocados sobre el cuero cabelludo. Este procedimiento ayuda a observar los patrones de las ondas cerebrales y se utiliza principalmente para apoyar el diagnóstico o seguimiento de alteraciones neurológicas como convulsiones, epilepsia, trastornos del sueño, lesiones cerebrales y otros problemas relacionados con la actividad cerebral (MedlinePlus, 2025).

Señales Biomédicas

Las señales biomédicas como PPG, ECG o EEG son representaciones digitales de procesos fisiológicos que revelan la función del sistema cardiovascular, nervioso y respiratorio. El análisis de estas señales permite diagnosticar patologías, evaluar riesgos y monitorear tratamientos, utilizando técnicas modernas de procesamiento de señales y aprendizaje automático. En el ámbito de dispositivos portátiles, esta capacidad ha impulsado avances hacia modelos predictivos y sistemas autocontrolados que actúan en tiempo real (Charlton et al., 2023).

Dispositivos Biomédicos

Los dispositivos biomédicos engloban sensores, *wearables*, equipos de diagnóstico y sistemas de monitorización que recopilan y procesan datos fisiológicos para uso clínico o personal. Con la proliferación de tecnologías digitales, estos dispositivos ahora integran conectividad inalámbrica, algoritmos de inteligencia artificial y almacenamiento en la nube. Aunque los dispositivos biomédicos modernos pueden capturar datos en tiempo real, su precisión puede verse comprometida por ruidos, movimiento y variaciones anatómicas del usuario, lo cual afecta la fiabilidad de las mediciones. Estudios recientes han desarrollado métodos avanzados de limpieza de señal y detectar errores en tiempo real para mejorar la calidad de las lecturas, especialmente durante actividades físicas intensas. Esto es clave para asegurar que las interpretaciones clínicas basadas en estos datos sean válidas (Verma et al., 2022), (Reyes, 2025).

Principio de Señales Eléctricas, PPG y Acelerómetro

La Fotopletoislografía (PPG) se ha consolidado como una herramienta fundamental en el ámbito de la salud, pues permite medir parámetros vitales como la frecuencia cardíaca, la saturación de oxígeno y el flujo sanguíneo a partir de principios ópticos (Park et al., 2022). Esta tecnología ha impulsado el desarrollo de diversos dispositivos de medición que integran sensores especializados y algoritmos avanzados, diseñados a partir de estudios bioeléctricos, lo que ha facilitado su aplicación en entornos clínicos y de investigación (Martínez Duque, 2024).

Sin embargo, una de las principales limitaciones de la señal PPG es su alta susceptibilidad al ruido, lo que puede afectar la calidad de los registros y conducir a errores en la interpretación de los datos. Para reducir estas interferencias resulta necesario aplicar procesos de pretratamiento de la señal, ya que en los registros biomédicos son frecuentes problemas como el ruido eléctrico de la red de energía, las variaciones en la línea base y, especialmente, los

artefactos de movimiento, generados por desplazamientos involuntarios o voluntarios del paciente durante la medición (Park et al., 2022).

Existen múltiples sensores de Fotopleximografía (PPG) disponibles en el mercado, que permiten adquirir señales biomédicas para monitoreo de frecuencia cardíaca y saturación de oxígeno, desde módulos básicos para prototipos electrónicos hasta soluciones integradas en *wearables* comerciales, a continuación, se presenta una tabla comparativa con algunos de los sensores más comerciales.

Tabla 1

Comparativa de Características Técnicas de Sensores PPG Comerciales

Modelo Sensor/Modulo	Señales de aplicación	Interfaz de comunicación	Resolución ADC	Características relevantes
MAX86141	PPG: HR, SpO2	SPI	19 bits	Doble canal de lectura óptica simultánea. Front-end analógico de bajo ruido. Cancelación avanzada de luz ambiental (ALC). Ultra bajo consumo energético y encapsulado compacto (WLP).
MAXM86161	PPG: HR, SpO2	I2C	19 bits	Tres drivers LED programables de alta corriente. Front-end analógico de bajo ruido. Cancelación avanzada de luz ambiental (ALC) y algoritmo de detección/corrección “picket fence”.
MAX30102	PPG: HR, SpO2	I2C	18 bits	Electrónica de bajo ruido con rechazo de luz ambiental. Modo de apagado por software, facilitando la integración con microcontroladores y reduciendo el consumo en estado inactivo.
ams AS7058	PPG, ECG, BIOZ (Body Impedance), EDA (Electrodermal Activity)	Análoga	20 bits	Adquisición multimodal sincronizada, al integrar en un solo sistema la captura de señales ópticas (PPG) y bioeléctricas (ECG, bioimpedancia y actividad electro dermal).

Modelo Sensor/Modulo	Señales de aplicación	Interfaz de comunicación	Resolución ADC	Características relevantes
				Front-end analógico de alta sensibilidad y bajo ruido. Capacidad avanzada de censado óptico, con múltiples entradas para fotodiodos y drivers de emisión configurables, junto con mecanismos de cancelación de interferencias por luz ambiental.
ams AS7056	PPG, HRM, SpO2, PTT	Análoga	20 bits	<p>Soporte flexible para múltiples configuraciones ópticas, al integrar drivers para LEDs y VCSEL, junto con la capacidad de muestrear múltiples entradas de fotodiodo de manera simultánea. Adquisición paralela de señales PPG, mediante canales ADC independientes que permiten mediciones simultáneas y un mejor análisis comparativo de señales ópticas.</p> <p>Funciones internas de control y compensación de señal, como el ajuste automático de offset del fotodiodo y la detección de proximidad integrada en uno de los canales PPG, mejorando la estabilidad de la medición.</p>
MAX86176	PPG + ECG	SPI / I2C	20 bits	<p>Front-end analógico integrado para adquisición sincronizada de ECG y PPG, permitiendo el registro simultáneo y coherente de señales bioeléctricas y ópticas.</p> <p>Canal ECG avanzado con funciones de acondicionamiento y seguridad, que incorpora filtrado de interferencias electromagnéticas, polarización de electrodos, detección de contacto y circuitos de realimentación para estabilidad de la señal.</p>

Modelo Sensor/Modulo	Señales de aplicación	Interfaz de comunicación	Resolución ADC	Características relevantes
				Sistema óptico PPG flexible y sincronizado con ECG, con soporte para múltiples emisores y entradas de fotodiodo, facilitando configuraciones ópticas variadas y análisis multimodal. Capacidades internas de autodiagnóstico y calibración, que permiten verificar el correcto funcionamiento del sistema de adquisición sin requerir instrumentación externa adicional.
MAX30101	PPG: HR, SpO2	I2C	18 bits	Electrónica de adquisición de bajo ruido con rechazo de luz ambiental.
MAX32664	Sensor hub Biométrico con MCU integrada	I2C, SPI	NA	Sensor hub con firmware y algoritmos embebidos, capaz de gestionar sensores biomédicos ópticos y entregar datos crudos o procesados al sistema anfitrión, reduciendo la carga de procesamiento externo. Interfaz dedicada para sensores biomédicos, que permite la comunicación directa con distintos sensores ópticos de Analog Devices mediante buses SPI o I ² C, según la versión del dispositivo. Comunicación digital con microcontrolador anfitrión, a través de una interfaz I ² C en modo esclavo, facilitando el acceso a datos, configuración del sistema y actualización de firmware. Soporte para integración de acelerómetros, permitiendo la compensación de artefactos por movimiento mediante el uso de datos inerciales, ya sea de sensores conectados directamente o proporcionados por el sistema anfitrión.

Nota. Abreviaturas: PPG = fotopletismografía; HR = frecuencia cardíaca; SpO₂ = saturación de oxígeno; ECG = electrocardiograma; BIOZ = bioimpedancia; EDA = actividad electrodérmica; PTT = tiempo de tránsito de pulso; ADC = convertidor analógico a digital; MCU = unidad de microcontrolador; NA = no aplica. Los modelos MAX pertenecen a Analog Devices y los modelos AS a ams OSRAM. Elaboración basada en las hojas de especificaciones técnicas de los fabricantes.

Un dispositivo de Fotopletismografía (PPG) está compuesto normalmente por un diodo emisor de luz (LED) y un fotodetector, cuya disposición determina dos configuraciones principales, transmisiva y reflectante. En el modo transmisivo, el fotodetector se ubica frente al LED, con el tejido en medio, lo que permite medir la luz que atraviesa zonas delgadas como los dedos, lóbulos de las orejas o los pies. Este tipo suele ofrecer mediciones más estables (Jhuma et al., 2024). En contraste, el modo reflectante posiciona LED y fotodetector en el mismo lado, captando la luz dispersada tras incidir en el tejido. Aunque la señal suele ser de menor intensidad y más susceptible al ruido, este diseño facilita la medición en áreas donde la transmisión es difícil, como la frente, la muñeca o la arteria carótida (Venema et al., 2012).

El principio de funcionamiento se fundamenta en la interacción de la luz con los tejidos, explicada mediante la Ley de Beer-Lambert y su versión modificada. En este contexto, parámetros como la absorción y dispersión de la luz dependen de la concentración y propiedades ópticas de los componentes biológicos presentes en la sangre y tejidos (Buxi et al., 2015).

La estructura básica de hardware incluye el LED, el fotodetector, un controlador del emisor, filtros para reducir ruido, un convertidor analógico-digital y un microprocesador. Gracias a esta arquitectura sencilla y de bajo costo, los sistemas PPG han logrado una amplia aplicación

en la monitorización de parámetros fisiológicos en contextos clínicos y portátiles (Jhuma et al., 2024).


La fotopleletismografía es una técnica bastante práctica porque, a diferencia de otros métodos para analizar la circulación sanguínea, no requiere procedimientos invasivos, es de bajo costo y permite una gran movilidad (Allen, 2007). Esto ha hecho que su uso crezca tanto en aplicaciones clínicas como en dispositivos portátiles. Una de sus principales ventajas es que los sensores se colocan fácilmente y las mediciones resultan relativamente sencillas de obtener. Sin embargo, la calidad de los registros puede verse alterada por factores externos, como la temperatura en el lugar donde se mide, la luz ambiental presente o incluso las características particulares de cada persona, por ejemplo, el tipo de piel. Por eso, todavía es necesario trabajar en técnicas más avanzadas de procesamiento de señales que permitan conseguir resultados más claros y confiables (Park et al., 2022).

De manera complementaria a las señales fotopleletismográficas previamente descritas, los acelerómetros digitales basados en tecnología MEMS constituyen un componente fundamental en los sistemas modernos de monitoreo biomédico, al permitir la adquisición objetiva de información relacionada con el movimiento y la orientación corporal (Szermer et al., 2021). Estos sensores están constituidos por microestructuras mecánicas integradas en un chip de silicio, donde una masa inercial suspendida se desplaza ante la presencia de aceleraciones estáticas o dinámicas, generando variaciones físicas, generalmente capacitivas, que son acondicionadas y convertidas a formato digital por circuitos electrónicos integrados en el mismo dispositivo (Zhao et al., 2019). Gracias a esta integración, los acelerómetros MEMS ofrecen reducido tamaño, bajo consumo energético y comunicación directa mediante interfaces digitales, lo que facilita su incorporación en sistemas embebidos portátiles (Mohammed et al., 2018).

En la Figura 1, se muestra el diseño mecánico interno de un circuito con tecnología MEMS (Sistema microelectromecánico). Esta arquitectura integra elementos mecánicos, sensores, actuadores y componentes electrónicos sobre un sustrato común de silicio mediante tecnología de microfabricación (Analog Devices, 2015).

Figura 1

Modelo Mecánico de un Acelerómetro con 2 AXIS



Nota. En la imagen se muestra el diseño mecánico interno de un circuito con tecnología MEMS (Sistema microelectromecánico), específicamente cómo la orientación a 90 grados del sensor permite crear un acelerómetro de dos ejes. Tomado de *Accelerometer and Gyroscopes Sensors: Operation, Sensing, and Applications* (p. 6), por M. Dadafshar, 2015, Analog Devices.

En el ámbito biomédico, su uso resulta especialmente relevante para el registro de patrones de actividad, detección de movimientos anómalos y caracterización de eventos motores (Davidashvilly et al., 2024), permitiendo complementar señales fisiológicas como EEG y PPG en plataformas de monitoreo multimodal orientadas al análisis de estados neurológicos y fisiológicos en entornos no clínicos (Ingolfsson et al., 2024).

Existen múltiples acelerómetros digitales basados en tecnología MEMS, a continuación, se presenta en la **¡Error! No se encuentra el origen de la referencia.** la comparativa de diferentes sensores comerciales disponibles comercialmente.

Tabla 2

Comparativa de Características Técnicas de Sensores IMU (Unidad De Medición Inercial)

Comerciales

Sensor IMU	Grados de Libertad (DoF)	Componentes Integrados	Interfaz	Notas / Aplicaciones
MPU-6050	6 DoF	Acelerómetro, Giroscopio	I ² C / SPI	Módulo clásico muy usado en proyectos de movimiento y estabilización; alta disponibilidad de ejemplos y librerías.
MPU-9250	9 DoF	Acelerómetro, Giroscopio, Magnetómetro	I ² C / SPI	IMU con magnetómetro, útil para orientación completa y navegación en 3D.
LSM6DS3	6 DoF	Acelerómetro, Giroscopio	I ² C / SPI	Sensor MEMS de STMicro; Detecta inclinación y movimiento preciso, bajo consumo.
BMI160	6 DoF	Acelerómetro, Giroscopio	I ² C / SPI	IMU moderno con detección de movimiento eficiente y soporte para conteo de pasos.
BMI323	6 DoF	Acelerómetro, Giroscopio	I ² C / SPI	Versión más reciente mejorada en consumo y filtrado de movimiento, robusto para Wearables.
LSM303D + L3GD20	9 DoF	Acelerómetro, Magnetómetro, Giroscopio	I ² C	Combinación modular usada para orientación 3D y proyectos educativos.

Nota. La tabla presenta una comparación de distintos sensores IMU disponibles en el mercado, destacando sus grados de libertad, componentes integrados, interfaces de comunicación y aplicaciones típicas. La información se organiza para facilitar la selección de sensores según necesidades de proyectos de movimiento, orientación o consumo energético.

Dispositivos Portátiles y Bajo Consumo Energético

Los dispositivos portátiles (*wearables* o sensores remotos) son aquellos sistemas electrónicos diseñados para ser llevados sobre el cuerpo o ubicados en el entorno inmediato, de manera cómoda, sin estar permanentemente conectados a una fuente fija de energía (Moeve Global, 2025). Una característica imprescindible de estos dispositivos es su bajo consumo energético, lo cual significa que operan eficientemente con recursos limitados de energía, prolongando su autonomía, minimizando la intervención humana para recargas y garantizando su viabilidad en ambientes remotos o con acceso limitado a la electricidad y permitiendo la recolección continua de datos biomédicos o industriales (Sarma et al., 2019). En este tipo de soluciones, la eficiencia se logra mediante estrategias como modos de suspensión, desactivación selectiva de periféricos y transmisión por lotes, que reducen significativamente el gasto energético y extienden la vida útil de la batería (Schuhmacher et al., 2023). Su aplicación es fundamental en entornos de Internet de las Cosas (IoT), donde se requiere autonomía y conectividad constante, especialmente en áreas de salud y monitoreo ambiental (Sarma et al., 2019). En el ámbito biomédico, estos dispositivos facilitan la medición de parámetros críticos como la saturación de oxígeno y la frecuencia cardíaca, ofreciendo portabilidad, bajo costo y escalabilidad para estudios clínicos o de investigación (Zambrana-Vinaroz et al., 2022). Estas características los convierten en una base tecnológica idónea para proyectos que combinan almacenamiento local, envío de datos a la nube y monitoreo en tiempo real. En la Tabla 3 se presenta los elementos claves a considerar en dispositivos IoT para bajo consumo energético.

Tabla 3*Elementos Claves para el Diseño de Dispositivos IoT de Bajo Consumo*

Categoría	Elementos Clave	Descripción y Aplicación
Estrategias de Bajo Consumo	Modos de suspensión (<i>sleep modes</i>)	Apagado o reposo de componentes críticos cuando no hay actividad.
	Desactivación de periféricos	Apagado selectivo de módulos (ej. radio) cuando no se transmite información.
	Transmisión por lotes (<i>batching</i>)	Acumulación local de datos para envíos periódicos en lugar de continuos.
	Hardware especializado	Uso de aceleradores y sensores de bajo <i>duty cycle</i> para reducir carga de CPU.
Ventajas de Implementación	Selección de componentes	Elección de microcontroladores y chips (PPG, ultrasonido) con bajas corrientes.
	Autonomía prolongada	Mayor continuidad en el monitoreo de señales críticas (PPG, EEG).
	Portabilidad real	Reducción del peso y tamaño de la batería para uso cómodo en el hogar o niños.
	Escalabilidad	Despliegue en diversas áreas sin depender de infraestructura compleja.
	Eficiencia operativa	Menores costos de mantenimiento, recarga y dependencia energética externa.
	Integración clínica	Capacidad de operar en condiciones de campo (movimiento, luz variable).
Retos y Criterios de Diseño	Balance muestreo vs. energía	Equilibrio entre el detalle de la señal (muestreo alto) y la vida de la batería.
	Calidad y procesamiento	Necesidad de filtrado de ruido y artefactos que incrementan el consumo.
	Gestión de datos	Decisión entre almacenar localmente (memoria) vs. transmitir (radiofrecuencia).
	Seguridad y privacidad	Implementación de cifrado y autenticación en dispositivos médicos.
	Cumplimiento regulatorio	Certificación clínica bajo estándares de límites de potencia y emisiones.

Nota. La tabla describe los parámetros técnicos necesarios para optimizar la eficiencia energética en dispositivos médicos portátiles. Abreviaturas: PPG = fotopleletismografía; EEG = electroencefalograma.

Este tipo de tecnologías ha crecido rápidamente gracias al avance de los sistemas IoT (*Internet of Things*) y a la miniaturización de los circuitos electrónicos, que posibilitan integrar sensores de alta precisión en equipos cada vez más pequeños y eficientes (Mansergas Fernández, 2021). Estudios recientes destacan que la demanda global de *wearables* para salud alcanzará un crecimiento anual superior al 20 % debido a la necesidad de monitoreo remoto y a la tendencia de eficiencia energética en electrónica (Grand View Research, 2025). Estas innovaciones son esenciales para aplicaciones que requieren autonomía prolongada, como la medición de variables cardiovasculares o neurológicas en entornos domésticos o clínicos (Kurul et al., 2026).

La creciente demanda de monitorización domiciliaria y seguimiento remoto de pacientes hace imperativo el desarrollo de dispositivos portátiles y de bajo consumo energético. Los informes de mercado muestran un crecimiento sostenido del sector de *wearables* médicos, con un valor estimado en decenas de miles de millones de dólares para 2024 (Grand View Research, 2025). A nivel técnico y clínico, la literatura reciente respalda el uso de dispositivos portátiles para tareas como pulsioximetría remota (Sinthia et al., 2026) y monitoreo cardíaco (Ranjan et al., 2025), y subraya que las técnicas de diseño de bajo consumo, como modos de sueño, transmisión por lotes y aceleradores de hardware para *Edge-AI*, son críticas para prolongar la autonomía y reducir costos operativos en implantaciones masivas. En el desarrollo de dispositivos médicos portátiles, la eficiencia energética es un factor crítico que determina su viabilidad en aplicaciones clínicas reales. Tesema et al. (2024) presentan una taxonomía detallada de técnicas de bajo consumo que abordan este desafío, clasificando métodos como la gestión dinámica de energía, el

diseño de hardware optimizado y el uso de algoritmos de procesamiento eficientes. Estas estrategias no solo prolongan la vida útil de los dispositivos, sino que también permiten su integración en sistemas de monitoreo continuo sin comprometer la precisión ni la conectividad (Tesema et al., 2024). Asimismo, revisiones sobre IoT en salud destacan que la combinación de almacenamiento local temporal con respaldo en la nube mejora la continuidad de los datos y la viabilidad operativa en entornos domésticos (Li et al., 2018). Estudios clínicos recientes demuestran que los oxímetros de bajo coste aplicados en el hogar pueden mantener una adecuada precisión diagnóstica y mejorar la detección temprana, por ejemplo, de complicaciones respiratorias (Rojas & Mosquera, 2024; Wilkerson et al., 2023).

La pandemia provocada por el COVID-19 evidenció la fragilidad de los sistemas de salud ante emergencias sanitarias masivas, generando un colapso en los entornos clínicos. En este contexto, los dispositivos médicos portátiles adquirieron un papel crucial, ya que permiten realizar diagnósticos preliminares desde casa, reduciendo la necesidad de asistencia hospitalaria directa. Sin embargo, el acceso a estas tecnologías sigue siendo limitado por su alto costo y el gran volumen de los equipos, lo que impide que muchas personas puedan beneficiarse de ellas (Mansergas Fernández, 2021).

En los últimos años se ha evidenciado que el desarrollo de equipos y dispositivos electrónicos se orienta cada vez más hacia la personalización y la búsqueda del ultra bajo consumo energético, como respuesta a la necesidad de eficiencia y al auge de los dispositivos portátiles en múltiples áreas, no solo en el ámbito de la salud, sino también a nivel industrial. A lo largo del tiempo, la electrónica ha avanzado de manera constante hacia la eficiencia energética, la miniaturización y, en la actualidad, hacia una mayor personalización e innovación. En consecuencia, la justificación técnica y de mercado apoya la elección de un dispositivo

portátil de baja potencia para la captura de señales PPG/EEG con fines de investigación y detección precoz, siempre acompañado de validación y consideraciones éticas sobre privacidad y seguridad de los datos.

La Figura 2 presenta un análisis PESTEL adaptado específicamente al diseño eficiente de dispositivos portátiles biomédicos, destacando los factores externos que condicionan su viabilidad. La estructura se organiza en seis dimensiones clave. Político (P), la cual se centra en el marco regulatorio, subrayando la importancia de cumplir con certificaciones y normativas para garantizar su uso clínico seguro. Económico (E), aborda la sostenibilidad financiera y operativa, con énfasis en la reducción de costos mediante un mantenimiento simplificado y un consumo energético mínimo. Social (S), considera la escalabilidad, proponiendo un despliegue en múltiples ubicaciones para ampliar el acceso y beneficiar a usuarios fuera del entorno hospitalario. Tecnológico (T), examina la incorporación de técnicas de bajo consumo, como la transmisión por lotes y los modos de suspensión, con el fin de prolongar la vida útil del sistema. Ecológico (E), se orienta a maximizar la eficiencia energética, favoreciendo la operación en contextos con recursos limitados. Legal (L), resalta la necesidad de garantizar la privacidad de los datos mediante mecanismos de cifrado y autenticación.

Figura 2

Características para un Diseño Eficiente de Dispositivos Portátiles Biomédicos Basado en el Análisis PESTEL



Nota. El acrónimo PESTEL representa los factores políticos, económicos, sociales, tecnológicos, ecológicos y legales. Representación visual generada mediante la herramienta de inteligencia artificial Napkin AI.

Base de Datos en la Nube y Plataformas Gratuitas

Las bases de datos en la nube son sistemas de almacenamiento y gestión de información que operan en servidores remotos y se acceden a través de Internet, lo que permite a los usuarios consultar, actualizar y escalar sus datos sin necesidad de infraestructura física propia. Estas soluciones ofrecen ventajas como escalabilidad elástica, alta disponibilidad mediante replicación geográfica, copias de seguridad automáticas y acceso multiplataforma, características que las convierten en un componente esencial para aplicaciones que requieren transmisión y almacenamiento continuo de datos en tiempo real (Kurul et al., 2026).

Dentro de este ecosistema, las plataformas con planes gratuitos, por ejemplo, Firebase (Google, 2026), MongoDB Atlas Free Tier (MongoDB, 2026) o AWS DynamoDB Free Tier (Amazon Web Services [AWS], 2026), proporcionan un entorno de prueba ideal para proyectos

académicos y prototipos, pues permiten validar conceptos, realizar las primeras pruebas de conectividad y almacenamiento y evaluar el rendimiento sin incurrir en costos iniciales significativos. Estos planes ofrecen capacidades básicas de escalabilidad, seguridad y APIs de integración que facilitan el desarrollo rápido, aunque presentan limitaciones de capacidad y concurrencia que los desarrolladores deben considerar al pasar a etapas comerciales.

A continuación, se presenta una tabla comparativa de plataformas en la nube para enviar, almacenar, gestionar y visualizar datos. Las plataformas evaluadas corresponden a soluciones comerciales ampliamente utilizadas, con distintos niveles de complejidad y escalabilidad, desde herramientas orientadas a prototipos hasta infraestructuras empresariales.

Tabla 4

Comparativas Plataformas en la Nube más Usadas

Plataforma	Tipo / Enfoque	Base de datos / Visualización	Escalabilidad / Nivel	Facilidad de uso	Notas / Aplicaciones	Referencia
Firebase (Google)	Backend general + BD en tiempo real	Realtime Database / Firestore	Media-alta	Fácil	BD NoSQL en tiempo real, ideal para prototipos y Apps móviles/web; integrado con Google Cloud Platform	(Google, 2026)
AWS IoT + AWS Cloud	IoT completo + servicios en la nube	DynamoDB, S3 y otros	Muy alta	Intermedia	Solución con servicios integrados para IoT y BD; AWS tiene amplia escalabilidad y opciones avanzadas como	(MongoDB, s/f)

Plataforma	Tipo / Enfoque	Base de datos / Visualización	Escalabilidad / Nivel	Facilidad de uso	Notas / Aplicaciones	Referencia
					análisis, ML y gestión de dispositivos	
Microsoft Azure IoT	IoT empresarial + nube	Cosmos DB, SQL, Blob Storage	Alta	Intermedia	Ofrece servicios IoT Hub, análisis y herramientas BI; buena integración para entorno Microsoft y soluciones híbridas	(Microsoft, s/f)
Google Cloud IoT	IoT + servicios de datos de Google	BigQuery, Cloud SQL	Alta	Intermedia	Potente para análisis de datos y ML (TensorFlow), pero requiere configuración más técnica; IoT Core fue discontinuado y se integra con Pub/Sub	(Google Cloud, 2024)
ThingSpeak	IoT + visualización básica	Sí (almacenas series de tiempo)	Baja-Media	Fácil	Ideal para proyectos académicos y prototipos pequeños, con visualización de datos y análisis simples	(MathWorks, s/f)
Ubidots	IoT orientado a dashboards	Sí (tiempo real, API REST)	Media	Fácil	Permite enviar datos, crear dashboards y	(Ubidots, s/f)

Plataforma	Tipo / Enfoque	Base de datos / Visualización	Escalabilidad / Nivel	Facilidad de uso	Notas / Aplicaciones	Referencia
					alertas; apto para prototipos y aplicaciones de monitoreo	
Blynk / Particle Cloud	IoT + App móvil	Sí (API para BD básica)	Baja	Fácil	Más orientado a prototipos y soluciones móviles rápidas que a soluciones de producción grandes	(Bayborodin, 2023)

Nota. Elaboración basada en la información técnica y descriptiva de las plataformas consultadas.

Las categorías de escalabilidad, nivel y facilidad de uso corresponden a una valoración comparativa cualitativa orientada a proyectos IoT, académicos y de prototipado. BD significa base de datos. Fuentes: Bayborodin (2023), Google (2026), MathWorks (s. f.), Microsoft (2026), MongoDB (2026) y Ubidots (2026).

