

**Cuidado Neonatal mediante Internet de las Cosas Médicas: Validación y Evaluación
de un Sistema de Monitoreo en Incubadoras**

VALERIA TABARES SANCHEZ

FISIOTERAPEUTA – TERAPEUTA OCUPACIONAL

MAESTRÍA EN INGENIERÍA BIOMÉDICA

**UNIVERSIDAD DEL ROSARIO Y ESCUELA COLOMBIANA DE INGENIEROS JULIO
GARAVITO**



TUTORES

Jefferson Sarmiento Rojas, Ing, Lic, Esp, MEng

Pedro Antonio Aya Parra, Ing, MEng

Agradecimientos

A la Universidad del Rosario, especialmente a la Escuela de Medicina y Ciencias de la Salud, por ofrecerme el espacio y las herramientas para crecer como investigadora y profesional comprometida con la innovación en salud.

Al Grupo de Investigación GIBIOME, por acogerme en un entorno donde la ciencia y la empatía pueden encontrarse.

A mis tutores, profesor Jefferson Sarmiento y profesor Pedro Aya, por su guía, confianza y constante disposición para abrirme caminos de aprendizaje, su acompañamiento ha sido esencial no solo en este proyecto, sino también en las oportunidades profesionales en las que me permitieron participar, crecer y transformarme a mí y a mi futuro.

A mis padres, por ser la base de mi vida y de cada una de las oportunidades que he tenido; su amor y apoyo incondicional me sostienen siempre, me han permitido soñar.

A mi novio y a mi mejor amiga, por ser mi refugio emocional, por su admiración sincera y por recordarme, en los días difíciles, lo mucho que vale este camino.

Finalmente, agradezco a todos los profesionales de la salud y a mi profesión que me permite unir la ciencia y la ternura, la virtud de transformar la tecnología en un acto de cuidado.

Tabla de contenido

Resumen	6
Palabras clave	6
Abstract	7
Keywords	7
Aportes 8	
1. Introducción	9
2. Objetivos.....	12
2.1. Objetivo general	12
2.2. Objetivos específicos	12
3. Problema y justificación.....	13
4. Marco teórico y estado del arte	17
4.1. Estado del arte	17
4.2. Marco teórico	24
Prematuro	24
Temperatura en neonatos	26
Humedad en neonatos	28
Procesamiento auditivo en neonatos	28
Procesamiento táctil en neonatos	29
Integración multisensorial.....	29
Machine learning	30
TinyML.....	31
Edge Impulse.....	32
Transfer Learning	33
5. Metodología.....	36
5.1. Diseño e implementación de la arquitectura IoT para la adquisición de variables ambientales	37
5.1.1. Arquitectura del dispositivo:	38
.....	38
5.2. Medición remota y gestión de la información del sistema IoT	39
5.3. Evaluación de la confiabilidad y eficiencia del sistema IoT	43
5.4. Entrenamiento e implementación del modelo de IA para el análisis acústico.....	43
5.4.1. Entrenamiento de la IA:.....	44
6. Resultados.....	48
6.1. Diseño e implementación de la arquitectura IoT para la adquisición de variables ambientales	48

6.2.	Medición remota y gestión de la información del sistema IoT	51
6.3.	Evaluación de la confiabilidad y eficiencia del sistema IoT	53
6.4.	Implementación y entrenamiento del modelo de IA para el análisis acústico	55
7.	Discusión	64
8.	Conclusiones	67
9.	Recomendaciones y trabajos futuros	69
10.	Anexos.....	70
	Anexo 1. Aval Comité de Ética.....	70
	Anexo 2. Certificado Tercer puesto en la categoría de Mejores Propuestas de Investigación en el VIII Encuentro CIMED – 2024	70
	Anexo 3. Notificación resultados presentación poster en el XII Congreso Panamericano de Neonatología 2024	71
	Anexo 4. Certificado de asistencia para el XIV Congreso Colombiano de Neurociencias y XV Seminario Internacional de Neurociencias COLNE 2025.	71
	Anexo 5. Notificación de aceptación del póster para el XIV Congreso Colombiano de Neurociencias y XV Seminario Internacional de Neurociencias COLNE 2025.	72
	Anexo 6. Base de Datos Central en la nube	72
	Bibliografía.....	73

Lista de figuras

Figura 1. Establecimiento de redes neuronales sensoriales	13
Figura 2. Propósitos desarrollo tecnología IoT en UCIN	21
Figura 3. Arquitectura del dispositivo.	38
Figura 4. Batería Utilizada en el dispositivo. Batería RCR123A	40
Figura 5. Sensor de sonido utilizado en el dispositivo de IoT	40
Figura 6. Sensor de temperatura y humedad utilizado en el dispositivo de IoT	41
Figura 7. Placa utilizada en dispositivo de IoT	42
Figura 8. Instrumento de recolección para el modelo de IA	44
Figura 9. Datos recolectados para el modelo de IA	45
Figura 10 Descarga de la batería en el dispositivo	49
Figura 11 Proceso de carga de la batería del dispositivo	51
Figura 12 Histograma de las variables de temperatura, humedad, sonido y batería	52
Figura 13 Distribución de las variables registradas por el sistema IoT.....	53
Figura 14 Línea temporal de las variables de temperatura, humedad, sonido y batería.	55
Figura 15 Entrenamiento del primer impulso	56
Figura 16. Matriz de confusión primer impulso	57
Figura 17 Desempeño del primer impulso	59
Figura 18 Entrenamiento del segundo impulso.....	61
Figura 19 Desempeño del segundo impulso post-entrenamiento con variables conocidas.....	63

Lista de tablas

Tabla 1. Reporte de literatura sobre IoT y UCIN.....	16
Tabla 2 Ruidos relevantes para el ambiente neonatal.....	22
Tabla 3 Reporte literatura IA y sonido en la UCIN	23
Tabla 4 Mediciones de corriente del dispositivo	50
Tabla 5. Metricas por clase matriz entrenamiento	58
Tabla 6. Metricas por clase matriz validación	60

Resumen

El nacimiento prematuro representa un desafío clínico y tecnológico significativo, dado que la interrupción del desarrollo intrauterino expone al neonato a condiciones ambientales radicalmente distintas, particularmente dentro de las Unidades de Cuidados Intensivos Neonatales (UCIN). En este entorno, variables como la temperatura, la humedad y el ruido influyen directamente en la estabilidad fisiológica y el neurodesarrollo del recién nacido. Ante esta problemática, la presente investigación tuvo como objetivo diseñar un sistema de monitoreo basado en Internet de las Cosas (IoT) para la gestión de variables relevantes en incubadoras neonatales, incorporando además herramientas de inteligencia artificial (IA) para el análisis de sonido. La metodología se estructuró en dos fases: la primera consistió en la implementación y evaluación del sistema IoT para la medición remota de temperatura, humedad, sonido y voltaje de batería; la segunda, en el entrenamiento de un modelo de IA capaz de clasificar fuentes acústicas relevantes mediante estrategias de Transfer Learning. Los resultados evidenciaron un desempeño estable del sistema, con una disponibilidad del 94,23 %, un tiempo medio entre fallos (MTBF) de 32 horas y un tiempo medio de recuperación (MTTR) de 118 minutos. La temperatura y la batería mostraron comportamientos estables, mientras que la humedad presentó variabilidad esperable y el sonido se consolidó como la variable más crítica, con la mayor frecuencia de valores extremos. Respecto a la IA, el modelo basado en red neuronal convolucional clásica alcanzó un accuracy del 99 % y métricas sobresalientes de precisión, recall y F1-score (0,99), superando al modelo de Transfer Learning con Keyword Spotting lo que confirma su potencial aplicación en entornos hospitalarios para el monitoreo continuo y la interpretación avanzada de eventos sonoros. En conclusión, la integración de tecnologías IoT e IA permite avanzar hacia entornos de cuidado neonatal más seguros y humanizados, donde la supervisión ambiental no solo cuantifica, sino también interpreta las condiciones sensoriales, favoreciendo el bienestar y el neurodesarrollo del neonato.

Palabras clave: Desarrollo neurosensorial, Incubadora, Inteligencia Artificial, Internet de las cosas, Machine Learning, Unidad de Cuidado Intensivo Neonatal.

Abstract

Premature birth represents a significant clinical and technological challenge, given that the interruption of intrauterine development exposes the newborn to radically different environmental conditions, particularly within Neonatal Intensive Care Units (NICUs). In this environment, variables such as temperature, humidity, and noise directly influence the physiological stability and neurodevelopment of the newborn. Given this problem, the objective of this research was to design an Internet of Things (IoT)-based monitoring system for managing relevant variables in neonatal incubators, also incorporating artificial intelligence (AI) tools for sound analysis. The methodology was structured in two phases: the first consisted of implementing and evaluating the IoT system for remote measurement of temperature, humidity, sound, and battery voltage; the second consisted of training an AI model capable of classifying relevant acoustic sources using transfer learning strategies. The results showed stable system performance, with 94.23% availability, a mean time between failures (MTBF) of 32 hours, and a mean time to repair (MTTR) of 118 minutes. Temperature and battery showed stable behavior, while humidity presented expected variability and sound emerged as the most critical variable, with the highest frequency of extreme values. With regard to AI, the model based on a classic convolutional neural network achieved 99% accuracy and outstanding precision, recall, and F1-score (0.99) metrics, outperforming the Transfer Learning model with Keyword Spotting, confirming its potential application in hospital environments for continuous monitoring and advanced interpretation of sound events. In conclusion, the integration of IoT and AI technologies allows us to move towards safer and more humanized neonatal care environments, where environmental monitoring not only quantifies but also interprets sensory conditions, promoting the well-being and neurodevelopment of the newborn.

Keywords: Artificial Intelligence, Incubator, Internet of Things, Neonatal Intensive Care Unit, Neurosensory development

Aportes

El presente proyecto no solo representó un avance en el desarrollo de soluciones tecnológicas para el monitoreo y análisis de variables relevantes en entornos clínicos, con aportes que combinan el conocimiento de neurociencia y tecnología, sino que también generó un impacto significativo en el ámbito académico, científico y formativo, ya que los resultados y avances alcanzados fueron reconocidos en distintos escenarios de divulgación e intercambio de conocimiento. Es importante recalcar que el presente proyecto nace de uno inicial macro, que obtuvo el tercer puesto en la categoría de Mejores Propuestas de Investigación en el VIII Encuentro CIMED – 2024 (Anexo 2), por tanto, la estudiante encargada de este proyecto actual tuvo la oportunidad de participar como coinvestigadora en el proyecto que se adelanta con la red hospitalaria Mederi, lo cual constituye un reconocimiento a la pertinencia y calidad de la propuesta para el sector hospitalario y deja en evidencia las oportunidades a largo plazo que permiten los trabajos de tesis de la Maestría.

Asimismo, fue socializado en espacios de carácter internacional como proyecto derivado del XII Congreso Panamericano de Neonatología 2024 (Anexo 3), donde se presentó un póster que permitió visibilizar la aplicabilidad del sistema propuesto en el cuidado neonatal. De igual forma, se participó en el Mercado de Proyectos de Investigación y Desarrollo de la Universidad de Bartin, un espacio de intercambio interdisciplinar de carácter internacional que fortaleció la proyección y escalabilidad de la iniciativa con una retroalimentación recibida por parte de expertos que permitió reforzar los aspectos de reproducibilidad y validez del proyecto.

En cuanto a la comunidad científica nacional, el proyecto tuvo presencia en el XIV Congreso Colombiano de Neurociencias y XV Seminario Internacional de Neurociencias COLNE 2025 (Anexo 4 y Anexo 5), donde se presentó un póster con los principales hallazgos y reflexiones derivados del trabajo, en esta participación se destacó el aporte de la tecnología al campo de las neurociencias, en especial como herramienta para favorecer decisiones clínicas informadas en tiempo real orientadas al neurodesarrollo.

Estos aportes reflejan no solo el alcance del proyecto en escenarios de investigación y difusión científica, sino también el valor formativo que representó para el equipo de trabajo, al consolidar competencias en investigación, comunicación científica y trabajo interdisciplinar. De esta manera, el proyecto trasciende la esfera académica y se posiciona como una contribución al avance del conocimiento en las áreas de neurociencia, neonatología e ingeniería biomédica.

1. Introducción

Las tasas de nacimientos prematuros —aquellos que ocurren antes de las 37 semanas de gestación— se han mantenido prácticamente constantes durante la última década. A nivel mundial, aproximadamente uno de cada diez bebés nace de manera prematura, lo que equivale a un nacimiento anticipado cada dos segundos [1]. Estos recién nacidos requieren de atención especializada en Unidades de Cuidados Intensivos Neonatales (UCIN), espacios hospitalarios diseñados para proporcionar un entorno clínico controlado que les permita estabilizar sus funciones vitales y minimizar el riesgo de mortalidad [2]. El progreso de la medicina y de las tecnologías biomédicas ha contribuido significativamente a mejorar las tasas de supervivencia neonatal; sin embargo, muchos de los niños que sobreviven a la prematuridad presentan alteraciones del desarrollo que impactan su vida futura y la de sus familias. Entre las secuelas más frecuentes se encuentran los retrasos en el desarrollo neuromotor y cognitivo, los trastornos del procesamiento sensorial y del comportamiento, el déficit de atención, las dificultades de aprendizaje y el trastorno del espectro autista [3–5].

Además, en las vulnerabilidades que presenta este neonato el control ambiental dentro de las UCIN constituye un componente esencial tanto como input sensorial táctil como para garantizar la estabilidad fisiológica del recién nacido prematuro. En las UCIN, por ejemplo, la temperatura y la humedad, inputs somatosensoriales, son factores determinantes para mantener la homeostasis, ya que los neonatos presentan una superficie corporal amplia en relación con su peso, escasa grasa subcutánea y mecanismos inmaduros de termorregulación [7].

Estas condiciones los hacen especialmente vulnerables a la hipotermia y a la deshidratación, lo que puede aumentar el gasto metabólico y comprometer su desarrollo. En este contexto, La incubadora desempeña un papel crucial como entorno termo-controlado ya que permite conservar una temperatura estable y una humedad relativa adecuada que favorecen la integridad de la piel, disminuyen la pérdida transepidérmica de agua y reducen el riesgo de irritación de las vías respiratorias, sin embargo, a pesar de su función protectora, este espacio controlado también expone al neonato a una serie de estímulos ambientales que pueden ser potencialmente perjudiciales.

Es por esto por lo que estas alteraciones a largo plazo del prematuro no siempre se deben exclusivamente a las condiciones médicas que motivaron la hospitalización, sino que también pueden estar asociadas al ambiente y a las prácticas de cuidado dentro de la UCIN, lo que pone en evidencia la necesidad de evaluar con mayor precisión los factores ambientales que rodean al neonato durante su estancia hospitalaria [4]. Esto se da ya que el nacimiento prematuro supone una transición abrupta hacia un entorno radicalmente diferente, las UCIN, aunque indispensables para la supervivencia del neonato, presentan condiciones ambientales que contrastan profundamente con el medio intrauterino: niveles elevados de ruido, iluminación intensa, frecuentes manipulaciones físicas y exposición a procedimientos dolorosos [8]. Sin embargo, durante el desarrollo intrauterino, el feto está expuesto a una variedad de estímulos sensoriales que favorecen la maduración progresiva de sus sistemas neurológicos. Entre estos se encuentran los sonidos amortiguados del entorno materno, como el latido cardíaco y el flujo sanguíneo, o estímulos vestibulares y propioceptivos derivados del movimiento corporal de la madre; estos son estímulos, rítmicos y predecibles que contribuyen a la organización sensorial y al establecimiento temprano de redes neuronales funcionales [9]. Es por esto, que la UCIN, aunque un entorno, diseñado principalmente para el soporte vital, puede interferir con los procesos naturales de autorregulación y neurodesarrollo del recién nacido, afectando la consolidación de las vías sensoriales.

Por lo tanto, surge la necesidad imperativa de supervisar que los valores de los parámetros ambientales (temperatura, humedad, sonido), principalmente cuando se encuentra en la incubadora,

garantizando que se mantengan dentro de los rangos establecidos por las normativas internacionales y/o nacionales, endosando que no representen un riesgo para el neonato y favorezcan su evolución hacia un estado de salud satisfactorio. Sin embargo, esta necesidad se ve obstaculizada por la falta de recursos económicos en muchas instituciones hospitalarias, especialmente en aquellas con recursos limitados, donde la adquisición o renovación de equipos biomédicos es bastante costosa.

Es el caso de las incubadoras neonatales, las cuales son utilizadas para reducir la mortalidad infantil; se utilizan como medio de condiciones óptimas para su calidad de vida [8]. En tal sentido, en la búsqueda de la seguridad del paciente, la tecnología es un factor fundamental, sobre todo si se trata de un recién nacido, los ecosistemas o proyectos basados en Internet de las Cosas (IoT) permite la incorporación un sistema inteligente para gestionar las fuentes de sonido, temperatura y humedad en cualquier incubadora neonatal lo cual es fundamental para mitigar los efectos adversos de los estímulos ambientales que pueden alterar su desarrollo neurosensorial. Al emplear tecnologías que ajusten estos parámetros a niveles más rítmicos, predecibles y tranquilos, se busca crear un entorno que simule mejor las condiciones intrauterinas, favoreciendo la adaptación y el desarrollo adecuado del bebé.

El internet de las cosas surge así como una de las herramientas en la interacción entre pacientes y profesionales de la salud, pues a través de estas se habilitan canales para que médicos en hospitales puedan monitorear de forma remota la salud de los pacientes continuamente de forma fácil y eficiente; y actuar en consecuencia a la información recibida, impactando principalmente en la reducción de costos en atención médica, reducción en la estadía en hospitales, reingreso de pacientes y la mejora en resultados de tratamientos [10]. Para promover un control efectivo que favorezca el neurodesarrollo, resulta fundamental identificar y clasificar las fuentes específicas de ruido presentes en la UCIN, diferenciando aquellas de carácter constante y fisiológicamente familiares de las que representan estímulos disruptivos para la maduración auditiva temprana. Este análisis detallado constituye la base para diseñar estrategias de monitoreo y control acústico más precisas, que apoyen la formación saludable de los mapas tonotópicos y, en consecuencia, el procesamiento auditivo a largo plazo. En este contexto, y considerando el reconocimiento de la tecnología como una estrategia de cambio en la concepción del ambiente sensorial de la UCIN, el uso de inteligencia artificial (IA) puede resultar una herramienta interesante como estrategia de cambio en la concepción del ambiente sensorial de la unidad de cuidados intensivos neonatales para el análisis profundo de la fuente del ruido.

El panorama actual de IoT está adquiriendo una importancia significativa, y en esto nace la necesidad de evolucionar su procesamiento de la información adquirida bajo la implementación del aprendizaje automático, y con ello el desarrollo de casos de uso inteligentes. Las arquitecturas de sistemas integrados dependen en gran medida de la plataforma donde se desarrolla, lo que también obstaculiza el desarrollo de un marco estándar de aprendizaje automático para todos los sistemas de procesamiento de datos al borde de IoT, además, en el dominio tecnológico actual, existe una brecha entre el hardware integrado dedicado al aprendizaje automático y el software necesario para su optimización [11].

En este sentido, uno de los elementos esenciales para el neurodesarrollo del neonato más allá de la temperatura y humedad también es el ruido, pero este no basta para la evaluación del ambiente acústico a los niveles globales de ruido (dB).

Los avances en Machine Learning (ML) han permitido el desarrollo de algoritmos capaces de identificar patrones complejos en grandes volúmenes de datos, aplicados en entornos de salud y rehabilitación para contribuir a la toma de decisiones clínicas más precisas y personalizadas [12]. La

evolución hacia Tiny Machine Learning (TinyML) ha potenciado la posibilidad de implementar dichos modelos en dispositivos de bajo consumo energético, permitiendo ejecutar algoritmos de aprendizaje directamente en tarjetas cuyo poder de cómputo es considerablemente menor que el de un servidor o un computador convencional, lo cual elimina la necesidad de depender de equipos externos o conexiones permanentes a un servidor para procesar la información, favoreciendo sistemas más autónomos, eficientes y adecuados para entornos con recursos limitados [13, 14]. Esta es una ventaja crítica en entornos hospitalarios y neonatales donde el monitoreo debe ser continuo y no dependiente de la nube. De igual manera, plataformas como Edge Impulse han facilitado la integración de modelos de ML en sistemas embebidos y microcontroladores, ofreciendo un acceso más amplio y ágil a tecnologías aplicables en el ámbito biomédico y del Internet de las Cosas médicas (IoMT por sus siglas en inglés) [15].

Complementariamente, el Transfer Learning ha surgido como una estrategia eficaz para entrenar modelos en contextos con bases de datos limitadas, adaptando representaciones previamente aprendidas a poblaciones específicas, como la neonatal [16, 17]. Así, la integración de ML, TinyML, Edge Impulse y Transfer Learning en sistemas de monitoreo acústico ofrece una vía prometedora para clasificar las fuentes de ruido en UCIN, distinguir aquellas que son familiares de las potencialmente disruptivas y, en consecuencia, diseñar soluciones inteligentes que favorezcan el neurodesarrollo temprano de los neonatos.

2. Objetivos

2.1. Objetivo general

Diseñar un sistema de monitoreo basado en Internet de las cosas para la gestión de variables relevantes en Incubadoras Neonatal.

2.2. Objetivos específicos

- Implementar una arquitectura de IoT para la adquisición de las variables de una incubadora en un ambiente controlado.
- Realizar la medición remota de las variables para la evaluación del dispositivo y sistema de gestión de información.
- Describir el comportamiento de las variables medidas y el comportamiento del dispositivo durante la medición.
- Evaluar la confiabilidad y eficiencia del sistema según las mediciones registradas, tiempos de envío de datos, tiempos de respuesta, pérdidas de datos y errores de información y visualización de información.

3. Problema y justificación

La prematuridad implica que el desarrollo cerebral crucial, que regularmente tiene lugar dentro del útero, se ve alterado al ocurrir en un entorno diferente al ideal. Esto conlleva cambios en la calidad y cantidad de estímulos sensoriales que experimenta el bebé prematuro, lo que podría impactar desfavorablemente en el desarrollo normal de sus sistemas sensoriales. Si bien la estructura física básica de los receptores sensoriales (es decir, ojos, oídos, etc.) se desarrolla temprano en la gestación, la mayor parte del desarrollo neurosensorial ocurre en las últimas dieciséis a veinte semanas, muchos de los procesos y estimulaciones necesarios para facilitar el desarrollo cerebral pueden resultar en efectos adversos si la exposición es en el momento incorrecto del desarrollo o si el nivel de intensidad no es apropiado [9].

El establecimiento de redes neuronales sensoriales, en las cuales patrones precisos de actividad neuronal inician procesos de refinamiento que subyacen al establecimiento de redes neuronales sensoriales precisas, como se ilustra en la figura 1. La exposición a estímulos visuales, auditivos y somatosensoriales inadecuados y/o inapropiados durante estos períodos críticos de desarrollo temprano puede resultar en alteraciones duraderas en la conectividad y función de las cortezas sensoriales [4]. El objetivo de los profesionales de la salud que asisten a los recién nacidos prematuros en la unidad de cuidado intensivo va más allá de la supervivencia de los recién nacidos; se busca asegurar que los neonatos superen esta etapa con su salud y bienestar completamente preservados. Existe así una necesidad de ajustar el entorno sensorial de las unidades neonatales para satisfacer las necesidades y capacidades sensoriales de los bebés prematuros, mejorar así la atención al recién nacido y asegurar su bienestar óptimo para un desarrollo favorable; es una posibilidad tecnológica [18].

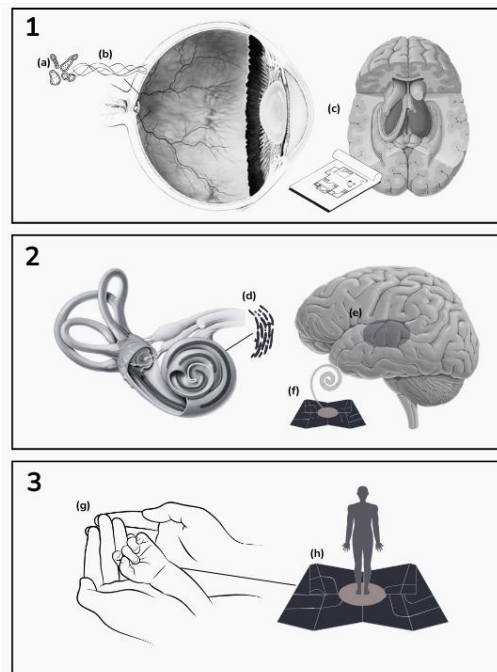


Figura 1. Establecimiento de redes neuronales sensoriales. Antes del nacimiento, las (a) células vecinas en la retina se activan juntas, esto se denomina (b) ondas retinianas para esculpir la (c) citoarquitectura funcional del tálamo visual y la corteza cerebral. En el sistema auditivo, la descarga

sincrónica de las (d) células ciliadas internas vecinas es necesaria para formar grupos de neuronas de la (e) corteza auditiva primaria y establecer (f) mapas sensoriales auditivos tonotópicos. También hay una extensa literatura sobre la influencia de los (g) receptores sensoriales periféricos en el desarrollo de los (h) mapas somatosensoriales [4].

A estos recién nacidos se les lleva a la UCIN, espacios adecuados en hospitales que cuentan con el talento humano en salud y dispositivos con tal de reducir la tasa de mortalidad en estos grupos de recién nacidos, controlando condiciones y complicaciones como la hipotermia, las infecciones, los problemas respiratorios y la alimentación. Tanto los avances médicos como la tecnología han contribuido a aumentar la tasa de supervivencia de los bebés prematuros, pero aun así millones de prematuros sobreviven con discapacidades que les perseguirán a ellos y a sus familias durante toda su vida, por lo que las afecciones neonatales son la principal causa de pérdida de capital humano en las estimaciones más recientes de la carga mundial de morbilidad, sin cambios desde 1990 [2]. Pueden presentar más probabilidad de tener un resultado negativo en el desarrollo neurológico y conductual como se encuentra en riesgo de presentar: retraso del desarrollo, retrasos cognitivos, trastornos del procesamiento sensorial, trastorno por déficit de atención e hiperactividad, trastorno del espectro autista, problemas de aprendizaje, memoria y comportamiento [3,4,5].

El servicio de neonatología, tanto en Colombia como en el resto de los hospitales del mundo, es de vital importancia dentro de una institución hospitalaria, ya que proporciona la atención necesaria para preservar o mejorar la calidad de vida de los recién nacidos. Es fundamental que las instituciones que cuenten con este servicio dispongan de todos los dispositivos biomédicos necesarios para aumentar las probabilidades de supervivencia de los neonatos que lo requieran [2]. Sin embargo, el medio ambiente de una UCIN está diseñado para sostener médicamente al frágil recién nacido prematuro, pero contrasta ampliamente con el medio intrauterino, ya que interfiere con la capacidad de los prematuros para desarrollar respuestas adaptativas a un medio ambiente agresivo para ellos [8]. Durante su desarrollo intrauterino, aunque el recién nacido ha estado expuesto a una amplia gama de estímulos, incluyendo estímulos auditivos como el latido cardíaco materno y sonidos ambientales atenuados, estímulos vestibulares y kinestésicos derivados de los movimientos fetales de la madre, así como patrones rítmicos cíclicos como el latido cardíaco materno, el sueño de la madre y los patrones de actividad neurohormonal. Sin embargo, al nacer, experimenta un cambio abrupto de ambiente, enfrentándose continuamente a una exposición a luces intensas, ruidos fuertes y súbitos, así como a experiencias dolorosas y agresivas, lo cual puede influir significativamente en su comportamiento durante un periodo de extrema vulnerabilidad [3].

De esta manera, la exposición a estímulos visuales, auditivos y somatosensoriales inadecuados y/o inapropiados durante estos períodos críticos de desarrollo temprano puede resultar en alteraciones duraderas en la conectividad y función de las cortezas sensoriales [5]. Debido a lo anterior el recién nacido una vez ingresa a UCIN, se encuentra expuesto a diversas agresiones físicas ambientales, siendo las más prominentes el ruido, la luz, la temperatura y la humedad, las cuales pueden incidir en su estado clínico y su progreso posterior, manifestándose en alteraciones fisiológicas (tales como cambios en la frecuencia cardíaca, respiratoria, oxigenación y niveles hormonales). De otro lado, pueden presentarse discapacidades que están vinculadas con el desarrollo interrumpido de los sistemas sensoriales, como más probabilidades de tener un resultado negativo en el desarrollo neurológico y conductuales, se encuentra en riesgo de presentar: retraso del desarrollo, retrasos cognitivos, trastornos del procesamiento sensorial, trastorno por déficit de atención e hiperactividad, trastorno del espectro autista, problemas de aprendizaje, memoria y del comportamiento [7].

Además de las alteraciones en sus sistemas sensoriales, los bebés prematuros no cuentan con la cantidad suficiente de grasa corporal para regular su temperatura y, en muchos casos, sus órganos

aún no están completamente desarrollados para generar calor de manera eficiente [19]. Por esta razón, una de las condiciones esenciales de seguridad en una incubadora es proporcionar un entorno con temperatura controlada, reduciendo así el gasto energético del neonato. Asimismo, la piel de los prematuros es más delgada y frágil, lo que los hace especialmente vulnerables a la deshidratación debido a la pérdida de humedad. Por ello, el control adecuado de la humedad relativa dentro de la incubadora es crucial para su bienestar. Mantener niveles óptimos de humedad no solo ayuda a minimizar la evaporación excesiva a través de la piel, sino que también protege las vías respiratorias de la sequedad y posibles daños [20]. Por esto, una de las condiciones básicas de seguridad de la incubadora debe ser un entorno termo controlado y así permitir el menor gasto energético del prematuro. A su vez los prematuros tienen una piel más delicada y fina lo que los convierte a ser particularmente propensos a la deshidratación debido a la pérdida de humedad, por esto el manejo adecuado de la humedad relativa del aire es igual de fundamental en su cuidado de los recién nacidos en incubadoras. Mantener así un nivel adecuado de humedad en el ambiente ayuda a prevenir la pérdida excesiva de humedad a través de la piel y reduce el riesgo de sequedad y daños en las vías respiratorias [6].

La seguridad del paciente hace parte de las prioridades de los sistemas de salud en Colombia. Actualmente el principal objetivo de las instituciones de salud es el de prevenir eventos adversos durante la atención de los neonatos en su etapa de desarrollo, donde se encuentran más vulnerables a sufrir lesiones durante su hospitalización [21]. Mejorar la asistencia al recién nacido y proporcionarle el bienestar que precisa para que se desarrolle en las mejores condiciones es tecnológicamente posible, y de ello pueden depender su calidad, su promedio y, desde luego, su percepción inmediata de la vida. Es por ello por lo que la actual propuesta de investigación se enfocó a desarrollar un sistema de monitoreo para conocer el comportamiento de las variables objeto de estudio. La creación de sistemas inteligentes que generan alertas tanto de temperatura, humedad y sonido también ayuda a evitar impactos negativos en la conectividad cerebral, contribuyendo a un proceso de desarrollo óptimo y reduciendo el riesgo de trastornos del desarrollo a largo plazo.

Desde la perspectiva más general, IoT se ha convertido en una ficha fundamental en la continua interacción que se tiene entre los diferentes dispositivos tecnológicos “cosas” con los cuales se convive e interactúa día a día. El internet de las cosas surge como una de las herramientas en la interacción entre pacientes y profesionales de la salud, pues a través de estas se habilitan canales para que médicos en hospitales puedan monitorear de forma remota la salud de los pacientes continuamente de forma fácil y eficiente; y actuar en consecuencia a la información recibida, impactando principalmente en la reducción de costos en atención médica, reducción en la estadía en hospitales, reingreso de pacientes y la mejora en resultados de tratamientos [10].

El IoMT emerge como una solución ingeniosa, donde el progreso tecnológico sirve como enlace con los profesionales de la salud. Esta tecnología permite el monitoreo continuo y remoto de la salud de los pacientes de forma fácil y accesible. Estudios han demostrado su efectividad, especialmente en el cuidado de neonatos, donde su aplicación ha mejorado significativamente el monitoreo y la atención médica, contribuyendo así a mejores resultados para los recién nacidos prematuros y enfermos. Específicamente en el monitoreo y control de las incubadoras para bebés prematuros en la última década, el desarrollo y la implementación de tecnologías basadas en IoT han generado alternativas innovadoras, lo cual ha permitido avances significativos en la precisión y eficiencia del seguimiento de las variables críticas del ambiente en las incubadoras [26, 27, 31]. La capacidad de realizar monitoreo remoto y en tiempo permite a los profesionales de la salud y a los padres acceder a datos esenciales desde cualquier lugar y así tomar decisiones informadas de manera oportuna. Este enfoque no solo mejora la calidad del cuidado neonatal, sino que también ofrece soluciones

accesibles y asequibles, especialmente en regiones con recursos limitados, contribuyendo a un cuidado más equitativo y eficaz para todos los neonatos.

En las UCIN, el ambiente sonoro difiere radicalmente del intrauterino, siendo un sistema de importancia para el neonato lo expone a frecuencias medias y altas que pueden alterar el establecimiento normal de los mapas tonotópicos en la corteza auditiva, un desajuste en la calidad del estímulo auditivo que afecta los procesos de plasticidad cerebral temprana, lo que refuerza la necesidad de monitorear no solo la intensidad del ruido (dB), sino también la naturaleza y el origen de las fuentes sonoras presentes [4]. Tradicionalmente, la evaluación del entorno acústico neonatal se ha limitado a la medición de niveles globales de ruido, lo cual resulta insuficiente para distinguir entre estímulos familiares y aquellos potencialmente disruptivos para el neurodesarrollo, esta limitación ha impulsado el interés en herramientas de IA que permitan caracterizar y clasificar las fuentes acústicas en la UCIN [22].

Diversos estudios han demostrado la aplicabilidad de modelos de aprendizaje profundo en la detección automática de fuentes sonoras, utilizando arquitecturas como redes neuronales convolucionales (CNN por sus siglas en inglés), redes neuronales recurrentes (LSTM por sus siglas en inglés) y modelos no supervisados para el agrupamiento de patrones acústicos [22–24]. Estas investigaciones han logrado identificar con alta precisión sonidos característicos del entorno neonatal —como alarmas de equipos, voces humanas y pasos del personal—, lo que confirma el potencial de la IA para el análisis sensorial automatizado. En este contexto, la incorporación de estrategias como *Edge computing* y *transfer learning* permite procesar la información directamente en dispositivos de bajo consumo energético, garantizando una operación eficiente y segura, hacen que la implementación de sistemas inteligentes de monitoreo acústico en UCIN sea técnicamente viable y clínicamente relevante, especialmente en instituciones con recursos limitados [35, 36]. Por tanto, el desarrollo de un sistema capaz de identificar y clasificar en tiempo real las fuentes de ruido en el ambiente neonatal representa un avance significativo hacia entornos de cuidado más humanizados, seguros y basados en evidencia, la integración de tecnologías IoT con algoritmos de IA no solo posibilita la medición continua de variables ambientales, sino también su interpretación contextual, permitiendo intervenciones tempranas orientadas a proteger el neurodesarrollo y el bienestar del recién nacido prematuro.