Estudios recientes muestran que una alta proporción de organizaciones de salud ya utilizan soluciones basadas en nube, por ejemplo, el 70 % de organizaciones del sector salud en EE. UU. han adoptado cómputo en la nube, con expectativa de que ese porcentaje alcance el 90% para 2025 (DuploCloud, 2023). En paralelo, el mercado global de dispositivos médicos portátiles ha crecido de USD 22.44 mil millones en 2022 a USD 27.37 mil millones en 2023, con una tasa de crecimiento anual compuesta (CAGR) cercana al 21.9 % (Globenewswire, 2023), y se espera que alcance más de USD 75 mil millones hacia 2030 (MarketsandMarkets, 2025). Además, investigaciones técnicas han demostrado que arquitecturas IoT que incorporan *Fog Computing* pueden reducir significativamente la latencia en aplicaciones médicas sensibles, un

factor crítico para dispositivos biomédicos portátiles que envían datos en tiempo real (Shukla et al., 2019).


Se espera a futuro que las bases de datos en la nube y las plataformas gratuitas formen parte integral de la infraestructura tecnológica de los dispositivos biomédicos portátiles (Rashid et al., 2024). Estas tecnologías no sólo reducen barreras de entrada (costo, infraestructura física), sino que permiten escalabilidad, interoperabilidad y respaldo remoto de datos críticos (Shah et al., 2022). En el contexto de IoT aplicado a la salud, la nube hace posible la recolección continua de señales fisiológicas (como PPG, ECG, EEG) desde dispositivos portátiles, su procesamiento, análisis y visualización remota, fortaleciendo la telemedicina y la intervención temprana.

En el proyecto en curso, el uso de una base de datos en la nube añade valor en varios aspectos. Permite almacenar historiales de pacientes de forma segura, sin necesidad de infraestructura local pesada. Facilita la actualización remota de software o modelos si se usan algoritmos de detección de epilepsia, sabiendo que los datos están accesibles desde cualquier lugar. Ofrece respaldo automático de registros, lo que reduce riesgo de pérdida de datos, y posibilita análisis longitudinales para investigación. Mejora la escalabilidad; si el prototipo se convirtiera en dispositivo real, la nube permite crecer a más usuarios sin duplicar infraestructura.

En la Figura 3, se muestra una representación de los beneficios acerca del almacenamiento en la nube, mencionados anteriormente.

Figura 3

Beneficios de Almacenamiento en la Nube



Nota. La figura presenta los principales beneficios del almacenamiento en la nube aplicados a sistemas IoT, destacando el almacenamiento seguro, el respaldo automático, las actualizaciones remotas y la mejora de la escalabilidad. Representación visual generada mediante la herramienta de inteligencia artificial Napkin AI.

Conceptos de Epilepsia

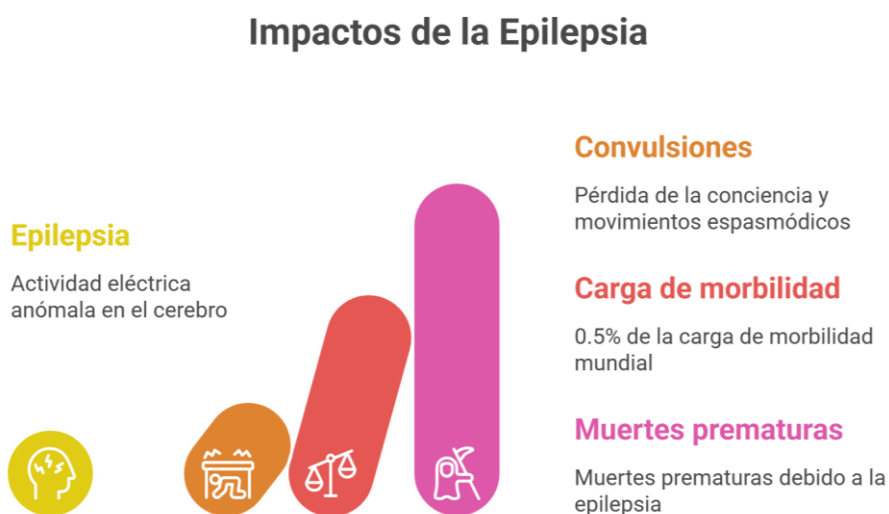
La epilepsia constituye una alteración del sistema nervioso central caracterizada por una actividad eléctrica anómala en el cerebro, que puede desencadenar una gama de manifestaciones clínicas como convulsiones, y pérdida de la conciencia (Organización Mundial de la Salud [OMS], 2024). Este padecimiento se encuentra entre los trastornos neurológicos más frecuente a nivel global, alrededor de 50 millones de personas padecen epilepsias, y representa un 0.5% de la carga de morbilidad mundial, con muertes prematuras (Organización Mundial de la Salud [OMS], 2024). La epilepsia puede manifestarse en cualquier etapa de la vida, aunque es más común en la infancia y en la tercera edad (Beghi, 2020). Siendo su incidencia en la infancia más

del doble que en la población adulta (Zuberi & Symonds, 2015). Un estudio en (Xu et al., 2026) publicó resultados sobre la epidemiología global, regional y nacional de la epilepsia idiopática (de origen genético) en niños de 0 a 14 años, abarcando el periodo de 1990 a 2021. En sus conclusiones indica que la epilepsia infantil sigue siendo un problema de salud global, con mayor impacto en niños menores de 1 año y en regiones de bajo desarrollo socioeconómico. Desde el enfoque clínico, la epilepsia se clasifica en función de los síntomas iniciales que presenta el paciente, diferenciándose entre epilepsias focales, generalizadas, de causa desconocida y aquellas no clasificadas (Reséndiz-Aparicio et al., 2019). Un diagnóstico preciso de la epilepsia es crucial para implementar un tratamiento adecuado. La duración y el enfoque del tratamiento varían según el tipo específico de epilepsia y las características individuales del paciente. La clasificación de las epilepsias se basa en el origen de la actividad cerebral anormal, distinguiéndose principalmente en focales, cuando se inician en una zona específica del cerebro, o generalizadas, cuando afectan a ambos hemisferios cerebrales (Scheffer et al., 2017). Las crisis focales se dividen en dos categorías: Crisis focales sin pérdida del conocimiento, y las crisis focales con alteración de la conciencia (Scheffer et al., 2017). Para las crisis generalizadas existen seis tipos de categorías: crisis de ausencia, crisis tónicas (causan rigidez muscular), crisis atónicas (pérdida del control muscular), crisis clónicas (movimientos musculares espasmódicos y repetitivos), crisis mioclónicas (movimientos espasmódicos breves y repentinos), crisis tónico-clónicas (rigidez y sacudidas del cuerpo, pérdida del control de la vejiga o mordedura de la lengua) (Scheffer et al., 2017). La Figura 4 ilustra los impactos de la Epilepsia, resume visualmente las principales consecuencias y características de esta enfermedad neurológica. Las barras crecientes de colores refuerzan visualmente la progresión y el alcance de estos impactos, ofreciendo una visión concisa de los desafíos que presenta la epilepsia en cuanto a las muertes

prematuras. El manejo tardío de esta condición es un factor determinante en la mortalidad prematura, especialmente en entornos con poco acceso a servicios de urgencias (Cook et al., 2015).

Figura 4

Concepto e Impacto de las Epilepsias en las Personas



Nota. La figura resume algunos impactos asociados con la epilepsia, como la presencia de convulsiones, la carga de morbilidad y las muertes prematuras relacionadas con esta condición. Representación visual generada mediante la herramienta de inteligencia artificial Napkin AI.

El diagnóstico de la epilepsia se realiza en un entorno hospitalario donde se realizan estudios basados en evaluaciones clínicas detalladas, estudios de electroencefalografía (EEG) y técnicas avanzadas de neuroimagen como lo es la resonancia Magnética (MRI), mientras que su tratamiento puede incluir terapia farmacológica, cirugía en casos específicos y el uso de dispositivos de neuro modulación (Scheffer et al., 2017). El monitoreo y seguimiento de la epilepsia en niños fuera del entorno hospitalario es fundamental para evaluar la eficacia del

tratamiento y ajustar las estrategias terapéuticas según la evolución del paciente (Hirtz et al., 2000). Actualmente, este proceso se basa principalmente en el autoinforme de los pacientes y sus cuidadores, quienes registran la frecuencia, duración e intensidad de los episodios epilépticos. Sin embargo, este método presenta múltiples limitaciones que pueden comprometer la precisión del seguimiento clínico. Uno de los principales desafíos es la subnotificación de crisis, ya que muchas convulsiones, en especial las crisis de ausencia y las nocturnas, pueden pasar desapercibidas, lo que dificulta una evaluación realista del control de la enfermedad. Además, la falta de conocimiento sobre los distintos tipos de crisis epilépticas por parte de los cuidadores puede llevar a una interpretación inexacta de los síntomas, generando reportes imprecisos. Otro factor que afecta la confiabilidad del seguimiento es la dificultad para recordar y documentar episodios epilépticos con exactitud, especialmente cuando los eventos ocurren en momentos inesperados o si los cuidadores no pueden registrar la información de inmediato. Esta falta de precisión puede impactar negativamente en la toma de decisiones médicas, ya que un subregistro de crisis podría generar ajustes inadecuados en el tratamiento, mientras que un sobre registro podría conducir a una medicación innecesaria y efectos adversos (Elger & Hoppe, 2018).

A continuación, se presenta una descripción detallada de estudios más significativos y relevantes encontrados, acorde al tema principal del proyecto en la detección de epilepsias por dispositivos portátiles. Aunque inicialmente desde la elaboración de la propuesta se planteó una brecha en la literatura respecto al uso simultáneo de señales de Electroencefalografía (EEG), Fotopletismografía (PPG) y acelerometría (ACC), investigaciones recientes han demostrado que la fusión de estos sensores es el camino hacia la robustez diagnóstica (Ingolfsson et al., 2024).

Un avance crítico es el sistema *BrainFuseNet*, propuesto por Ingolfsson et al. (2024). Este estudio presenta un marco de detección de crisis que utiliza precisamente la combinación de

EEG, PPG y acelerómetros. Su arquitectura emplea una red neuronal de fusión de sensores que permite un despliegue eficiente en dispositivos de bajo consumo (*edge devices*), logrando una alta precisión al correlacionar la actividad eléctrica cerebral con las respuestas autonómicas (frecuencia cardíaca) y motoras. *BrainFuseNet* se implementó en el microcontrolador GAP9, de ultra bajo consumo de vanguardia para aplicaciones de Tiny Machine Learning en dispositivos portátiles. El GAP9 es un procesador diseñado puramente para computación de IA (*PULP - Parallel Ultra-Low Power*), que no tiene conectividad inalámbrica nativa. El diseño que se propone en nuestro proyecto se basa en la ESP32, que ya incluye Wi-Fi y Bluetooth (*Classic y BLE*) en el mismo chip. Para un dispositivo de salud, esto es vital, porque permite enviar alertas al celular de los padres o subir datos a la sin añadir módulos externos que agrandan el dispositivo. El desarrollo que proponemos representa menor costo de componentes y diseño de circuito impreso (PCB) mucho más simple. Aunque el GAP9 es más potente procesando redes neuronales, el ESP32 (especialmente las versiones S3) incluye instrucciones vectoriales que aceleran los algoritmos de IA, permitiendo ejecutar modelos de *TensorFlow Lite* o *Edge Impulse* de manera eficiente. Para la arquitectura de *BrainFuseNet*, el ESP32 S3 tiene suficiente músculo para procesar la fusión de sensores en tiempo real. Aunque el GAP9 consume menos microvatios en modo activo, el ESP32 tiene modos de Deep Sleep muy refinados, que se pueden programar para que solo despierte el núcleo de procesamiento o conectividad en ciertos episodios de acuerdo con los datos que se obtengan. *BrainFuseNet* utiliza la Entropía Cruzada Ponderada por Sensibilidad y Especificidad (SSWCE), detectando con éxito el 95% de los eventos de crisis y con un número de falsos positivos de solo 0.21 FP/h para estimaciones basadas en muestras, con menos de una falsa alarma por día al considerar estimaciones basadas en eventos.

El estudio *Recent Trends in Epileptic Seizure Detection Using EEG Signal: A Review* (Thomas & Anto Sahaya Dhas, 2021) examina técnicas avanzadas para la identificación de crisis epilépticas mediante señales de electroencefalograma (EEG). La investigación abarca algoritmos operativos en los dominios temporal y frecuencial, así como el análisis de señales no lineales y la aplicación de redes neuronales convolucionales (CNN) para la detección automática de crisis. Se destaca que los métodos basados en señales EEG han alcanzado una precisión superior al 90%, especialmente en clasificaciones ternarias dentro del dominio de frecuencia, superando a las estrategias basadas en el dominio temporal. No obstante, el estudio reconoce el desafío de desarrollar métodos robustos y versátiles que conserven su eficacia en distintos conjuntos de datos. Estos avances subrayan el potencial del EEG y de los algoritmos de vanguardia para optimizar la detección automatizada de la epilepsia, representando un progreso significativo en las prácticas diagnósticas de este trastorno neurológico.

En (Joyner et al., 2024) se introduce un estudio innovador sobre el uso del electroencefalograma colocado en la oreja (*ear-EEG*) para la detección de crisis epilépticas de inicio focal. En un estudio clínico con 20 pacientes con epilepsia focal resistente al tratamiento, el *ear-EEG* se validó durante 1,255 horas frente a EEGs convencionales de cuero cabelludo e intracraneales. El dispositivo logró identificar el 86.4% de las crisis detectadas por los métodos estándar, con una baja tasa de falsos positivos de 0.1 eventos por día. Las crisis no identificadas por el *ear-EEG* tenían origen en zonas cerebrales profundas, como el lóbulo temporal mesial. Los participantes reportaron una alta aceptación del dispositivo, experimentando únicamente efectos adversos menores en comparación con el grupo que utilizó EEG de cuero cabelludo. Este estudio representa un avance significativo en la monitorización de la epilepsia, ofreciendo una alternativa cómoda y discreta para la detección de crisis fuera del entorno clínico.

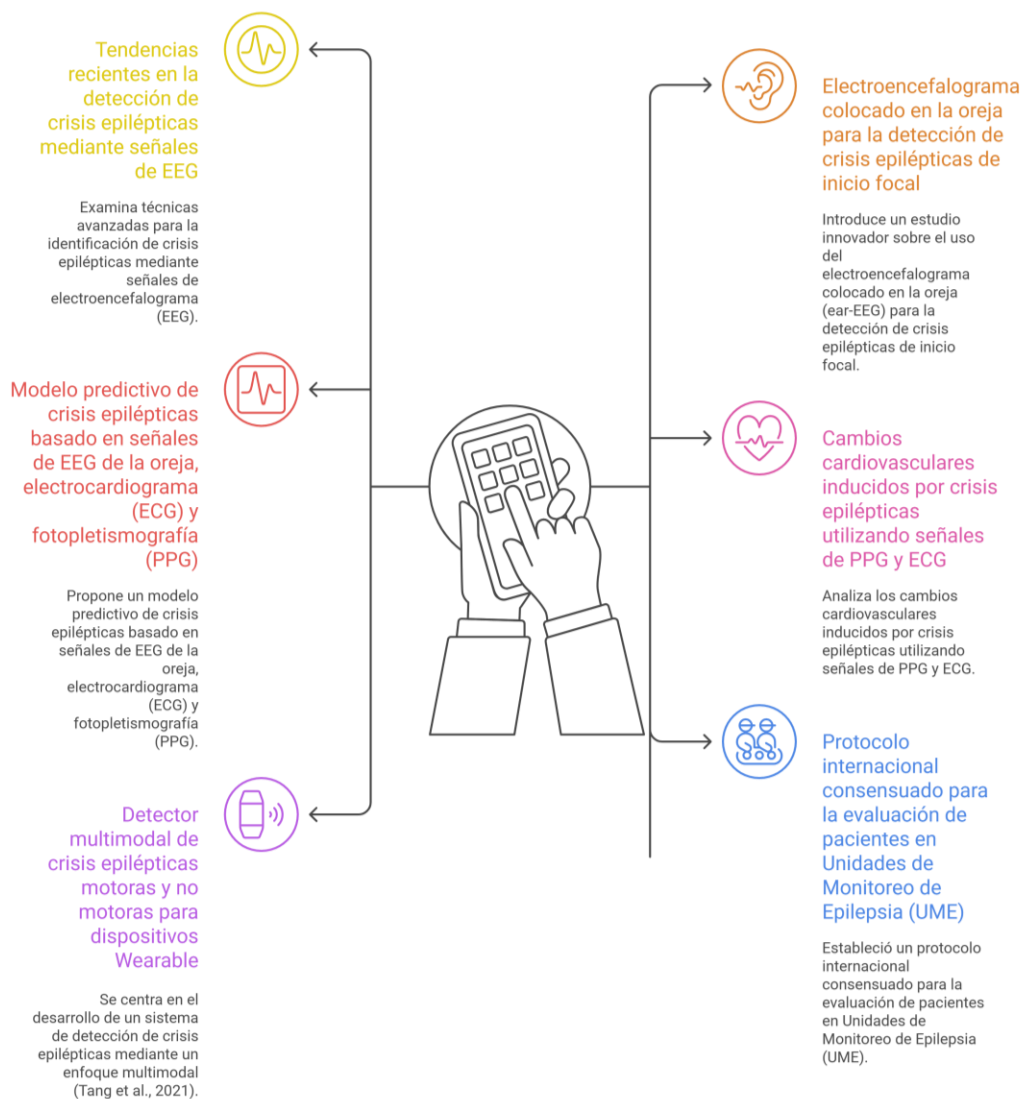
El estudio publicado en (Zambrana-Vinaroz et al., 2022) propone un modelo predictivo de crisis epilépticas basado en señales de EEG de la oreja, electrocardiograma (ECG) y fotopletismografía (PPG). Utilizando técnicas de aprendizaje automático supervisado, el modelo fue evaluado en un entorno clínico con pacientes epilépticos para clasificar el estado de la enfermedad en normal, precrisis y crisis. La validación de un modelo basado en Árboles Potenciados (*Boosted Trees*) alcanzó una precisión del 91.5% y una sensibilidad del 85.4%, evidenciando su potencial como herramienta de apoyo para determinar el estado epiléptico y prevenir crisis, mejorando así la calidad de vida de los pacientes. Además, dos estudios realizados en (Safavi et al., 2019) y (Safavi et al., 2020), analizaron los cambios cardiovasculares inducidos por crisis epilépticas utilizando señales de PPG y ECG. Su investigación demostró patrones consistentes de alteraciones hemodinámicas durante las convulsiones, sugiriendo que estas variaciones pueden emplearse en dispositivos de detección de crisis basados en sensores ópticos.

El trabajo titulado "Detector multimodal de crisis epilépticas motoras y no motoras para dispositivos *wearable*" se centra en el desarrollo de un sistema de detección de crisis epilépticas mediante un enfoque multimodal (Molina Rivera, 2019). Este sistema combina actividad electrodermal, acelerometría y PPG para identificar tanto crisis motoras como no motoras. Se diseñaron algoritmos para analizar las señales registradas y detectar patrones característicos de crisis epilépticas, demostrando que la integración de señales PPG con otras métricas biomédicas mejora la precisión de la detección. Como trabajo futuro, se recomienda adaptar el sistema a los estándares de validación clínica propuestos por (Beniczky & Ryvlin, 2018). Los resultados obtenidos por un grupo de trabajo conjunto de la Liga Internacional contra la Epilepsia (ILAE), la Comisión de Asuntos Europeos y la Asociación de Unidades de Monitoreo de Epilepsia,

liderado por (Beniczky & Ryvlin, 2018), establecieron un protocolo internacional consensuado para la evaluación de pacientes en Unidades de Monitoreo de Epilepsia (UME). El objetivo fue estandarizar los procedimientos de manejo y valoración de pacientes durante y después de las crisis. Para ello, se desarrolló la Batería de Pruebas Ictales (ITB), compuesta por 10 elementos esenciales para documentar las manifestaciones clínicas relevantes de las convulsiones, adaptándose a su variabilidad individual. La ITB fue evaluada en 250 episodios de convulsiones en 152 pacientes de 10 centros distintos, demostrando su aplicabilidad en el 93% de los casos, aunque se identificó su limitación en la evaluación de convulsiones de muy breve duración. Este avance representa un paso significativo hacia la estandarización de la evaluación clínica de la epilepsia en entornos especializados, con potencial para la elaboración de protocolos en contextos ambulatorios. Por otro lado, la implementación de dispositivos portátiles con acelerómetros ofrece múltiples ventajas, incluida la posibilidad de monitorear a los pacientes de manera continua y en tiempo real, permitiendo intervenciones rápidas en caso de crisis. Además, estos dispositivos proporcionan a los profesionales de la salud datos valiosos sobre la frecuencia y severidad de las crisis, facilitando la toma de decisiones clínicas informadas. Sin embargo, a pesar de los avances en la tecnología de detección de crisis mediante acelerómetro, es necesario continuar investigando para evaluar la eficacia de estos dispositivos en la detección de crisis epilépticas que no presenten movimientos convulsivos generalizados (Murugappan & Yuvaraj, 2022). Como se evidencia en la Figura 5, los estudios actuales sobre crisis epilépticas respaldan el uso de tecnología electrónica para optimizar la detección de variables biomédicas.

Figura 5

Estudios sobre la Epilepsia



Nota. La figura sintetiza estudios relacionados con la detección de crisis epilépticas mediante señales biomédicas como EEG, ECG, PPG, actividad electrodermal y acelerometría, así como protocolos de evaluación en Unidades de Monitoreo de Epilepsia. Esquema basado en Beniczky & Ryvlin (2018), Molina Rivera (2019), Murugappan y Yuvaraj (2022) y Naseer et al. (2019), con asistencia de Napkin AI.

Soluciones IoT en Salud

El Internet de las Cosas (IoT) se ha consolidado como una tecnología clave en el ámbito de la salud debido a su capacidad para facilitar sistemas de monitoreo remoto de pacientes en tiempo real, lo cual es esencial para mejorar la calidad de vida de las personas. En un estudio de revisión (Abdulmalek, et al., 2022) destacan que los sistemas basados en IoT permiten integrar sensores inalámbricos y dispositivos portátiles con plataformas de monitoreo que capturan signos vitales de forma continua y remota, lo que contribuye al seguimiento de pacientes fuera de los entornos clínicos tradicionales y al análisis de grandes volúmenes de datos sanitarios para la toma de decisiones clínicas (Abdulmalek, et al., 2022).

Además, estos sistemas IoT no solo recopilan información sobre parámetros biométricos básicos como temperatura corporal o frecuencia cardíaca, sino que también abordan retos importantes como la seguridad, la privacidad de datos y la calidad de servicio, aspectos que los investigadores consideran fundamentales para garantizar la confianza y adopción masiva de estas tecnologías en contextos clínicos reales (Abdulmalek, et al., 2022).

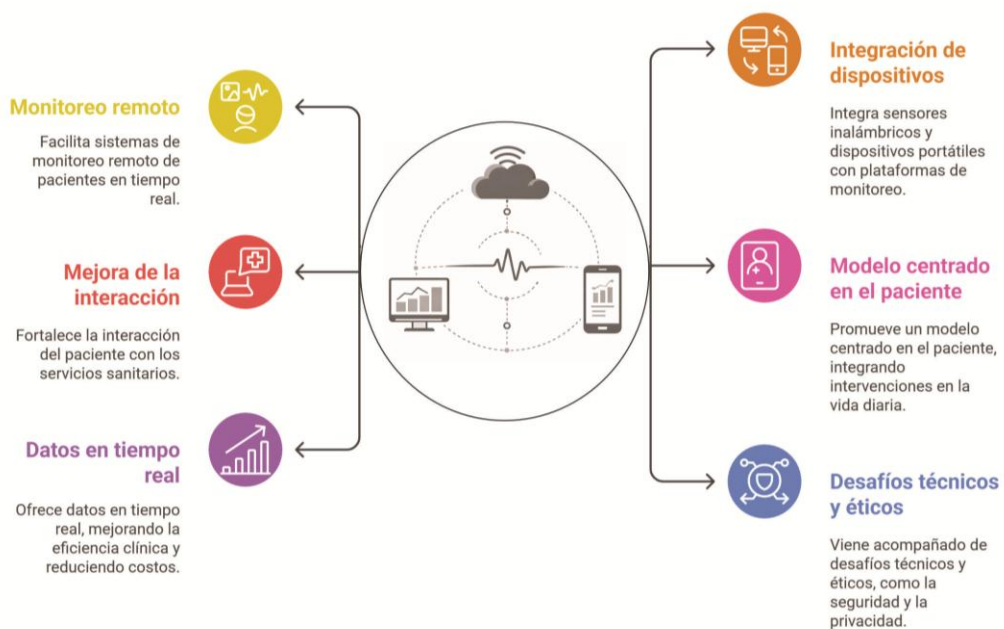
La literatura científica reciente también resalta el papel de IoT como una herramienta que transforma la relación entre pacientes y proveedores de servicios de salud. Según Agali et al. (2024), los sistemas de monitoreo remoto basados en IoT representan “una nueva era para el compromiso del paciente” (*a new era for patient engagement*), ya que pueden fortalecer la interacción del paciente con los servicios sanitarios, permitiendo un seguimiento continuo, una comunicación más directa y una respuesta temprana ante cualquier signo de alarma (Agali et al., 2024).

Este enfoque promueve un modelo centrado en el paciente, donde las intervenciones no se limitan exclusivamente a visitas presenciales en centros de salud, sino que se integran de

manera más natural en la vida diaria del individuo. Tal participación puede traducirse en mejores resultados de salud, mayor adherencia a tratamientos y una reducción en la carga asistencial para los sistemas de salud, especialmente en el manejo de enfermedades crónicas o condiciones que requieren vigilancia constante (Agali et al., 2024).

Tanto en aplicaciones de monitoreo como en estrategias de interacción con el paciente, el IoT ofrece múltiples beneficios, incluyendo la posibilidad de obtener datos en tiempo real, mejorar la eficiencia clínica, apoyar la toma de decisiones y reducir los costos asociados con la atención tradicional (Abdulmalek, et al., 2022). señalan que estos sistemas tienen un impacto positivo al proporcionar información continua que puede ser utilizada para detectar cambios sutiles en la condición de salud del paciente antes de que se conviertan en emergencias (Abdulmalek, et al., 2022).

Sin embargo, estos beneficios vienen acompañados de desafíos técnicos y éticos, como la seguridad de la información, la interoperabilidad entre dispositivos y plataformas, y la protección de la privacidad del paciente, cuestiones que son recurrentes en la investigación sobre IoT en salud y que requieren soluciones robustas para garantizar un uso seguro y eficaz de estas tecnologías (Abdulmalek, et al., 2022). Representación generada con Napkin AI. Como se ilustra en la Figura 6, el despliegue de tecnologías IoT en entornos médicos ofrece múltiples beneficios operativos, aunque introduce retos críticos en materia de seguridad.