4. Marco teórico y estado del arte

4.1. Estado del arte

A continuación, se presenta las diferentes investigaciones y avances alrededor del tema de cuidado neonatal con dispositivos de internet de las cosas y los avances que cada una de este logro alrededor del bienestar de los recién nacidos.

Tabla 1. Reporte literatura sobre IoT y UCIN.

Título	Autor, año, publicación y país	Tipo de dispositivo	Avances y ventajas de la tecnología
"Design of an IoT-based smart incubator that listens to the baby"	F. Fahmi, W. Shalannanda, I. Zakia, E. Sutanto. 2020. IOP Conference Series. Indonesia	Prototipo de un sistema de monitorización de la incubadora basado en IoT que a partir de IA y más de 40 datasets interpreta el llanto del bebe en 5 condiciones	Construyeron un prototipo que logró con éxito capturar la voz e interpretarla mediante IA en cinco posibles términos del estado del bebé: eructos, sueño, hambre, incomodidad y dolor mediante el análisis de la señal de energía y el espectro para el desarrollo de incubadoras que puedan interpretar el llanto del bebé. [24]
"An IoT-based Vitals Monitoring System for Babies in Neonatal Intensive Care Unit"	Darniss R, Vidya S Nair, Sai Shibu N B, Aryadevi Remanidevi Devidas. 2022. Humanitarian Technology Conference.	Sistema de detección basado en IoT que monitoriza la temperatura, movimiento, llanto, orientación del bebé, presión, frecuencia cardíaca y saturación de oxígeno con acceso a través de una aplicación móvil o un panel web para los profesionales de salud.	Crearon un sistema que monitoriza variables útiles para el análisis clínico donde el personal de salud podía acceder para supervisar el estado de todos los bebés de la UCIN y tomar decisiones acertadas. [26]
"Intelligent Neonatal Monitoring System Based on Android Application using Multi Sensors"	S.M. Najib, Norshahida Binti Hassan, Nur Tysha Atikah binti Mohd Shair, N Rahim, N. Ab Wahab. 2019. 9th	Sistema Inteligente de Monitorización Neonatal basado en IoT que transmite las constantes vitales del neonato, como la temperatura corporal y el pulso.	Su sistema es útil para el seguimiento de los neonatos en cualquier momento y en cualquier lugar a través de Internet, jugando un papel vital para una mejor atención. [27]

	Symposium on Computer Applications & Industrial Electronics (ISCAIE). Malasia		
“Accurate Body Temperature Measurement of a Neonate Using Thermography Technology”	Kianoush Rassels & Paddy French. 2021. Smart Systems Integration (SSI). Holanda	Tecnología termográfica que mide con precisión la temperatura corporal de los neonatos en una incubadora.	Su técnica elimina factores externos no deseados realizando el perfil de temperatura de formas geométricas o Región de Interés (ROI) a lo largo del tiempo a partir de técnicas como la IA, el Aprendizaje Automático o el Aprendizaje Profundo reduciendo así el estrés y la incomodidad para el bebé y proporciona una entrada valiosa para los médicos o enfermeras para brindar atención de mayor calidad [28].
“IoT-based neonatal incubator for the developing. World and conflict zones”	Mayamiko Kalilani, Nai Shyan Lai, Raed Abdulla. 2021. Journal of Applied Technology and Innovation. Malaysia.	Incubadora neonatal de bajo costo con IoT que integra sensores biométricos para monitorear al bebé en tiempo real y usa la plataforma Blynk.	Con el uso de la plataforma de IoT Blynk, desarrollaron un sistema capaz de crear un microclima deseado dentro del recinto de la incubadora con una humedad autónoma dentro del rango del 90 al 95% y sensores biométricos que producen resultados comparables a las mediciones tomadas simultáneamente por el médico [29].
“Real Time Monitoring and Control of Neonatal Incubator using IOT.”	Rasha M. Abd El-Aziz, Ahmed I. Taloba. 2021. International Journal of Grid and Distributed Computing. Arabia Saudita.	Desarrollaron una incubadora neonatal de bajo costo basada en IoT con manta de fototerapia y una plataforma efectiva de IoT para el monitoreo en tiempo real de la temperatura y humedad	Realizaron modelado y simulación del entorno de la incubadora basados en principios termodinámicos estándar utilizando el lenguaje de programación Python demostrando que el dispositivo fue efectivo para

		de la incubadora	el monitoreo en tiempo real de las condiciones ambientales en la incubadora generando así una alternativa para países con recursos limitados que se caracterizan por una alta mortalidad infantil debido al alto costo y la falta de disponibilidad de incubadoras neonatales convencionales [30].
“Baby Incubator with Overshoot Reduction System using PID Control Equipped with Heart Rate Monitoring Based on the Internet of Things”	Bambang Guruh Irianto, Anita Miftahul Maghfiroh, Mohamad Sofie, Mohamad Sofie, Abd Kholiq. 2023. International Journal of Technology. Indonesia.	Desarrollaron una incubadora para bebés con un sistema de monitoreo a través de IoT de datos de temperatura, señales de ECG y frecuencia cardíaca.	Esta incubadora está específicamente diseñada para bebés con defectos cardíacos que puedan ser monitoreados de forma remota. Las pruebas demostraron que el valor de error de la temperatura estuvo por debajo del 5%, y el control del dispositivo logró reducir el aumento de temperatura en no más del 5%, en la señal de ECG se obtuvo un valor de $p > 0.05$, con un valor de error en estado del sistema estable del 2% demostrando la posibilidad de estos sistemas y la posibilidad de que el usuario o la familia del paciente pueden monitorear fácilmente el desarrollo del bebé en cualquier lugar y momento [31].
“DEVELOPMENT OF INCUBATOR MONITORING SYSTEM USING IoT”	Bindhu H C, Sumana M, Vandhana S, Prakash Jadhav. 2023. Gradiva Review Journal. India.	Dispositivo de bajo costo para el monitoreo en tiempo real de la incubadora neonatal que monitorea frecuencia cardíaca, temperatura, humedad, gas (CO ₂) y luz.	Crearon un dispositivo de bajo costo y efectivo que transmite los datos a los médicos o enfermeras de manera inalámbrica a través de IoT para poder tomar las acciones necesarias en el momento oportuno y mantener un ambiente

			apropiado para la seguridad de la vida de los bebés prematuros [32].
“A Low-Cost Baby Incubator Design Equipped with Vital Sign Parameters”	Lamidi, Abd.Kholiq, Muslim Ali. 2021. Indonesian Journal of Electronics, Electromedical, and Medical Informatics (IJEEEMI). Indonesia.	Diseñaron un sistema compacto a bajo costo en una incubadora para bebés que estabiliza la temperatura, calcula la frecuencia cardíaca y el valor de saturación de oxígeno.	A partir de los datos del dispositivo puede detectar los síntomas tempranos de anomalías congénitas. Las pruebas demostraron que el mayor error en el sistema es del 0,517%, una diferencia de temperatura de solo 0,175 °C, una diferencia en el parámetro de humedad del 0,21% y sistemas de frecuencia cardíaca y saturación dentro de la tolerancia en un sistema que puede funcionar automáticamente y es capaz de ajustar la estabilidad de la incubadora [33].
“Development of Incubator Analyzer Based on a Computer with Temperature and Humidity Parameters”	Syarifatul Ainiyah, Dwi Herry Andayani, Andjar Pundji, Triwiyanto M Shaib. 2020. Journal of Electronics, Electromedical Engineering, and Medical Informatics (JEEEMI). Indonesia.	Diseño de un dispositivo calibrador basado en un ordenador para medir los parámetros de ruido y flujo de aire en una incubadora que tiene cuatro parámetros que medir temperatura, ruido, humedad y flujo de aire	El dispositivo cuenta con un error del 0,5% a una temperatura de ajuste de 36°C y 37°C; se demostró que puede ser utilizado para la calibración de incubadoras para bebés [34].

En conclusión, estas investigaciones y desarrollos tecnológicos reflejan un esfuerzo continuo por mejorar la eficiencia y seguridad de las incubadoras neonatales, con un enfoque especial en la implementación de tecnologías IoT para facilitar el monitoreo remoto y reducir los riesgos asociados con el uso de equipos médicos en el cuidado de los bebés prematuros. La integración de sensores avanzados que miden variables críticas como la temperatura, la humedad, la frecuencia cardíaca y la oxigenación de la sangre, permite una supervisión constante y precisa del estado de los neonatos. Se destaca la importancia de la monitorización en tiempo real, proporcionando a los médicos y

enfermeras datos esenciales para la toma de decisiones rápidas y efectivas, lo cual es vital en situaciones críticas [26, 27].

Asimismo, la creación de dispositivos asequibles y eficientes demuestra el potencial de las tecnologías IoT para transformar el cuidado neonatal, especialmente en regiones con recursos limitados [30]. Estas tecnologías no solo mejoran la precisión de las mediciones, sino que también aseguran que los padres y el personal médico puedan acceder a la información vital del bebé desde cualquier lugar, ofreciendo tranquilidad y reduciendo el estrés asociado con el cuidado de neonatos vulnerables. Se subraya el objetivo de hacer que estas innovaciones sean accesibles en economías menos desarrolladas, al utilizar plataformas IoT, estos sistemas permiten un monitoreo económico y eficaz, lo que es crucial para reducir la mortalidad infantil en regiones con recursos limitados [29]. Por otro lado, se encuentran dispositivos que desarrollaron sistemas para medir el ruido y el flujo de aire, resalta la necesidad de un entorno controlado y estable en las incubadoras, lo cual es crucial para el bienestar de los neonatos [33]. En la figura 2 se ilustran los diferentes objetivos con los que se han desarrollado estos dispositivos a través de los años.




Figura 2. Propósitos desarrollo tecnología IoT en UCIN

Estos estudios no solo demuestran la viabilidad técnica de estas innovaciones, sino también su impacto potencial en la mejora de la atención neonatal. La tecnología IoT en las incubadoras no solo facilita el monitoreo preciso y constante de las condiciones ambientales y vitales, sino que también representa un avance significativo hacia un cuidado neonatal más seguro, eficiente y accesible en todo el mundo. Esto subraya la necesidad de continuar invirtiendo en el desarrollo de estas tecnologías para asegurar que todos los bebés prematuros, independientemente de su ubicación geográfica o situación económica, tengan acceso a la mejor atención posible.

Este proyecto tuvo como objetivo diseñar un sistema de monitoreo basado en Internet de las cosas para la gestión de variables relevantes en Incubadoras Neonatal, mediante el uso de IoT. El propósito es proporcionar un apoyo adicional a los especialistas, facilitando la toma de decisiones y mejorando la seguridad de los recién nacidos prematuros. La información sobre las condiciones ambientales,

accesible en tiempo real a través de una aplicación, contribuirá al proceso de mejora continua de la unidad.

A su vez, frente a la identificación de fuentes de ruido en la unidad de cuidados intensivos según la literatura se encontraron diversos estudios sobre la identificación y medición de sonidos en la UCIN para comprender su impacto en el bienestar neonatal, estos han abarcado desde la caracterización del ambiente acústico hasta estrategias de reducción de ruido y clasificación con IA [22-24]. Se consideran los siguientes tipos de ruido como los cuales han sido reportados en la literatura como relevantes para el ambiente neonatal con sus decibeles ideales para no afectar al neonato:

Tabla 2 Ruidos relevantes para el ambiente neonatal

Ruido	Descripción	Intensidad de sonido (dB)
Alarmas de equipos	Sonidos generados por monitores, ventiladores mecánicos, bombas de infusión y otros dispositivos médicos. Estas alarmas tienen variaciones en frecuencia e intensidad dependiendo del tipo de advertencia	Alarma de la bomba de infusión: 60 – 78 Alarma Incubadora: 67 – 96 Monitor paciente alarma de alta prioridad: 69 Alarma ventilador: 56 [22,24]
Voz adulta	Sonidos producidos por el personal médico, cuidadores o familiares dentro de la UCIN. Puede incluir comunicación entre profesionales o interacción con los neonatos.	Conversación: 45 – 50 [22,24]
Pasos	Ruido generado por el desplazamiento del personal dentro de la unidad. La intensidad y el patrón varían según el tipo de calzado, la velocidad de movimiento y la superficie del piso.	Correr: <140 [22]
Incubadora	Sonidos internos y externos asociados al uso de la incubadora, incluyendo la apertura y cierre de compuertas, la manipulación del equipo o colocar elementos sobre ella.	Cerrar la puerta/cajón de la incubadora: 67 – 87 Dejar caer una bandeja sobre la incubadora: 88 – 117 Colocar un objeto sobre la incubadora: 84 – 108 [22]
Espacio atención	Abarca sonidos generados por actividades cotidianas que influyen en el ambiente sonoro sin provenir directamente de equipos médicos. Incluye los tonos de llamada y notificaciones del teléfono de la unidad, así como el flujo de agua en lavabos y el sonido de desechos al ser depositados en contenedores de basura. También comprende el movimiento de sillas dentro del espacio, contribuyendo al entorno acústico de la unidad.	Flujo de agua: 54 Contenedor de basura: 56 Teléfono: 49 – 66 Silla arrastrada en el suelo: 62 Cuidado Recién nacido: 109 – 126 [22]

Ruido ambiental	El conjunto de eventos sonoros presentes en el entorno acústico sin la intervención directa de fuentes humanas o mecánicas. Incluye sonidos naturales como la brisa, el sistema de ventilación del hospital o ruidos de baja intensidad, que forman parte del paisaje sonoro de la UCIN. Se considera el ambiente sonoro base sobre el cual se superponen otros sonidos relevantes, permitiendo identificar y diferenciar fuentes de ruido en el proceso de recolección de datos.	No Aplica
-----------------	---	-----------

A su vez se realiza una búsqueda de literatura de investigación sobre el estudio de sonidos de UCIN e IA y los avances que cada una de este logro alrededor del bienestar de los recién nacidos

Tabla 3 Reporte literatura IA y sonido en la UCIN

Título	Autor, año, publicación y país	Herramienta de IA	Avances y ventajas
Assessing the Acoustic Noise in Intensive Care Units via Deep Learning Technique	Althahab, A. Q. J., Vuksanovic, B., Al-Mosawi, M., & Ma, H. (2024). <i>Acoustics</i> Australia. Reino Unido.	Deep Learning (CNN + clustering): La CNN se usa como un extractor de características, estas características extraídas se alimentan a un algoritmo de clustering para agrupar los datos automáticamente en categorías basadas en similitudes, así identifica diferentes tipos de patrones sin conocerlos de antemano.	Clasifica con precisión eventos acústicos en la unidad de cuidados intensivos; identifica la voz como principal fuente de ruido. Ofrece un sistema IoT de bajo costo para detección y monitoreo de fuentes sonoras [35].
Machine Listening in a Neonatal Intensive Care Unit	Tailleur, M., Lostanlen, V., Rivière, J. P., & Aumond, P. (2024). <i>arXiv preprint. Francia.</i>	Edge computing + Transfer learning (PANNs): PANNs es un modelo potente y preentrenado para audio y se utiliza el Transfer Learning para ajustarla a la tarea específica de la investigación y se despliega en un dispositivo de Edge Computing para hacer la detección en tiempo real e in situ.	Integra privacidad desde el diseño (sin grabar audio crudo). Usa redes neuronales preentrenadas adaptadas, mostrando factibilidad de "machine listening" polifónico en UCIN [23].
On the Acoustic Environment of a Neonatal	Raboshchuk, G., Nadeu, C., Ghahabi, O., Solvez, S., Mahamud, B.M.,	Deep Belief Networks (DBN): tipo de red neuronal generativa	Mejora la detección de alarmas frente a GMM y refuerza el

Intensive Care Unit: Initial Description, and Detection of Equipment Alarms	Veciana, A.R.d., Hervas, S.N. (2014). Proc. Interspeech 2014. España.	profunda compuesta por múltiples capas de Máquinas de Boltzmann Restringidas (RBMs) que se entrenan de manera no supervisada (sin etiquetas) capa por capa para aprender a extraer características de forma jerárquica y probabilística, una vez preentrenada, la red puede ser ajustada mediante aprendizaje supervisado para tareas de clasificación.	valor de IA profunda para ambientes complejos de UCIN [36].
Sensor Sound Classification in Neonatal Intensive Care Units Based on Multiple Features and Neural Networks	I. Fontes, A. Melo, A. C. Frery and A. Aquino. (2024). IEEE 21st Consumer Communications & Networking Conference (CCNC). Brasil.	CNN + LSTM: La CNN procesa las entradas de señal de sonido para extraer características espaciales en cada paso de tiempo, estas se pasan a la LSTM, que luego procesa la secuencia de estas características a lo largo del tiempo para predecir el resultado final o clasificar la secuencia completa.	Logra clasificación precisa de llanto, voces y alarmas, en este estudio el LSTM supera a CNN en recuerdo, mostrando que modelos secuenciales son más robustos para flujos acústicos en UCIN [22].

El análisis de los estudios evidencia que las herramientas de IA aplicadas a la detección de ruido en la UCIN ofrecen un aporte sustancial a la monitorización ambiental, superando las limitaciones de las mediciones convencionales centradas en niveles globales de decibelios. Los modelos basados en redes neuronales profundas [22,35,36]. Estos permiten identificar con mayor precisión las fuentes acústicas críticas, distinguiendo entre alarmas de equipo, voces humanas y sonidos fisiológicamente familiares, a su vez, el uso de Edge computing y transfer learning garantiza soluciones escalables, respetuosas con la privacidad y eficientes en entornos hospitalarios sensibles [23]. En conjunto, estos avances confirman que la IA es una herramienta esencial para caracterizar, clasificar y eventualmente mitigar los estímulos disruptivos en la UCIN, favoreciendo así estrategias de intervención más precisas para la protección del neurodesarrollo neonatal.

4.2. Marco teórico:

Prematuro

Según la Organización Mundial de la Salud, un bebé se considera prematuro si nace vivo antes de completar las 37 semanas de gestación, dentro de esta población, se identifican subcategorías que se clasifican según su edad gestacional [39]. La categoría de los nacidos pretérmino incluye a niños cercanos al término (35-37 semanas cumplidas), a prematuros moderados (32 a 34 semanas

cumplidas), prematuridad marcada (28 a 31 semanas cumplidas) y a prematuros extremos (nacidos antes de completar la semana 28).

La prematuridad es común y contribuye significativamente a la alta morbilidad y mortalidad, afectando desproporcionadamente a las gestaciones de mujeres con desventajas sociales y económicas. En Colombia, según estadísticas del DANE, la tasa de bajo peso al nacer no ha cambiado y se mantiene alrededor del 9%, mientras que la tasa de prematuridad es del 19.3% [37].

Otra clasificación de importancia para los prematuros son los criterios de ingreso a las unidades de recién nacidos en Colombia. Estos criterios determinan qué bebés requieren cuidados especializados en unidades neonatales, lo cual es crucial para asegurar que los recién nacidos prematuros reciban la atención necesaria para mejorar sus chances de supervivencia y desarrollo óptimo.

Según la Asociación Colombiana de Neonatología las unidades de recién nacidos en Colombia clasifican a los pacientes según la urgencia de su necesidad de atención en la UCIN y su ingreso a alguna de las unidades disponibles de cuidados intensivos, intermedios o básicos [38].

En cuanto a los criterios de priorización, la cual es crucial para maximizar la eficiencia y efectividad de la atención neonatal especializada. Los pacientes con mayor necesidad y mayores beneficios potenciales reciben prioridad 1, asegurándose acceso inmediato a cuidados intensivos. En contraste, aquellos cuya condición no justifica el ingreso reciben prioridad 4, reservando los recursos para quienes más los necesitan, la especificación de cada nivel de prioridad se especifica a continuación [38]:

- Prioridad 1: Son pacientes inestables con necesidad de monitoreo y tratamiento intensivo que no puede ser manejado fuera de la UCIN. En estos pacientes generalmente no hay límites para la prolongación de la terapia que están recibiendo. Pueden incluir pacientes en postoperatorio, con insuficiencia respiratoria que requieren soporte ventilatorio, que están en choque o inestabilidad circulatoria, necesitan monitoreo invasivo y/o drogas vasoactivas y/o hemodiálisis aguda.
- Prioridad 2: Estos pacientes requieren monitoreo intensivo y potencialmente pueden necesitar una intervención inmediata y no se han estipulado límites terapéuticos. Por ejemplo, pacientes con estados comórbidos quienes han desarrollado una enfermedad severa médica o quirúrgica.
- Prioridad 3: Pacientes que pueden recibir tratamiento intensivo para aliviar su enfermedad aguda, sin embargo, se le puede determinar readecuación de las medidas asistenciales, tales como no intubar o no efectuar reanimación cardiopulmonar si la requirieron. Ejemplos: pacientes con enfermedades malignas en cuidados paliativos.
- Prioridad 4: Son pacientes no apropiados para cuidados en UCIN. Estos deberían ser admitidos sobre una base individual, bajo circunstancias inusuales y bajo la autorización del jefe de la unidad.

Frente a los criterios de ingreso a los diferentes tipos de unidades neonatal, la admisión se realiza según el servicio y la condición del prematuro. La Unidad de Cuidado Intensivo, Intermedio o Básico Neonatal, tienen en común que admiten recién nacidos a término menores de 30 días o recién

nacidos pretérmino hasta las 44 semanas de edad gestacional corregida, que presenten patologías médicas o quirúrgicas especializadas [38]. Además, todas basan su criterio de admisión en el diagnóstico más complejo y proporcionan cuidados especializados según las necesidades del paciente. Sin embargo, difieren en cuanto al nivel de atención y monitoreo proporcionado. Mientras que la Unidad de Cuidado Intensivo Neonatal ofrece un monitoreo más intensivo con registros de signos vitales cada hora, evaluaciones médicas mínimas tres veces al día, y atención de enfermería permanente; la Unidad de Cuidado Intermedio Neonatal brinda un nivel de atención intermedio con registros de signos vitales cada 8 horas, evaluaciones médicas mínimas dos veces al día, y atención de enfermería cada 3 horas. Por otro lado, la Unidad de Cuidado Básico proporciona un nivel de atención menos intensivo con registros de signos vitales cada 6 horas, evaluaciones médicas diarias, y atención de enfermería según los criterios de habilitación establecidos [37].

Cada una de estas unidades cuenta con criterios diferenciales en el paciente, los criterios de ingreso a la unidad de cuidado básico se centran en pacientes estables provenientes de cuidados intermedios con un peso superior a 1600 gramos y estabilidad hemodinámica y metabólica, o recién nacidos a término con condiciones específicas. Estas incluyen neumopatía crónica estable, hiperbilirrubinemia sin riesgo para exanguinotransfusión, sepsis neonatal asintomática después de la estabilización clínica, pacientes con adecuación de esfuerzo terapéutico sin necesidad de soporte ventilatorio, y vigilancia de pacientes asintomáticos con criterios de riesgo, como adaptación familiar y neonatal para el egreso, administración de antibióticos por riesgo de sepsis, o recién nacidos cuyas madres están hospitalizadas [38].

Los criterios de admisión a la unidad de cuidados intermedios incluyen a pacientes con peso entre 1300 gramos y 1600 gramos, o menores de 34 semanas, que demuestran estabilidad hemodinámica, respiratoria y metabólica, provenientes de la unidad de cuidados intensivos. Estos criterios abarcan pacientes que presenten estabilidad cardiopulmonar, hemodinámica, metabólica-nutricional y hematológica, así como aquellos que requieran adecuación de esfuerzo terapéutico con soporte ventilatorio. Entre las condiciones específicas se incluyen la necesidad de oxígeno, la estabilidad después de la extubación orotraqueal, la administración de líquidos endovenosos, el síndrome de respuesta inflamatoria sistémica neonatal, la alimentación parenteral o enteral, y la presencia de hiperbilirrubinemia severa [40].

La unidad de cuidados intensivos neonatales admite a todos los recién nacidos con peso inferior a 1,300 gramos, aquellos que requieren procedimientos especiales y los prematuros de bajo peso (< 1800 g y/o < 32 semanas). Además, se consideran para ingreso a esta unidad a los recién nacidos con inestabilidad cardiopulmonar que requieran manejo con ECMO, óxido nítrico, ventilación mecánica invasiva o no invasiva, así como aquellos con alteraciones respiratorias, cardiológicas, hemodinámicas, neurológicas, metabólicas, nutricionales, hidroelectrolíticas, hematológicas, inflamatorias e infecciosas. Se incluyen también pacientes con malformaciones congénitas que requieran urgencia quirúrgica y aquellos con falla renal aguda [40].

Temperatura en neonatos

La temperatura es un factor crucial en el cuidado de los neonatos, particularmente en los casos de recién nacidos prematuros. En UCIN, mantener una temperatura del aire apropiada es crucial para el cuidado óptimo de los recién nacidos prematuros y de alto riesgo, esta temperatura proporciona un entorno térmico estable que ayuda a prevenir la hipotermia y la hipertermia, garantizando así el bienestar y la salud de los bebés en la incubadora.

Estos bebés enfrentan desafíos únicos debido a su menor masa corporal y a una relación superficie-corporal/peso más alto en comparación con los bebés nacidos a término. Con una menor cantidad de grasa subcutánea, los prematuros son más susceptibles a la pérdida de calor, lo que puede conducir rápidamente a una temperatura corporal anormalmente baja, como lo es la hipotermia. Cuando la temperatura corporal desciende el metabolismo celular se ralentiza, este descenso conlleva a una disminución en la producción de energía, lo que a su vez resulta en una menor eficiencia en la utilización del oxígeno.

El cuerpo, como respuesta, aumenta la demanda de oxígeno para compensar esta disminución en la producción de energía y mantener las funciones vitales. Este aumento en la demanda de oxígeno puede provocar un estrés adicional en el sistema respiratorio y cardiovascular, especialmente en los recién nacidos prematuros. Por esto, este descenso en la temperatura puede aumentar el riesgo de complicaciones metabólicas, como una mayor demanda de oxígeno y la acumulación de ácido láctico en la sangre [41].

Esta acumulación de ácido láctico en sangre se da ya que cuando el metabolismo celular se ralentiza resulta en una menor producción de energía en forma de ATP (trifosfato de adenosina), esta disminución afecta la capacidad de las células para utilizar el oxígeno de manera eficiente en el proceso de respiración celular aeróbica, por esto las células recurren a la fermentación láctica como una fuente alternativa de energía, lo que conduce a la acumulación de ácido láctico en la sangre. A su vez, la hipotermia puede provocar vasoconstricción lo cual disminuye el flujo sanguíneo periférico lo que limita la entrega de oxígeno y la eliminación de productos de desecho, como el ácido láctico, de los tejidos [41].

Así mismo, la temperatura puede también interferir con la producción de surfactante pulmonar, una sustancia crucial para el adecuado funcionamiento de los pulmones, ya que reduce la tensión superficial en los alvéolos, permitiendo así la expansión pulmonar y evitando el colapso al final de la espiración, un elemento crucial para la función respiratoria adecuada. Cuando la temperatura corporal desciende por debajo de niveles óptimos, el metabolismo celular se ralentiza y esto afecta la producción de surfactante debido a que las enzimas necesarias para su síntesis pueden volverse menos activas, lo que puede interferir con la capacidad del organismo para producir y secretar surfactante en los pulmones de manera adecuada.

Además, la hipotermia prolongada puede tener repercusiones graves, incluido un crecimiento deficiente y una mayor vulnerabilidad a las infecciones, ya que en condiciones de hipotermia el sistema inmunológico puede volverse menos eficiente en la lucha contra las infecciones por una variedad de factores fisiológicos. Entre estos, la función de los glóbulos blancos, que son células responsables de combatir las infecciones, puede disminuir en condiciones de hipotermia, lo que dificulta la capacidad del cuerpo para defenderse contra los patógenos invasores. Igualmente, la hipotermia puede afectar la integridad de las membranas mucosas y la función de barrera de la piel, lo que puede facilitar la entrada de microorganismos patógenos al cuerpo. Asimismo, la hipotermia puede ralentizar la respuesta inflamatoria del cuerpo, lo que dificulta la capacidad de combatir y eliminar las infecciones de manera efectiva. En conjunto, estos factores pueden hacer que los individuos hipotérmicos sean más susceptibles a las infecciones y tengan dificultades para combatirlas, lo que aumenta el riesgo de complicaciones y enfermedades asociadas [28].

Todo lo anterior resalta la importancia crítica de mantener una temperatura óptima en la atención neonatal, con el objetivo de minimizar el estrés metabólico y promover un desarrollo saludable.

Humedad en neonatos

La humedad desempeña un papel crucial en la regulación de la temperatura y el equilibrio hídrico en neonatos, especialmente en bebés prematuros. Para prevenir la pérdida excesiva de calor por evaporación y la deshidratación, es necesario mantener niveles elevados de humedad relativa (80%–90%) en la incubadora durante las primeras 2–4 semanas de vida.

La elevada pérdida evaporativa de agua en los prematuros se debe a la inmadurez de su piel, la cual no se vuelve funcionalmente madura hasta las 32–34 semanas de gestación, esta pérdida transepidermica de agua puede causar hipotermia, deshidratación e hiperosmolaridad, afectando negativamente el desarrollo neonatal, que el ambiente de la unidad de cuidado del prematuro tenga una humedad relativamente alta (80%–90%) reduce significativamente esta transferencia de calor por evaporación hasta que la piel se desarrolla completamente, lo cual es esencial para el control de la temperatura y el equilibrio hídrico [42].

La pérdida de agua transepidermica es la evaporación del agua desde las capas superficiales de la piel hacia el ambiente externo y es una medida de la función de la barrera cutánea, en los bebés prematuros cuya piel es más delgada y menos desarrollada, esta pérdida puede llevar a deshidratación, hipotermia e infecciones, subrayando la necesidad de un ambiente de humedad controlada en las incubadoras. Por lo anterior, la cantidad de humedad en la incubadora es afectada por las condiciones clínicas de los infantes prematuros, como la pérdida de agua transepidermica, la hipotermia, el desequilibrio electrolítico, el consumo de oxígeno, la infección y la integridad de la piel; sin embargo, el uso de humedad en las incubadoras de las UCIN no siempre es consistente.

La humedad adecuada reduce la pérdida de agua transepidermica, ayudando a mantener el volumen de fluidos corporales y evitando desequilibrios electrolíticos, los cuales son esenciales para funciones fisiológicas como la regulación del equilibrio ácido-base y la función neuromuscular, y pueden desbalancear con la pérdida excesiva de agua. La capacidad limitada de los prematuros para regular su homeostasis debido a la inmadurez de sus sistemas corporales se ve beneficiada por un entorno de humedad controlada, reduciendo el estrés y manteniendo un equilibrio interno más estable, crucial para su desarrollo y supervivencia [20].

Procesamiento auditivo en neonatos

En el sistema auditivo, incluso antes del nacimiento, la descarga sincrónica de las células ciliadas internas vecinas es esencial para formar grupos de neuronas corticales auditivas primarias y establecer mapas sensoriales auditivos tonotópicos. Este refinamiento de los procesos continúa mediante mecanismos de plasticidad dependientes de la actividad durante el período perinatal y la vida temprana postnatal. Por lo tanto, la exposición a estímulos auditivos inadecuados o inapropiados durante estos periodos críticos puede resultar en alteraciones duraderas en la conectividad y función de las cortezas sensoriales.

La exposición al ruido ambiental en las unidades de cuidados intensivos neonatales puede retrasar el establecimiento de mapas tonotópicos en la corteza auditiva. Durante su estancia, los prematuros permanecen en la UCIN durante días o meses, según sus necesidades individuales; en este tiempo están expuestos a sonidos de alta y media frecuencia en un momento de desarrollo en el que normalmente estarían dentro del útero, experimentando sonidos de muy baja intensidad y frecuencia. Aunque la mayoría de las UCIN buscan mantener el sonido ambiental por debajo de los 50 dB, se ha demostrado que el ambiente intrauterino supera estos valores, variando entre 70 y 90 dB. Sin embargo, la principal diferencia entre el "ruido" del entorno intrauterino y el de la UCIN no es la intensidad del sonido, sino su calidad [4].

Dentro del útero, predominan los sonidos de baja frecuencia, como la frecuencia cardíaca, el flujo sanguíneo y los movimientos peristálticos. En contraste, la UCIN tiene muchas fuentes de sonidos de alta y media frecuencia, como pitidos de monitores, voces y ventiladores. Por lo anterior, resulta insuficiente limitar la evaluación del ambiente acústico a los niveles globales de ruido (dB). Para lograr un control efectivo que favorezca el neurodesarrollo, es necesario identificar y clasificar las fuentes específicas de ruido presentes en la UCIN, diferenciando aquellas de carácter constante y fisiológicamente familiares de las que representan estímulos disruptivos para la maduración auditiva temprana. Solo de esta manera será posible diseñar estrategias de monitoreo y control acústico más precisas, que apoyen la formación saludable de los mapas tonotópicos y, en consecuencia, del procesamiento auditivo a largo plazo [4].

Procesamiento táctil en neonatos

En cuanto a la estimulación táctil, en lugar de recibir un contacto constante del entorno amniótico/uterino, los bebés en la UCIN están aislados en incubadoras y tienen contacto con telas artificiales y numerosos procedimientos médicos esenciales (es decir, cánulas nasales, colocación de líneas intravenosas, punciones en el talón). Por lo tanto, el entorno de cuidado necesario que experimentan los bebés prematuros implica exposición a un entorno que es significativamente diferente del útero. Así, el entorno de la UCIN puede contribuir a cambios sutiles en las cortezas sensoriales que podrían traducirse en déficits sensoriales duraderos.

De hecho, los niños pequeños y adolescentes nacidos prematuros a menudo presentan discapacidades que están vinculadas con el desarrollo interrumpido de los sistemas sensoriales, como el trastorno por déficit de atención con hiperactividad (TDAH), el trastorno del espectro autista y problemas de aprendizaje y memoria. Por ejemplo, un estudio observacional prospectivo mostró que los bebés prematuros que presentan reactividad táctil anormal tienen más probabilidades de presentar un mal resultado de neurodesarrollo. Las alteraciones observadas en las cortezas primarias también podrían reflejarse en áreas asociativas que reciben entradas convergentes de diferentes modalidades sensoriales, afectando especialmente el procesamiento multisensorial [4].

Integración multisensorial

Las alteraciones en las cortezas primarias también pueden reflejarse en áreas asociativas que reciben entradas de diferentes modalidades sensoriales, afectando el procesamiento multisensorial. Este procesamiento se caracteriza por la transferencia de información entre modalidades sensoriales y depende de neuronas multimodales, que pueden ser activadas por más de una modalidad sensorial, y ocurre a un nivel alto de procesamiento cortical [4].