Figura 6*Beneficios del Uso de IoT en la Salud*

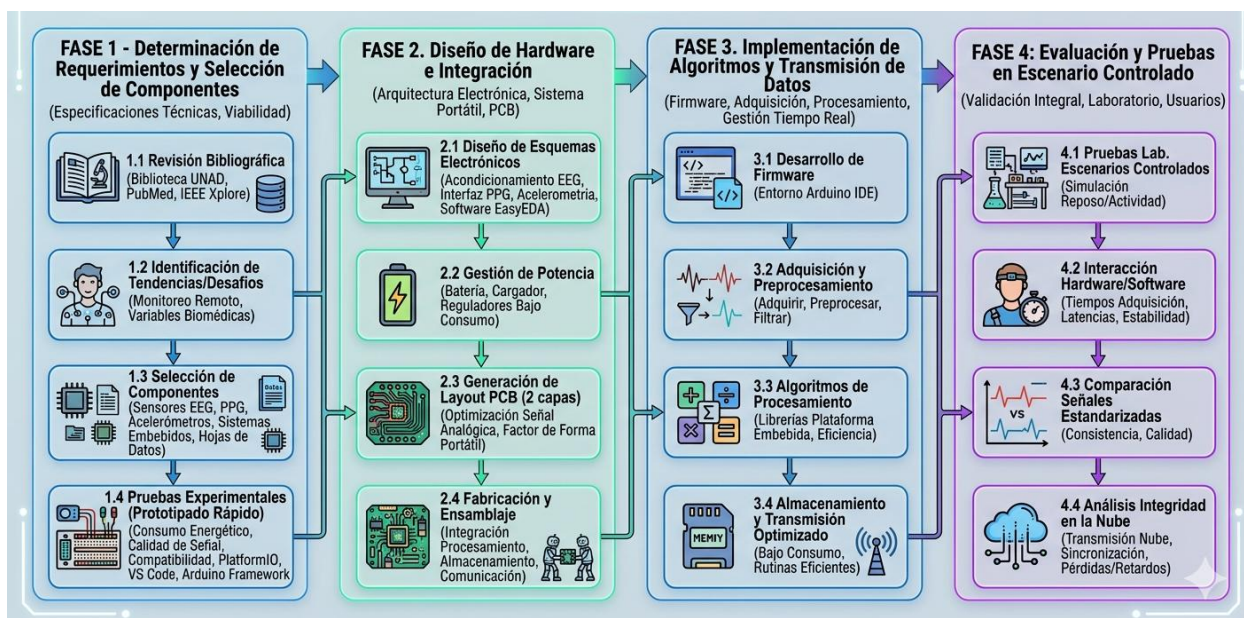
Nota. El diagrama presenta las ventajas clave del IoT en salud, tales como el monitoreo remoto, la integración de dispositivos y la obtención de datos en tiempo real, junto con los desafíos éticos y de seguridad asociados. Representación visual generada mediante la herramienta de inteligencia artificial Napkin AI.

Metodología

La metodología adoptada sigue un enfoque secuencial con iteraciones de validación experimental, orientado al diseño de prototipos electrónicos. Este enfoque permite abordar la complejidad de integrar sensores de distinta naturaleza (biopotenciales, ópticos y mecánicos), garantizando la integridad de los datos antes de la implementación final. El proceso se articula de manera progresiva con los cuatro objetivos específicos del proyecto, priorizando la convergencia eficiente entre hardware y software en un prototipo funcional optimizado para bajo consumo energético y monitoreo continuo, requisitos esenciales para el estudio portátil de crisis epilépticas. A continuación, se describen las fases de la metodología, junto con las actividades, técnicas e instrumentos empleados en cada una (ver Figura 7).

Figura 7

Fases del Proyecto



Nota. El diagrama de flujo ilustra las cuatro fases metodológicas: (1) Determinación de Requerimientos y Selección de Componentes, (2) Diseño de Hardware e Integración, (3) Implementación de Algoritmos y Transmisión de Datos y (4) Evaluación y Pruebas en Escenario Controlado. Se detallan las actividades específicas, herramientas de software (como EasyEDA y Arduino IDE) y objetivos de validación en cada etapa. Gráfico técnico generado con asistencia de ChatGPT de OpenAI.

Fase 1 – Determinación de Requerimientos y Selección de Componentes

En esta primera fase se establecen las especificaciones técnicas y funcionales del sistema, validando la viabilidad de integrar sensores en una plataforma de bajo consumo. Para ello se realiza una revisión bibliográfica en la biblioteca de la UNAD y en bases de datos académicas como PubMed e IEEE Xplore, lo que permite identificar tendencias, arquitecturas y desafíos en

el monitoreo remoto de variables biomédicas. A partir de esta investigación se seleccionan sensores EEG, PPG y acelerómetros, así como sistemas embebidos, mediante un análisis comparativo de sus hojas de datos. Posteriormente, se llevan a cabo pruebas experimentales con el sistema embebido y los sensores comerciales en configuraciones de prototipado rápido, evaluando consumo energético, calidad de señal y compatibilidad. Estas pruebas, realizadas con PlatformIO sobre Visual Studio Code y el framework Arduino, permiten verificar el funcionamiento individual de cada componente y anticipar restricciones de diseño electrónico.

Fase 2 – Diseño de Hardware e Integración

En esta fase se desarrolla la arquitectura electrónica completa del sistema portátil, garantizando la integración de los sensores y módulos de soporte en una tarjeta de circuito impreso (PCB). Se diseñan los esquemas electrónicos para el acondicionamiento de señales EEG, la interfaz PPG y la acelerometría, utilizando el software EasyEDA. Asimismo, se implementa un sistema de gestión de potencia que incluye batería, cargador y reguladores de bajo consumo. Luego, se genera el layout de una PCB de dos capas, optimizada para preservar la integridad de las señales analógicas y mantener un factor de forma portátil. Finalmente, se procede a la fabricación y ensamblaje de la placa, integrando los módulos de procesamiento, almacenamiento y comunicación necesarios para el funcionamiento del prototipo.

Fase 3 – Implementación de Algoritmos y Transmisión de Datos

Durante esta fase se desarrolla el firmware encargado de adquirir, preprocesar, filtrar, almacenar y transmitir las señales biomédicas de manera eficiente y confiable. Se emplean entornos de desarrollo como Arduino IDE y se implementan algoritmos básicos de adquisición y procesamiento mediante librerías disponibles para la plataforma embebida seleccionada. El

objetivo es optimizar las rutinas de transmisión y almacenamiento, garantizando que las señales biomédicas puedan ser gestionadas en tiempo real con estabilidad y bajo consumo energético.

Fase 4 – Evaluación y Pruebas en Escenario Controlado

La última fase consiste en validar el funcionamiento integral del prototipo en condiciones de laboratorio y con usuarios en escenarios controlados. Se realizan pruebas que simulan distintos estados de reposo y actividad, verificando la correcta interacción entre hardware y software, así como los tiempos de adquisición, latencias de transmisión y estabilidad del sistema. Los datos obtenidos se comparan con señales estandarizadas para evaluar su consistencia y calidad. Finalmente, se analiza la integridad y sincronización de la información transmitida y visualizada en la nube, identificando posibles pérdidas de paquetes o retardos que puedan comprometer la confiabilidad del sistema.

Resultados

Resultados Fase 1 – Determinación de Requerimientos y Selección de Componentes

A partir de la revisión bibliográfica realizada y presentada en el marco teórico del proyecto, se realizó un análisis comparativo de las especificaciones técnicas de los dispositivos disponibles comercialmente (Ver Tabla 1, 2 y 3). En el contexto actual, el monitoreo remoto de variables biomédicas muestra una tendencia creciente hacia el uso de dispositivos corporales, con la integración de sensores miniaturizados, con conectividad IoT y plataformas de análisis en la nube, lo que permite un seguimiento continuo y en tiempo real de variables fisiológicas fuera del entorno hospitalario. Esta evolución favorece modelos de atención más personalizados, preventivos y centrados en el paciente. Sin embargo, su adopción todavía enfrenta desafíos importantes, entre ellos la necesidad de contar con evidencia clínica más consistente sobre ciertos desenlaces, la interoperabilidad entre las etapas de captura, transmisión, almacenamiento, análisis y visualización de datos, la validación de los dispositivos para asegurar que sean adecuados para su propósito clínico, y la protección de la privacidad y seguridad de la información del paciente (Vaghasiya et al., 2023; Tan et al., 2024; Claggett et al., 2024; U.S. Food and Drug Administration [FDA], 2023; World Health Organization [WHO], 2021).

Para el núcleo de procesamiento del prototipo se seleccionó la tarjeta de desarrollo ESP32-C3, debido a su capacidad de procesamiento, su tamaño compacto y la integración de conectividad Wi-Fi y Bluetooth Low Energy (BLE). Estas características la convierten en una alternativa adecuada para un dispositivo *wearable*, ya que facilitan la comunicación con el módulo EEG y respaldan la arquitectura IoT planteada para la transmisión de datos hacia la nube. Asimismo, sus modos de bajo consumo energético resultan fundamentales para aumentar la autonomía de la batería en escenarios de monitoreo continuo.

Para la adquisición de señales PPG, se eligió el módulo MAX30102, que integra LED y fotodetectores con acondicionamiento analógico de bajo ruido para la medición de la saturación de oxígeno y la frecuencia cardíaca. Su selección obedeció a su buena relación señal-ruido, su capacidad de rechazo a la luz ambiental y su fácil integración con el ESP32 mediante interfaz I2C. Además, su bajo consumo energético lo hace apropiado para los criterios de eficiencia requeridos en el prototipo.

En cuanto a la adquisición de datos cinemáticos, específicamente acelerometría y giroscopía de 6 ejes, se seleccionó el sensor BMI323 en reemplazo de módulos genéricos utilizados en pruebas preliminares. Esta decisión se fundamentó en su orientación hacia aplicaciones *wearables* y sistemas IoT de monitoreo continuo, destacándose por su bajo consumo, su alta resolución y sensibilidad, así como por sus capacidades de procesamiento embebido. Estas prestaciones son especialmente relevantes para el estudio de patrones fisiológicos asociados a crisis epilépticas, ya que permiten registrar movimientos bruscos y sutiles con alta fidelidad.





Uno de los principales aportes del BMI323 es su motor de procesamiento integrado, que incluye memoria FIFO y pines de interrupción programables. Gracias a ello, el sensor puede almacenar temporalmente los datos o generar una interrupción de hardware cuando detecta umbrales específicos de movimiento, como los que podrían asociarse al inicio de una convulsión. Esta funcionalidad permite que el microcontrolador permanezca en modos de bajo consumo y solo se active cuando sea necesario transmitir información crítica, optimizando así el funcionamiento general del firmware. Adicionalmente, la información cinemática suministrada por este sensor resulta clave para mejorar la calidad de las señales biomédicas, ya que las mediciones de EEG y PPG suelen verse afectadas por artefactos de movimiento. En este sentido,

los datos inerciales del BMI323 podrán emplearse posteriormente en algoritmos de procesamiento digital de señales para reducir el ruido y recuperar señales más limpias. Su compatibilidad con interfaz I2C también simplifica la integración con el sensor PPG, al permitir el uso de un mismo bus de datos y reducir la complejidad del diseño de la PCB.

Por otra parte, el diseño desde cero de un sistema de acondicionamiento analógico para señales EEG representa un alto riesgo de ruido en las primeras etapas del proyecto. Para mitigar esta limitación, se seleccionó el módulo TGAM, basado en el chip ThinkGear, el cual ofrece un sistema de un solo canal con preamplificación y filtrado por hardware. Este módulo fue escogido por su capacidad de entregar tanto la señal cruda (raw) como el procesamiento integrado de bandas de frecuencia (alfa, beta, theta, delta y gamma) mediante una interfaz serial UART, lo que disminuye la carga computacional del ESP32 y agiliza la validación inicial de la transmisión de datos neurológicos.

La Tabla 5 resume los dispositivos seleccionados para las pruebas iniciales, tales como, tarjeta de desarrollo ESP32 Super Mini, módulo sensor PPG MAX30102, módulo sensor acelerómetro y giroscopio para pruebas iniciales, y EEG de un electrodo Sichirai TGAM. Las imágenes de referencia fueron tomadas de catálogos comerciales.

Tabla 5*Tarjetas y Dispositivos de Desarrollo Seleccionados para Pruebas Iniciales*

			
Tarjeta de desarrollo ESp32 Super mini para pruebas iniciales	Modulo sensor PPG MAX30102	Modulo sensor Acelerómetro y Giroscopio para pruebas iniciales	EEG de un electrodo Sichirai TGAM

Nota. Abreviaturas: PPG = fotopleletismografía; EEG = electroencefalografía. Las imágenes de los componentes integrados en esta tabla fueron adaptadas de los catálogos comerciales de los fabricantes.

Se analizaron la hoja de datos para la selección de los pines adecuados del SoC (ver Figura 8), considerando las restricciones particulares del ESP32-C3 en cuanto a pines de arranque y programación, así como su comportamiento durante la inicialización del sistema. De esta forma, se aseguró que la distribución de pines en la PCB final no interfiriera con el correcto inicio del microcontrolador, garantizando la funcionalidad y estabilidad del hardware diseñado.

Figura 8

Pinout y Distribución de Pines de la Tarjeta de Desarrollo ESP32 C3 Super Mini



Nota. El diagrama detalla la configuración de pines (Pinout) de la placa, incluyendo las funciones de alimentación (5V, 3V3, GND), entradas analógicas (ADC), y protocolos de comunicación digital como SPI, I2C y UART. Tomado de *ESP32-C3 Super Mini Pinout*, por ESPBoards, 2026, <https://www.espboards.dev/esp32/esp32-c3-super-mini/>

Para la selección de pines se tuvieron en cuenta las restricciones particulares del SoC ESP32-C3. Los pines GPIO2, GPIO8 y GPIO9 actúan como *Strapping pins* (pines de configuración de arranque) y determinan el modo de arranque del microcontrolador, por lo que se evitó su uso para funciones críticas que pudieran interferir con la inicialización del sistema. El GPIO8 se utilizó únicamente para el LED indicador, respetando su condición de *Strapping pin*, pero, aprovechando que su estado durante el arranque no afecta la funcionalidad deseada.

La asignación de pines para el circuito ESP32 se especifica en la Tabla 6. El esquema de conexiones y la arquitectura electrónica del sensor PPG MAX30102 se muestran en las Figuras 9 y 10. Adicionalmente, la Figura 11 detalla el conexionado sugerido para el módulo IMU a través del bus I2C.

Tabla 6*Asignación de Pines ESP-32*

Pin ESP32- C3	Función	Componente	Observación
GPIO0	ADC1_CH0	Circuito detector nivel de batería	Entrada análoga para la señal de nivel de batería
GPIO1	I/O Digital	Circuito detector nivel de batería	Salida digital para controlar el switch de medición de batería
GPIO2	Strapping pin	Conectado a VCC: 3.3VDC	Pin que debe permanecer en alto durante el arranque
GPIO3	I/O Digital	Circuito manejador Zumbador	Salida digital para activar la alarma de nivel bajo de batería
GPIO4	I/O Digital / SCK SPI	SPI Socket micro-SD	Pin de reloj para bus SPI de SD
GPIO5	I/O Digital / MISO SPI	SPI Socket micro-SD	Pin MISO para bus SPI de SD
GPIO6	I/O Digital / MOSI SPI	SPI Socket micro-SD	Pin MOSI para bus SPI de SD
GPIO7	I/O Digital / SS SPI	SPI Socket micro-SD	Pin Selector Chip (CS) para bus SPI de SD
GPIO8	I/O Digital / Strapping pin	Led de Estado	Salida digital para activar Led de Estados del sistema / Pin que debe permanecer en alto durante el arranque
GPIO10	I/O Digital	Socket micro-SD	Entrada digital para indicar SD insertada
GPIO18	I/O Digital	USB-C	Pin de D- para conexión USB
GPIO19	I/O Digital	USB-C	Pin de D+ para conexión USB
GPIO20	I/O Digital	Módulos PPG e IMU	Pin para bus I2C SDA, circuitos integrados PPG e IMU

Pin ESP32- C3	Función	Componente	Observación
GPIO21	I/O Digital	Módulos PPG e IMU	Pin para bus I2C SCL, circuitos integrados PPG e IMU

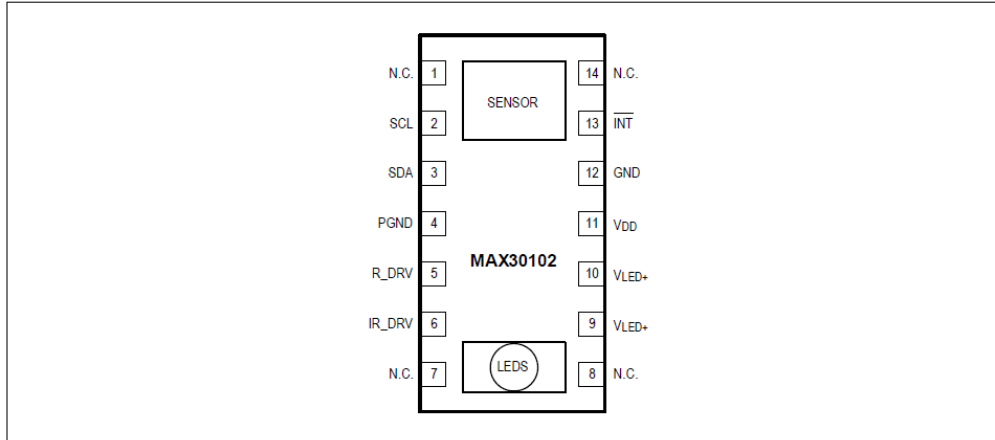
Nota. Abreviaturas: GPIO = Entrada/Salida de propósito general; ADC = Convertidor analógico a digital; I/O = Entrada/Salida; SPI = Interfaz periférica serial; SCK = Reloj serie; MISO = Entrada de maestro, salida de esclavo; MOSI = Salida de maestro, entrada de esclavo; SS = Selector de esclavo; I2C = Circuito inter-integrado; SDA = Datos seriales; SCL = Reloj serial; PPG = Fotopletismografía; IMU = Unidad de medición inercial.

En las Figuras 9, 10 y 11 se detalla la asignación de pines correspondiente a los distintos circuitos empleados en el diseño electrónico; para ampliar la información técnica de cada componente, se pueden consultar los Apéndices A, B y C.

Figura 9

Configuración de Pines y Funciones del Sensor MAX30102

Pin Configuration

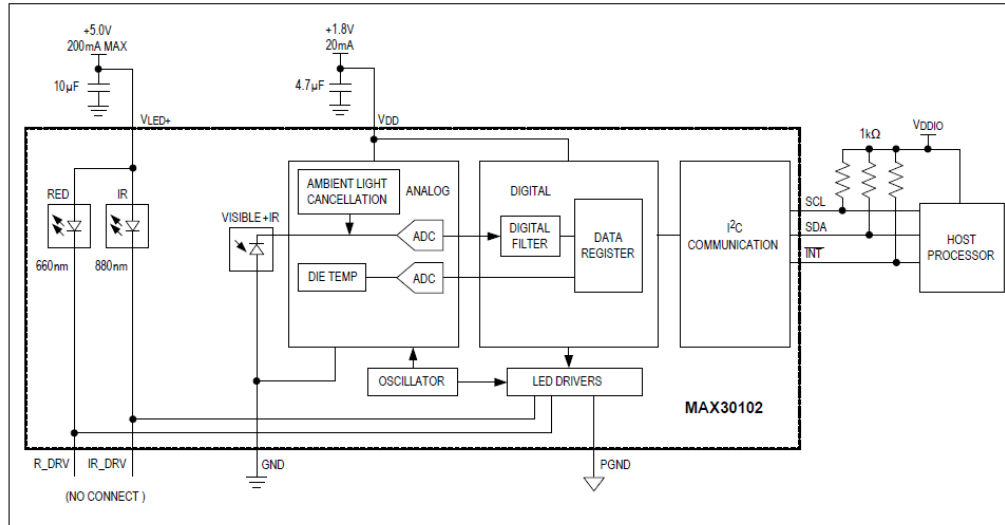


Nota. El diagrama presenta la disposición de los 14 pines del encapsulado OLGA, destacando las conexiones para el bus I2C (SCL, SDA), los controladores de LED (R_DRV, IR_DRV), la alimentación (VDD, VLED+) y la terminal de interrupción (INT). Tomado de *High-Sensitivity Pulse Oximeter and Heart-Rate Sensor for Wearables* (p. 8), por Maxim Integrated, 2018.

Figura 10

Circuito de Aplicación Típica y Diagrama de Bloques del Sensor MAX30102

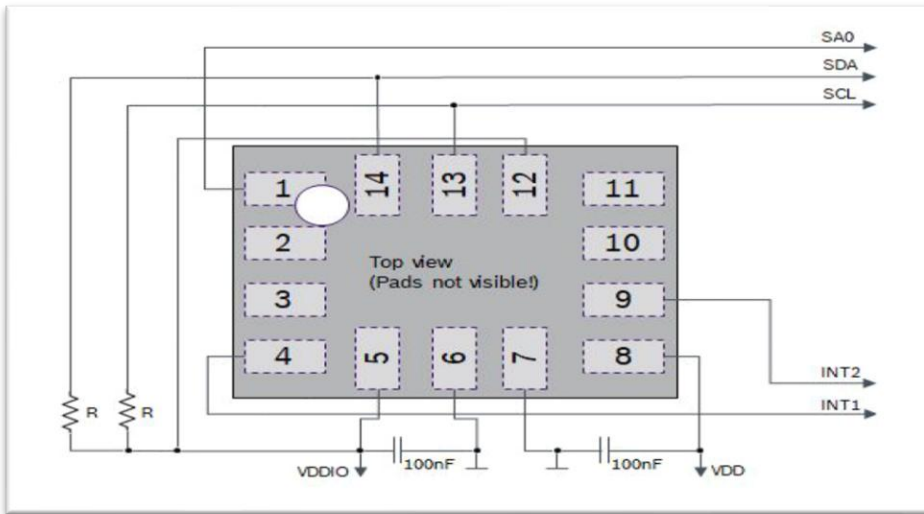
Typical Application Circuit



Nota. El diagrama muestra la integración del sensor con un procesador anfitrión (*Host Processor*) mediante el bus I2C. Se observan las etapas de alimentación dual (+5.0 V para los LED y +1.8 V para el VDD), el sistema de cancelación de luz ambiental, los convertidores Analógico-Digitales (ADC) y los controladores de LED integrados. Tomado de *High-Sensitivity Pulse Oximeter and Heart-Rate Sensor for Wearables* (p. 31), por Maxim Integrated, 2018.

Figura 11

Conexiones Recomendadas para Integrado IMU (Bus I2C)



Nota. El diagrama esquemático ilustra la configuración de pines y los componentes externos necesarios para la operación del sensor en modo I2C, incluyendo los resistores de *Pull-up* (R) en las líneas SCL y SDA, así como los capacitores de desacoplo de 100nF para las líneas de alimentación VDD y VDDIO. Tomado de *BMI323: Shuttle Board 3.0 Flyer* (p. 27), por Bosch Sensortec, 2023, <https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bmi323-ds000.pdf>

La tabla 7 presenta una síntesis de los requerimientos funcionales y eléctricos de los principales componentes seleccionados para el prototipo de monitoreo biomédico. En ella se organiza, para cada dispositivo, la información relacionada con la tensión de alimentación necesaria, el consumo energético de referencia, la interfaz de comunicación empleada y el papel funcional que cumple dentro del sistema. De esta manera, la tabla no solo permite identificar las condiciones mínimas de operación de cada módulo, sino también verificar su compatibilidad con

la arquitectura general del prototipo, especialmente en términos de integración electrónica, transmisión de datos y eficiencia energética.

En particular, la tabla 7 muestra que la ESP32 Super Mini funciona como la unidad central de procesamiento y comunicación del sistema, ya que se encarga de adquirir, organizar y transmitir la información proveniente de los sensores. Por su parte, el MAX30102 se utiliza para la captura de señales PPG, permitiendo la estimación de variables como la saturación de oxígeno y la frecuencia cardíaca. El BMI323 aporta el registro de movimiento mediante acelerometría y giroscopía, lo que resulta útil tanto para detectar eventos cinemáticos como para apoyar la reducción de artefactos en otras señales biomédicas. Finalmente, el TGAM cumple la función de adquirir la señal EEG de un canal y entregar tanto datos crudos como parámetros procesados, facilitando su integración con el microcontrolador. En conjunto, la tabla evidencia que la selección de componentes responde a criterios de bajo consumo, capacidad de comunicación digital y adecuación para aplicaciones portátiles o *wearables*.

Tabla 7

Especificaciones Técnicas y Requerimientos de Integración de los Componentes del Sistema

Componente	Alimentación requerida	Consumo de referencia	Interfaz / comunicación	Requerimientos funcionales de integración en el sistema
Tarjeta de desarrollo ESP32 Super Mini	Alimentación por USB-C 5 V o por fuente externa al pin 5V, con soporte de 3.3 a 6 V en la placa. El chip ESP32-C3 trabaja con tensión recomendada de 3.0 a 3.6 V.	En la hoja de la placa se reporta deep sleep \approx 43 μ A. En operación activa el consumo depende del uso de CPU, Wi-Fi, BLE, GPIO y periféricos.	I2C, SPI, UART, Wi-Fi 2.4 GHz y BLE 5.0.	Debe actuar como unidad central de adquisición y procesamiento, leer simultáneamente sensores biomédicos, gestionar marcas de tiempo, ejecutar filtrado básico, transmitir datos y operar en bajo consumo.

Componente	Alimentación requerida	Consumo de referencia	Interfaz / comunicación	Requerimientos funcionales de integración en el sistema
Módulo sensor PPG MAX30102	El CI MAX30102 requiere 1.8 V para el sensor y 3.3 V para los LED internos.	0.7 μ A típico en <i>shutdown</i> ; en monitor de frecuencia cardíaca puede trabajar con < 1 mW. La corriente de LED es programable de 0 a 50 mA según configuración.	I2C.	Debe adquirir señal PPG para estimar SpO2 y frecuencia cardíaca, permitir muestreo configurable, operar con bajo consumo y ofrecer tolerancia a luz ambiental para uso wearable.
Módulo sensor Acelerómetro y Giroscopio BMI323	VDD: 1.71 a 3.63 V; VDDIO: 1.08 a 3.63 V.	15 μ A en modo <i>suspend</i> ; 45 μ A en acelerómetro de bajo consumo a 25 Hz; 145 μ A en acelerómetro de alto desempeño; 790 μ A en acelerómetro + giroscopio de alto desempeño.	I2C, I3C y SPI.	Debe capturar aceleración y velocidad angular en 6 ejes, detectar eventos de movimiento, generar interrupciones, apoyar la cancelación de artefactos en señales EEG/PPG y mantener bajo consumo para monitoreo continuo.
EEG de un electrodo Sichirai TGAM	2.97 a 3.63 V.	Consumo máximo de 15 mA a 3.3 V.	UART serial; velocidades de 1200, 9600 y 57600 baud.	Debe adquirir EEG de un canal, entregar señal cruda y bandas procesadas, reportar calidad de señal, permitir integración serial con el microcontrolador y funcionar con bajo consumo en aplicaciones portátiles.

Nota. Abreviaturas: PPG = fotopletismografía; EEG = electroencefalografía; IMU = unidad de medición inercial; BLE = Bluetooth de baja energía; VDD/VDDIO = voltajes de alimentación de drenaje común; UART = receptor-transmisor asíncrono universal. Los valores de consumo y

voltaje han sido extraídos de las hojas de datos (*datasheets*) oficiales de los fabricantes (Analog Devices, Bosch Sensortec, Espressif Systems y NeuroSky/Sichirai).

De acuerdo con los requerimientos funcionales y asignaciones de pines, se realizan las pruebas experimentales iniciales, las cuales se desarrollaron bajo la PlatformIO dentro de Visual Studio Code bajo el framework de Arduino. Estas pruebas confirmaron la viabilidad de la arquitectura propuesta. La Figura 12 ilustra los resultados parciales obtenidos con el sistema biomédico, de acuerdo con los componentes seleccionados. En la sección izquierda de la imagen se observa el montaje físico sobre una placa de pruebas (*protoboard*), donde el ESP32-C3 actúa como núcleo de procesamiento. Allí se evidencia la interconexión de los sensores de fotopleximografía (PPG) y de la unidad de medición inercial (IMU) mediante un sistema de cableado que permite la adquisición en tiempo real, mientras que el módulo de electroencefalografía (EEG) se comunica por Bluetooth. También se aprecia la integración de un módulo de almacenamiento externo microSD para el registro local de los datos.