Aunque tradicionalmente se considera que los sentidos de los recién nacidos están separados al nacer, la integración sensorial se incrementa con el tiempo a medida que los bebés acumulan experiencias sensoriomotoras. En el estudio titulado "The potential effects of NICU environment and multisensory stimulation in prematurity, se evidenció mediante imágenes de resonancia magnética funcional en estado de reposo que dos regiones corticales implicadas en el procesamiento e integración multisensorial, el surco intraparietal (IPS) y el surco supratemporal (STS), ya presentan conexiones con áreas corticales unisensoriales en neonatos. En particular, el STS mostró una conectividad funcional notable con áreas visuales, auditivas y somatosensoriales. Esto puede atribuirse a la existencia de regiones corticales que reciben entradas sensoriales convergentes en las primeras semanas de vida, lo que implica que el establecimiento de estas conexiones sensoriales influye en el procesamiento multisensorial. Con el tiempo, el desarrollo sensorial en la infancia

temprana progresa hacia un procesamiento más avanzado y especializado, que depende en gran medida de la experiencia previa, lo que contribuye a los altos índices de discapacidad asociados con antecedentes de prematuridad [4].

El procesamiento multisensorial se define por la transferencia de información entre distintas modalidades sensoriales. Este fenómeno depende de neuronas multimodales, que pueden activarse por más de una modalidad sensorial, y se produce en niveles avanzados de procesamiento cortical. Un ejemplo de esta transferencia se puede observar desde el nacimiento, cuando un estímulo auditivo puede alterar la percepción de un estímulo visual que sigue en los recién nacidos. A la edad de un mes, un bebé es capaz de reconocer visualmente un objeto que ha sido explorado con anterioridad a través del tacto. A pesar de que los sentidos se consideran tradicionalmente como separados al nacer, su integración se fortalece a medida que los bebés adquieren más experiencias sensoriomotoras con el tiempo.

Machine learning

Entendida como una rama de la IA, permite que los sistemas aprendan patrones y reglas a partir de grandes volúmenes de datos para generar predicciones precisas en escenarios clínicos complejos [12]. Su potencial se ha reflejado en la capacidad de detectar interacciones entre múltiples atributos, identificar marcadores pronósticos y construir modelos de predicción aplicados en diferentes patologías neurológicas y críticas [12,18,19]. La integración de ML en los sistemas de información hospitalaria ha permitido el desarrollo de herramientas de apoyo a la decisión clínica en tiempo real, estos sistemas aprovechan la capacidad de los algoritmos para analizar grandes volúmenes de datos en periodos muy cortos, transformando registros clínicos electrónicos en insumos valiosos para anticipar riesgos y guiar intervenciones tempranas [18]. De esta manera, el uso de ML contribuye a mejorar la eficiencia del personal sanitario, a reducir la carga cognitiva asociada al análisis manual de información y a optimizar los tiempos de respuesta en situaciones críticas [18, 19]. Estas aproximaciones no solo aportan al pronóstico, sino que también optimizan la asignación de recursos y priorizan la atención a poblaciones vulnerables.

La variedad de algoritmos empleados en ML responde a diferentes necesidades de interpretabilidad y precisión. Modelos como la regresión logística destacan por su transparencia, mientras que técnicas más avanzadas como Random Forest, Extreme Gradient Boosting (XGBoost), Light Gradient Boosting Machine (LightGBM) o redes neuronales multicapa (Multi-layer Perceptron, MLP) permiten capturar relaciones no lineales y patrones complejos en datos clínicos de alta dimensionalidad y con distribución desequilibrada [12]. No obstante, la adopción de estas metodologías plantea desafíos relacionados con la explicabilidad, lo cual ha impulsado el desarrollo de enfoques como la IA explicativa (XAI), siendo SHAP (SHapley Additive exPlanations) una de las técnicas más utilizadas para interpretar la relevancia de variables clínicas en los modelos [12].

En entornos de UCI, la investigación reciente ha mostrado que ML puede contribuir a mejorar predicciones clave, como la mortalidad, la evolución de enfermedades respiratorias críticas o el momento óptimo de egreso hospitalario, sin embargo, persisten retos importantes relacionados con la heterogeneidad de los pacientes, la temporalidad de los trayectos clínicos y la generalización de los modelos más allá de estudios unicéntricos [19,20]. Por otro lado, la literatura también muestra una rápida expansión del uso de ML en cuidados críticos, con más de 25.000 publicaciones desde 2019 en el ámbito de la unidad de cuidados intensivos [22]. Esta producción evidencia tanto la diversidad de enfoques metodológicos —que van desde modelos convencionales como árboles de decisión y Naïve Bayes hasta arquitecturas de aprendizaje profundo como redes convolucionales y

recurrentes— como los debates emergentes sobre la transparencia, equidad y aplicabilidad clínica de los modelos, especialmente en unidades neonatales y pediátricas, se han desarrollado marcos innovadores basados en visión computacional y análisis de comorbilidades que amplían las capacidades diagnósticas y pronósticas tempranas [22].

En síntesis, el machine learning se posiciona como una herramienta clave en la medicina crítica, aportando valor en la predicción de resultados, la estratificación de riesgos y el soporte a la toma de decisiones clínicas. Aun así, la necesidad de modelos explicables, validados en contextos multicéntricos y sensibles a la diversidad poblacional, constituye un reto central para su implementación segura y efectiva en las unidades de cuidados intensivos.

TinyML

Se ha consolidado en los últimos años como una de las tendencias más prometedoras en la convergencia entre sistemas embebidos e IA. Esta tecnología busca integrar algoritmos de aprendizaje automático en dispositivos con recursos limitados, como microcontroladores, que tradicionalmente se consideraban inadecuados para ejecutar modelos de IA debido a sus restricciones de memoria, potencia de cómputo y consumo energético; sin embargo, el desarrollo de marcos especializados y la creciente necesidad de inteligencia en el borde de la red han impulsado su rápida adopción en múltiples sectores, especialmente en el de la salud [23, 24].

Los estudios revisados evidencian que TinyML ofrece un abanico de ventajas significativas como el procesamiento local de datos, reducción de la latencia, menor consumo energético, disminución de la dependencia de servidores externos, bajo costo de implementación y, sobre todo, un mayor control sobre la privacidad. En un contexto en el que los sistemas de salud generan y procesan enormes volúmenes de información sensible, estas características convierten a TinyML en una opción viable y estratégica para aplicaciones clínicas y de investigación biomédica. Según Aanjankumar y colaboradores, esta tecnología, pese a enfrentar retos de capacidad, robustez y sostenibilidad, tiene la capacidad de cambiar radicalmente la forma en que los sistemas gestionan la información en tiempo real, particularmente en salud, ya que su implementación plantea oportunidades para proteger datos confidenciales mediante técnicas de preservación de privacidad y desplegar algoritmos de manera segura en aplicaciones críticas [24].

En el ámbito clínico, Kim y su equipo desarrollaron un sistema embebido basado en TinyML para la clasificación de señales ECG. El trabajo resalta cómo los microcontroladores, al procesar la información de manera local, reducen la latencia, optimizan el uso del ancho de banda y permiten una monitorización continua sin depender de conexiones constantes a servidores externos [13]. De manera similar, otros proyectos aplicaron TinyML a la detección temprana de enfermedades respiratorias mediante kits portátiles, a sistemas de análisis de audio para diferenciar entre voces de adultos y niños, y a tareas de visión por computadora como la identificación del uso correcto de mascarillas. Estas experiencias, aunque en fases iniciales, demuestran que la tecnología es capaz de abordar problemas complejos en salud con niveles de precisión adecuados y gran eficiencia energética [13, 14, 24].

Por otro lado, investigaciones como las de Mala y colegas plantean el papel de TinyML en el ecosistema del edge computing y el IoMT. El análisis muestra cómo la incorporación de inteligencia en dispositivos periféricos permite reducir la dependencia de la nube, mejorar la autonomía del sistema, reforzar la seguridad frente a ataques cibernéticos y minimizar los costos relacionados con la transmisión y almacenamiento de datos; el estudio resalta que, en el caso de dispositivos de salud inteligentes, el procesamiento local es clave no solo para preservar la privacidad de los pacientes,

sino también para garantizar la capacidad de respuesta en tiempo real frente a eventos críticos [14]. A nivel más sistémico, Pazmiño Ortiz y colaboradores presentan una mirada holística sobre la evolución de TinyML en el contexto de IoT, argumentando que el crecimiento exponencial de los dispositivos conectados ha puesto en evidencia las limitaciones del modelo basado en la nube: alto consumo de ancho de banda, latencia inaceptable en aplicaciones críticas y riesgos de seguridad y privacidad al centralizar grandes volúmenes de información. En este sentido, TinyML representa una transición hacia un modelo distribuido de inteligencia, donde el procesamiento se realiza directamente en la fuente de datos. Este cambio responde tanto a necesidades técnicas como sociales y medioambientales, al reducir el consumo energético asociado con la transmisión masiva de información [14, 22].

El desarrollo de frameworks especializados como TensorFlow Lite for Microcontrollers, microTVM, CMSIS-NN y Edge Impulse ha sido fundamental para materializar esta visión. Estas plataformas permiten comprimir y optimizar modelos entrenados en sistemas más potentes, para luego desplegarlos en microcontroladores con memoria del orden de kilobytes. Gracias a ello, hoy en día es posible ejecutar tareas como el reconocimiento de palabras clave, la detección de anomalías en señales biomédicas y el análisis básico de imágenes en dispositivos de bajo costo y consumo ultra bajo de energía [23, 13].

No obstante, persisten importantes retos para la consolidación de TinyML en salud. Entre ellos se destacan la necesidad de estandarizar benchmarks que permitan comparar de manera realista la eficiencia de los modelos bajo restricciones de energía, memoria y latencia; la implementación de mecanismos de seguridad multicapa que protejan los dispositivos frente a ataques y fugas de datos; la búsqueda de equilibrio entre modelos especializados para alta eficiencia y modelos adaptativos con mayor flexibilidad; y la atención a las implicaciones éticas y medioambientales del despliegue masivo de dispositivos embebidos [23, 24].

En síntesis, TinyML se perfila como un eje transformador en la atención sanitaria y en el diseño de dispositivos médicos portátiles. Su capacidad para procesar información sensible en tiempo real, de manera segura y eficiente, abre la puerta a una nueva generación de cuidados personalizados, sostenibles y respetuosos de la privacidad del paciente. Con ello, TinyML no solo contribuirá al avance de la IA en el borde, sino también a la consolidación de un ecosistema de salud más ágil, equitativo y centrado en las personas [13, 23].

Edge Impulse

Edge Impulse se ha posicionado como una de las plataformas más relevantes en el ecosistema de TinyML y el desarrollo de aplicaciones de IA en dispositivos embebidos, su propuesta central consiste en simplificar el proceso de recolección de datos, entrenamiento de modelos, validación y despliegue en hardware de recursos limitados, como microcontroladores, con un consumo energético ultra bajo y la capacidad de operar en tiempo real [15]. Uno de los principales aportes de Edge Impulse radica en su enfoque integral como plataforma basada en la nube, que actúa como un sistema de Machine Learning Operations (MLOps) especializado en dispositivos embebidos, es así como los retos más frecuentes del aprendizaje automático en el borde —como la captura y procesamiento de datos, el entrenamiento de modelos y el monitoreo de su desempeño en condiciones reales— pueden ser gestionados de manera eficiente en un mismo entorno [25]. Según reportes de octubre de 2022, la plataforma ya contaba con más de 118.185 proyectos desarrollados por 50.953 usuarios, lo cual refleja su creciente adopción a nivel global [25].

A nivel técnico, Edge Impulse proporciona un flujo de trabajo estructurado en bloques de entrada, procesamiento y aprendizaje, conocidos como impulso. Los bloques de entrada permiten definir el tipo de datos que se usarán en el entrenamiento (series temporales como audio, vibraciones o movimiento; o imágenes). Posteriormente, los bloques de procesamiento ejecutan operaciones de Digital Signal Processing (DSP) para extraer características relevantes del conjunto de datos, como es el caso del uso de coeficientes cepstrales en las frecuencias de Mel (MFCC) para señales de audio. Finalmente, los bloques de aprendizaje permiten entrenar el modelo, lo que habilita tanto el diseño automático a través de interfaces gráficas como la edición manual del código para optimizar la arquitectura del modelo [26].

En términos de hardware, Edge Impulse ofrece una gran versatilidad, soportando dispositivos que van desde Cortex-M0+ para análisis de vibración, Cortex-M4F para procesamiento de audio, Cortex-M7 para clasificación de imágenes y Cortex-A para identificación de objetos, entre otros. En un caso de estudio, se utilizó el Arduino Nano 33 BLE Sense, basado en un Cortex-M4F a 64 MHz, para implementar un sistema de clasificación de cantos de aves. Allí, la plataforma permitió el desarrollo de un modelo de aprendizaje profundo capaz de ejecutar inferencias localmente y enviar los resultados clasificados a otros dispositivos o a la nube para su monitoreo [25]. Desde el ámbito industrial, Edge Impulse también ha demostrado ser una herramienta clave en la analítica predictiva de mantenimiento, evaluaron el desempeño de modelos TinyLSTM y TinyModel entrenados con Keras y posteriormente desplegados a través de Edge Impulse en equipos industriales [15]. Los resultados evidenciaron que la plataforma no solo optimiza la implementación de modelos complejos en dispositivos con recursos limitados, sino que además habilita su uso en contextos de mantenimiento predictivo en tiempo real, minimizando fallos no planificados y reduciendo los costos asociados al reemplazo de componentes.

La utilidad de Edge Impulse también ha sido explorada en el sector salud la plataforma es capaz de integrar señales fisiológicas obtenidas de pacientes, como registros de audio relacionados con síntomas respiratorios; en este caso, el uso de Edge Impulse permitió entrenar clasificadores para la predicción de patologías como neumonía y asma en entornos de diagnóstico en tiempo real. De manera complementaria se resalta la capacidad de los bloques de procesamiento y aprendizaje en Edge Impulse para implementar redes neuronales profundas optimizadas mediante Keras, con posibilidad de realizar validación cruzada, técnicas de aumento de datos y exportación de modelos directamente a hardware embebido [26].

En síntesis, Edge Impulse no solo representa un marco de desarrollo accesible y potente para TinyML, sino también una plataforma estratégica que conecta la captura de datos en tiempo real, el diseño y la optimización de modelos de IA, y su despliegue en dispositivos de borde. Su versatilidad ha permitido aplicaciones que abarcan desde la clasificación de cantos de aves, la detección de fallos en equipos industriales y el diagnóstico en tiempo real de patologías respiratorias, hasta la creación de dispositivos de bajo costo para entornos de salud y neurociencias. De esta manera, Edge Impulse se consolida como un ecosistema esencial en la transición hacia un modelo distribuido de inteligencia, caracterizado por el procesamiento local, la eficiencia energética y la privacidad de los datos.

Transfer Learning

El transfer learning constituye una de las técnicas más relevantes dentro del aprendizaje automático contemporáneo, especialmente en escenarios donde la disponibilidad de datos es limitada o costosa de obtener. Esta metodología se fundamenta en la idea de que el conocimiento adquirido en una

tarea inicial puede ser reutilizado para abordar un nuevo problema que comparte ciertas similitudes, lo que reduce los requerimientos de datos, acelera el proceso de entrenamiento y mejora el rendimiento del modelo en comparación con aquellos construidos desde cero [16]. Su aplicación se ha extendido en áreas como la visión por computador, el procesamiento de lenguaje natural y, particularmente, en el análisis de audio, donde los modelos preentrenados sobre grandes bases de datos permiten reconocer patrones acústicos generales antes de ser adaptados a tareas específicas [12]. Este enfoque resulta especialmente útil en entornos sensibles, como la UCIN, donde es fundamental distinguir sonidos relevantes —como alarmas médicas, conversaciones del personal o llantos de bebés— para garantizar un monitoreo adecuado del ambiente sonoro y su impacto en el bienestar del neonato.

Desde un punto de vista metodológico, el transfer learning puede implementarse a través de distintas estrategias, siendo las más comunes el feature extraction y el fine-tuning. En el primer caso, se reutilizan las capas iniciales de un modelo preentrenado para extraer representaciones generales de los datos, manteniendo congelados sus pesos, mientras que en el segundo se ajustan parcialmente las capas superiores para adaptarlas a la especificidad del nuevo conjunto de datos [26]. Adicionalmente, algunos estudios han explorado la generación de datos sintéticos como complemento a los reales, con el fin de ampliar la diversidad y robustez de los modelos entrenados, logrando así una mejor generalización en la detección de eventos acústicos [17]. Entre sus principales ventajas se destacan la reducción en tiempos de entrenamiento, el ahorro de recursos computacionales y la mejora de métricas de rendimiento como la precisión, la sensibilidad y la F1-score; sin embargo, también enfrenta desafíos, como la selección adecuada del modelo de origen, la posible transferencia de sesgos presentes en los datos iniciales y la necesidad de ajustar cuidadosamente los hiperparámetros para evitar sobreajuste. En síntesis, el transfer learning se configura como una herramienta clave para el desarrollo de sistemas de IA aplicados al análisis de sonido, al permitir que modelos entrenados en bases de datos amplias puedan ser reutilizados y adaptados a contextos específicos, potenciando así la capacidad de detección y clasificación en entornos complejos y clínicamente relevantes como las UCIN.

Métricas en IoT

En los sistemas del Internet de las Cosas (IoT), la medición del rendimiento y la fiabilidad es fundamental para evaluar la continuidad operativa de los dispositivos y la calidad de los datos que producen.

Una de las métricas centrales es el uptime, entendido como la proporción de tiempo en la que un servicio o dispositivo permanece disponible dentro de un intervalo específico. Esta medida se calcula a partir del tiempo real de operación sobre el periodo total de observación, y permite cuantificar la disponibilidad del sistema a partir de valores que oscilan entre 0 y 1, donde 1 corresponde al funcionamiento ininterrumpido del servicio [50]. El downtime, por su parte, se refiere al periodo en el que el sistema permanece inactivo y constituye un indicador crítico para evaluar el impacto de interrupciones operativas, especialmente en contextos donde estas afectan la entrega de servicios o la respuesta a eventos. Su relevancia en IoT ha sido ampliamente discutida, dado que altos niveles de inactividad comprometen la capacidad del sistema para generar información en tiempo real y afectan la eficiencia global del entorno técnico [51].

Junto a estas métricas, la confiabilidad del sistema se evalúa mediante el Mean Time Between Failures (MTBF), que estima el tiempo promedio transcurrido entre fallos inherentes durante la operación. Este valor se obtiene dividiendo el tiempo total de funcionamiento entre el número de

fallos ocurridos, lo que permite proyectar la estabilidad del sistema y anticipar necesidades de mantenimiento preventivo. Una mayor magnitud del MTBF refleja una mayor robustez, periodos prolongados de operación sin interrupciones y un mejor desempeño de los componentes [52]. Complementariamente, el Mean Time To Repair (MTTR) ofrece una estimación del tiempo promedio necesario para identificar, corregir y restablecer la funcionalidad del sistema tras un fallo. Este indicador resume la capacidad de recuperación del dispositivo y su mantenibilidad, permitiendo valorar la eficiencia de los procesos de reparación y su efecto sobre la disponibilidad total. Al igual que en el caso anterior, su cálculo se deriva del tiempo total dedicado a reparaciones dividido entre la cantidad de eventos de fallo registrados [52].

Debido a que los sistemas IoT generan flujos continuos de datos susceptibles a variaciones inesperadas o errores de medición, la detección de anomalías adquiere un papel clave en la interpretación y depuración de la información. Entre los enfoques estadísticos más utilizados se encuentra el método Z-score, que cuantifica cuántas desviaciones estándar separan un dato de la media y permite identificar valores atípicos que superan un umbral determinado, especialmente en distribuciones cercanas a la normalidad [53]. De manera complementaria, el enfoque basado en el Interquartile Range (IQR) se fundamenta en establecer límites utilizando los percentiles 25 y 75, lo que otorga mayor resistencia frente a distribuciones sesgadas y valores extremos. Este método destaca por su simplicidad y su bajo costo computacional, características que facilitan su adopción en dispositivos IoT con restricciones de procesamiento, permitiendo una detección de anomalías en tiempo real mediante umbrales estadísticos accesibles incluso en microcontroladores [54].

5. Metodología

Para recolectar y sistematizar la información del sistema de monitorización de manera efectiva en el ambiente controlado, es fundamental tener presente el procedimiento planteado de tal manera que se garantice la recolección, verificación y sistematización de los datos; para ello se propuso una metodología de investigación observacional descriptiva, y se realizó en el laboratorio de Ingeniería Clínica de la Universidad del Rosario. Los dispositivos de monitoreo fueron validados únicamente en el laboratorio de ingeniería clínica.

El proyecto se dividió en dos fases, las cuales se detallan a continuación:

Primera fase: Monitorización y evaluación del sistema

Tras la activación del dispositivo, se inició el registro periódico de las variables ambientales, cuyos valores fueron enviados a la base de datos en tiempo real mediante conectividad IoT, los datos recopilados se utilizaron para un análisis estadístico y temporal que permitió identificar patrones de comportamiento, variaciones y estabilidad en el funcionamiento del sistema.

- **Base de datos:** Los datos recolectados se almacenaron en Firebase Realtime Database en formato JSON y fueron posteriormente procesados mediante Python para la organización y análisis de la información, para esto, se implementaron procedimientos de limpieza y control de calidad para asegurar la validez de los registros, eliminando valores duplicados, incompletos o fuera de rango.
- **Frecuencia y continuidad de envío de datos:** Se evaluó la frecuencia real de envío de datos y la continuidad de la transmisión, identificando posibles interrupciones o retrasos respecto a la configuración esperada, en este se calculó la tasa de pérdida de información y se determinó la confiabilidad del canal de comunicación entre el dispositivo y la base de datos en la nube.
- **Análisis visual de la información:** Se desarrolló con la base depurada la visualización de los datos—como histogramas, boxplots y líneas de tiempo— que permitieron una visualización clara de las tendencias, la estabilidad y la variabilidad de cada variable ambiental lo cual permitió comprender la dinámica del sistema y detectar posibles anomalías en el comportamiento de los sensores.
- **Rendimiento general del sistema:** Se analizó a partir de métricas clásicas de Internet de las Cosas, como el tiempo de actividad y el tiempo medio entre fallos, para así medir la disponibilidad y confiabilidad de la transmisión. A su vez se midió la velocidad de respuesta, la cual se interpretó a partir de los intervalos de envío observados, comparándolos con la frecuencia programada para valorar la capacidad del dispositivo para mantener la comunicación de manera continua y eficiente a lo largo del periodo de prueba.
- **Comportamiento energético:** Se realizó un seguimiento del voltaje de la batería a lo largo del tiempo, complementado con mediciones puntuales de corriente para comprender las fases de carga y descarga para así estimar la autonomía del sistema y explorar la posible relación entre el consumo energético y las variaciones de temperatura, humedad y sonido lo cual se apoyó en la comparación entre registros continuos y mediciones de laboratorio.

- **Prueba de transferencia de datos:** Para determinar la robustez del sistema en términos de confiabilidad y disponibilidad se calcularon indicadores como el porcentaje de tiempo operativo (uptime), el tiempo de inactividad (downtime), el tiempo medio entre fallos (MTBF) y el tiempo medio de recuperación (MTTR) junto con la evaluación de la batería y la frecuencia de transmisión, permitieron valorar de manera integral la eficiencia y estabilidad del sistema IoT durante su funcionamiento continuo.
- **Identificación de patrones y eventos relevantes:** Se aplicaron métodos estadísticos de detección de anomalías, tales como Z-score e IQR, con el fin de reconocer valores atípicos o desviaciones significativas tanto en las variables ambientales como en el comportamiento energético se distinguió entre fluctuaciones esperadas del entorno y posibles errores de medición.

Segunda fase: Implementación de Modelos de IA para el análisis de sonido

A partir de la revisión de la literatura inicial, se evidenció que el monitoreo de ruido mediante niveles globales (dB) resulta insuficiente para caracterizar la complejidad acústica del entorno de la unidad de cuidado crítico neonatal, por esto se planteó el desarrollo de un modelo de IA capaz de identificar la fuente del sonido registrado, fortaleciendo la capacidad del sistema IoT para la toma de decisiones frente a anomalías en las variables ambientales. Para esto se recolectó una base de datos con sonidos relevantes, estos datos recolectados se procesaron en la plataforma Edge Impulse, donde fueron segmentados en ventanas de un segundo y sometidos a un preprocesamiento basado en Mel Frequency Energy (MFE) para la extracción de características relevantes del audio, el modelo de IA se entrenó aplicando estrategias de Transfer Learning de Feature Extraction para evaluar la efectividad del modelo entrenado en Edge Impulse, se utilizaron métricas como accuracy, precision, recall y F1-score, además del seguimiento del loss durante el entrenamiento para analizar el rendimiento global del clasificador, así como su capacidad para identificar correctamente las diferentes fuentes de ruido (precision), detectar la mayor cantidad posible de eventos relevantes (recall) y mantener un equilibrio entre ambas (F1-score). La descripción detallada de este proceso se presenta en el apartado correspondiente al entrenamiento del modelo de IA, en el cual se especifican las etapas que conformaron su desarrollo, incluyendo la recolección y adquisición de datos mediante hardware, la selección del algoritmo, el diseño del impulso, la configuración de los bloques de aprendizaje y la detección de eventos, a su vez, se describen los procesos de configuración de los parámetros de extracción de características MFCC (Mel-Frequency Cepstral Coefficients) y la configuración de la red neuronal que permitieron optimizar el desempeño del modelo en la clasificación de las fuentes sonoras.

5.1. Diseño e implementación de la arquitectura IoT para la adquisición de variables ambientales

Se realizó la ubicación del dispositivo en conjunto con los sensores de temperatura, humedad y sonido en el laboratorio de ingeniería clínica y se programó la toma de datos con un intervalo de medición de por lo menos cada 2 minutos, esto permitió tomar lecturas a intervalos regulares y así toda la información será almacenada en una base de datos estructurada para el sistema de monitoreo, donde se configuró para que los datos se registraran automáticamente. Una vez comprobado que el dispositivo funcionara correctamente, se verificó la recolección de los datos que continuamente fueron enviados, se verificaron los registros utilizando un sistema de gestión de datos que almacena automáticamente las mediciones en intervalos predeterminados para corroborar que cada uno de los registros correspondan a la frecuencia de toma con relación a la hora y fecha y se realizó un

monitoreo continuo del voltaje de la batería y complementado con mediciones puntuales de corriente eléctrica para estimar la autonomía del sistema.

5.1.1. Arquitectura del dispositivo:

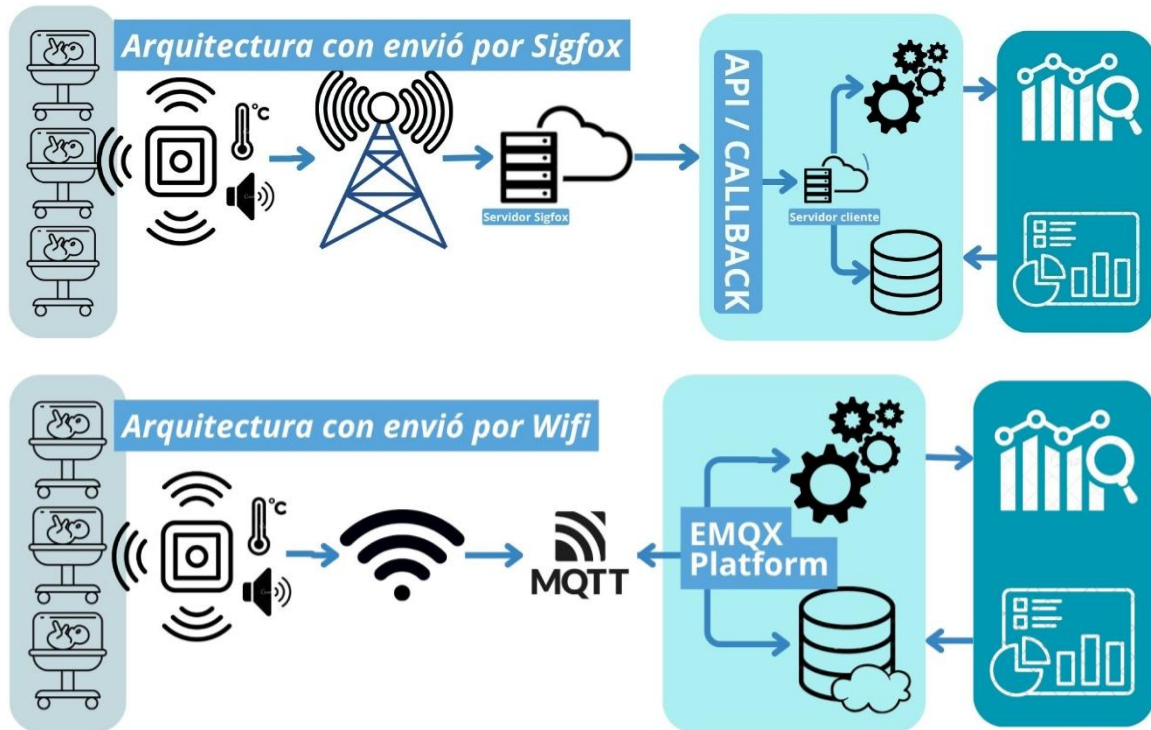


Figura 3. Arquitectura del dispositivo. Se experimentaron con 2 formas de envío de información, la imagen de arriba se observa la arquitectura a partir del envío de datos con Sigfox y debajo aquella implementada con el envío de información a través de Wifi.

En este tipo de arquitectura, el flujo de información se distribuye entre distintos niveles de procesamiento, combinando el análisis local en el dispositivo y la gestión remota en la nube. Esta configuración corresponde a una arquitectura distribuida, en la cual las tareas de adquisición, procesamiento, almacenamiento y visualización de datos se reparten entre el nodo físico (dispositivo IoT), servidores intermedios y la plataforma en la nube. De esta manera, el sistema puede ejecutar procesos de preprocesamiento y clasificación inicial de la información directamente en el dispositivo o en el borde de la red, mientras que la nube se encarga del almacenamiento, análisis avanzado y visualización. Esta organización mejora la eficiencia, reduce la latencia y fortalece la resiliencia del sistema frente a interrupciones de conectividad. En la figura 3 se presenta una representación gráfica de las capas que conforman esta arquitectura y se describe en detalle el comportamiento de los componentes que intervienen en cada una de ellas.

a. Capa de percepción

Los dispositivos encargados de captar la información del entorno son:

- Sensores: se implementó el ADMP401 para la detección de sonido y los sensores DHT22 para temperatura y humedad. Es importante resaltar que, de acuerdo con la literatura, no

basta con medir solo los niveles globales de ruido en la UCIN; resulta esencial avanzar hacia la identificación de las fuentes de ruido [22, 23, 35, 36]. Aunque inicialmente el dispositivo mide el nivel de ruido ambiental, se incorporó el entrenamiento de modelos de IA para la detección de fuentes sonoras específicas que se explica más adelante su entrenamiento e implementación.

- MCU: se utilizó una ESP32, que permite tanto la adquisición de datos como la transmisión inalámbrica.
- Fuente de energía: batería recargable, con la cual se realizaron pruebas de duración en función del envío periódico de datos.
- Almacenamiento: los datos se envían directamente a la nube, sin almacenamiento local intermedio.

b. Capa de comunicación

Esta capa asegura la transmisión de los datos desde el dispositivo hasta la nube, para esto se planteó de la siguiente manera:

- Protocolos: inicialmente se hicieron pruebas con Sigfox, y posteriormente con Wifi, comparando ventajas y limitaciones de cada uno. Según cada protocolo se utilizó un Gateway para enviar a internet los datos recibidos a el backend de Sigfox. En el caso de la ESP32 con Wifi se enviaron los datos directamente a la nube, no se usó un Gateway.

c. Capa de aplicación

Para la gestión de la información recolectada para ser interpretada por el usuario final se utilizó:

- Plataforma en la nube: Node-RED.
- Visualización: dashboards con gráficas y una interfaz web accesible, que permite la visualización en tiempo real de los datos recolectados.
- Procesamiento: en esta fase se centró en la recolección y visualización, sin integrar aún procesamiento avanzado de IA en la nube.

d. Modelo de arquitectura

La arquitectura implementada en este proyecto corresponde a un modelo Cloud-Centric, en el cual los sensores (ADMP401 para sonido y DHT11/DHT22 para temperatura y humedad) envían los datos a través de la tarjeta ESP32 mediante conexión Wifi hacia la nube, donde son gestionados y visualizados en Node-RED. Todo el procesamiento se realiza en la nube, limitándose el dispositivo a la adquisición y transmisión de datos.

En paralelo, se realizaron pruebas exploratorias de entrenamiento de un modelo de IA para clasificación de fuentes de ruido utilizando la plataforma Edge Impulse con datos recolectados por otro dispositivo conocido por sus aplicaciones en tinyML. No obstante, dicho modelo no fue desplegado en el prototipo, por lo que no hace parte de la arquitectura actual.

5.2. Medición remota y gestión de la información del sistema IoT

El dispositivo para adquisición de información de temperatura, humedad y sonido desarrollado para la primera fase cuenta con un sensor de sonido ADMP401 y un sensor de temperatura y humedad

DHT22, integrados en una caja fabricada en material de filamento ácido poliláctico (PLA), que ofrece resistencia térmica y cierta protección frente a condiciones ambientales. Por otro lado, el dispositivo cuenta con una batería RCR123A. El sistema se gestiona a través de un microcontrolador ESP32, el cual permite tanto la adquisición de datos como la transmisión inalámbrica utilizando los protocolos de comunicación probados (Sigfox y Wifi). Finalmente, la información recolectada se envía a un servidor en la nube, específicamente en la plataforma Node-RED, donde se centraliza el almacenamiento y la visualización de los datos mediante dashboards interactivos en tiempo real.



Figura 4. Batería Utilizada en el dispositivo. Batería RCR123A

La figura 4 muestra la batería RCR123A la cual es recargable hasta 500-600 ciclos de iones de litio (Li-ion) de tamaño 16340, con un voltaje nominal de 3.7V y una capacidad típicamente entre 650 y 850 mAh, tiene una protección integrada contra sobrecarga y sobre descarga, y es ideal para dispositivos electrónicos de alto consumo [43].




Figura 5. Sensor de sonido utilizado en el dispositivo de IoT. Sensor de sonido ADMP401

El sensor de sonido se basa en un micrófono MEMS (Micro-Electro-Mechanical System) ADMP401, en la figura 5, montado en una placa de ruptura que posee una serie de ventajas clave para la integración en proyectos al destacarse en el mercado por su rendimiento, con una alta relación señal/ruido (SNR) de -62 dBA y buena sensibilidad operando con un bajo consumo de energía con un voltaje de alimentación que va de 1.5 V a 3.3 V y un ancho de banda útil por un roll off de -3 dB entre 100 Hz y 15 kHz. Es compatible con los procesos de montaje en superficie disponible en paquetes muy pequeños y no muestra casi ningún cambio en el rendimiento después de la soldadura por reflujo, además de poseer excelentes características de temperatura. El breakout incluye un amplificador con una ganancia de 67 y la salida de audio (AUD) del amplificador es fácilmente integrable, ya que flota a medio V_{cc} en ausencia de sonido y produce una señal de pico a pico de aproximadamente 200 mV al captar un volumen de conversación normal, facilitando su conexión directa al ADC de un microcontrolador [44].