En la sección derecha de la Figura 12 se muestra el monitor serial del entorno de desarrollo, el cual confirma la correcta gestión de la información adquirida. En esta visualización se observa un flujo constante de marcas de tiempo (*timestamps*), lo que contribuye a garantizar la integridad de las muestras. Asimismo, se presentan valores de saturación de oxígeno (SpO2-%), frecuencia cardíaca (HR-bpm) y acelerometría en los ejes A(x), A(y) y A(z). De igual manera, se evidencia la segmentación de los datos provenientes del EEG, dejándolos listos para su posterior análisis o transmisión hacia la nube.

Se logró establecer comunicación simultánea con los sensores mediante buses I2C y UART independientes, evitando colisiones de datos. Las lecturas preliminares demostraron que

el ESP32 puede adquirir los paquetes de datos provenientes del EEG, el PPG y el giroscopio a las frecuencias de muestreo requeridas, empaquetarlos y enviarlos a través del monitor serial, tal como se aprecia en la Figura 12. Estos resultados constituyen una base sólida para avanzar hacia la Fase 2, centrada en el diseño electrónico y la consolidación de la PCB.

Figura 12

Pruebas del ESP-32 C3 con el PPG, IMU y EEG



Nota. Se ilustra la interconexión general de los sensores integrados al sistema durante la fase de pruebas y la estructura de los datos adquiridos.

Resultados Fase 2 – Diseño de Hardware e Integración

En esta fase se llevó a cabo el diseño del hardware definitivo del sistema, incluyendo el desarrollo del esquemático electrónico y el diseño de la tarjeta de circuito impreso (PCB), de acuerdo con los requerimientos funcionales y eléctricos establecidos en la fase anterior. A partir de este diseño, se realizó la fabricación de la tarjeta electrónica y el montaje de los componentes, permitiendo la integración física de los módulos, sensores y elementos de soporte del sistema.

El diseño se llevó a cabo mediante el software EasyEDA Professional Online, el cual permitió integrar el esquemático, el diseño del PCB y la gestión de componentes. La plataforma

facilitó la selección de dispositivos disponibles a través de un distribuidor asociado, los cuales fueron considerados directamente durante el proceso de fabricación y montaje. De manera complementaria, se verificó la disponibilidad de componentes equivalentes en otros distribuidores electrónicos, con el fin de asegurar opciones de respaldo en la adquisición de piezas. El diseño del PCB fue enviado a fabricación y montaje mediante un proveedor externo especializado, permitiendo la obtención de una tarjeta electrónica funcional para las pruebas del sistema.

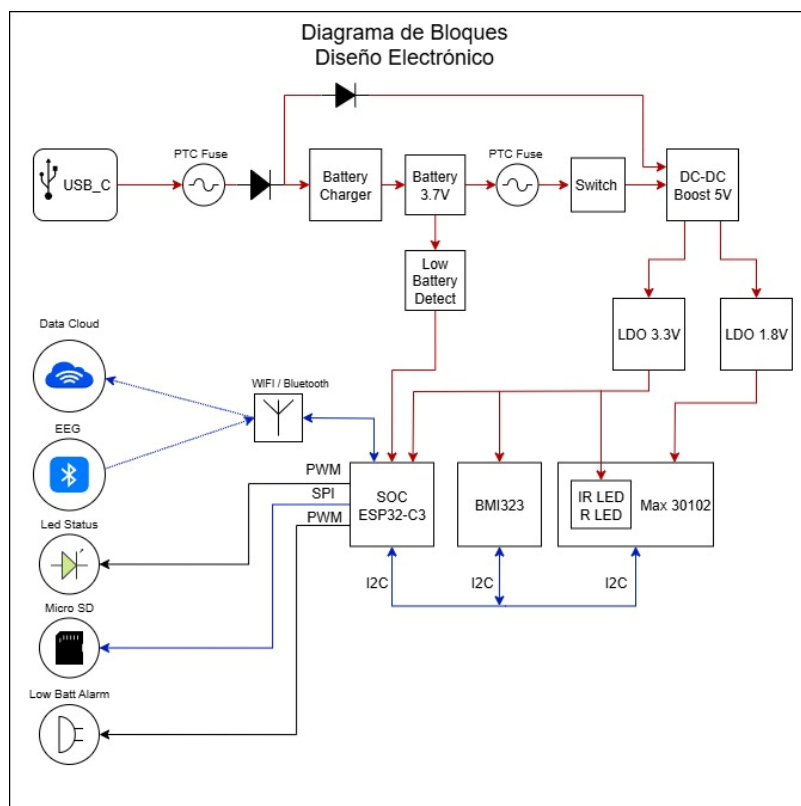
De acuerdo con la metodología planteada, el diseño del sistema se concibió de manera integral, considerando desde etapas tempranas la lógica general de funcionamiento del algoritmo y su relación directa con el hardware propuesto. El sistema fue diseñado para adquirir señales biomédicas, realizar un procesamiento inicial y gestionar su transmisión hacia una plataforma en la nube, manteniendo una estructura modular que facilita la integración y futuras ampliaciones.

A nivel funcional, el algoritmo define una secuencia básica que incluye la inicialización del sistema, la lectura de los sensores biomédicos, el procesamiento primario de las señales, la gestión de eventos como alertas de batería baja y la transmisión de los datos a través de comunicación inalámbrica. Esta lógica general sirvió como base para la selección de los componentes electrónicos y el diseño del hardware.

En la Figura 13, se presenta el diagrama de bloques del sistema donde se representa gráficamente desde el suministro de energía hasta el procesamiento de la información.

Figura 13

Diagrama de Bloques del Sistema y Base del Diseño Electrónico



Nota. El esquema describe la arquitectura del sistema, dividida en la etapa de alimentación (entrada USB-C, carga y regulación DC-DC/LDO), el núcleo de procesamiento (SoC ESP32-C3) y los módulos de sensado (BMI323 y Max30102). Se especifican las interfaces de comunicación I2C, SPI y PWM, así como los periféricos de almacenamiento, alertas y transmisión inalámbrica hacia la nube.

El sistema incorpora un mecanismo de encendido y apagado mediante un interruptor táctil implementado con componentes discretos y una base de tiempo para el apagado por pulsación prolongada. Esta configuración permite evitar apagados accidentales y mejora la usabilidad del dispositivo durante su operación.

La gestión de encendido y protección se implementan mediante dos transistores MOSFET de canal P configurados para operar como diodos ideales. Esta disposición permite proteger el sistema frente a inversión de polaridad en la entrada de alimentación y controlar eficientemente el flujo de corriente. A diferencia de los diodos convencionales, esta configuración reduce significativamente las caídas de tensión, mejorando la eficiencia energética del circuito. Asimismo, el diseño evita que la corriente proveniente de la interfaz USB fluya directamente hacia la batería, garantizando que esta sea cargada únicamente a través del circuito dedicado de carga.

En condiciones iniciales, al conectar la batería, la corriente queda disponible en el terminal de fuente del primer MOSFET, permitiendo la carga de un capacitor asociado al circuito de control. Este proceso establece un nivel de voltaje en la compuerta del segundo MOSFET de canal P que lo mantiene en estado de corte, por lo que el dispositivo permanece apagado aun cuando la batería esté conectada. Cuando se acciona el interruptor táctil, el capacitor de control se descarga momentáneamente, generando una diferencia de potencial entre compuerta y fuente que habilita la conducción del segundo MOSFET. Como consecuencia, se energiza el convertidor DC-DC encargado de generar la tensión regulada del sistema. Una vez establecida esta tensión, se activa un MOSFET adicional que mantiene el estado de encendido, permitiendo que el dispositivo permanezca alimentado todo el tiempo.

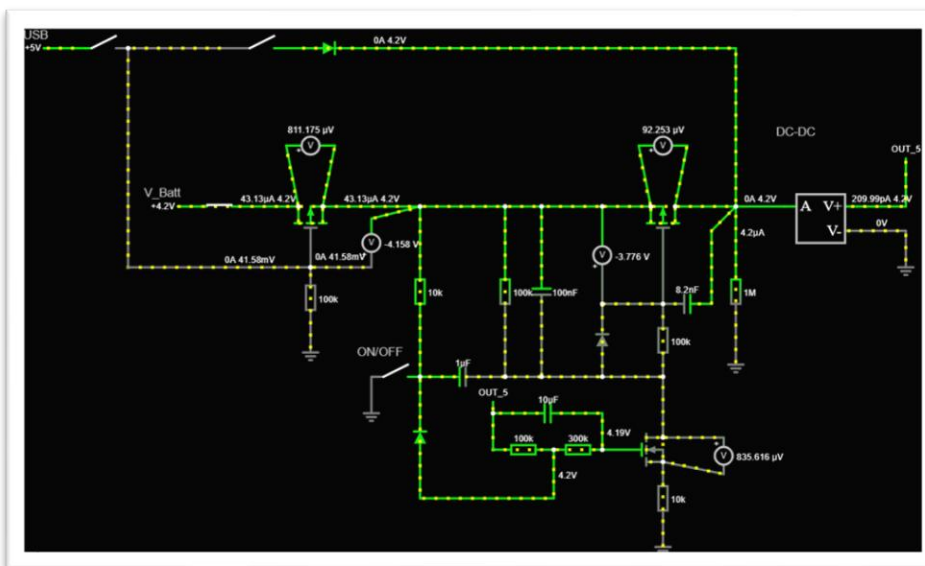
El apagado del dispositivo se realiza mediante una pulsación prolongada del interruptor táctil. Esta acción provoca una disminución progresiva del voltaje en la compuerta del MOSFET de retención hasta que desciende por debajo del umbral necesario para mantenerlo en conducción. En consecuencia, el MOSFET principal retorna a su estado de corte, interrumpiendo el suministro de energía y apagando completamente el sistema de forma controlada.

Cuando se conecta el cable USB, el circuito conmuta automáticamente la fuente de alimentación, deshabilitando el MOSFET asociado a la batería y permitiendo que el convertidor DC-DC sea alimentado directamente desde la fuente externa. De esta manera, la corriente proveniente del USB se dirige al circuito cargador y al mismo tiempo mantiene encendido el dispositivo.

En conjunto, este sistema de gestión de energía permite una administración segura y eficiente de la alimentación del dispositivo, integrando funciones de protección eléctrica, encendido y apagado controlado, así como selección automática de fuente de alimentación. Estas características resultan fundamentales para dispositivos portátiles alimentados por batería destinados a aplicaciones de monitoreo continuo. En las Figuras 14 y 15, se muestra el comportamiento simulado del circuito para encendido.

Figura 15

Simulación del Circuito de Gestión de Potencia en Estado Activado (On).



Nota. La captura de pantalla, obtenida mediante el software CircuitJS, ilustra el comportamiento del sistema tras el cierre del interruptor de encendido (ON/OFF). En este estado, se observa la polarización de los MOSFET de potencia que permite el paso de la corriente desde la fuente activa (Batería o USB) hacia el regulador DC-DC, estableciendo una tensión de salida estable en el nodo OUT_5 para la alimentación de los módulos del sistema.

El diseño electrónico incorpora un conector USB tipo C, utilizado para la alimentación del sistema, comunicación, programación del firmware y carga de la batería. Esta última función se implementa mediante un circuito especializado para baterías de Litio de 3.7 V, configurado para suministrar una corriente máxima de 250 mA, además de incluir indicadores visuales del estado de carga.

El circuito cargador emplea el integrado TP4057, diseñado específicamente para la gestión de carga de baterías de litio. Este dispositivo integra un algoritmo de carga optimizado

que permite realizar el proceso de manera segura y eficiente, reduciendo la cantidad de componentes externos necesarios y simplificando el diseño del sistema. El integrado dispone de salidas dedicadas para la indicación del estado de carga mediante LEDs, facilitando la supervisión visual del proceso por parte del usuario. La corriente de carga se define mediante una resistencia externa, lo que permite ajustarla de acuerdo con los requerimientos del sistema; en este diseño se estableció una corriente máxima de 250 mA, adecuada para la batería empleada. Durante la etapa de prototipado se utiliza una batería de 3.7 V y 600 mAh, con circuito de protección integrado contra sobrecarga y sobre descarga.

El sistema incluye un conector dedicado para la batería, el cual permite su conexión y desconexión rápida, facilitando las pruebas durante el desarrollo del prototipo. Adicionalmente, se implementa un circuito de monitoreo del nivel de batería destinado a evaluar su estado y activar una alerta cuando el voltaje desciende por debajo del umbral definido. Este circuito está compuesto por un MOSFET de canal P y un MOSFET de canal N configurados como una etapa de control que habilita de forma selectiva la medición del voltaje de la batería desde el SoC. Esta arquitectura permite realizar la medición únicamente cuando es requerida, evitando el consumo continuo de corriente que produciría un divisor de tensión conectado permanentemente y contribuyendo a una gestión energética más eficiente.

El voltaje de la batería conmutado se aplica a un divisor de tensión dimensionado para adecuar el nivel de señal al rango permitido por la entrada analógica del SoC. De esta forma, incluso cuando la batería alcanza su voltaje máximo, la señal entregada permanece dentro de los límites seguros de operación. La activación del circuito mediante el control de los MOSFET permite obtener lecturas precisas del estado de la batería sin afectar el funcionamiento normal del sistema ni comprometer la integridad del dispositivo.

El sistema de alimentación incorpora un convertidor DC-DC tipo Boost encargado de elevar la tensión de la batería (3.7 V) hasta 5 V, con el propósito de permitir la realización de pruebas con sensores PPG cuyos LEDs requieren dicho nivel de alimentación. Posteriormente, esta tensión se regula mediante dos reguladores lineales (LDO) que generan 3.3 V y 1.8 V, utilizados para alimentar el SoC y el sensor externo de fotopleitismografía (PPG).

La etapa elevadora garantiza la disponibilidad de una tensión estable de 5 V necesaria para el funcionamiento de los sensores durante las pruebas experimentales. Asimismo, asegura un margen adecuado para la operación de los reguladores lineales posteriores, permitiendo que estos mantengan una salida estable incluso cuando la batería se encuentra en niveles bajos de carga. Esto contribuye a preservar la estabilidad del sistema y el correcto funcionamiento de los módulos electrónicos asociados a la adquisición de señales biomédicas.

En lugar de utilizar módulos preensamblados, el diseño integra directamente el SoC ESP32-C3 de Espressif junto con sus componentes externos esenciales, tales como capacitores de desacoplo para reducción de ruido, resistencias pull-up y un cristal de 40 MHz, todos montados en la tarjeta principal. Esta decisión permite una mayor integración del sistema y facilita la miniaturización del dispositivo.

La comunicación con el sensor PPG se realiza mediante el bus I2C, mientras que la interacción con el módulo EEG externo se establece a través de Bluetooth y la transmisión de datos hacia la nube se efectúa mediante WIFI, utilizando las capacidades de conectividad inalámbrica integradas en el propio SoC.

El SoC seleccionado incorpora de forma nativa una interfaz USB, lo que permite su programación y comunicación directa sin requerir circuitos adicionales de conversión serial. Esta interfaz opera bajo la clase USB CDC (Communication Device Class), permitiendo la

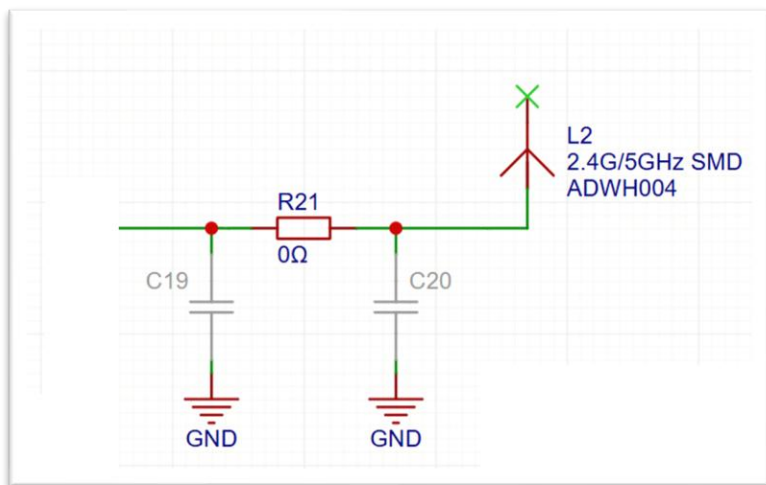
programación del firmware y la depuración del sistema mediante un puerto serial virtual, lo que simplifica significativamente el proceso de desarrollo y pruebas del prototipo.

Para la comunicación inalámbrica se integró una antena de RF diseñada para operar en la banda de 2.4 GHz, con una ganancia máxima aproximada de 4.62 dBi y una eficiencia cercana al 85 %. El diseño del PCB se realizó siguiendo las recomendaciones del fabricante, incluyendo las consideraciones necesarias para el enrutamiento de la línea de RF y la disposición de la antena con el fin de garantizar un desempeño adecuado del enlace inalámbrico.

Asimismo, se incorporó la red de adaptación de impedancia de la antena con el objetivo de optimizar el acoplamiento y permitir posibles ajustes en la cobertura del sistema (ver Figura 16). Para esta etapa del proyecto se utilizó la red de adaptación recomendada por el fabricante junto con la huella de PCB propuesta en la hoja de datos, lo que permitió asegurar un funcionamiento adecuado de la antena sin recurrir a equipos especializados de caracterización de RF, como analizadores de espectro o analizadores de redes. En la Figura 17 se detallan las dimensiones del diseño aplicado al PCB para la ubicación recomendada de la antena.

Figura 16

Diseño del Circuito de Adaptación de Impedancia para Antena Wi-Fi Bluetooth



Nota. El esquema muestra una configuración de red de acoplamiento para la antena SMD (L2). El circuito incluye una resistencia de 0Ω (R21) y espacios para capacitores de sintonización (C19 y C20) conectados a tierra (GND), diseñados para ajustar la impedancia característica a 50Ω y maximizar la transferencia de potencia en las bandas de comunicación inalámbrica. Gráfico copiado desde el entorno de diseño EasyEDA.

permitiendo la transferencia de datos de aceleración y movimiento necesarios para el monitoreo de la actividad del usuario.

Las líneas del bus I2C utilizadas para la comunicación con el IMU y el sensor PPG incorporan resistencias pull-up de 4.7 k Ω , necesarias para garantizar niveles lógicos estables y el correcto funcionamiento del protocolo. Esta configuración permite una comunicación confiable entre los sensores y el ESP32-C3, operando en modo rápido a frecuencias de hasta 400 kHz según las especificaciones del fabricante (ESPBoards, 2026).

El sistema también incorpora un zócalo para memoria microSD, destinado al registro local de las señales biomédicas adquiridas durante la operación del dispositivo. Esta funcionalidad permite almacenar los datos generados por el sistema para su posterior análisis. La memoria se conecta al SoC mediante la interfaz SPI, seleccionada por su velocidad de transferencia adecuada para aplicaciones de registro continuo de datos.

La interfaz SPI permite gestionar de manera eficiente las operaciones de lectura y escritura sobre la memoria, proporcionando un mecanismo confiable de almacenamiento local para los registros generados por el prototipo durante su funcionamiento.

Adicionalmente, el diseño incorpora un conector de expansión destinado a la conexión del sensor MAX30102, utilizado para la medición de señales de Fotopleitismografía (PPG). Este sensor se fija físicamente al dedo del usuario y se comunica con el SoC mediante el bus I2C.

Debido a que el sensor MAX30102 requiere contacto directo con el dedo para obtener mediciones confiables y considerando que, por las características físicas del dispositivo desarrollado, no resulta viable su integración directa en la estructura principal del hardware, se optó por implementar un conector dedicado en la tarjeta electrónica. Este conector proporciona las líneas de alimentación y comunicación necesarias, permitiendo la conexión del módulo

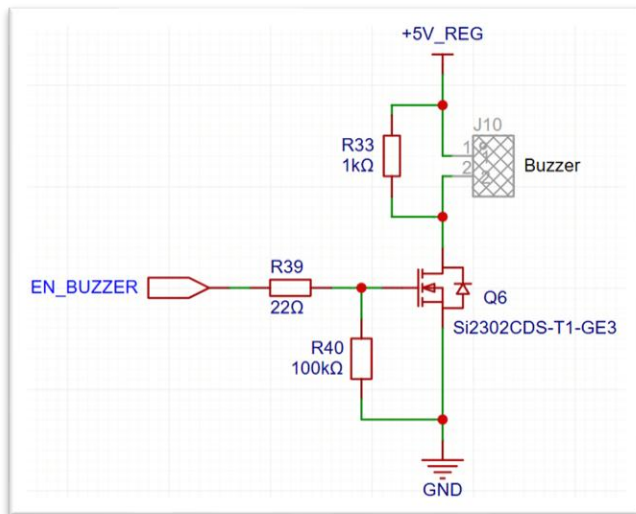
sensor mediante cableado externo. Esta solución facilita la correcta adquisición de las señales fisiológicas y aporta mayor flexibilidad durante las pruebas y la utilización del prototipo.

Además de los módulos principales, el sistema incluye circuitos destinados a la señalización visual y acústica del estado de operación. Para ello se incorpora un LED indicador de estado, el cual es controlado mediante señales PWM con el objetivo de optimizar el consumo energético. A través de diferentes patrones de parpadeo, el LED permite representar información relevante del sistema, como la actividad del procesamiento interno, la transmisión de datos hacia la plataforma en la nube o la detección de eventos de alerta, incluyendo la desconexión de la memoria microSD. Este LED se encuentra conectado directamente a una salida GPIO del SoC, facilitando su control desde el firmware.

De manera complementaria, se implementa un sistema de señalización acústica mediante un Buzzer, accionado a través de una etapa de control basada en un MOSFET. Esta configuración permite aislar eléctricamente la salida del SoC y garantizar un manejo adecuado del dispositivo. El Buzzer se incorpora inicialmente con el propósito de generar una alerta audible cuando el sistema detecta un nivel bajo de batería, permitiendo advertir al usuario sobre la necesidad de recarga, en la Figura 18 se presenta su esquema. La activación se realiza mediante señales PWM a una frecuencia determinada, generando una señal acústica perceptible sin incrementar de forma significativa el consumo energético del dispositivo. Esta arquitectura también permite ampliar su uso en futuras versiones del firmware para la generación de otros tipos de alertas del sistema.

Figura 18

Esquema del Circuito de Control y Activación para El Buzzer

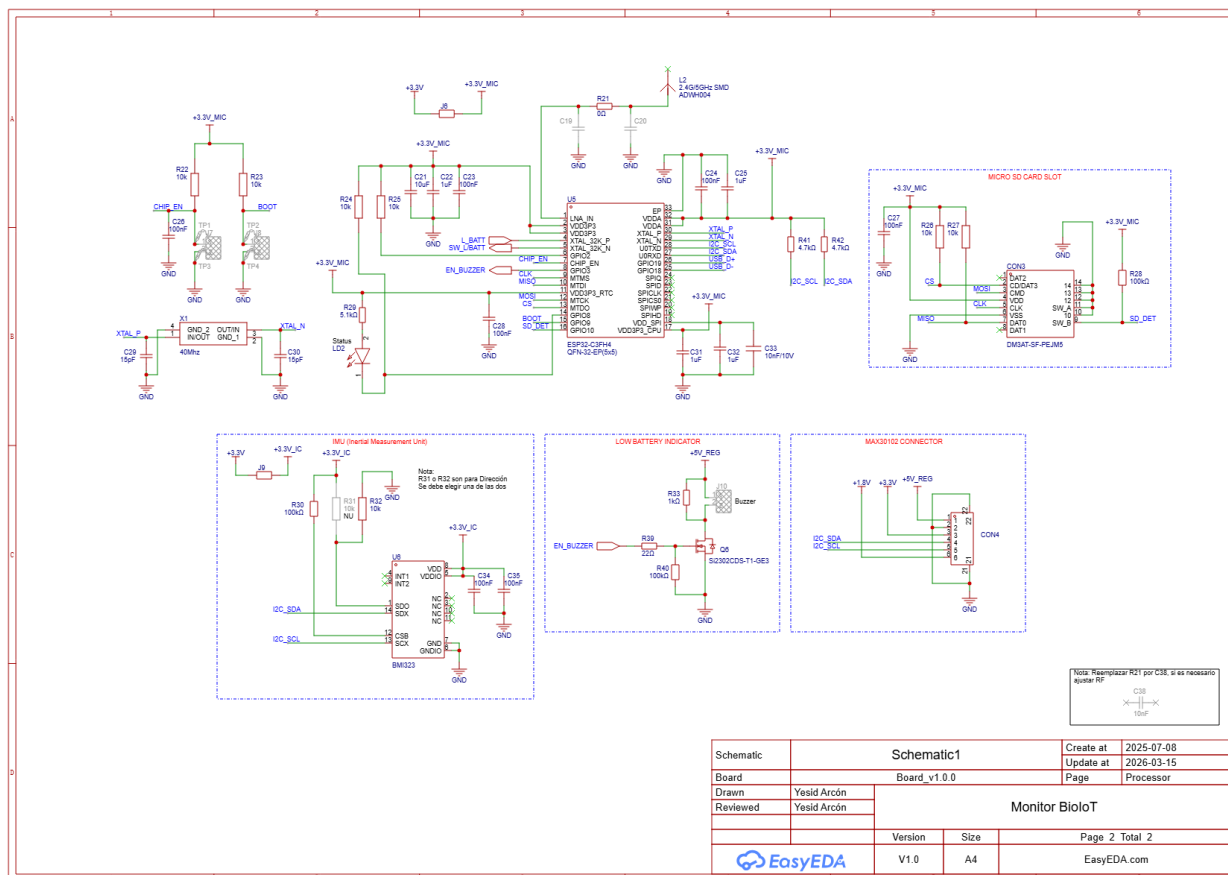


Nota. El diagrama ilustra la etapa de control mediante un transistor MOSFET de canal N (Q6, Si2302CDS) configurado como interruptor. El circuito incluye una resistencia de gate (R39) para limitar picos de corriente, una resistencia de *Pull-down* (R40) para asegurar el estado de corte en ausencia de señal (EN_BUZZER) y una resistencia de protección (R33) en paralelo con el zumbador. Gráfico copiado desde el entorno de diseño EasyEDA.

En las Figuras 19 y 20, se muestran los planos del diseño del hardware y en la Figura 21 el PCB desarrollado con el software Easy Eda.

Figura 20

Esquema Electrónico del Sistema de Procesamiento Central y Periféricos de Entrada/Salida




Nota. El diagrama detalla la interconexión del SoC ESP32-C3 con sus periféricos críticos, organizados en bloques funcionales: (a) el circuito de reloj y cristal de 40MHz, (b) la red de adaptación de impedancia para la antena de 2.4/5 GHz, (c) el lector de tarjetas Micro-SD vía bus SPI, (d) la unidad de medición inercial (IMU BMI323), (e) la etapa de alerta sonora por bajo nivel de batería y (f) el conector para el sensor biomédico MAX30102. Gráfico copiado desde el entorno de diseño EasyEDA.

Figura 21

Vista de Diseño de las Capas Superior (Top) e Inferior (Bottom) de la PCB del Sistema Monitor

BioIoT



Nota. La imagen presenta el renderizado en 3D del diseño de la placa de circuito impreso. En la cara superior (izquierda) se observa la etapa de gestión de potencia, el conector USB-C y los componentes de regulación. En la cara inferior (derecha) se destaca el área de radiofrecuencia con la antena cerámica para Wi-Fi/Bluetooth, el zócalo para tarjeta Micro SD y el conector interfaz para el sensor biomédico. Gráfico copiado desde el entorno de diseño EasyEDA.

En la Tabla 8, se detalla el listado de materiales de la tarjeta electrónica, para información adicional, consulte el Apéndice D.

Tabla 8

Lista de Materiales (BOM) y Especificaciones de Componentes del Sistema

Componente	Valor	Cantidad	Posición	Tamaño / Encapsulado
Capacitor	100nF	10	C1,C11,C18,C23,C24,C26, C27,C28, C34,C35	C0201
Capacitor	10uF	10	C2,C3,C4,C6,C8,C9,C12, C16,C17, C21	C0402
Capacitor	330pF	1	C5	C0201
Capacitor	2.2uF	1	C7	C0402
Capacitor	1uF	7	C10,C14,C15,C22,C25,C3 1,C32	C0201
Capacitor	10nF	1	C13	C0201
Capacitor	15pF	2	C29,C30	C0201
Capacitor	10nF/10V	1	C33	C0201
Conector USB	5V/3A	1	CON1	USB-C_SMD- TYPE-C-31-M-12
Conector Batería	2A	1	CON2	CONN- SMD_P2.00_S2B- PH-SM4-TB-LF-SN
Zócalo MicroSD	NA	1	CON3	SD-SMD_DM3AT- SF-PEJM5
Conector sensor PPG	200mA	1	CON4	CONN- SMD_SM06B- XSRS-ETB
Diodo Schottky	40V/1A	3	D1,D5,D6	SOD-123_L2.7- W1.6-LS3.7-RD
Diodo TVS	10V/6A	1	D2	DFN1006-2L-BI
Diodo TVS	10.5V/5A	2	D3,D4	DFN1006-2L-BI
Diodo	80V/125mA	2	D7,D8	SOD-523_L1.2- W0.8-LS1.6-RD
Fisible PTC	6V/750mA	2	F1,F2	F0603
Puentes	NA	7	J1,J2,J3,J4,J5,J6,J9	RESC0603X26N
Inductor	2.2uH	1	L1	L1008

Componente	Valor	Cantidad	Posición	Tamaño / Encapsulado
Antena	2.4G/5G	1	L2	ANT-SMD_L8.0- W3.0_A
Diodo Led	2.1V/20mA	1	LD1	LED-SMD_3P- L3.0-W2.0-R-RD
Diodo Led	2.9V/5mA	1	LD2	INS63AS5B
Transistor Mosfet	20V/3.7A	2	Q1,Q2	SOT-23-3_L2.9- W1.6-P1.90-LS2.8- BR
Transistor Mosfet	50V/130mA	1	Q3	SOT-23-3_L2.9- W1.6-P1.90-LS2.8- BR
Transistor Mosfet	20V/2.9A	3	Q4,Q5,Q6	SOT-23_L2.9- W1.3-P1.90-LS2.4- BR
Resistor	1k Ω	2	R1,R33	R0402
Resistor	4.7k Ω	1	R2	R0402
Resistor	5.1k Ω	3	R3,R4,R29	R0201
Resistor	22 Ω	3	R5,R6,R39	R0201
Resistor	10 Ω	1	R7	R0402
Resistor	10k	9	R8,R22,R23,R24,R25,R26 ,R27,R31,R32	RESC0603X26N
Resistor	1M Ω	2	R9,R13	R0201
Resistor	100k Ω	10	R10,R11,R12,R16,R17,R1 8,R20,R28,R30,R40	R0201
Resistor	54.9k	1	R14	RESC0603X26N
Resistor	200k	1	R15	RESC0603X26N
Resistor	300K	1	R19	R0201
Resistor	0 Ω	1	R21	R0402
Resistor	4.7k Ω	2	R41,R42	R0201
Switch táctil	12V/50mA	1	SW1	KEY-SMD_TX- 1010-X-X
Circuito Integrado cargador de batería	1500mA	1	U1	SOT-23-6_L2.9- W1.6-P0.95-LS2.8- BR

Componente	Valor	Cantidad	Posición	Tamaño / Encapsulado
Convertor DC-DC 5V		1	U2	TSOT-23-5_L2.9- W1.6-P0.95-LS2.8- BR
LDO 3.3V	600mA	1	U3	TSOT-23-5_L2.9- W1.6-P0.95-LS2.8- BL
LDO 1.8V	200mA	1	U4	SOT95P280X145- 5N
Microcontrolador SOC	NA	1	U5	QFN-32_L5.0- W5.0-P0.50-TL- EP3.7
Circuito IMU	NA	1	U6	LGA-14_L3.0- W2.5-P0.50- TL_QMI8658A
Cristal	40Mhz	1	X1	ECS4001037B2CK MTR

Nota. Abreviaturas: NA = No aplica; SMD = Dispositivo de montaje superficial; LDO = Regulador de baja caída; TVS = Supresor de picos de tensión; PTC = Coeficiente de temperatura positivo (fusible rearmable); SoC = Sistema en un chip; IMU = Unidad de medición inercial. Las dimensiones de los encapsulados (ej. 0201, 0402, SOT-23) corresponden a estándares de la industria electrónica para el diseño de PCB.

Como parte del proceso de validación del hardware, las placas de circuito impreso recibidas del proceso de fabricación y ensamblaje fueron sometidas a una inspección previa a la energización con el fin de detectar posibles defectos. Esta inspección incluyó una revisión visual detallada para identificar soldaduras deficientes, componentes mal posicionados o daños físicos, así como mediciones de resistencia en los terminales de alimentación para descartar cortocircuitos entre las líneas de voltaje y tierra, minimizando el riesgo de fallas durante las

pruebas posteriores. Estas verificaciones constituyen una etapa fundamental en la validación inicial del hardware.

Una vez completada la revisión física, se procedió a la puesta en marcha del prototipo. Inicialmente, se alimentó el dispositivo para comprobar el correcto funcionamiento del circuito de carga de la batería y de los indicadores de estado asociados.

Durante las pruebas iniciales, se identificó un comportamiento inestable en el circuito de encendido y apagado, evidenciado por reinicios constantes del dispositivo. Para solucionarlo, se modificó un componente pasivo en el circuito de control, lo que permitió lograr un encendido estable y confiable. Este ajuste fue necesario debido a que se requería un mayor flujo de corriente hacia GND a través del switch para mantener el estado activo. El diseño de este circuito se basó en la topología de interruptor de enclavamiento (latch switch) tomada de la página de Mosaic Documentation Web (Latch and Toggle Power Circuits).

Posteriormente, se estableció la comunicación con un computador mediante la configuración de los pines de arranque y reinicio del SoC ESP32-C3, lo que permitió su reconocimiento como puerto serie y la carga del programa. Para ello se utilizó PlatformIO como entorno de desarrollo integrado sobre el Framework de Arduino, decisión que permitió aprovechar las ventajas de una herramienta profesional y adquirir nuevas destrezas durante el desarrollo del proyecto.

A continuación, se verificaron las etapas de regulación de voltaje midiendo los niveles de salida de cada convertidor para garantizar su correcta operación.

Dado que el módulo externo para PPG incorpora en su tarjeta los circuitos reguladores de voltaje, se optó por prescindir de ellos y utilizar directamente los voltajes regulados provenientes de la tarjeta prototipo principal. De esta forma, se alimenta únicamente el integrado junto con sus

capacitores para filtrado de ruido en la alimentación, evitando la necesidad de diseñar una nueva PCB para este dispositivo.

Debido a que no se contaba en ese momento con el cable de conexión entre la tarjeta principal desarrollada y el módulo PPG, se decidió soldar temporalmente el cableado necesario. Esto incluyó las tensiones de 3.3 V (para los LEDs) y 1.8 V (para la etapa digital), así como los pines del bus I2C. Cabe destacar que la interfaz I2C del sensor MAX30102 utiliza una configuración de drenador abierto, lo que permite la compatibilidad con niveles lógicos de 3.3 V mediante resistencias de pull-up externas, aunque el núcleo del sensor opere a 1.8 V. Esta característica facilita la integración directa con el SoC de 3.3 V sin necesidad de desplazadores de nivel (level shifters).


Seguidamente, se realizaron pruebas independientes sobre los diferentes módulos del sistema mediante sketches específicos, evaluando la comunicación con la tarjeta microSD, el funcionamiento del LED de estado, el circuito del buzzer, la conectividad WIFI, la comunicación con el sensor IMU, el módulo externo PPG y el enlace Bluetooth. Estas pruebas permitieron validar progresivamente la operación integral del prototipo.

Finalmente, se cargó el firmware completo para poner en marcha el sistema de manera integrada. Durante esta etapa, se verificaron las señales de los sensores EEG y PPG a través del monitor serie, se evaluó el envío de datos a la plataforma Firebase y el almacenamiento en la tarjeta SD, y se simulaban condiciones de falla para comprobar la activación de las alarmas visuales (LED) y sonoras (Buzzer). Esta validación integral permitió confirmar el correcto funcionamiento del prototipo ante situaciones normales y de contingencia.


A continuación, en las Figuras 22 a la 25 se muestran fotografías del prototipo desarrollado y la integración con sus componentes externos, tal como: La batería para alimentación, el Buzzer y el sensor para PPG.

Figura 22

Integración Física de los Módulos de Hardware del Prototipo Monitor BioIoT




Nota. La fotografía muestra el prototipo funcional con sus componentes interconectados: (a) la placa de circuito impreso (PCB) principal con el logo institucional y conexión USB-C activa, (b) la batería de Polímero de Litio (LiPo) de 3.7V y 600mAh, (c) el zumbador electromagnético para alarmas sonoras y (d) el módulo sensor biomédico MAX30102.

Figura 23*Modificaciones para Conexiones hacia Módulo PPG*

Nota. En la fotografía se evidencian las modificaciones realizadas en las conexiones hacia el módulo MAX30102, las cuales fueron necesarias para adaptar el cableado ante la indisponibilidad del microconector original de la tarjeta durante la fase de pruebas y validación del circuito.

Figura 24

Medición de Corriente Durante el Proceso de Carga de la Batería Lipo



Nota. La fotografía ilustra la validación experimental del sistema de alimentación. Se observa un multímetro digital (Uni-T UT133A) configurado en la escala de corriente continua (ADC), registrando un consumo de 0.206A extraído de la fuente USB. Esta corriente fluye hacia la PCB principal para alimentar el circuito cargador y, simultáneamente, recargar la batería de Litio, confirmando el funcionamiento de la etapa de gestión de potencia.

Figura 25

Medición de Consumo de Corriente del Sistema en Modo de Operación Local sin Transmisión Inalámbrica



Nota. La fotografía muestra la validación del consumo energético del prototipo durante la ejecución de procesos internos (lectura de sensores y procesamiento local) sin activación del módulo de comunicación Wi-Fi/Bluetooth. El multímetro digital registra una corriente de 0.084A (84mA), lo que representa una reducción significativa de consumo respecto al modo de carga, validando la eficiencia del firmware y el hardware en estado de espera activa.

Durante las pruebas de consumo del prototipo se midió la corriente en diferentes estados de operación. En modo activo, con los módulos WiFi y Bluetooth encendidos, pero sin realizar envíos a la nube, el dispositivo presentó un consumo estable entre 77mA y 84mA. Al ejecutar eventos de transmisión inalámbrica, se observaron picos de corriente entre 100mA y 115mA, correspondientes al incremento temporal de actividad del radio. Por su parte, el circuito cargador de batería suministró aproximadamente 205mA durante el proceso de carga, valor consistente con la configuración del integrado dedicado a esta función.

Con base en estas mediciones y considerando la batería actual de 600mAh, se estima un tiempo de carga cercano a 3 horas, así como una autonomía aproximada de 6 horas de operación continua, dependiendo de la frecuencia de envío de datos y de la actividad de los sensores.

Las mediciones de voltaje en los reguladores arrojaron valores dentro de los rangos esperados (3.3V y 1.8V para la lógica del sistema, 4.2V para la carga de batería), validando el diseño de las etapas de alimentación. Asimismo, se comprobó la correcta polaridad y conexión de todos los sensores y periféricos, quedando el prototipo en condiciones óptimas para su energización y pruebas funcionales.

Con el hardware verificado, se energizó el sistema y se procedió a validar el funcionamiento de cada integrado de manera independiente. Se corroboró la comunicación I2C con los sensores MAX30102 y BMI323, así como la recepción de datos del módulo EEG vía Bluetooth. Las señales PPG adquiridas permitieron la detección de latidos y el cálculo de frecuencia cardíaca y SpO₂. El sensor IMU reportó correctamente los datos de aceleración y giroscopio, detectando movimientos bruscos dentro de los umbrales establecidos para referencias. Por su parte, el módulo EEG entregó las tramas de datos, con las que se pudo extraer los valores de potencias para bandas, validándose su recepción y procesamiento en el SoC. Todas

las lecturas se realizaron dentro de los intervalos de muestreo definidos en el firmware, confirmando la capacidad del sistema para adquirir y procesar señales biomédicas en tiempo real.

Resultados Fase 3 – Implementación de Algoritmos y Transmisión de Datos

En esta fase se realizó la integración del hardware con el software embebido y los servicios IoT, permitiendo la interacción entre los sensores biomédicos, el microcontrolador y la plataforma en la nube. Se implementó la comunicación inalámbrica y la conexión con la base de datos remota, habilitando el almacenamiento, la sincronización y la gestión de los datos biomédicos generados por el sistema. Asimismo, se desarrollaron e integraron los mecanismos de autenticación y control de acceso de usuarios, y se llevaron a cabo pruebas funcionales iniciales por etapas, orientadas a verificar el correcto funcionamiento del diseño electrónico, la adquisición de señales, la transmisión de datos y la interacción entre los diferentes módulos del sistema, antes de avanzar hacia las pruebas de validación completas.

A continuación, se presenta el diagrama de flujo general del sistema de monitoreo biomédico portátil, el cual describe la estructura integral de operación del prototipo IoT diseñado para la adquisición, procesamiento y transmisión de señales fisiológicas. Este diagrama sintetiza el flujo completo desde la inicialización de los componentes hardware (incluyendo sensores PPG, módulos EEG y acelerómetro) hasta el ciclo continuo de captura de datos, gestión de conectividad WiFi, almacenamiento local en tarjeta SD, transmisión a plataforma en la nube (Firebase) y control de interfaz visual, garantizando así un monitoreo confiable y continuo orientado al estudio de patrones asociados a condiciones neurológicas como la epilepsia.

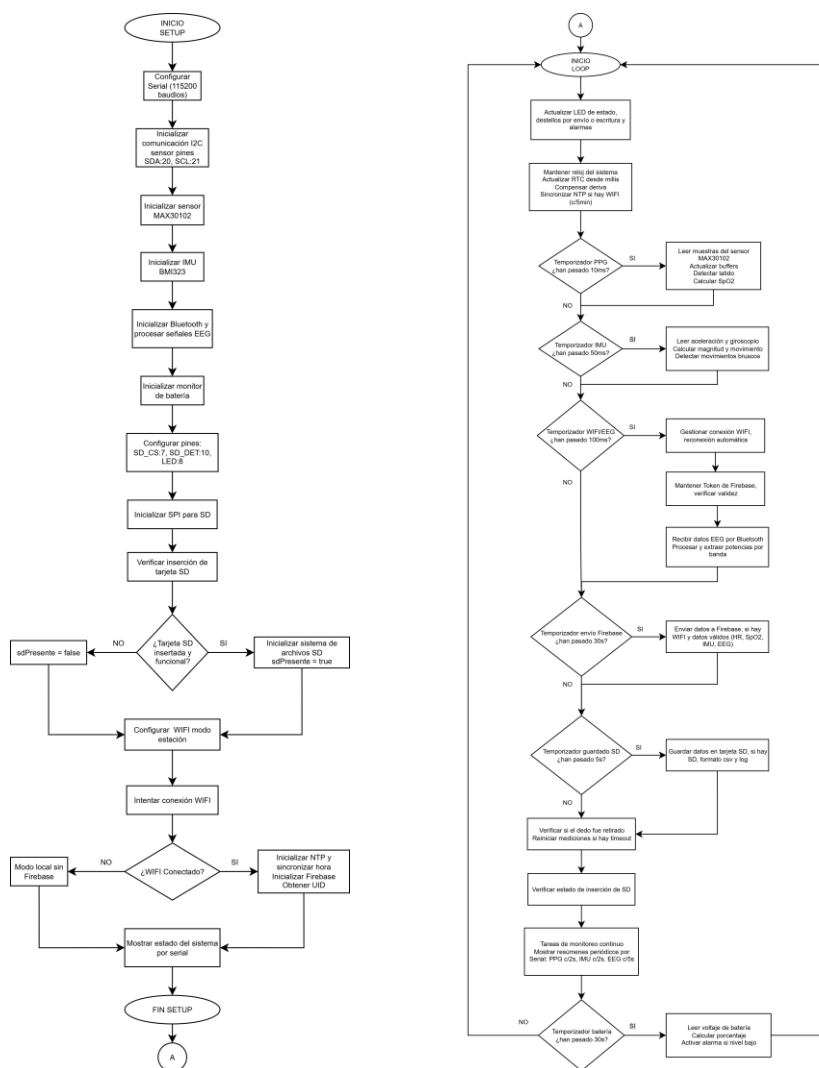
El algoritmo del sistema fue diseñado para gestionar de manera integrada la adquisición de señales biomédicas, el almacenamiento local de datos, la comunicación inalámbrica y la supervisión del estado del dispositivo. Durante la etapa de inicialización, el sistema configura los

módulos de adquisición, almacenamiento y conectividad, verificando la disponibilidad de los sensores, la memoria microSD y la conexión a la red inalámbrica. En caso de que alguno de estos elementos no se encuentre disponible, el sistema ajusta su modo de operación para garantizar la continuidad del funcionamiento local del prototipo.

El firmware fue diseñado bajo un enfoque secuencial no bloqueante, basado en un único lazo principal de ejecución encargado de gestionar las diferentes funciones del sistema. Este esquema permite atender múltiples tareas de forma cooperativa mediante la evaluación periódica de eventos y temporizadores, simulando un comportamiento concurrente sin requerir paralelismo real ni la implementación explícita de sistemas operativos en tiempo real.

Figura 26

Diagrama de Flujo del Algoritmo Principal del Firmware (Setup y Loop)



Nota. El diagrama describe la lógica de ejecución del dispositivo, dividida en dos fases: El Setup, donde se inicializan los protocolos de comunicación (I2C, SPI), sensores (MAX30102, BM323) y la conexión inalámbrica; y el Loop principal, basado en temporizadores no bloqueantes.

Gráfico desarrollado con el software Lucidchart.

Una vez inicializado, el sistema entra en un ciclo de operación continuo en el que se gestionan las diferentes tareas de adquisición y procesamiento de señales biomédicas. Dentro de esta

arquitectura, la prioridad principal se asigna a la recepción de la señal EEG, considerada la fuente primaria de información del sistema. De manera complementaria, el sistema realiza la lectura de las señales provenientes del sensor PPG y a partir de estas señales, el algoritmo ejecuta la detección de latidos cardíacos y el cálculo de la frecuencia cardíaca y la saturación de oxígeno en sangre, aplicando filtros y promedios con el fin de mejorar la estabilidad de las mediciones. Adicionalmente, se implementa un mecanismo de detección de presencia del dedo que permite reiniciar las mediciones cuando se interrumpe la señal, evitando así el registro de datos inválidos.

De manera intercalada durante el ciclo de adquisición de datos, el algoritmo gestiona el almacenamiento local de la información en una memoria microSD, registrando las mediciones junto con marcas de tiempo y el estado de la conectividad del sistema. Este proceso se realiza de manera periódica y no bloqueante, garantizando que la adquisición de señales no se vea afectada por las operaciones de escritura. Asimismo, se implementa un sistema de supervisión del estado de la tarjeta de memoria, generando alertas visuales cuando esta no se encuentra disponible.

En cuanto a la conectividad, el algoritmo incorpora una gestión inteligente de la conexión inalámbrica, basada en intentos de reconexión controlados y tiempos de espera definidos, con el fin de reducir el consumo energético y evitar bloqueos del sistema. La comunicación con la plataforma en la nube se inicializa únicamente cuando la conexión WIFI es estable, permitiendo el envío periódico de los datos biomédicos. En caso de pérdida de conexión, el sistema continúa operando en modo local, asegurando la conservación de la información mediante el almacenamiento interno.

El algoritmo coordina los indicadores visuales del sistema, utilizando patrones de encendido y parpadeo para representar eventos como el envío exitoso de datos, el almacenamiento local, la ausencia de la memoria microSD o fallas en la conectividad. De esta

manera, el firmware implementa un control basado en estados, optimizado para operación continua, bajo consumo energético y robustez frente a fallas, cumpliendo con los requerimientos funcionales del prototipo biomédico propuesto.

El firmware del dispositivo se estructuró en dos bloques principales. Configuración inicial (Setup) y bucle principal (Loop), siguiendo un enfoque de programación no bloqueante basado en máquinas de estado y temporizadores.

En la etapa de Setup se inicializan secuencialmente los periféricos. Primero la comunicación I2C para los sensores MAX30102 (frecuencia cardíaca y oximetría) e IMU BMI323 (acelerometría y giroscopía); a continuación, se configura el módulo Bluetooth para recibir los datos del dispositivo EEG externo, se inicializa el monitor de batería, y se prepara la interfaz SPI para la tarjeta SD verificando su presencia. Posteriormente se intenta la conexión WiFi y, en caso de éxito, se sincroniza la hora mediante NTP y se inicializa Firebase, quedando el sistema listo para operar en modo local o con conectividad en la nube. El Loop principal ejecuta de manera periódica y asíncrona la adquisición de datos de cada sensor con intervalos definidos (10 ms para PPG, 50 ms para IMU, 100 ms para la recepción y procesamiento de señales EEG y tareas de gestión), actualiza el reloj interno con compensación de deriva, gestiona la reconexión WIFI y el token de Firebase, y almacena localmente en la tarjeta SD, en formato CSV y log legible, los registros que cumplen criterios de validez (señal de contacto en el dedo, movimientos significativos, calidad de señal EEG adecuada). El envío a Firebase se realiza cada 30 segundos únicamente cuando hay conectividad y al menos un grupo de datos es válido, optimizando así el uso de la red y la base de datos. Adicionalmente, se implementó un esquema de indicación visual mediante LED que refleja el envío de datos (destello) o alertas por ausencia de tarjeta SD (parpadeo), y se monitorea continuamente el nivel de batería para generar alarmas

cuando sea necesario. Esta arquitectura modular y eficiente permite que el sistema funcione de manera autónoma y robusta, tanto en línea como fuera de línea, garantizando la integridad de los datos fisiológicos recolectados.

El sistema de temporización se basa en la función `millis()`, que proporciona el tiempo transcurrido desde el inicio del dispositivo. Cada tarea periódica mantiene una variable que almacena el último momento de ejecución; en cada iteración del bucle principal se calcula la diferencia con el valor actual de `millis()` y, si es igual o superior al intervalo definido, se ejecuta la tarea y se actualiza la variable. Este enfoque no bloqueante permite que múltiples tareas con diferentes frecuencias (desde 10 ms hasta 30 segundos) coexistan sin interferencias. Además, la aritmética de enteros sin signo utilizada garantiza el correcto funcionamiento incluso ante el desbordamiento del contador cada 49.7 días, por lo que el sistema puede operar de forma continua sin necesidad de reinicios.

El firmware utiliza la función `millis()` como base de tiempo, la cual cuenta los milisegundos desde el encendido del dispositivo. Cada tarea del sistema (lectura de sensores, envío a la nube, almacenamiento) posee su propia variable que almacena el instante de su última ejecución. En cada iteración del bucle principal, se compara el tiempo actual con dicho registro; si ha transcurrido el intervalo definido, la tarea se ejecuta y actualiza su marca. Este mecanismo permite que múltiples procesos con diferentes frecuencias convivan sin bloqueos, ya que la mayoría de las tareas son de corta duración (inferior a 1 ms). El envío a Firebase, que puede demorar algunos cientos de milisegundos, ocurre únicamente cada 30 segundos, por lo que su impacto en la adquisición de datos es mínimo y no compromete la integridad del sistema.

Las tareas de adquisición de señales fisiológicas (PPG cada 10 ms, IMU cada 50 ms) tienen la prioridad más alta, seguidas de la gestión de conectividad y procesamiento EEG cada

100ms. El envío a la nube y el almacenamiento local se realizan cada 30 y 5 segundos respectivamente, pero solo cuando hay datos válidos y los medios están disponibles. Todas las tareas conviven armónicamente porque ninguna supera unos pocos milisegundos de ejecución, y los temporizadores garantizan que no se acumulen ni bloqueen el flujo principal.

En el desarrollo del firmware también se implementó un filtro digital de primer orden, específicamente un filtro IIR (Infinite Impulse Response) de tipo pasa bajos, también conocido como filtro de media móvil exponencial (EMA) o filtro de suavizado exponencial, con el objetivo de estabilizar las lecturas de frecuencia cardíaca (BPM) y saturación de oxígeno (SpO2) que se muestran al usuario y se almacenan en la nube y en la tarjeta SD. Este filtro actúa sobre los valores instantáneos calculados a partir de la señal PPG, no sobre la forma de onda cruda, y responde a la necesidad de presentar mediciones suaves y coherentes, eliminando fluctuaciones bruscas provocadas por ruido o propias del contacto o posición del dedo.

La ecuación general que describe el comportamiento del filtro es:

$$y[n] = \alpha \cdot x[n] + (1 - \alpha) \cdot y[n - 1]$$

$$salida_filtrada[n] = \alpha \cdot muestra_actual[n] + (1 - \alpha) \cdot salida_filtrada[n - 1]$$

donde:

$x[n]$: es el valor instantáneo de la variable en la muestra actual (por ejemplo, beatsPerMinute o SpO2).

$y[n-1]$: es el valor filtrado en la muestra anterior.

$y[n]$: es el nuevo valor suavizado.

α : es el factor de suavizado, que toma un valor entre 0 y 1.

- Si $\alpha = 1$, la salida es $y[n] = x[n]$ (no hay filtrado, respuesta instantánea, pero sin suavizado).

- Si $\alpha = 0$, la salida es $y[n] = y[n-1]$ (la salida nunca cambia, es un filtro inútil).

En el código, para la frecuencia cardíaca se emplea la siguiente instrucción:

```
beatAvg = (beatAvg == 0) ? beatsPerMinute : (beatAvg * 0.8 + beatsPerMinute * 0.2);
```

De forma análoga, para la saturación de oxígeno se utiliza:

```
spo2Avg = (spo2Avg == 0) ? spo2 : (spo2Avg * 0.8 + spo2 * 0.2);
```

En ambos casos, el coeficiente ($\alpha = 0.2$) asigna un peso del 20 % al nuevo valor instantáneo y un 80 % al valor previamente filtrado ($1 - \alpha$). Esta elección responde a un compromiso entre la velocidad de respuesta ante cambios fisiológicos reales y la atenuación de ruido de alta frecuencia. Un valor de (α) pequeño proporciona un fuerte suavizado, pero introduce un ligero retardo; el valor adoptado ($\alpha = 0.2$) permite que el filtro se estabilice en aproximadamente 5 a 20 iteraciones, lo que resulta adecuado para señales biomédicas donde los cambios significativos (por ejemplo, durante el ejercicio) ocurren en escalas de tiempo de varios segundos.

Asumiendo un valor típico para el MAX30102 de 100 Hz (100 muestras por segundo), se calcula la frecuencia de corte:

$$f_c \approx (\alpha * F_s) / (2\pi)$$

$$f_c \approx (0.2 * 400) / (2\pi)$$

$$f_c \approx 80 / 2\pi$$

$$f_c \approx 12.73 \text{ Hz}$$

La frecuencia cardíaca en reposo oscila entre 0.5 Hz y 3.33 Hz (30 a 200 latidos por minuto). Con una frecuencia de corte de 12.73 Hz, las frecuencias por debajo de ese valor pasan casi sin atenuación, y las de arriba empiezan a atenuarse, logrando un equilibrio entre suavizado y fidelidad.