Figura 6. Sensor de temperatura y humedad utilizado en el dispositivo de IoT. Sensor de temperatura y humedad DHT22

El sensor DHT22 es un dispositivo de medición digital y serial basado en el sensor AM2302, diseñado para una amplia gama de aplicaciones que incluyen equipos meteorológicos, reguladores de humedad, electrodomésticos, automóviles y cuartos de control, su operación es flexible, requiriendo un voltaje de alimentación entre 3.3 V y 5.5 V, y se conecta fácilmente mediante un cable de 3 hilos, se puede ver su estructura en la figura 6. En cuanto a la medición, el sensor tiene un rango de operación muy amplio, cubriendo temperaturas desde -40 hasta 80 °C y una humedad relativa que va de 0 al 99.9 %, no obstante, para garantizar una medición precisa, el rango de temperatura debe limitarse a 0 a 50 °C con una precisión de ± 2.0 °C, y el de humedad relativa a 20 % a 90 % RH con una precisión de ± 4 % RH y para asegurar la fiabilidad de las lecturas, el sensor requiere un tiempo de ciclo mínimo entre lecturas de 1 o 2 segundos [45].



Figura 7. Placa utilizada en dispositivo de IoT. Placa Seeed Studio XIAO ESP32C3

La Seeed Studio XIAO ESP32C3, que se muestra en la figura 7, es una mini placa de desarrollo ideal para el IoT, construida alrededor del versátil System on Chip (SoC) ESP32-C3 de Espressif se distingue por integrar una CPU RISC-V de 32 bits que garantiza un cálculo potente y eficiente y una conectividad inalámbrica con un excelente rendimiento de radiofrecuencia, soportando los estándares Wifi (IEEE 802.11 b/g/n) y Bluetooth 5 (BLE) de modo dual para maximizar el alcance y la fiabilidad de las aplicaciones inalámbricas, incluye una antena externa. Presenta un factor de forma pequeño y un diseño de montaje en superficie de un solo lado viene equipada con interfaces ricas: cuenta con 11 pines de E/S digitales (que pueden funcionar como pines PWM) y 4 pines de E/S analógicas (que sirven como pines ADC) como también es compatible con interfaces seriales comunes como UART, I2C y SPI e incluye un pequeño botón de reinicio y un botón para el modo bootloader. Por esto, se establece como una mini placa IoT de alto rendimiento, bajo consumo y rentable, especialmente indicada para el desarrollo de aplicaciones portátiles inalámbricas y soluciones IoT que requieren eficiencia energética [46].

Para determinar el número de datos necesarios para generar conclusiones con un margen de error del 2%, un nivel de confianza del 95% y una proporción estimada (p) de 0.5 para maximizar el tamaño de la muestra, se puede utilizar la fórmula del tamaño de muestra. En este caso, el valor Z correspondiente al 95% de confianza es aproximadamente 1.96. Sustituyendo estos valores en la fórmula, se calcula que se requieren aproximadamente 2401 datos, lo cual, asegura que el estudio tenga suficiente poder estadístico para detectar diferencias significativas dentro del margen de error especificado, permitiendo una evaluación precisa de la población en cuestión.

Se realizó la ubicación del dispositivo en conjunto con los sensores de temperatura, humedad y sonido en el laboratorio de ingeniería clínica, en un espacio estratégico central para poder obtener toda la información ambiental y se programó la toma de datos con un intervalo de medición de por lo menos cada 2 minutos con el modo de sueño profundo. Este modo se utilizó como una estrategia para optimizar el consumo energético del dispositivo y prolongar la autonomía de la batería, el funcionamiento continuo en modo activo no es adecuado para sistemas alimentados por baterías — pues implica un drenaje acelerado de energía—, se configuró el microcontrolador para suspender temporalmente las actividades de mayor demanda, como el procesamiento de la CPU y la comunicación Wifi. En este estado, el ESP32 mantiene únicamente activo el coprocesador de ultra bajo consumo, donde se reactiva el sistema en el tiempo programado.

Esto permitió tomar lecturas a intervalos regulares y así toda la información fue almacenada en un base de datos estructurada para el sistema de monitoreo, donde se configuró para que los datos se registraran automáticamente. Una vez comprobado que el dispositivo funcionó correctamente, se verificó la recolección de los datos que continuamente fueron enviados, se verificaron los registros utilizando un sistema de gestión de datos que almaceno automáticamente las mediciones en intervalos predeterminados para corroborar que cada uno de los registros correspondan a la frecuencia de toma con relación a la hora y fecha.

5.3. Evaluación de la confiabilidad y eficiencia del sistema IoT

Para evaluar la confiabilidad, eficiencia y estabilidad del sistema IoT durante el monitoreo continuo, se establecieron procedimientos cuantitativos y estadísticos orientados a analizar la integridad de los datos, la continuidad de la transmisión y el rendimiento energético del dispositivo.

Se aplicaron filtros de depuración para eliminar registros duplicados, incompletos o fuera del rango esperado, asegurando la validez y consistencia de la base de datos final. Los resultados fueron comparados con la frecuencia teórica programada (2 minutos) para identificar desviaciones, retrasos o pérdidas de comunicación. Se determinaron las tasas de pérdida de datos y la estabilidad del enlace entre el dispositivo y la nube. A su vez, se realizó un análisis visual y estadístico donde se emplearon histogramas, boxplots y líneas de tiempo para representar la distribución y evolución temporal de las variables ambientales (temperatura, humedad, sonido y voltaje). Por último, se analizaron las relaciones entre consumo energético y variables ambientales (temperatura, humedad y sonido), con el fin de determinar si existían patrones de mayor demanda de energía ante variaciones ambientales.

El rendimiento del sistema se midió empleando métricas clásicas en proyectos de IoT, incluyendo:

- Uptime (%): se refiere al tiempo operativo del sistema.
- Downtime (%): hace referencia a el tiempo de inactividad relativo al total del periodo de prueba.
- MTBF (Mean Time Between Failures): es una medida sobre el promedio de tiempo entre fallos detectados.
- MTTR (Mean Time To Recovery): esta medida es el tiempo medio de recuperación tras un fallo, valores que se estimaron con base en los registros de interrupciones en la transmisión y eventos de reconexión identificados en la base de datos.
- Métodos de detección de anomalías Z-score e IQR (Interquartile Range): esta medida permite identificar valores atípicos o comportamientos anómalos, diferenciando entre fluctuaciones esperadas del entorno y posibles errores de medición.

5.4. Entrenamiento e implementación del modelo de IA para el análisis acústico

En cuanto a el entrenamiento de IA como instrumento de recolección para detección de sonido se llevó a cabo mediante el uso de la placa de expansión (Sense Expansion Board) que se acopla a la XIAO ESP32S3 principal mediante un conector B2B, esta tarjeta es esencialmente la que agrega las funcionalidades de detección incluyendo el micrófono y una ranura para tarjeta MicroSD que soporta hasta 32 GB. En cuanto a las características técnicas del micrófono que se encuentra en esta placa, se trata de un micrófono de tipo PDM (Pulse Density Modulation) este utiliza el protocolo I2S para la comunicación de audio con el chip ESP32S3, específicamente empleando los pines GPIO 41 para los datos (DATA) y GPIO 42 para el reloj (CLK) está diseñado para operar en modo mono

(PDM_MONO_MODE) y la resolución de muestreo es de 16 bits, como la velocidad de muestreo más estable para el chip ESP32-S3 en esta configuración es de 16 kHz, estas características le permiten a la placa realizar funciones como la detección de sonoridad ambiental y la grabación de audio en formato WAV directamente a la tarjeta MicroSD [47].

Las grabaciones se realizarán en el laboratorio de ingeniería clínica de la universidad del rosario y se almacenarán inicialmente en formato WAV en la tarjeta SD, posteriormente, se subirán a la base de datos de Edge Impulse para su procesamiento y análisis y se considerarán como eventos sonoros de interés aquellos descritos en la literatura especializada en entornos neonatales, incluyendo alarmas, ruidos de equipos, voz adulta, llanto y pasos.



Figura 8. Instrumento de recolección para el modelo de IA. XIAO ESP32S3 Sense

De manera simultánea, para el entrenamiento de la IA para detección de ruido se realizó la grabación de los diferentes “ruidos” identificados en el laboratorio de ingeniería clínica de la universidad del Rosario con los dispositivos y elementos disponibles en el mismo como alcance contextual y financiero del proyecto, como lo son los equipos biomédicos en funcionamiento, sus alarmas o elementos del ambiente replicables, esta grabación será un espectrograma que se almacenará en una carpeta de único acceso para los investigadores y se utilizará para la creación de modelos de IA para identificar la fuente del “ruido”.

5.4.1. Entrenamiento de la IA:

Para el entrenamiento en Edge impulse se realizó de la siguiente manera:

Recolección de datos

El proceso de etiquetado de los audios se realizó a partir de la revisión de la literatura científica, donde se identificaron las principales fuentes sonoras presentes en entornos de cuidado neonatal (que se encuentra en la Tabla 2 Ruidos relevantes para el ambiente neonatal) incluyendo alarmas de equipos médicos, voces del personal, pasos, sonidos asociados a la atención cotidiana (como flujo de agua, manipulación de desechos o movimiento de mobiliario) y ruido ambiental, a partir de esta revisión, se establecieron las categorías acústicas y sus rangos típicos de intensidad (dB), utilizados como referencia para la clasificación posterior de los registros recolectados.

La adquisición de los audios se llevó a cabo en el laboratorio de ingeniería clínica, empleando el micrófono integrado en la Sense Expansion Board acoplada a la placa XIAO ESP32S3, debido a

limitaciones técnicas y de control del entorno, se registraron únicamente aquellas fuentes sonoras reproducibles en el laboratorio: alarma de ventilador, alarma de monitor, flujo de agua, cierre de contenedor de basura, movimiento mobiliario (sillas), pasos, voces y ruido de fondo.

El proceso de etiquetado de los audios se realizó de forma simultánea a la adquisición de los datos, empleando el micrófono integrado en la Sense Expansion Board acoplada a la placa XIAO ESP32S3, para esto antes de cada grabación se definía en el entorno de programación Arduino IDE la etiqueta correspondiente a la fuente sonora (por ejemplo, alarma de monitor, voz, sillas, pasos, agua, basura, ruido de fondo o alarma de ventilador). Una vez asignada la etiqueta, el sistema iniciaba la captura del sonido y almacenaba el archivo resultante con el nombre de la clase en la memoria microSD incorporada en la placa lo cual permitió que cada archivo de audio quedara automáticamente identificado desde su origen, evitando errores posteriores en la clasificación y asegurando la correspondencia directa entre el evento sonoro y su etiqueta.

Posteriormente, los audios fueron transferidos a la plataforma Edge Impulse, donde se realizaron los procesos de segmentación y extracción de características para el entrenamiento del modelo y se verificó la entrada de audio que correspondiera a la etiqueta y se tuvieran variaciones del sonido lo cual permitió garantizar la coherencia entre las etiquetas asignadas y las propiedades acústicas reales de los registros.



Figura 9. Datos recolectados para el modelo de IA. Se observa las etiquetas de cada clase, el tiempo total recolectado (con datos de menos de 1 segundo) los datos de test y de entrenamiento con la proporción de cada uno.

Cada grabación tuvo una duración de hasta 10 minutos, a partir de la cual se segmentaron fragmentos de menos de un segundo que contenían información valiosa con lo cual en cada clase quedaron datos entre 1 a 3 minutos, asegurando la captura de variaciones naturales en frecuencia e intensidad, estos audios fueron almacenados inicialmente en la memoria SD de la placa de

expansión y posteriormente cargados a la plataforma Edge Impulse, donde se realizó el corte y segmentación automática en fragmentos de 1 segundo para facilitar el entrenamiento supervisado. Con el fin de mantener la calidad y representatividad del conjunto de datos se aplicó un balance aproximado de 80-20 en la proporción entre entrenamiento y validación por clase, tanto el tiempo como el balance se puede observar en la ilustración 6. Para este entrenamiento no se implementaron técnicas de aumento de datos (data augmentation), más allá de los recortes realizados en las señales.

Adquisición de datos con hardware

Las grabaciones fueron realizadas utilizando una tarjeta Seeed Studio XIAO ESP32S3 con micrófono digital integrado, la recolección se efectuó en condiciones controladas dentro del laboratorio, con un promedio de 60 a 180 muestras por clase. Las especificaciones del dispositivo se encuentran en el apartado de Instrumentos de recolección.

Selección del algoritmo

Se evaluaron dos aproximaciones de modelado para así contrastar dos enfoques, uno con una red convolucional y otro basado en transfer learning, lo que permitió comparar desempeño y adaptabilidad al contexto del proyecto, se especifica su arquitectura a fondo:

1. **Modelo CNN propio:** Una red neuronal convolucional compuesta por capas convolucionales 2D con 8 y 16 filtros, seguidas de una capa de *dropout* del 50% para reducir el sobreajuste, una capa de *flatten* y una capa de salida configurada para reconocer las ocho clases acústicas. El entrenamiento se desarrolló durante 100 épocas, con una tasa de aprendizaje de 0,005 y un *batch size* de 25 y se aplicó la opción de auto-weight para la representación equivalente de los datos de cada clase. Además, se implementó una versión cuantizada del modelo en formato int8, optimizada para dispositivos embebidos.
2. **Transfer learning (Keyword Spotting):** Se entrenó un modelo Tiny Conv2D sin capa densa final y con *dropout* del 50%, también configurado para las ocho clases acústicas. Este modelo se entrenó durante 100 épocas, con tasa de aprendizaje de 0,005 y un *batch size* de 35.

El desempeño de los modelos se evaluó mediante métricas estándar de clasificación (precisión, recall y F1-score), con el fin de comparar objetivamente las diferentes arquitecturas probadas. Dado que la tarea corresponde a una clasificación multiclase, las métricas de precisión, recall y F1-score se calcularon utilizando el promedio ponderado (weighted average), tal como lo proporciona Edge Impulse. Esto permite evaluar el desempeño global considerando la contribución de cada clase según su frecuencia.

Diseño del impulso y Bloques de aprendizaje

El *impulse* inicial se configuró con audio como señal de entrada, empleando una ventana de análisis de 1000 ms con un *stride* de 500 ms y frecuencia de muestreo de 16 kHz, para la extracción de características se utilizó la técnica de *Mel Frequency Energy* (MFE), por su eficiencia en la representación espectral de los eventos acústicos [48]. En el segundo entrenamiento, se integró un bloque de *transfer learning* (Keyword Spotting) que también emplea MFE, aprovechando un modelo preentrenado optimizado para clasificación de audio en contextos con bases de datos reducidas.

Los bloques de aprendizaje empleados correspondieron, en primer lugar, a una CNN configurada manualmente en Edge Impulse, y, en segundo lugar, a un bloque de *transfer learning* Tiny Conv2D ambos se entrenaron bajo los parámetros descritos en la sección de la selección del algoritmo, ajustando proporciones de validación y tamaño de *batch* de acuerdo con la estrategia seleccionada.

Configuración de parámetros de procesamiento de la señal de entrada

La extracción de características acústicas se llevó a cabo con MFE (similar a MFCC), empleando ventanas de 1000 ms y frecuencia de muestreo de 16 kHz. La MFE utiliza una escala no lineal en el dominio de la frecuencia, denominada escala Mel la cual funciona con datos de audio como los del estudio, se escoge ya que se usa principalmente en reconocimiento no vocal, como lo son los audios del estudio de ruidos ambientales [48].

Detección de eventos

El evento por detectar correspondió a la fuente del sonido, es decir, identificar qué tipo de evento acústico se estaba produciendo y se configuró para la evaluación en conjuntos de datos estáticos, con el fin de validar la robustez del sistema frente a ruidos reales de un ambiente clínico de unidad de cuidados intensivos neonatales.

Medidas de evaluación

Para el desarrollo y validación del sistema se definieron indicadores técnicos que permiten evaluar su rendimiento:

- **Clasificación de fuentes de ruido:** identificación automática de categorías previamente definidas (alarmas, equipos, voz adulta, llanto, ambiente, entre otras).
- **Métricas de desempeño:** precisión (*accuracy*), sensibilidad (*recall*), precisión positiva (*precision*) y F1-score, como medidas para valorar la efectividad del modelo en la identificación y clasificación de eventos sonoros.

6. Resultados

6.1. Diseño e implementación de la arquitectura IoT para la adquisición de variables ambientales

El sistema IoT desarrollado fue evaluado en condiciones controladas dentro del laboratorio de ingeniería clínica, con el fin de analizar su desempeño en la captura y transmisión de variables ambientales (temperatura, humedad y nivel de sonido), así como en el comportamiento energético de su batería. La base de datos recopilada permitió aplicar técnicas de estadística descriptiva y análisis temporal para identificar patrones de funcionamiento, frecuencia de envío de datos, estabilidad operativa y posibles anomalías en las mediciones.

La base de datos contiene 7,890 registros recopilados con una frecuencia de envío configurada de 2 minutos, cubriendo un periodo de aproximadamente 12.8 días. En este intervalo se esperaban 9,204 registros, por lo que se obtuvo una tasa de pérdida del 14.28 %. El archivo descargado desde Firebase Realtime Database tiene formato JSON y pesa aproximadamente 1.57 MB. La estructura de cada registro incluye los campos: batería, fecha, humedad, sonido y temperatura.