Con respecto a la constante de tiempo del filtro, que nos indica cuanto tarda este en reaccionar, se calcula para hallar el número de muestras:

$$\tau \approx (1 - \alpha) / \alpha$$

$$\tau \approx (0.8) / (0.2) = 4 \text{ muestras}$$

- El filtro tarda aproximadamente 4 muestras en alcanzar el 63% de un cambio repentino.

Se considera que el filtro se estabiliza después de 3 a 5 veces esa constante de tiempo (3τ a 5τ). El tiempo de establecimiento es de solo 30-50 ms, imperceptible para cambios fisiológicos.

El filtro implementado es de tipo IIR de primer orden pasa bajos, esta topología se eligió por las siguientes razones:

- Eficiencia computacional: Requiere solo una multiplicación y una suma por cada actualización, lo que minimiza la carga de procesamiento en el SoC, especialmente relevante dado que el sistema ejecuta múltiples tareas en tiempo real (adquisición de sensores, gestión WIFI, envío a Firebase, almacenamiento en SD, etc.).
- Simplicidad de implementación: No necesita buffers extensos ni coeficientes complejos, lo que facilita su mantenimiento y depuración.
- Idoneidad para el propósito: El objetivo es suavizar un valor escalar que ya ha sido extraído de la señal (BPM y SpO2), no filtrar la señal cruda.

Cabe destacar que no se aplicó ningún filtro digital sobre las señales crudas de infrarrojo (IR) y rojo (RED) provenientes del sensor MAX30102. Esta decisión obedece a que el objetivo principal del sistema no es la visualización de la forma de onda, sino la obtención de parámetros fisiológicos confiables y su transmisión a la nube.

La implementación de filtros digitales para el acondicionamiento de señales en sistemas embebidos es una práctica ampliamente documentada en la literatura. Trabajos recientes como el de De Fazio et al. (2026) demuestran la aplicación de filtros IIR en el procesamiento de señales biomédicas, validando la pertinencia de este enfoque en instrumentación médica. En un ámbito complementario, Narváez (2025) aborda directamente la problemática del filtrado de ruido en conversiones analógico-digitales implementadas en microcontroladores PIC, donde desarrolla filtros de promedio móvil simple (SMA) y promedio móvil exponencial (EMA) para mitigar las componentes de ruido presentes en las adquisiciones de señales analógicas. Este último trabajo resulta particularmente relevante para la presente investigación, ya que no solo comparte el objetivo de atenuar el ruido en sistemas basados en microcontroladores, sino que también emplea la topología de filtro EMA, cuya ecuación en diferencias es análoga a la implementada en este estudio. La convergencia entre estos antecedentes y la solución propuesta refuerza la validez del enfoque metodológico adoptado.

El filtro IIR de primer orden constituye una solución eficaz y eficiente para estabilizar las lecturas de frecuencia cardíaca y saturación de oxígeno en un sistema de monitoreo fisiológico en tiempo real. Su implementación sobre los valores calculados, y no sobre la señal cruda, respeta la naturaleza de los algoritmos de detección y optimiza el uso de los recursos del SoC, contribuyendo a la robustez y fiabilidad del prototipo desarrollado.

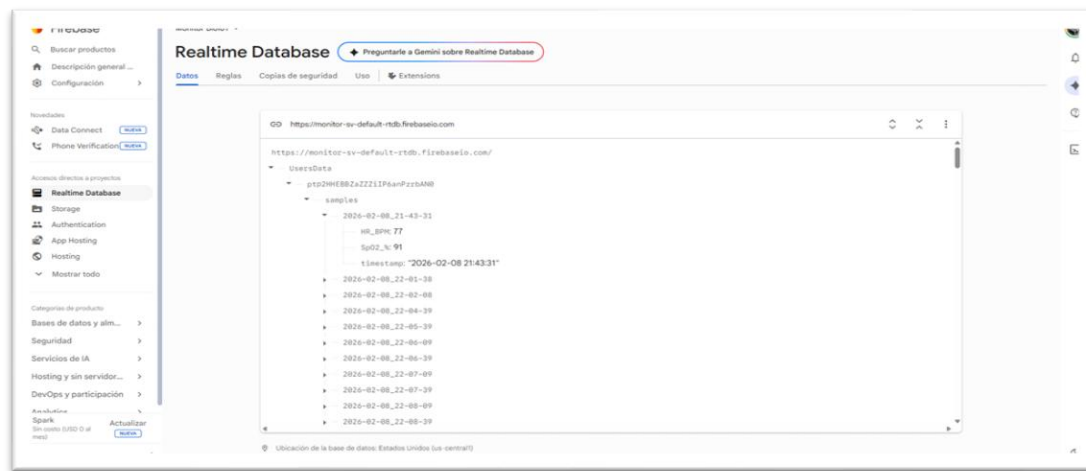
El sistema implementa una estrategia de almacenamiento dual que garantiza la integridad y disponibilidad de los datos fisiológicos registrados. Por una parte, se utiliza Firebase Realtime Database como plataforma en la nube para el almacenamiento y sincronización en tiempo real; por otra, se emplea una tarjeta SD como respaldo local ante eventuales fallos de conectividad.

La implementación del sistema de almacenamiento en la nube y visualización remota se realizó utilizando Firebase Realtime Database como plataforma de backend y un dashboard web para la consulta de las señales en tiempo real. Para el desarrollo de esta etapa se siguió el tutorial publicado por *PICAI0*, el cual proporciona una guía detallada para conectar un ESP32 con Firebase, crear un proyecto en la consola de Firebase, configurar la autenticación por correo electrónico y contraseña, desplegar una aplicación web y establecer las reglas para restringir el acceso por usuario. Dicho tutorial se basa a su vez en las guías de *Random Nerd Tutorials*, que constituyen una referencia ampliamente utilizada en proyectos de IoT con ESP32.

Firebase Realtime Database organiza la información en una estructura de árbol JSON, donde cada nodo representa una entidad del sistema. En este proyecto, los datos se almacenan bajo la ruta `/UsersData/{uid}/samples/`, generando un nuevo nodo por cada muestra enviada con un identificador basado en la marca de tiempo. Cada muestra contiene únicamente los datos que cumplen los criterios de validez establecidos: frecuencia cardíaca y saturación de oxígeno cuando hay detección de dedo, datos del IMU solo ante movimientos significativos, y potencias EEG exclusivamente cuando la calidad de la señal es adecuada. Esta estructura, además de optimizar el almacenamiento, facilita la consulta y el análisis posterior. En la Figura 27 se muestra la estructura de los datos recibidos en la plataforma Firebase.

Figura 27

Interfaz de Firebase Realtime Database con Estructura JSON para el Registro de Variables Biométricas



Nota. La imagen muestra la organización de los datos en formato JSON dentro de la base de datos en la nube. Se observa una jerarquía que clasifica la información por identificador único de usuario (UID), seguida de una colección de muestras (*samples*) indexadas por marcas de tiempo (*timestamps*). Cada entrada registra los valores de frecuencia cardíaca (HR_BPM) y saturación de oxígeno (SpO2%) enviados de forma asíncrona por el dispositivo IoT, permitiendo el monitoreo remoto en tiempo real. Captura tomada desde la consola de Firebase.

Paralelamente, el sistema registra todos los datos en una tarjeta microSD formateada en FAT32. Cada 5 segundos se escriben dos archivos: `datos.csv`, que almacena la información en formato estructurado con cabeceras para su posterior procesamiento, y `datos_log.txt`, que mantiene un registro legible para depuración. Este almacenamiento local garantiza la persistencia de los datos incluso en ausencia de conexión WIFI, actuando como mecanismo de respaldo y redundancia. En la Figura 28 y Figura 29 se pueden observar los datos almacenados en la tarjeta

micro-SD, los cuales han sido exportados y visualizados en diferentes formatos utilizando el Bloc de notas y Microsoft Excel.

Figura 28

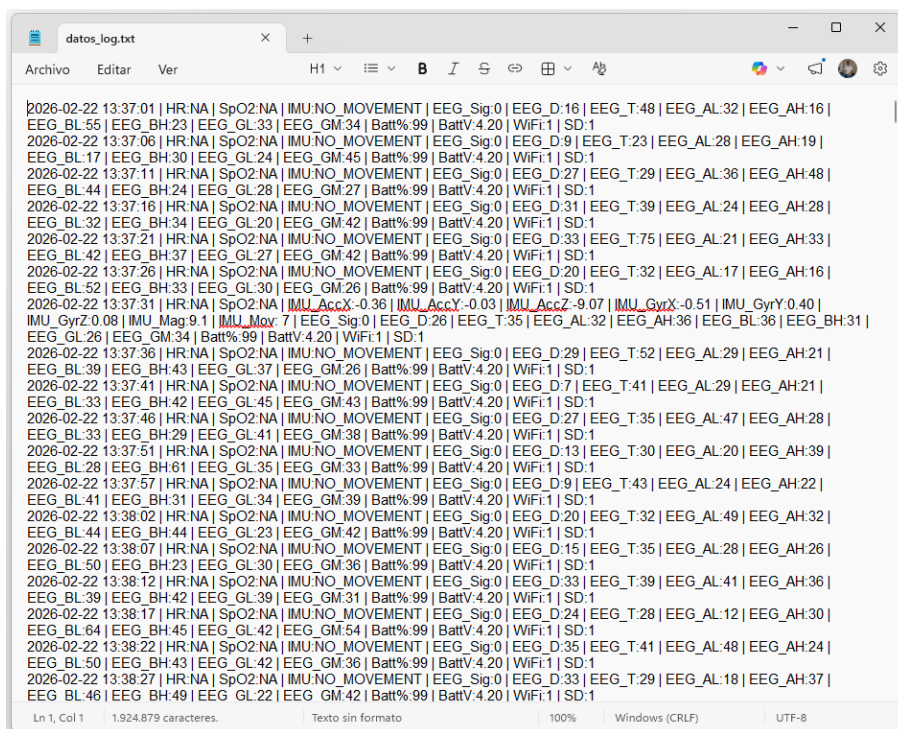
Visualización de Registros Históricos Biométricos y Ambientales Exportados a Formato de Hoja De Cálculo

The image shows a screenshot of the Microsoft Excel application. The spreadsheet contains a table with multiple columns. The first column is labeled 'Timestamp' and contains dates and times in the format 'dd/mm/yyyy hh:mm:ss'. The second column is labeled 'HR_BPM' and contains numerical values representing heart rate. The third column is labeled 'SpO2_%' and contains numerical values representing oxygen saturation. The following four columns are labeled 'EEG: Alpha', 'EEG: Beta', 'EEG: Delta', and 'EEG: Gamma', each containing numerical values representing power levels in different frequency bands. The data is organized into rows, with some rows having a 'NO' value in the 'HR_BPM' column, possibly indicating missing or invalid data. The Excel interface, including the ribbon and menu bar, is visible at the top of the window.

Nota. La imagen presenta una muestra de los datos almacenados localmente en la tarjeta micro-SD del dispositivo. El archivo en formato delimitado por comas (.csv) ha sido importado a Microsoft Excel, permitiendo observar columnas detalladas que incluyen la marca de tiempo (*timestamp*), frecuencia cardíaca (HR_BPM), saturación de oxígeno (SpO2_%), acelerometría en los tres ejes (X, Y, Z) y los niveles de potencia de ondas cerebrales (EEG: Alpha, Beta, Delta, Gamma). Esta estructura facilita el análisis estadístico posterior y la validación de la integridad de los datos recogidos durante las pruebas de campo.

Figura 29

Visualización del Archivo de Registro (Log.Txt) con Datos Estructurados por Delimitadores



```

2026-02-22 13:37:01 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:16 | EEG_T:48 | EEG_AL:32 | EEG_AH:16 |
EEG_BL:55 | EEG_BH:23 | EEG_GL:33 | EEG_GM:34 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:06 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:9 | EEG_T:23 | EEG_AL:28 | EEG_AH:19 |
EEG_BL:17 | EEG_BH:30 | EEG_GL:24 | EEG_GM:45 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:11 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:27 | EEG_T:29 | EEG_AL:36 | EEG_AH:48 |
EEG_BL:44 | EEG_BH:24 | EEG_GL:28 | EEG_GM:27 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:16 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:31 | EEG_T:39 | EEG_AL:24 | EEG_AH:28 |
EEG_BL:32 | EEG_BH:34 | EEG_GL:20 | EEG_GM:42 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:21 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:33 | EEG_T:75 | EEG_AL:21 | EEG_AH:33 |
EEG_BL:42 | EEG_BH:37 | EEG_GL:27 | EEG_GM:42 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:26 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:20 | EEG_T:32 | EEG_AL:17 | EEG_AH:16 |
EEG_BL:52 | EEG_BH:33 | EEG_GL:30 | EEG_GM:26 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:31 | HR:NA | SpO2:NA | IMU_AccX:-0.36 | IMU_AccY:-0.03 | IMU_AccZ:-9.07 | IMU_GyrX:0.51 | IMU_GyrY:0.40 |
IMU_GyrZ:0.08 | IMU_Mag:9.1 | IMU_Mov: 7 | EEG_Sig:0 | EEG_D:26 | EEG_T:35 | EEG_AL:32 | EEG_AH:36 | EEG_BL:36 | EEG_BH:31 |
EEG_GL:26 | EEG_GM:34 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:36 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:29 | EEG_T:52 | EEG_AL:29 | EEG_AH:21 |
EEG_BL:39 | EEG_BH:43 | EEG_GL:37 | EEG_GM:26 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:41 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:7 | EEG_T:41 | EEG_AL:29 | EEG_AH:21 |
EEG_BL:33 | EEG_BH:42 | EEG_GL:45 | EEG_GM:43 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:46 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:27 | EEG_T:35 | EEG_AL:47 | EEG_AH:28 |
EEG_BL:33 | EEG_BH:29 | EEG_GL:41 | EEG_GM:38 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:51 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:13 | EEG_T:30 | EEG_AL:20 | EEG_AH:39 |
EEG_BL:28 | EEG_BH:61 | EEG_GL:35 | EEG_GM:33 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:37:57 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:9 | EEG_T:43 | EEG_AL:24 | EEG_AH:22 |
EEG_BL:41 | EEG_BH:31 | EEG_GL:34 | EEG_GM:39 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:38:02 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:20 | EEG_T:32 | EEG_AL:49 | EEG_AH:32 |
EEG_BL:44 | EEG_BH:44 | EEG_GL:23 | EEG_GM:42 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:38:07 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:15 | EEG_T:35 | EEG_AL:28 | EEG_AH:26 |
EEG_BL:50 | EEG_BH:23 | EEG_GL:30 | EEG_GM:36 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:38:12 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:33 | EEG_T:39 | EEG_AL:41 | EEG_AH:36 |
EEG_BL:39 | EEG_BH:42 | EEG_GL:39 | EEG_GM:31 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:38:17 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:24 | EEG_T:28 | EEG_AL:12 | EEG_AH:30 |
EEG_BL:64 | EEG_BH:45 | EEG_GL:42 | EEG_GM:54 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:38:22 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:35 | EEG_T:41 | EEG_AL:48 | EEG_AH:24 |
EEG_BL:50 | EEG_BH:43 | EEG_GL:42 | EEG_GM:36 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1
2026-02-22 13:38:27 | HR:NA | SpO2:NA | IMU:NO_MOVEMENT | EEG_Sig:0 | EEG_D:33 | EEG_T:29 | EEG_AL:18 | EEG_AH:37 |
EEG_BL:46 | EEG_BH:49 | EEG_GL:22 | EEG_GM:42 | Batt%:99 | BattV:4.20 | WiFi:1 | SD:1

```

Nota. La captura muestra el flujo de datos en tiempo real almacenado en la memoria no volátil.

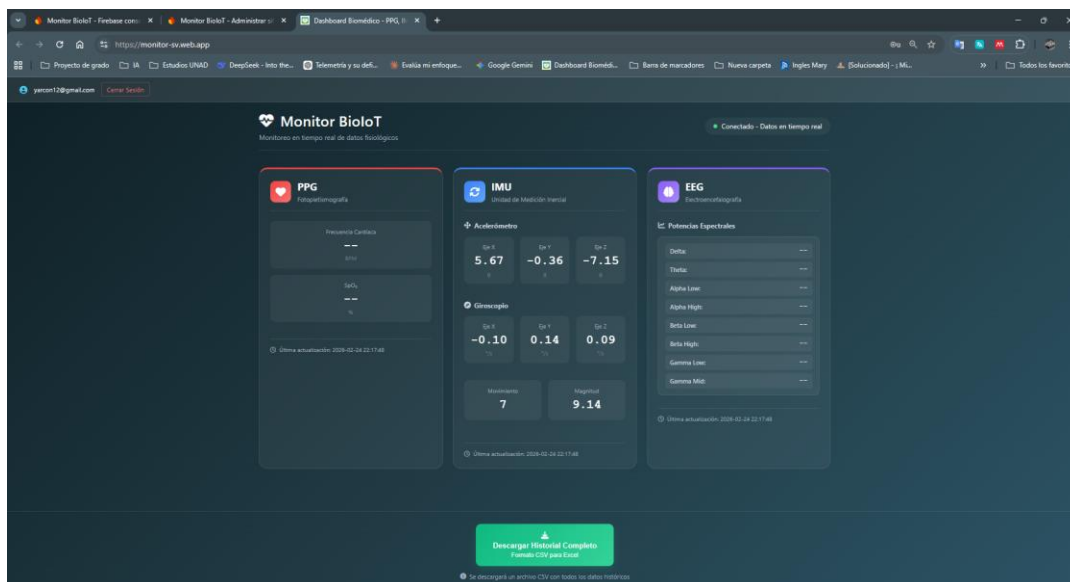
Cada entrada comienza con una marca de tiempo (*timestamp*), seguida de variables separadas por el carácter pleca (|), lo que permite una organización eficiente de datos de múltiples fuentes: Frecuencia cardíaca (HR), saturación de oxígeno (SpO2), acelerometría (IMU), potencia de bandas cerebrales (EEG), estado de la batería, conectividad Wi-Fi y disponibilidad de la tarjeta micro-SD.

Para la visualización y monitoreo, se desarrolló un Dashboard Web utilizando HTML, CSS y JavaScript (sin frameworks adicionales), que se conecta directamente a Firebase Realtime Database para recuperar y presentar los datos en tiempo real. La interfaz permite observar las variables fisiológicas actuales y consultar el historial de mediciones. Este enfoque, proporciona

una solución liviana, multiplataforma y de fácil acceso desde cualquier dispositivo con navegador web. En la Figura 30 se presenta la visualización de los datos en tiempo real dentro del Dashboard, implementado en la infraestructura de alojamiento de la plataforma Firebase.

Figura 30

Panel de Control (Dashboard) Web para la Monitorización en Tiempo Real de Datos Fisiológicos e Inerciales

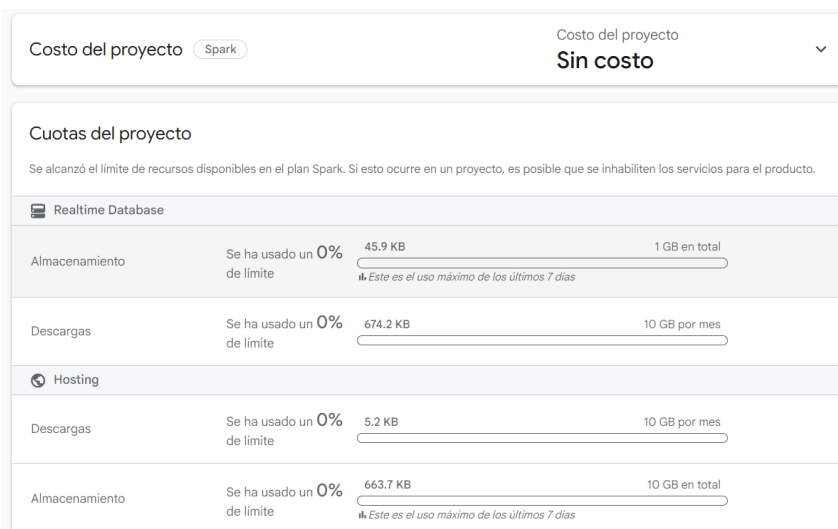


Nota. La interfaz gráfica permite la visualización centralizada de los tres módulos principales del sistema: (a) Fotopletismografía (PPG) para frecuencia cardíaca y saturación, (b) unidad de medición inercial (IMU) con lecturas de acelerómetro, giroscopio y magnitud de movimiento, y (c) electroencefalografía (EEG) con el desglose de potencias espectrales. El tablero incluye indicadores de estado de conexión y una función de descarga para el historial completo en formato CSV, integrando el backend de Firebase con una plataforma de usuario final accesible mediante navegador.

La combinación del almacenamiento en la nube con el respaldo local y la interfaz web de visualización conforma un ecosistema completo que garantiza la disponibilidad, persistencia y accesibilidad de los datos fisiológicos, cumpliendo con los requisitos de confiabilidad y redundancia propios de un sistema de monitoreo de salud.

Almacenamiento en Firebase Realtime Database

La sincronización en la nube se utiliza bajo el plan gratuito Spark, que ofrece 1 GB de almacenamiento total. Los datos se envían cada 30 segundos en formato JSON, con un tamaño promedio de 500 bytes por muestra. Esto se traduce en un consumo diario de 1.44 MB, mensual de 43.2 MB y anual de 518 MB. Con esta tasa, el límite de almacenamiento gratuito permite acumular cerca de dos años de registros, suficientes para la fase de validación del proyecto y demostración del concepto, sin incurrir en costos adicionales. Esta capacidad, sumada a la transferencia de datos de 10 GB mensuales incluida en el plan, garantiza el funcionamiento continuo del sistema durante toda la etapa de pruebas. En la Figura 31 se ilustran los límites de almacenamiento y las cuotas permitidas dentro del plan gratuito (*Spark*) que ofrece la plataforma Firebase para la base de datos *Realtime Database*.

Figura 31*Cuotas de Consumo y Almacenamiento para el Plan Spark en la Plataforma Firebase*

Nota. La imagen detalla el estado de los recursos disponibles bajo el plan gratuito (*Spark*), evidenciando un uso del 0% de los límites permitidos para el almacenamiento y descarga en *Realtime Database* y *Hosting*. Esta configuración permite el despliegue del sistema Monitor BioIoT sin costos operativos, ofreciendo una capacidad total de almacenamiento de 1GB en base de datos y un ancho de banda mensual de 10 GB para descargas, lo cual es suficiente para el volumen de datos biométricos generado por el prototipo.

Almacenamiento en Tarjeta MicroSD

El dispositivo incorpora una tarjeta microSD de 16 GB como mecanismo de almacenamiento local, garantizando la persistencia de los datos incluso en ausencia de conectividad. Cada 5 segundos se escriben dos archivos: uno en formato CSV y otro de texto legible, con un tamaño conjunto aproximado de 300 bytes por evento. Esto representa un consumo diario de 5.18 MB, mensual de 155 MB y anual de 1.86 GB. Con estas cifras, la tarjeta de 16 GB tiene capacidad para almacenar más de 8 años de datos continuos, lo que asegura la

autonomía del dispositivo durante ciclos prolongados de operación sin necesidad de mantenimiento o descarga de información, actuando como un respaldo confiable ante fallos de conectividad.

Las cifras presentadas corresponden a estimaciones basadas en el tamaño promedio de los registros generados por el sistema, considerando las frecuencias de muestreo y envío establecidas en el firmware. Es importante señalar que, en condiciones reales de operación, el volumen de datos puede experimentar ligeras variaciones debido a que no todos los campos están presentes en cada muestra. Por ejemplo, en ausencia de movimiento, los campos correspondientes al IMU no se incluyen en los envíos a Firebase, lo que reduce el tamaño efectivo de las muestras; de manera similar, cuando la señal EEG no cumple los criterios de calidad, dichos datos se omiten tanto en la nube como en el almacenamiento local. No obstante, los valores empleados en los cálculos representan un escenario conservador que garantiza la validez de las conclusiones sobre la capacidad del sistema, siendo suficientes para demostrar la viabilidad del proyecto para una fase inicial.

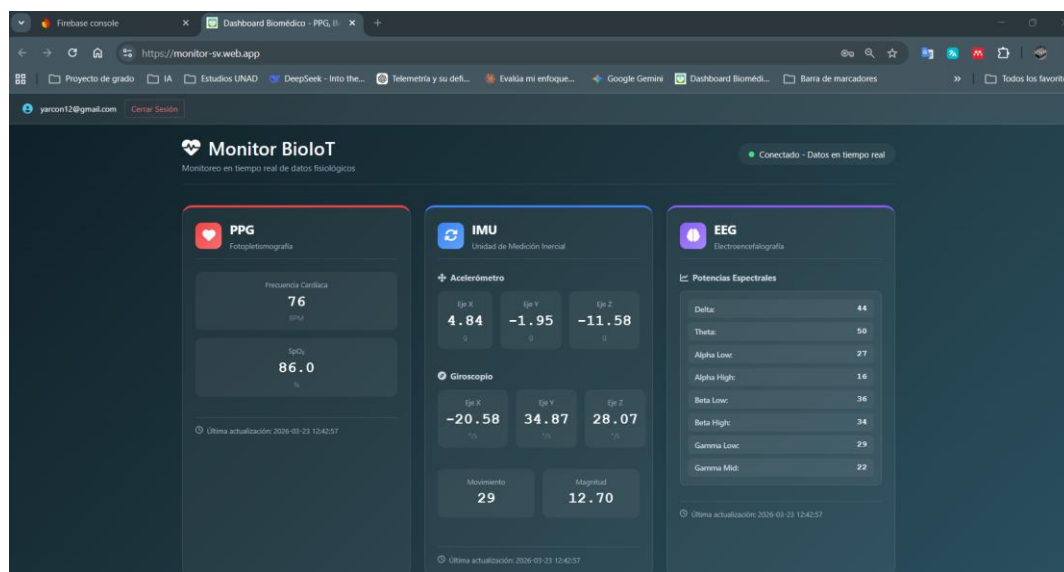
Resultados Fase 4 – Evaluación y Pruebas en Escenario Controlado

En esta fase del proyecto se procedió a evaluar la integración completa del sistema, verificando el flujo de datos desde la adquisición hasta su almacenamiento local y en la nube. Se confirmó que el firmware guarda correctamente los registros en la tarjeta microSD cada 5 segundos, generando archivos CSV con la estructura definida y un log legible para depuración (para más información del tiempo ver Apéndice E). Adicionalmente, se comprobó el envío periódico de datos a Firebase Realtime Database cada 30 segundos, únicamente cuando se cumplían los criterios de validez establecidos (detección de dedo, movimiento significativo, calidad de señal EEG adecuada). La información almacenada en la nube pudo ser consultada

exitosamente desde Realtime Database y el Dashboard Web, evidenciando la correcta sincronización entre el dispositivo y la interfaz de visualización, tal como se observa en las Figuras 32 y 33. Esta validación confirma la arquitectura de almacenamiento dual propuesta, garantizando la persistencia de los datos incluso ante fallos de conectividad.

Figura 32

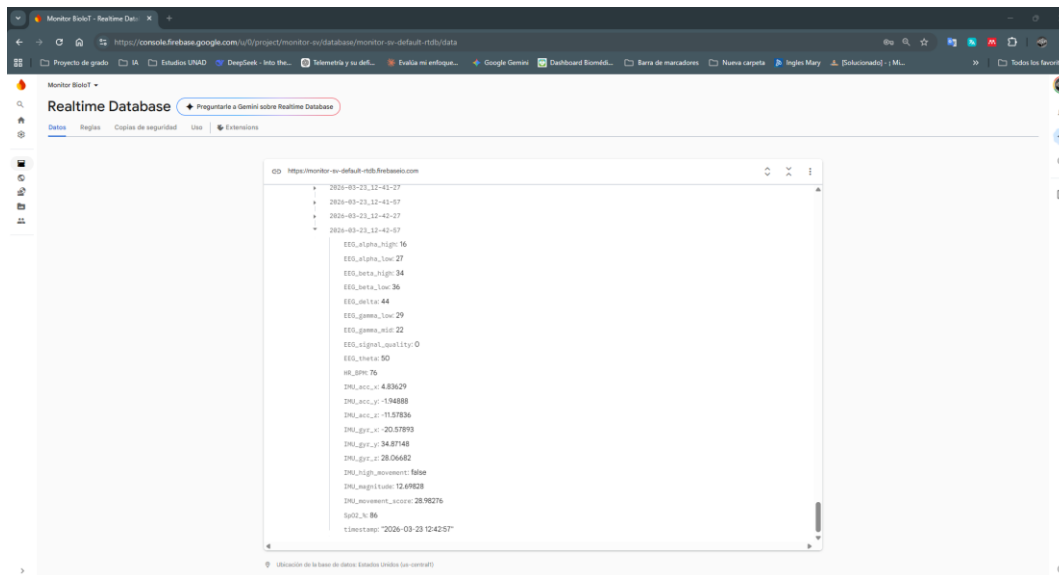
Visualización de Biomarcadores y Métricas de Movimiento en la Interfaz Web del Monitor BioIoT



Nota. La interfaz gráfica presenta el estado de operación del prototipo con datos fisiológicos e inerciales actualizados en tiempo real. En el bloque izquierdo (PPG) se observa una frecuencia cardíaca de 76 BPM y una saturación de oxígeno (SpO₂) del 86%; en el bloque central (IMU) se detallan los vectores de aceleración y giroscopio junto a una magnitud de movimiento de 12.70; y en el bloque derecho (EEG) se visualiza la distribución de potencias espectrales por banda (Delta a Gamma). La plataforma confirma la sincronización exitosa entre el hardware y el servicio de Hosting de Firebase para el monitoreo remoto.

Figura 33

Estructura de Datos JSON en Firebase Realtime Database para el Monitoreo Multivariable de Biomarcadores



Nota. La imagen ilustra un nodo de datos expandido donde se observa la persistencia de información proveniente de tres fuentes distintas: Potencias de ondas cerebrales (EEG: Delta a Theta), métricas de movimiento y orientación (IMU: acelerometría, giroscopio y puntaje de movimiento), y parámetros vitales (HR_BPM y SpO₂). Cada registro está vinculado a una marca de tiempo (*timestamp*) única, lo que garantiza la trazabilidad y permite la reconstrucción temporal de los eventos fisiológicos del usuario en el Dashboard.

Respuesta del Sistema ante Condiciones Críticas

Para verificar la correcta activación de los mecanismos de alerta y la respuesta del firmware ante eventos anómalos, se realizaron pruebas simulando distintas condiciones de fallo. Se evaluaron las alarmas visuales (LED) y sonoras (Buzzer), así como el registro de estos eventos en los distintos medios (monitor serie, tarjeta SD y Firebase).

Pérdida de Señal del Sensor PPG

Al retirar el dedo del sensor durante más de tres segundos, el sistema reinició automáticamente los valores calculados de frecuencia cardíaca y saturación de oxígeno, generando un mensaje en el monitor serie. Esta respuesta confirma la correcta implementación del temporizador de timeout en el firmware.

Movimientos Bruscos Detectados por el IMU

Se indujeron movimientos bruscos en el sensor IMU, superando el umbral de 20 m/s^2 establecido en el firmware. En cada evento, el sistema activó una bandera de alerta (highMovementDetected) que quedó registrada en los archivos de la tarjeta SD. La correcta detección y almacenamiento de estos eventos valida el funcionamiento del algoritmo de detección de movimientos bruscos.

Alarma de Batería Baja

Para la prueba del sistema de monitoreo de batería, se simuló un nivel de voltaje inferior al umbral crítico (aproximadamente 3.0 V , correspondiente a un 0% de carga). El circuito respondió activando una alarma sonora intermitente con el Buzzer, siguiendo un patrón de cuatro pitidos repetidos cada cinco segundos. En esta condición, el LED de estado no presenta ningún comportamiento especial, limitándose a las funciones habituales de destello por envío de datos o alerta por falta de tarjeta SD.

Ausencia de Tarjeta SD

Al retirar la tarjeta SD durante la operación, el firmware detectó la ausencia del dispositivo de almacenamiento y activó un patrón de parpadeo en el LED cada diez segundos (tres segundos de parpadeo rápido seguidos de siete segundos apagado), tal como se definió en la

lógica de control. Al reinsertar la tarjeta, la escritura de datos se restableció automáticamente, demostrando la robustez del manejo de errores en tiempo real.

En todos los casos evaluados, las alertas visuales y sonoras respondieron dentro de los tiempos esperados, y los eventos críticos quedaron correctamente registrados en los diferentes medios de almacenamiento. Los resultados obtenidos validan el correcto funcionamiento del sistema de notificaciones del prototipo y su capacidad para operar de manera confiable ante condiciones anómalas.

A continuación, se presenta capturas de pantalla del monitor serial en VS Code, Figuras 34 a la 36, donde se observa el comportamiento del sistema en tiempo real. En la imagen se evidencian eventos como la detección del dedo, la lectura de señales EEG y PPG, la actualización de fecha y hora mediante NTP, el envío de muestras a la nube (Firebase) y el almacenamiento local en la tarjeta SD.

Figura 35

Respuesta del Sistema y Flujo de Datos Capturados Mediante Comunicación Serial

```

PROBLEMS  OUTPUT  DEBUG CONSOLE  TERMINAL  PORTS  SERIAL MONITOR

***** Mediciones reseteadas *****
[PPG] Esperando señal | IR: 101518 | Red: 91285

[IMU] Mag: 9.7 m/s2 | Mov: 1%
[EEG] ***** Sin datos - Verificar conexión *****
***** Dedo detectado - Iniciando medición *****
[PPG] HR: 68 bpm | SpO2: 82% | Señal: OK
[IMU] Mag: 9.7 m/s2 | Mov: 1%
[PPG] HR: 69 bpm | SpO2: 82% | Señal: OK
[IMU] Mag: 9.7 m/s2 | Mov: 1%
[SD] ***** Datos guardados [2026-03-23 13:06:03] *****
[EEG] Señal: 0 (Buena) | Delta: 30 | Theta: 25
[PPG] HR: 69 bpm | SpO2: 82% | Señal: OK
[IMU] Mag: 9.8 m/s2 | Mov: 0%
[PPG] HR: 72 bpm | SpO2: 82% | Señal: OK
[IMU] Mag: 9.7 m/s2 | Mov: 1%
[SD] ***** Datos guardados [2026-03-23 13:06:08] *****
[PPG] HR: 71 bpm | SpO2: 82% | Señal: OK
[IMU] Mag: 9.7 m/s2 | Mov: 1%
[EEG] Señal: 0 (Buena) | Delta: 5 | Theta: 28
[PPG] HR: 69 bpm | SpO2: 82% | Señal: OK
[IMU] Mag: 9.7 m/s2 | Mov: 1%
[PPG] HR: 68 bpm | SpO2: 82% | Señal: OK
[IMU] Mag: 9.7 m/s2 | Mov: 1%
[EEG] Señal: 0 (Buena) | Delta: 9 | Theta: 29
[SD] ***** Datos guardados [2026-03-23 13:06:13] *****
[PPG] HR: 71 bpm | SpO2: 82% | Señal: OK
[IMU] Mag: 9.7 m/s2 | Mov: 1%
[PPG] HR: 74 bpm | SpO2: 82% | Señal: OK
[IMU] Mag: 9.6 m/s2 | Mov: 2%
Hora sistema: 2026-03-23 13:06:17 (NTP) | Uptime: 775s

-----
Hora: 2026-03-23 13:06:17 | Uptime: 12 min | Batería: 99.84% (4.20V)
-----

[FIREBASE] Muestra enviada. ID: 2026-03-23_13-06-18

```

Nota. La captura de la terminal muestra el ciclo de operación del firmware tras la inicialización.

Se observa el procesamiento secuencial de señales que incluye: La detección de presencia de usuario ("Dedo detectado"), la obtención de métricas de frecuencia cardíaca (HR) y saturación (SpO2), la lectura de la unidad de medición inercial (IMU) y ondas cerebrales (EEG), y la confirmación de procesos críticos como el guardado local en la tarjeta micro-SD y el envío de muestras a Firebase con su respectiva marca de tiempo. Además, se visualiza el monitoreo del estado de la batería (4.20V) y la sincronización con el protocolo de tiempo de red (NTP).

Figura 36*Respuesta del Sistema y Gestión de Excepciones ante la Desconexión de la Tarjeta micro-SD*

```

PROBLEMS  OUTPUT  DEBUG CONSOLE  TERMINAL  PORTS  SERIAL MONITOR

[PPG] Esperando señal | IR: 456 | Red: 509

[IMU] Mag: 9.7 m/s2 | Mov: 1%
***** Tarjeta SD retirada *****
[EEG] Señal: 0 (Buena) | Delta: 48 | Theta: 41
[PPG] Esperando señal | IR: 695 | Red: 582

[IMU] Mag: 9.9 m/s2 | Mov: 1%
[PPG] Esperando señal | IR: 441 | Red: 516

[IMU] Mag: 9.7 m/s2 | Mov: 1%
[EEG] Señal: 0 (Buena) | Delta: 17 | Theta: 52
[PPG] Esperando señal | IR: 443 | Red: 505

[IMU] Mag: 9.7 m/s2 | Mov: 1%
[PPG] Esperando señal | IR: 450 | Red: 490

[IMU] Mag: 9.7 m/s2 | Mov: 1%
[PPG] Esperando señal | IR: 432 | Red: 484

[IMU] Mag: 9.7 m/s2 | Mov: 1%
[EEG] Señal: 0 (Buena) | Delta: 38 | Theta: 53
[PPG] Esperando señal | IR: 430 | Red: 493

[IMU] Mag: 9.7 m/s2 | Mov: 1%

[FIREBASE] Muestra enviada. ID: 2026-03-23_13-29-54

```

Nota. La terminal de depuración evidencia el comportamiento del firmware frente a una interrupción en el almacenamiento local. Se observa el mensaje de alerta "Tarjeta SD retirada", ante el cual el sistema activa una rutina de manejo de errores que permite continuar con la adquisición de señales PPG, IMU y EEG, así como el envío de datos a Firebase (identificado con el ID de muestra final), sin comprometer la estabilidad del programa principal. Esta validación confirma la independencia operativa de los módulos de comunicación y almacenamiento.

En el Apéndice F se presenta el diseño de la carcasa del dispositivo. Las dimensiones son de una altura de 44,5 mm, un ancho de 35 mm y una profundidad de 16,5 mm, lo que favorecen su portabilidad al garantizar un formato compacto y ligero que facilita tanto el transporte como la manipulación en diversos entornos. Estas medidas reducidas permiten que el dispositivo se

acomode fácilmente en bolsillos, estuches o compartimentos pequeños, minimizando el espacio requerido y aumentando la comodidad de uso en situaciones de movilidad. Asimismo, el volumen limitado contribuye a disminuir el peso total, lo que optimiza la ergonomía y posibilita su portabilidad. Estas características dimensionales refuerzan la viabilidad del dispositivo como una solución práctica y adaptable para aplicaciones que demandan alta portabilidad.

Análisis y Discusión

El desarrollo del presente proyecto permitió materializar un sistema portátil de monitoreo fisiológico multicanal, integrando sensores de frecuencia cardíaca, oximetría, movimiento y EEG, junto con capacidades de almacenamiento local y transmisión a la nube. A continuación, se analizan los resultados obtenidos, se discuten las limitaciones del estudio y se plantean las perspectivas futuras.

Es importante señalar que el alcance de esta investigación se centró en el diseño, implementación y validación funcional del hardware y firmware, así como en la demostración de la conectividad IoT para la adquisición y visualización remota de datos. Por consiguiente, no se realizaron pruebas de calibración formales de los sensores biomédicos ni estudios comparativos con dispositivos médicos certificados. La ausencia de estas validaciones responde a que el proyecto se concibió como una prueba de concepto orientada a sentar las bases tecnológicas para un futuro sistema de monitoreo clínico. En etapas posteriores, se requeriría una calibración metrológica rigurosa, así como ensayos clínicos que comparen las lecturas del dispositivo con equipos de referencia, con el fin de determinar su precisión, sensibilidad y especificidad en entornos reales.

De manera similar, no se efectuaron pruebas con usuarios o pacientes que permitieran evaluar la usabilidad, comodidad y confiabilidad del sistema en condiciones de uso prolongado. La etapa actual se limitó a validar el correcto funcionamiento de los módulos electrónicos y la coherencia de las señales adquiridas. Esta decisión metodológica se justifica por el carácter exploratorio del trabajo, cuyo objetivo primordial fue demostrar la viabilidad técnica de integrar múltiples sensores, gestionar la conectividad inalámbrica y garantizar la persistencia de los datos mediante almacenamiento dual (SD y nube).

A pesar de las limitaciones mencionadas, el sistema desarrollado constituye un avance significativo en la implementación de plataformas de monitoreo fisiológico de bajo costo y código abierto. Con logros tales como:

Diseñar y fabricar una placa de circuito impreso que integra de manera compacta un SoC ESP32-C3, sensores MAX30102 (PPG) y BMI323 (IMU), interfaz para módulo EEG externo vía Bluetooth, circuito de gestión de batería, y ranura para tarjeta microSD.

Implementar un firmware multitarea no bloqueante capaz de adquirir señales a frecuencias de 100 Hz (PPG), 20 Hz (IMU) y 100 Hz (EEG), procesarlas en tiempo real, almacenarlas localmente cada 5 segundos y transmitir las a Firebase cada 30 segundos, optimizando el consumo energético y los recursos de cómputo.

Demostrar la aplicación de conceptos de Internet de las Cosas (IoT) en el ámbito biomédico, mediante la sincronización de datos en la nube (Firebase Realtime Database) y su visualización en un Dashboard Web. Esta arquitectura permite el acceso remoto a las variables fisiológicas desde cualquier dispositivo con navegador, sentando las bases para futuras aplicaciones de telemedicina.

Los cálculos de capacidad de almacenamiento presentados evidencian que la tarjeta microSD de 16 GB puede albergar más de ocho años de datos continuos, mientras que el plan gratuito de Firebase permite acumular cerca de dos años de registros. Estas cifras confirman la idoneidad de las soluciones de almacenamiento seleccionadas para escenarios de monitoreo prolongado, sin requerir mantenimiento frecuente ni incurrir en costos adicionales durante la fase de validación.

En cuanto al procesamiento de señales, se implementó un filtro IIR de primer orden (filtro exponencial) sobre los valores calculados de frecuencia cardíaca y saturación de oxígeno,

con un factor de suavizado $\alpha = 0.2$. Este filtro, aunque no actúa sobre la forma de onda cruda, cumple la función de estabilizar las lecturas mostradas al usuario, reduciendo fluctuaciones abruptas y mejorando la experiencia visual. La decisión de no aplicar filtrado digital a las señales crudas respondió a la necesidad de mantener la fidelidad de estas para futuros algoritmos de procesamiento más avanzados, y a que el hardware del sensor MAX30105 ya incorpora cierto acondicionamiento analógico.

La detección de movimientos bruscos mediante el IMU, con un umbral de 20 m/s^2 , demostró ser efectiva para activar alertas que quedan registradas en la tarjeta SD. Sin embargo, en el envío a Firebase solo se incluye el campo `IMU_high_movement` como parte de las muestras periódicas, no como una alarma independiente. Esta decisión de diseño priorizó la simplicidad del modelo de datos en la nube, dejando el registro detallado de eventos para el almacenamiento local.

En síntesis, el sistema desarrollado cumple con los objetivos planteados al inicio del proyecto, demostrando la viabilidad de construir un dispositivo de monitoreo fisiológico multiparámetro con conectividad IoT y almacenamiento redundante, y establece una base sólida para futuras investigaciones orientadas a su validación clínica y eventual transferencia tecnológica.

Conclusiones

El desarrollo del presente proyecto permitió materializar un prototipo electrónico portátil orientado al monitoreo biomédico multimodal, integrando la adquisición de señales EEG, PPG y acelerométricas en un sistema compacto con capacidades IoT. El objetivo general planteado al inicio se cumplió satisfactoriamente, al diseñar, implementar y validar funcionalmente un dispositivo capaz de capturar parámetros fisiológicos relevantes, procesarlos en tiempo real y almacenarlos tanto localmente como en la nube. Este logro representa un avance significativo en la construcción de herramientas tecnológicas accesibles para el estudio preliminar de patrones fisiológicos asociados a crisis epilépticas, consolidando una base sólida para futuros desarrollos orientados a la investigación biomédica.

Desde el punto de vista técnico, el hardware desarrollado integró exitosamente un SoC, protección y carga de batería, conversión de voltajes, antena para comunicaciones, interfaz para microSD, sensor inercial y la conexión externa para el módulo PPG. Las pruebas experimentales validaron el desempeño eléctrico y funcional de cada subsistema, así como la estabilidad de la plataforma completa durante la adquisición continua de señales fisiológicas. El firmware desarrollado permitió coordinar múltiples tareas en tiempo real mediante una arquitectura no bloqueante, asegurando la correcta sincronización entre la captura de datos, el procesamiento digital, el almacenamiento local y la transmisión inalámbrica. Adicionalmente, la integración con Firebase Realtime Database y el dashboard web implementado validaron la capacidad del sistema para operar de manera remota, consumiendo recursos mínimos y ofreciendo una visualización estructurada y accesible de los datos fisiológicos.

A pesar de los resultados obtenidos, el proyecto presenta limitaciones propias de una primera etapa de diseño. No se realizaron procesos de calibración clínica de los sensores

biomédicos, por lo que las mediciones generadas no deben interpretarse como valores de referencia médica. Tampoco se llevaron a cabo pruebas con usuarios o estudios comparativos con equipos certificados, aspectos necesarios para determinar el desempeño real del sistema en condiciones fisiológicas diversas. Asimismo, la señal EEG obtenida corresponde a datos ya procesados por el módulo externo, lo que limita la posibilidad de aplicar técnicas avanzadas de análisis sobre la señal cruda. Estas limitaciones no afectan la validez del prototipo como prueba de concepto, pero sí delimitan su alcance como herramienta biomédica preliminar.

Finalmente, los resultados y aprendizajes derivados del proyecto abren múltiples líneas de mejora y expansión. Entre ellas destacan la incorporación de un sistema EEG con acceso a señal cruda, la optimización del consumo energético mediante modos de bajo consumo, la miniaturización del hardware, la integración del sensor PPG directamente en la tarjeta principal, y el desarrollo de algoritmos más avanzados para el análisis de señales fisiológicas. De igual manera, la realización de pruebas con voluntarios, la evaluación de usabilidad y la exploración de técnicas de inteligencia artificial para detección temprana de eventos fisiológicos representan oportunidades de evolución del sistema hacia aplicaciones más robustas y potencialmente clínicas. En conjunto, este proyecto sienta una base sólida para la construcción de un futuro equipo biomédico portátil, demostrando que el diseño del hardware realizado es funcional, escalable y técnicamente viable como plataforma inicial de investigación.

Recomendaciones

A partir de los resultados obtenidos y las limitaciones identificadas, se proponen las siguientes líneas de trabajo futuro.

Realizar estudios comparativos con dispositivos médicos certificados para determinar la precisión de las mediciones de frecuencia cardíaca, SpO₂ y potencias EEG. Esto implicaría el uso de simuladores de señales y pruebas con voluntarios sanos bajo protocolos éticos aprobados, con el fin de establecer la correlación y exactitud del sistema desarrollado.

Implementar modos de suspensión profunda (Deep Sleep) en el ESP32-C3 durante periodos de inactividad, así como evaluar el uso de nuevas tecnologías de comunicación de baja potencia o incluso migrar a un microcontrolador de ultra bajo consumo que permita reducir aún más la demanda energética. Estas medidas contribuirían a mejorar la autonomía de la batería y a minimizar el hardware asociado.

El módulo EEG empleado en el prototipo actual entrega datos ya procesados (potencias por banda), lo que limita la posibilidad de aplicar técnicas de filtrado y análisis personalizados sobre la señal cruda. Como mejora, se propone diseñar o adquirir un sistema EEG que proporcione acceso a las señales sin procesar, permitiendo implementar algoritmos de detección de artefactos, eliminación de ruido y extracción de características más avanzadas.

El sensor actual requiere colocación en el dedo, lo que puede resultar incómodo para un uso prolongado. Se sugiere explorar sensores PPG óptimos para medición en la muñeca, que permitan integrar el dispositivo en una pulsera o reloj inteligente, mejorando la comodidad del paciente y facilitando el monitoreo continuo sin accesorios adicionales.

Revisar y refinar el código embebido para mejorar la eficiencia en el procesamiento de señales, reducir la latencia en la detección de eventos y garantizar una mayor estabilidad en la

comunicación con los periféricos. Esto incluye la posibilidad de incorporar filtros digitales más avanzados sobre las señales crudas PPG y EEG, así como algoritmos de detección de artefactos y evaluación de la calidad de la señal.

Complementar el Dashboard Web con una aplicación nativa para dispositivos móviles que facilite el monitoreo en tiempo real, la visualización de históricos y la configuración del dispositivo, aprovechando las capacidades de notificaciones y conectividad de los teléfonos inteligentes.

Realizar pruebas con usuarios finales (personal de salud, pacientes) para evaluar la ergonomía, facilidad de uso y aceptación del sistema en entornos reales, recopilando retroalimentación que permita ajustar el diseño tanto a nivel de hardware como de interfaz.

Estas mejoras, en conjunto, permitirían evolucionar el prototipo actual hacia un sistema más robusto, preciso y cercano a un producto para monitoreo de señales biomédicas e integración IoT, con potencial aplicación en telemedicina y monitoreo ambulatorio.

Referencias Bibliográficas

- Abdulmalek, S., Nasir, A., Jabbar, W. A., Almuahaya, M. A. M., Bairagi, A. K., Khan, M. A.-M., Kee, S.-H., & Chen, T. (2022). IoT-based healthcare monitoring system towards improving quality of life: A review. *Healthcare*, *10*(10), 1993.
<https://doi.org/10.3390/healthcare10101993>
- Advanced Wireless Health. (2024). *2.4G/5GHz Dual band embedded antenna ADWH004 Datasheet*. <https://www.aboosty.com/product/adwh004-2-4g-5g-wifi-bluetooth-smd-antenna/>
- Agali, K., Masrom, M., Abdul Rahim, F., & Yahya, Y. (2024). IoT-based remote monitoring system: A new era for patient engagement. *Healthcare technology letters*, *11*(6), 437–446. <https://doi.org/10.1049/HTL2.12089>
- Allen, J. (2007). Photoplethysmography and its application in clinical physiological measurement. *Physiological measurement*, *28*(3). <https://doi.org/10.1088/0967-3334/28/3/R01>
- Amazon Web Services. (2026). *Amazon DynamoDB Developer Guide*. AWS Documentation.
<https://docs.aws.amazon.com/dynamodb>
- Analog Devices. (2015). *Accelerometer and gyroscopes sensors: operation, sensing, and applications*. <https://www.analog.com/en/resources/technical-articles/accelerometer-and-gyroscopes-sensors-operation-sensing-and-applications.html>
- Bayborodin, P. (2023, marzo 8). *Why use ESP32 + Blynk IoT platform for your connected product*. <https://www.blynk.io/blog/esp32-blynk-iot-platform-for-your-connected-product>
- Beghi, E. (2020). The epidemiology of epilepsy. *Neuroepidemiology*, *54*(2), 185–191.
<https://doi.org/10.1159/000503831>

- Beniczky, S., & Ryvlin, P. (2018). Standards for testing and clinical validation of seizure detection devices. *Epilepsia*, *59 Suppl 1*, 9–13. <https://doi.org/10.1111/epi.14049>
- Bosch Sensortec. (2023). *BMI323: Shuttle Board 3.0 Flyer (Document number: BST-BMI323-DS000-11)*. <https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bmi323-ds000.pdf>
- Brinkmann, B. H., Karoly, P. J., Nurse, E. S., Dumanis, S. B., Nasser, M., Viana, P. F., Schulze-Bonhage, A., Freestone, D. R., Worrell, G., Richardson, M. P., & Cook, M. J. (2021). Seizure diaries and forecasting with wearables: epilepsy monitoring outside the clinic. *Frontiers in neurology*, *12*. <https://doi.org/10.3389/fneur.2021.690404>
- Buxi, D., Redouté, J. M., & Yuce, M. R. (2015). A survey on signals and systems in ambulatory blood pressure monitoring using pulse transit time. *Physiological measurement*, *36*(3), R1–R26. <https://doi.org/10.1088/0967-3334/36/3/R1>
- Charlton, P. H., Allen, J., Bailón, R., Baker, S., Behar, J. A., Chen, F., Clifford, G. D., Clifton, D. A., Davies, H. J., Ding, C., Ding, X., Dunn, J., Elgendi, M., Ferdoushi, M., Franklin, D., Gil, E., Hassan, M. F., Hernesniemi, J., Hu, X., ... Zhu, T. (2023). The 2023 wearable photoplethysmography roadmap. *Physiological Measurement*, *44*(11), 111001. <https://doi.org/10.1088/1361-6579/acead2>
- Claggett, M., Brinkmann, B. H., & Karoly, P. J. (2024). The present and future of seizure detection, prediction, and forecasting with machine learning, including the future impact on clinical trials. *Frontiers in Neurology*, *15*, 1425490. <https://doi.org/10.3389/fneur.2024.1425490>
- Cook, M. J., Karoly, P. J., Freestone, D. R., Himes, D., Leyde, K., Berkovic, S., O'Brien, T., Grayden, D. B., & Boston, R. (2015). Human focal seizures are characterized by

populations of fixed duration and interval. *Epilepsia*, 57(3), 359–368.

<https://doi.org/10.1111/epi.13291>

Davidashvilly, S., Cardei, M., Hssayeni, M., Chi, C., & Ghoraani, B. (2024). Deep neural networks for wearable sensor-based activity recognition in Parkinson's disease: investigating generalizability and model complexity. *BioMedical Engineering OnLine* 2024 23:1, 23(1), 17-. <https://doi.org/10.1186/S12938-024-01214-2>

Devdepth. (2025, junio 28). *MongoDB Atlas Review: Complete Developer Guide*.

<https://devdepth.dev/tools/databases/mongodb-atlas>

DuploCloud. (2023, febrero 23). *70% of healthcare businesses have adopted cloud computing: DuploCloud report*. <https://www.globenewswire.com/news-release/2023/02/22/2613339/0/en/70-of-Healthcare-Businesses-Have-Adopted-Cloud-Computing-DuploCloud-Report.html>

Elger, C. E., & Hoppe, C. (2018). Diagnostic challenges in epilepsy: seizure under-reporting and seizure detection. *The Lancet Neurology*, 17(3), 279–288. [https://doi.org/10.1016/S1474-4422\(18\)30038-3](https://doi.org/10.1016/S1474-4422(18)30038-3)

ESPBoards. (2026). *ESP32 C3 Super Mini*. <https://www.espboards.dev/esp32/esp32-c3-super-mini/>

Globenewswire. (2023, febrero 10). *Wearable medical devices global market report 2023*. <https://www.globenewswire.com/news-release/2023/02/10/2606040/0/en/Wearable-Medical-Devices-Global-Market-Report-2023.html>

Google Cloud. (2024). *Arquitectura de producto de la plataforma de IoT en Google Cloud*. <https://docs.cloud.google.com/architecture/connected-devices/iot-platform-product-architecture?hl=es>

Google. (2026). *Firestore Documentation*. Google Cloud. <https://firebase.google.com/docs>

Grand View Research. (2025). *Wearable medical devices market size (2025-2030)*.

<https://www.grandviewresearch.com/industry-analysis/wearable-medical-devices-market>

Hirtz, D., Ashwal, S., Berg, A., Bettis, D., Camfield, C., Camfield, P., Crumrine, P., Elterman, R., Schneider, S., & Shinnar, S. (2000). Practice parameter: evaluating a first nonfebrile seizure in children: report of the quality standards subcommittee of the American Academy of Neurology, The Child Neurology Society, and The American Epilepsy Society. *Neurology*, 55(5), 616–623. <https://doi.org/10.1212/WNL.55.5.616>

Ingolfsson, T. M., Wang, X., Chakraborty, U., Benatti, S., Bernini, A., Ducouret, P., Ryvlin, P., Beniczky, S., Benini, L., & Cossettini, A. (2024). BrainFuseNet: Enhancing Wearable Seizure Detection Through EEG-PPG-Accelerometer Sensor Fusion and Efficient Edge Deployment. *IEEE Transactions on Biomedical Circuits and Systems*, 18(4), 720–733. <https://doi.org/10.1109/TBCAS.2024.3395534>

Jhuma, F. A., Harada, K., Misran, M. A. Bin, Mo, H. W., Fujimoto, H., & Hattori, R. (2024). A hybrid Photoplethysmography (PPG) sensor system design for heart rate monitoring. *Sensors (Basel, Switzerland)*, 24(23), 7634. <https://doi.org/10.3390/S24237634>

Johansson, D., Malmgren, K., & Alt Murphy, M. (2018). Wearable sensors for clinical applications in epilepsy, Parkinson’s disease, and stroke: a mixed-methods systematic review. *Journal of Neurology*, 265(8), 1740. <https://doi.org/10.1007/S00415-018-8786-Y>

Joshi, M., Iqbal, F. M., Sharabiani, M., Ashrafian, H., Arora, S., McAndrew, K., Khan, S., Cooke, G., & Darzi, A. (2025). Performance of Continuous Digital Monitoring of Vital Signs with a Wearable Sensor in Acute Hospital Settings. *Sensors 2025, Vol. 25*, 25(9). <https://doi.org/10.3390/s25092644>

- Joyner, M., Hsu, S. H., Martin, S., Dwyer, J., Chen, D. F., Sameni, R., Waters, S. H., Borodin, K., Clifford, G. D., Levey, A. I., Hixson, J., Winkel, D., & Berent, J. (2024). Using a standalone ear-EEG device for focal-onset seizure detection. *Bioelectronic Medicine*, *10*(1), 4. <https://doi.org/10.1186/S42234-023-00135-0>
- Kim, K. B., & Baek, H. J. (2023). Photoplethysmography in wearable devices: a comprehensive review of technological advances, current challenges, and future directions. *Electronics* *2023*, Vol. 12, *12*(13). <https://doi.org/10.3390/electronics12132923>
- Kurul, F., Aydoğan, D., Janat, S., Aydın Kırılıngıç, I., Kaya, H. O., & Topkaya, S. N. (2026). Wearable sensors for health monitoring: Current applications, trends, and future directions. *Biosensors and Bioelectronics: X*, *28*, 100727. <https://doi.org/10.1016/J.BIOSX.2025.100727>
- Lee, R. J., Sivakumar, S., & Lim, K. H. (2023). Review on remote heart rate measurements using photoplethysmography. *Multimedia Tools and Applications* *2023* *83:15*, *83*(15), 44699–44728. <https://doi.org/10.1007/s11042-023-16794-9>
- Li, S., Liu, L., Wu, J., Tang, B., & Li, D. (2018). Comparison and noise suppression of the transmitted and reflected photoplethysmography signals. *BioMed Research International*, *2018*, 4523593. <https://doi.org/10.1155/2018/4523593>
- Maganti, R. K., & Rutecki, P. (2013). EEG and epilepsy monitoring. *Continuum: Lifelong Learning in Neurology*, *19*(3 Epilepsy), 598. <https://doi.org/10.1212/01.CON.0000431378.51935.d8>
- Mansergas Fernández, I. (2021). *Portable low-power system for continuous monitorization of the cardiovascular system* [Universitat Politècnica de Catalunya]. <https://hdl.handle.net/2117/356168>

- MarketsandMarkets. (2025, agosto). *Wearable healthcare devices market: growth, size, share, and trends*. <https://www.marketsandmarkets.com/Market-Reports/wearable-medical-device-market-81753973.html>
- Martínez Duque, E. (2024). *Sistema de acondicionamiento y filtrado de señales fotopletismográficas implementando metodologías de aprendizaje de máquina*. <https://hdl.handle.net/11059/15284>
- MathWorks. (s/f). *ThingSpeak for IoT Projects*. Recuperado el 7 de abril de 2026, de <https://www.mathworks.com/products/thingspeak.html>
- Maxim Integrated. (2018). *MAX30102: High-Sensitivity Pulse Oximeter and Heart-Rate Sensor for Wearable Health [Hoja de datos]*. 2018. <https://www.analog.com/media/en/technical-documentation/data-sheets/max30102.pdf>
- MedlinePlus. (2025). *Electroencefalograma*. <https://medlineplus.gov/spanish/ency/article/003931.htm>
- Microsoft. (s/f). *Azure IoT Hub: Comunicación bidireccional para miles de millones de dispositivos IoT*. Recuperado el 7 de abril de 2026, de <https://azure.microsoft.com/es-es/products/iot-hub/>
- Moeve Global. (2025). *¿Qué es la tecnología wearable? Usos y beneficios*. <https://www.moeveglobal.com/es/planet-energy/innovacion-sostenible/tecnologia-wearable-que-es>
- Mohammed, Z., Elfadel, I. (Abe) M., & Rasras, M. (2018). Monolithic multi Degree of Freedom (MDoF) capacitive MEMS accelerometers. *Micromachines* 2018, Vol. 9, 9(11). <https://doi.org/10.3390/MI9110602>

Molina Rivera, E. A. (2019). *Detector multimodal de crisis epilépticas motoras y no motoras para dispositivos wearable Basado en actividad electrodermal, acelerometría y fotopleletismografía* [Universidad del Cauca].

<https://repositorio.unicauca.edu.co/xmlui/handle/123456789/8506>

MongoDB. (2026). *MongoDB Atlas Cloud Database*. MongoDB Documentation.

<https://www.mongodb.com/docs/atlas>

Murugappan, M., & Yuvaraj, R. (2022). Biomedical signals based computer-aided diagnosis for neurological disorders. En *Biomedical Signals Based Computer-Aided Diagnosis for Neurological Disorders*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-97845-7>

Naseer, N., Khan, M. J., Sajid, H., & Tanveer, M. A. (2019). Neonatal seizure detection using deep convolutional neural networks. *International Journal of Neural Systems*, 29(04), 1850011. <https://doi.org/10.1142/S0129065718500119>

Organización Mundial de la Salud [OMS]. (2024, febrero 7). *Epilepsia*.

<https://www.who.int/es/news-room/fact-sheets/detail/epilepsy>

Ortiz, B., & Lanau, S. (2021). Neuromonitoreo no invasivo en unidad de cuidados intensivos en Colombia. *Biomedica*, 41(4), 1–19. <https://doi.org/10.7705/biomedica.5990>

Park, J., Seok, H. S., Kim, S. S., & Shin, H. (2022). Photoplethysmogram analysis and applications: an integrative review. *Frontiers in Physiology*, 12, 808451.

<https://doi.org/10.3389/fphys.2021.808451>

Ranjan, S., Baria, D., & Reddy, Y. C. (2025). Systematic review: wearable technology for cardiac rhythm monitoring. *Journal of Heart Valve Disease*, 30, 71–77. <https://icr->

[heart.com/article/systematic-review-wearable-technology-for-cardiac-rhythm-monitoring-2336/](https://www.heart.com/article/systematic-review-wearable-technology-for-cardiac-rhythm-monitoring-2336/)

- Rashid, Z., Choudhury, A. R., Folarin, A. A., Ranjan, Y., Conde, P., Sansekara, H., Bruno, E., & Dobson, R. J. B. (2024). Remote monitoring of epilepsy patients with wearable device and smartphone. *UbiComp Companion 2024 - Companion of the 2024 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, 24, 96–100. <https://dl.acm.org/doi/10.1145/3675094.3677592>
- Reijmers, N., van Kootwijk, A., & de Waal, E. E. C. (2025). Accuracy of vital sign monitoring using a photoplethysmography upper arm wearable device in postoperative non-cardiac surgery patients: a prospective observational clinical validation study. *Journal of Clinical Monitoring and Computing* 2025, 1–9. <https://doi.org/10.1007/s10877-025-01358-z>
- Reséndiz-Aparicio, J. C., Pérez-García, J. C., Olivas-Peña, E., García-Cuevas, E., Roque-Villavicencio, Y. L., Hernández-Hernández, M., Castro-Macías, J. I., Rayo-Mares, J. D., Reséndiz-Aparicio, J. C., Pérez-García, J. C., Olivas-Peña, E., García-Cuevas, E., Roque-Villavicencio, Y. L., Hernández-Hernández, M., Castro-Macías, J. I., & Rayo-Mares, J. D. (2019). Guía clínica. Definición y clasificación de la epilepsia. *Revista mexicana de neurociencia*, 20(2), 7–12. <https://doi.org/10.24875/RMN.M19000052>
- Reyes, R. M., ORCID, & 0009-0007-2663-0325. (2025). *Dispositivo portátil basado en internet de las cosas médicas para análisis de la variabilidad de frecuencia cardíaca*. <https://ri-ng.uaq.mx/handle/123456789/11913>
- Rojas, A. N., & Mosquera, F. C. (2024). Advances and challenges associated with low-cost pulse oximeters in home care programs: a review. *Sensors* 2024, Vol. 24, 24(19). <https://doi.org/10.3390/S24196284>

- Safavi, S. M., Valisharifabad, N., Sabino, R. C., Tran, D., Lin, J., Lopour, B., & Chou, P. H. (2020). Investigation of morphological variations of photoplethysmography signal in human epilepsy. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2020-July*, 2687–2690.
<https://doi.org/10.1109/EMBC44109.2020.9175400>
- Safavi, S. M., Valisharifabad, N., Sabino, R., Chen, H., HeydariGorji, A., Tran, D., Lin, J., Lopour, B., & Chou, P. H. (2019). Analysis of cardiovascular changes caused by epileptic seizures in human photoplethysmogram signal. *arXiv e-prints, arXiv-1912*.
<https://arxiv.org/pdf/1912.05083>
- Sarma, J., Katiyar, A., Biswas, R., & Mondal, H. K. (2019). Power-aware IoT based smart health monitoring using wireless body area network. *Proceedings - International Symposium on Quality Electronic Design, ISQED, 2019-March*, 117–122.
<https://doi.org/10.1109/ISQED.2019.8697739>
- Scheffer, I. E., Berkovic, S., Capovilla, G., Connolly, M. B., French, J., Guilhoto, L., Hirsch, E., Jain, S., Mathern, G. W., Moshé, S. L., Nordli, D. R., Perucca, E., Tomson, T., Wiebe, S., Zhang, Y. H., & Zuberi, S. M. (2017). ILAE classification of the epilepsies: Position paper of the ILAE Commission for Classification and Terminology. *Epilepsia*, 58(4), 512–521. <https://onlinelibrary.wiley.com/doi/10.1111/epi.13709>
- Schuhmacher, L., Pollin, S., & Sallouha, H. (2023). *EcoBLE: a low-computation energy consumption prediction framework for bluetooth low energy*.
<https://doi.org/10.48804/XVOUAH>
- Serrano, L. P., Maita, K. C., Avila, F. R., Torres-Guzman, R. A., Garcia, J. P., Eldaly, A. S., Haider, C. R., Felton, C. L., Paulson, M. R., Maniaci, M. J., & Forte, A. J. (2023).

Benefits and Challenges of Remote Patient Monitoring as Perceived by Health Care Practitioners: A Systematic Review. *The Permanente Journal*, 27(4).

<https://doi.org/10.7812/TPP/23.022>

Shah, D. T., Patel, A., Budhrani, A., & Patel, K. (2022). Recent advancements of Internet of Medical Things (IoMT): challenges and future opportunities with emerging technologies. *International Conference on Automation, Computing and Renewable Systems, ICACRS 2022 - Proceedings*, 278–283. <https://doi.org/10.1109/ICACRS55517.2022.10029214>

Shukla, S., Hassan, M. F., Khan, M. K., Jung, L. T., & Awang, A. (2019). An analytical model to minimize the latency in healthcare internet-of-things in fog computing environment. *PLoS one*, 14(11). <https://doi.org/10.1371/JOURNAL.PONE.0224934>

Sinthia, P., Malathi, M., Kanchana, K., Anoop, K. J., & Kavitha, S. (2026). Low-cost portable pulse oximeter using arduino for accessible health monitoring and remote applications. *Lecture Notes in Networks and Systems, 1452 LNNS*, 389–398.

https://doi.org/10.1007/978-981-96-7292-9_32

Szermer, M., Zając, P., Amrozik, P., Maj, C., Jankowski, M., Jabłoński, G., Kiełbik, R., Nazdrowicz, J., Napieralska, M., & Sakowicz, B. (2021). A capacitive 3-axis MEMS accelerometer for Medipost: a portable system dedicated to monitoring imbalance disorders. *Sensors 2021, Vol. 21, 21*(10). <https://doi.org/10.3390/S21103564>

Tan, Z., Wang, L., & Liu, Y. (2024). A novel SE-TCN-BiGRU hybrid network for automatic seizure detection. *IEEE Access*, 12, 54001-54012.

<https://ieeexplore.ieee.org/document/10540601>

- Tesema, W., Jimma, W., Khan, M. I., Stiens, J., & da Silva, B. (2024). A taxonomy of low-power techniques in wearable medical devices for healthcare applications. *Electronics* 2024, Vol. 13, 13(15). <https://doi.org/10.3390/ELECTRONICS13153097>
- Thomas, V. J., & Anto Sahaya Dhas, D. (2021). *Recent trends in epileptic seizure detection using EEG signal: a review*. 507–525. https://doi.org/10.1007/978-981-33-6862-0_41
- U.S. Food and Drug Administration. (2023). *Artificial intelligence and machine learning (AI/ML)-enabled medical devices*. U.S. Food and Drug Administration. <https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-aiml-enabled-medical-devices>
- Ubidots. (s/f). *Advice and answers from the Ubidots Team*. Recuperado el 7 de abril de 2026, de <https://help.ubidots.com/en/>
- Vaghasiya, R., Rylvlin, P., & Beniczky, S. (2023). Non-electroencephalogram-based seizure detection devices: State of the art and future perspectives. *Current Opinion in Neurology*, 36(2), 101-107. <https://pubmed.ncbi.nlm.nih.gov/37857030/>
- Venema, B., Blanik, N., Blazek, V., Gehring, H., Opp, A., & Leonhardt, S. (2012). Advances in reflective oxygen saturation monitoring with a novel in-ear sensor system: results of a human hypoxia study. *IEEE transactions on bio-medical engineering*, 59(7), 2003–2010. <https://doi.org/10.1109/TBME.2012.2196276>
- Verma, D., Singh, K. R., Yadav, A. K., Nayak, V., Singh, J., Solanki, P. R., & Singh, R. P. (2022). Internet of things (IoT) in nano-integrated wearable biosensor devices for healthcare applications. *Biosensors and Bioelectronics: X*, 11(10), 100153. <https://doi.org/10.1016/j.biosx.2022.100153>

- Wilkerson, R. G., Annous, Y., Farhy, E., Hurst, J., & Smedley, A. D. (2023). Home pulse oximetry monitoring during the COVID-19 pandemic: An assessment of patient engagement and compliance. *Health Policy and Technology*, 12(3).
<https://doi.org/10.1016/j.hlpt.2023.100776>
- World Health Organization. (2021). *Epilepsy: A public health imperative*. World Health Organization. <https://www.who.int/news-room/fact-sheets/detail/epilepsy>
- Xu, K., Qian, W., Xu, W., Yang, W., Yang, Y., Song, Y., Li, Y., Yuan, Z., Zhang, S., Zhao, F., Wei, W., & He, W. (2026). Global, regional, and national epidemiology of childhood epilepsy from 1990 to 2021: a systematic study based on the GBD 2021. *Seizure*, 131, 351–360. <https://doi.org/10.1016/j.seizure.2025.08.001>
- Zambrana-Vinaroz, D., Vicente-Samper, J. M., Manrique-Cordoba, J., & Sabater-Navarro, J. M. (2022). Wearable Epileptic Seizure Prediction System Based on Machine Learning Techniques Using ECG, PPG and EEG Signals. *Sensors 2022, Vol. 22, Page 9372*, 22(23), 9372. <https://doi.org/10.3390/S22239372>
- Zhao, X., Wang, Y., & Wen, D. (2019). Fabrication and characteristics of a SOI three-axis acceleration sensor based on MEMS technology. *Micromachines 2019, Vol. 10, 10(4)*.
<https://doi.org/10.3390/MI10040238>
- Zuberi, S. M., & Symonds, J. D. (2015). Update on diagnosis and management of childhood epilepsies. *Journal de Pediatria*. doi: <https://doi.org/10.1016/j.jpmed.2015.07.003>

Apéndices


Apéndice A

Distribución Pines del SoC ESP32-C3

Se presenta la distribución física de los pines del SoC ESP32-C3.

Figura A1

Distribución Física de los Pines del SoC ESP32-C3



Nota. Tomado de *ESP32-C3 Series Datasheet* (p. 14), por Espressif Systems, 2025,

https://documentation.espressif.com/esp32-c3_datasheet_en.pdf

Apéndice C

Característica de Pines del Bus I2C para el MAX30102

Se destaca una de las características fundamentales del MAX30102: Aunque su etapa digital opera a 1.8 VDC, es capaz de comunicarse mediante el bus I2C a 3.3 VDC gracias a que sus líneas SDA y SCL utilizan una arquitectura interna de drenador abierto, lo que permite niveles lógicos más altos cuando se emplean resistencias de *Pull-up* externas.

Figura C1

Esquemático de la Tarjeta de Desarrollo ESP32-C3

Pin Description

PIN	NAME	FUNCTION
1, 7, 8, 14	N.C.	No Connection. Connect to PCB pad for mechanical stability.
2	SCL	I2C Clock Input
3	SDA	I2C Data, Bidirectional (Open-Drain)
4	PGND	Power Ground of the LED Driver Blocks
5	R_DRV	Red LED Driver.
6	IR_DRV	IR LED Driver.
9	V _{LED+}	LED Power Supply (anode connection). Use a bypass capacitor to PGND for best performance.
10	V _{LED+}	
11	V _{DD}	Analog Power Supply Input. Use a bypass capacitor to GND for best performance.
12	GND	Analog Ground
13	$\overline{\text{INT}}$	Active-Low Interrupt (Open-Drain). Connect to an external voltage with a pullup resistor.

Nota. Tomado de *MAX30102 High-Sensitivity Pulse Oximeter and Heart-Rate Sensor for Wearable Health Datasheet* (p. 8), por Maxim Integrated, 2018,

<https://www.analog.com/media/en/technical-documentation/data-sheets/MAX30102.pdf>

Apéndice D

Hojas de Datos de Componentes Preliminares

A continuación, se muestra un listado de los componentes más relevantes del diseño electrónico con enlaces a sus hojas de datos.

Tabla D1

Fuentes de Documentación Técnica y Especificaciones de los Componentes Principales del Hardware

Componente	Función	Fabricante/ Fuente	Enlace
ESP32-C3	Microcontrolador	Espressif	https://documentation.espressif.com/esp32-c3_datasheet_en.pdf
MAX30102	Sensor PPG	Maxim Integrated (actualmente Analog Devices)	https://www.analog.com/media/en/technical-documentation/data-sheets/MAX30102.pdf
Taurus TGAM EEG (Basado en TGAM de NeuroSky)	EEG potencias	Sichiray	https://sichiray-tech.yuque.com/dm0eyv/chanpin/xqmr73yqf5rcgbfz
BMI323	IMU	Bosch	https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bmi323-ds000.pdf
TP4057	Cargador batería Litio	UMW	https://www.umwic.com/static/pdf/a62b0c86d7543da6d2ba82f8104549b0.pdf
TPS613222	DC-DC Boost 5V	Texas Instruments	https://www.ti.com/lit/ds/symlink/tps61322.pdf?HQS=dis-dk-null-digikeymode-dsf-pf-null-ww&ts=1774155303627&ref_url=https%252A%252F%252Fwww.flux.ai%252F
RT9080-33GJ5	LDO 3.3V	Richtek	https://www.richtek.com/assets/product_file/RT9080/DS9080-09.pdf

Componente	Función	Fabricante/ Fuente	Enlace
TPS7A0218DBVR	LDO 1.8V	Texas Instruments	https://www.ti.com/lit/ds/symlink/tps7a02.pdf?ts=1647961719342&ref_url=https%253A%252F%252Fwww.ti.com%252Fstore%252Fti%252Fen%252Fproduct%252F%253Fp%253DTPS7A0233DQNR%2526keyMatch%253DTPS7A0233DQNR%2526tsearch%253Dsearch-everything%2526usecase%253D

Nota. Los enlaces proporcionados dirigen a las hojas de datos (*datasheets*) oficiales de cada fabricante para la consulta de parámetros eléctricos, diagramas de pines y protocolos de comunicación. Abreviaturas: PPG = Fotopletismografía; EEG = Electroencefalografía; IMU = Unidad de medición inercial; LDO = Regulador de baja caída de voltaje.

Apéndice E

Listado Tiempos del Sistema

A continuación, se presenta un listado estructurado que reúne los tiempos operativos del sistema, organizados por categorías específicas e incluyendo las condiciones bajo las cuales fueron obtenidos, así como notas de observación relevantes para su interpretación.

Tabla E1

Tiempos Operativos del Sistema

Componente / Proceso	Intervalo	Condición de ejecución	Control en firmware (variable/función)	Notas / Observaciones
SENSORES Y ADQUISICIÓN				
Muestreo PPG (MAX30102)	10 ms	Buffer no lleno (<100 muestras)	lastSensorSampleTime, SENSOR_SAMPLE_INTERVAL	Frecuencia efectiva: 100 Hz
Lectura IMU (BMI323)	50 ms	Siempre	lastIMURead, IMU_READ_INTERVAL	Frecuencia: 20 Hz
Procesamiento EEG	100 ms	Siempre	processEEG() (llamada desde tareas principales)	Depende del módulo externo Bluetooth
COMUNICACIONES				
Gestión WIFI (reconexión)	60 s (si desconectado)	WIFI perdido; tras 2 fallos espera 120 s	manageWiFiConnection(), wifiReconnectInterval, wifiRestDuration	Política de reconexión con backoff
Envío a Firebase	30 s	WIFI conectado, Firebase listo y al menos un dato válido*	lastSampleSent, sendToFirebase()	Los datos se envían solo si hay información válida según criterios
ALMACENAMIENTO				
Guardado en tarjeta SD	5 s	Tarjeta SD presente y detectable	lastSDWrite, SD_WRITE_INTERVAL	Se guardan datos en CSV y log legible

Componente / Proceso	Intervalo	Condición de ejecución	Control en firmware (variable/función)	Notas / Observaciones
Chequeo de inserción SD	100 ms	Siempre	checkSDCardStatus()	Detecta inserción/remoción en caliente
INTERFAZ DE USUARIO				
Actualización de LED	Continuo (cada loop)	Según eventos: envío Firebase, escritura SD, alarma SD	updateLEDStatus()	Modos: destello (100 ms), alarma SD (parpadeo 200 ms / 3 s, pausa 10 s)
Impresión resumen PPG	2 s	Siempre	lastPPGPrint, printPPGSummary()	Muestra estado del sensor PPG
Impresión resumen IMU	2 s	Siempre	lastIMUDisplay (en loop)	Muestra magnitud y puntuación de movimiento
Impresión resumen EEG	5 s	Siempre	lastEEGPrint (en loop)	Muestra calidad de señal y potencias por banda
Impresión encabezado hora	1 min	Siempre	printTimeHeader()	Muestra hora, uptime y estado de batería
SISTEMA Y RELOJ				
Mantenimiento del reloj	Continuo (cada loop)	Siempre	maintainSystemClock()	Agrupada actualización RTC, NTP y compensación
Actualización RTC desde millis()	1 s	Siempre	updateRTCFromMillis()	Mantiene el tiempo interno
Sincronización NTP	5 min	WiFi conectado	lastSyncAttempt (en maintainSystemClock)	Reintenta sincronizar con servidores NTP
Compensación de deriva RTC	1 h	Si hubo sincronización NTP previa	compensateRTCdrift()	Corrige deriva del reloj interno

Componente / Proceso	Intervalo	Condición de ejecución	Control en firmware (variable/función)	Notas / Observaciones
GESTIÓN DE ENERGÍA				
Actualización de batería	30 s	Siempre	lastBatteryUpdate (en loop)	Lee voltaje, calcula porcentaje y actualiza alarma
Alarma de batería baja	Continuo (cada loop)	Voltaje < umbral crítico	updateBatteryAlarm()	Activa patrón de 4 beeps (200 ms on/off) cada 5 s; solo afecta al buzzer (LED no participa)
CONDICIONES DE VALIDEZ DE DATOS				
HR / SpO ₂ para Firebase/SD	—	fingerDetected == true y beatAvg > 0 y spo2Avg > 0	—	Solo se incluyen si hay detección de dedo y valores positivos
IMU para Firebase/SD	—	movementScore > 5.0 o highMovementDetected == true	—	Se envían solo cuando hay movimiento significativo
EEG para Firebase/SD	—	eegDataValid == true y eegSignal < 50	—	Solo se incluye si la señal es buena (calidad > umbral)

Nota. La estructura del firmware utiliza temporizadores no bloqueantes para permitir la concurrencia de procesos. Se destacan los mecanismos de seguridad como la reconexión de Wi-Fi con política de espera (*backoff*) y los criterios de validez para el almacenamiento de datos, los cuales filtran el ruido antes de la persistencia en la tarjeta SD o el envío a Firebase. Unidades: ms, milisegundos; s, segundos; min, minutos; h, horas.

Apéndice F

Diseño Preliminar de la Carcasa

Para esta primera etapa del proyecto, el diseño de la carcasa no constituye un elemento central, ya que el objetivo principal fue el desarrollo y validación del hardware del prototipo. Sin embargo, se realizó un diseño preliminar utilizando el mismo software empleado para el esquemático y el PCB, con el fin de visualizar la disposición física básica del dispositivo.

Este modelo es únicamente conceptual y sirve como referencia general del volumen y la ubicación de los componentes. En una futura continuación del proyecto, será necesario desarrollar la carcasa en paralelo con el diseño del PCB, ya que la miniaturización del dispositivo y su ergonomía dependen directamente de esta integración mecánica y electrónica.

Figura F1

Vista 3D de la Carcasa Protectora



Nota. Prototipo virtual en 3D de la carcasa ergonómica, proyectada para el ensamblaje mecánico del dispositivo portable.