El sistema registró un total de 7.890 datos completos durante el período experimental, el intervalo típico de envío correspondió a 2 minutos (mediana), lo cual se ajusta al intervalo esperado en la configuración inicial. El promedio real fue de 2,33 minutos, lo que evidencia un cumplimiento general del sistema en cuanto a la frecuencia de transmisión, aunque con ligeros retrasos ocasionales. En términos de continuidad, se identificaron 9 interrupciones importantes (gaps) en las que el dispositivo no reportó información por períodos superiores a 6 minutos, esto se reflejó en una tasa de pérdida de datos del 14,28 %, es decir, aproximadamente 1 de cada 7 registros no fue recibido. Considerando la duración total del experimento (18.407 minutos, equivalentes a ~12,8 días), puede afirmarse que el sistema mostró un desempeño estable, aunque con oportunidades de mejora en la robustez de la transmisión de datos. En un contexto clínico donde el neonato pierde 3 veces mayor calor corporal por minuto debido a la relación de peso y superficie corporal, donde en un ambiente de temperatura normal de 20-25°C perderían cada minuto 0,3°C siendo el promedio de 2,33 minutos aceptable para la necesidad del servicio con incubadoras con temperaturas de 35°.

El análisis de la variable batería mostró un comportamiento estable durante casi 13 días de monitoreo continuo, el voltaje medio fue de 3,30 V, con una desviación estándar baja (0,066 V), lo que indica un consumo uniforme, en esta el mínimo registrado (2,81 V) se encontró en el límite inferior de operación segura tanto para la batería como para el ESP32. La tasa media de descarga fue de -0,0012 V/h, lo que proyecta una autonomía superior a un mes en condiciones ideales si no existieran recargas intermedias y se detectaron al menos 4 eventos de recarga, lo cual explica que la regresión lineal simple no fuera representativa ($R^2 \approx 0$). Al relacionar el voltaje con las variables ambientales se encontraron correlaciones positivas moderadas con temperatura (0,50), humedad (0,37) y sonido (0,40), lo cual sugiere que el consumo energético puede estar influenciado por condiciones ambientales que demandan mayor procesamiento y transmisión de datos por parte del dispositivo.

En cuanto al consumo energético y autonomía del dispositivo la tabla 4 de mediciones puntuales de voltaje y corriente de la batería permite validar el comportamiento energético observado en los registros continuos. Se evidencia una disminución progresiva del voltaje, desde 4.175 V (28/08/2025) hasta 3.104 V (09/09/2025), lo cual refleja el proceso natural de descarga de la batería recargable (RCR123A). El valor final de 0 V registrado el 09/09 a las 16:43 confirma el agotamiento completo del suministro energético.

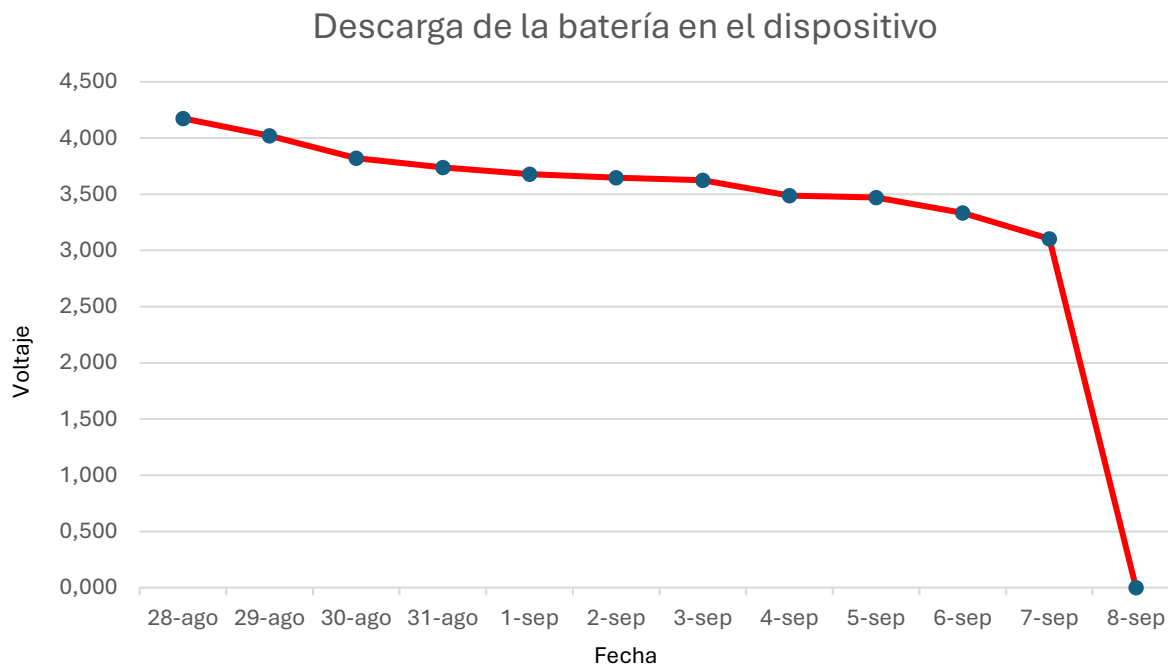


Figura 10 Descarga de la batería en el dispositivo

La anterior gráfica muestra la disminución progresiva del voltaje a lo largo de los días de monitoreo. Se observa una tendencia descendente desde valores cercanos a 4.1 V hasta el apagado completo en 0 V, lo que evidencia el ciclo de descarga natural de la batería durante el funcionamiento continuo del sistema.

En las mediciones puntuales de corriente de la batería se observó que el consumo de corriente osciló entre 10 mA y 38 mA a lo largo del periodo de prueba; los valores mínimos, cercanos a 12 mA, corresponden a los momentos en los que el dispositivo se encontraba en estado de bajo consumo o “sueño profundo”, mientras que los picos de corriente máxima, entre 32 mA y 38 mA, se asocian con las fases de transmisión de datos o procesamiento activo y a medida que avanzaron los días de observación, se identificó un aumento progresivo en la diferencia entre las corrientes máxima y mínima, que pasó de rangos de 2–5 mA en las primeras mediciones a valores superiores a 20 mA hacia el final del periodo.

Tabla 4 Mediciones de corriente del dispositivo

Fecha	Corriente Máxima	Corriente Mínima
28-ago	12,14 mA	10 mA
29-ago	17 mA	11,94 mA
1-sep	32 mA	12,1 mA
2-sep	32 mA	12,2 mA
3-sep	33 mA	12,4 mA
4-sep	32 mA	12,7 mA
5-sep	32 mA	11,2 mA
8-sep	38 mA	13,5 mA
8-sep	32 mA	13,3 mA
9-sep	32 mA	12 mA

En las mediciones puntuales de voltaje y corriente de la batería se identificó un aumento progresivo en la diferencia entre los valores de corriente máxima y mínima a lo largo del tiempo. En los primeros días de registro (28–29/08) esta diferencia se mantuvo reducida, con rangos cercanos a 2–5 mA. Sin embargo, hacia los últimos días del periodo de observación (08–09/09) la diferencia se incrementó de manera notable, alcanzando valores de hasta 24.5 mA.

La evolución de esta diferencia se representó en una gráfica de tendencia, en la cual se observa un crecimiento sostenido desde valores iniciales bajos hasta los máximos registrados en la fase final. Este comportamiento evidencia que, aunque el voltaje de la batería disminuyó de forma gradual (4.17 V al inicio a 3.10 V previo al apagado), la variabilidad de la corriente aumentó en paralelo, lo que indica un esfuerzo energético mayor del sistema conforme avanzaba el tiempo de uso.

Ahora bien, en cuanto a las pruebas de carga del dispositivo que se muestran en la tabla 2 el dispositivo paso de 0 V a su voltaje nominal máximo (≈ 4.1 V) en aproximadamente 2 horas de carga efectiva, aunque con un periodo prolongado de estabilización previa que sugiere que no estuvo en proceso de carga continua.




Figura 11 Proceso de carga de la batería del dispositivo

Durante las pruebas de carga, se registró un incremento del voltaje de la batería desde 0 V hasta 4.13 V en un intervalo aproximado de dos horas, lo que corresponde a un tiempo de carga completo bajo corriente controlada (≈ 12 mA) lo cual es coherente con las especificaciones de baterías de ion-litio de pequeña capacidad utilizadas en sistemas embebidos, donde la fase inicial presenta una rápida recuperación de voltaje y la fase final un incremento lento hasta alcanzar el voltaje nominal de carga.

6.2. Medición remota y gestión de la información del sistema IoT

Tras aplicar un proceso de limpieza y control de calidad (eliminando duplicados y registros fuera de rango), se obtuvo una base de datos final de 7.882 registros válidos, lo que representa una pérdida inferior al 0,2 %. Las variables monitorizadas incluyen una batería de 2,81–3,30 V, consistente con el rango operativo esperado para una celda RCR123A y un microcontrolador ESP32. La lectura de humedad de 46,1–65,6 % y de sonido de 0–60,7 dB, donde los valores cercanos a 0 representan lecturas espurias puntuales y el resto corresponde a fluctuaciones propias del espacio experimental. La temperatura estuvo en un rango de 20,5–24,8 °C, en coherencia con condiciones de laboratorio estable.

Este resultado garantiza la confiabilidad de la base para análisis posteriores, al demostrar que la adquisición de datos fue precisa y con mínima pérdida por errores en el registro, los histogramas confirman la estabilidad de la temperatura y la humedad, la irregularidad del sonido y la dinámica de la batería.

Distribución de variables registradas por el sistema IoT

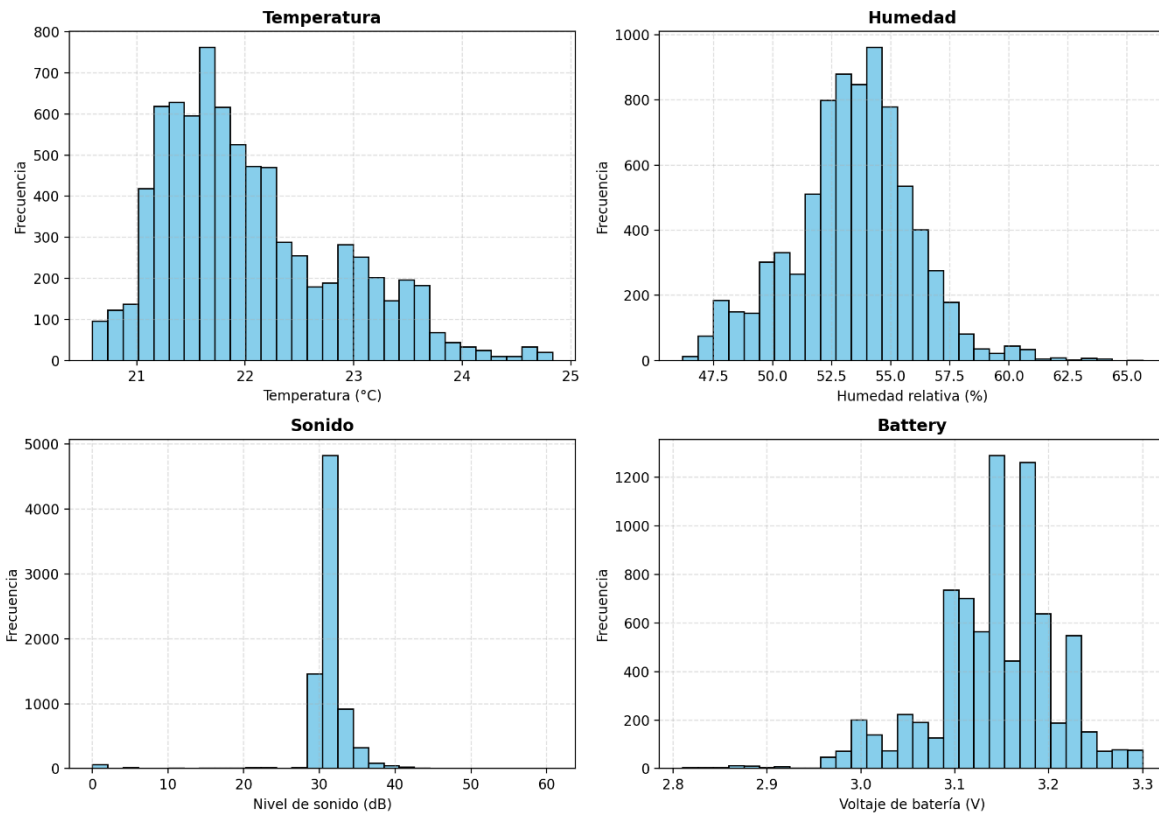


Figura 12 Histograma de las variables de temperatura, humedad, sonido y batería

En el histograma la temperatura se observa una distribución bastante simétrica y concentrada entre 21 y 23 °C, en concordancia con la media (≈ 22 °C). Los valores extremos son pocos y coinciden con los outliers detectados en el boxplot. En cuanto a la humedad presenta una distribución con centro en 53–55 %, reafirmando el promedio (≈ 53 %) y desviación estándar intermedia. Se observan valores dispersos hacia 60–65 %, que corresponden a los outliers ya identificados.

El sonido muestra una distribución asimétrica, con un pico marcado en torno a 30–32 dB, pero con valores dispersos hasta 60 dB. Esto coincide con la detección de anomalías, donde el sonido se identificó como la variable más crítica. Este hallazgo refuerza la necesidad de utilizar IA para identificar fuentes de ruido, no solo intensidades. Por último, para la batería exhibe una distribución multimodal con varios picos, reflejando momentos de recarga y descarga. Estos hallazgos concuerdan con las estadísticas temporales de subidas y caídas de voltaje y refuerzan la importancia del análisis energético para la confiabilidad del sistema IoT.

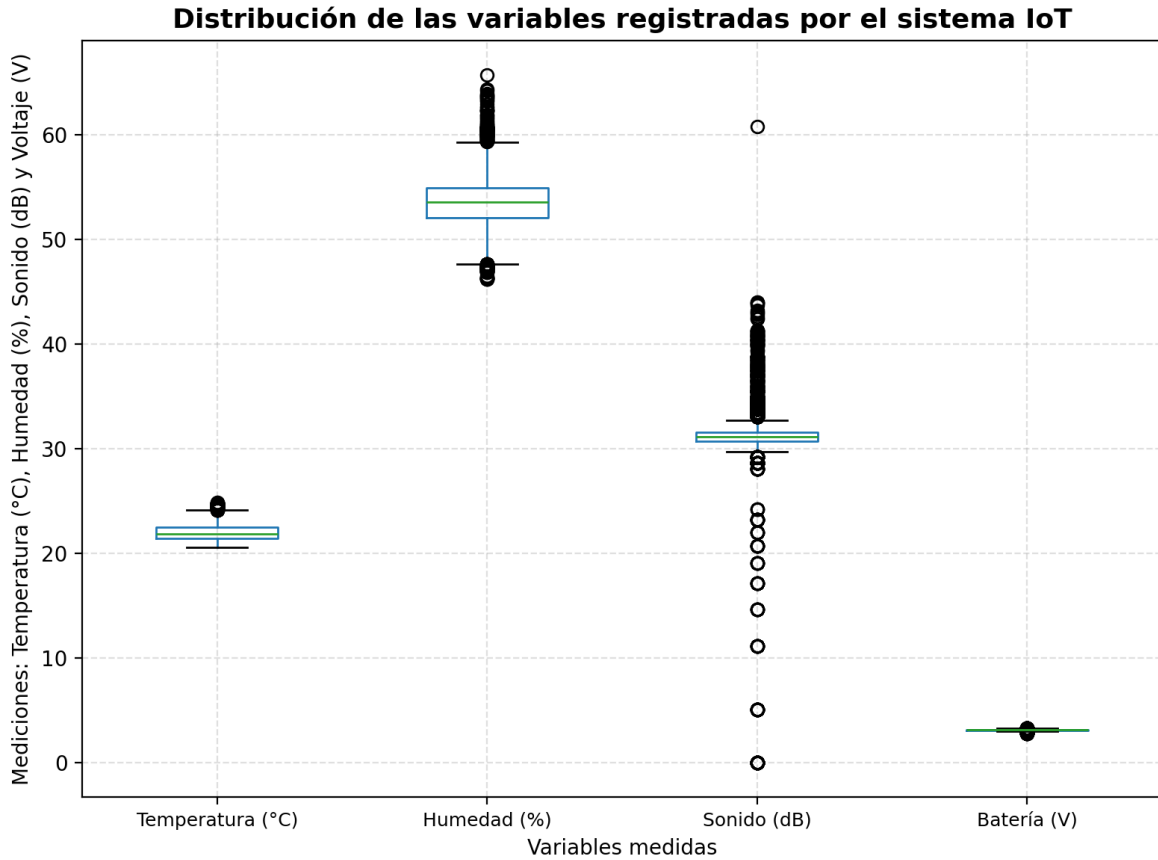


Figura 13 Distribución de las variables registradas por el sistema IoT

En el boxplot se puede observar que la temperatura muestra un rango estable entre 20.5 °C y 24.5 °C, con mediana cercana a 22 °C, en este solo se observan unos escasos outliers, lo que indica un sensor confiable. En cuanto a humedad se concentra en torno a 52–54 %, pero con outliers hacia 55–65 %, lo que sugiere variaciones puntuales de humedad, el sonido por su parte presenta una mediana ≈31 dB, pero con outliers hacia ambos extremos lo que indica un entorno acústico variable con picos de alarmas, voces o silencios en el laboratorio de ingeniería clínica. En cuanto a la batería se mantiene estable alrededor de 3.1–3.2 V, con variación mínima y casi sin outliers, lo que refleja un rendimiento energético estable.

6.3. Evaluación de la confiabilidad y eficiencia del sistema IoT

El análisis de los registros permitió explorar patrones globales en las variables ambientales monitorizadas, así como la calidad de los datos recopilados. Las variables mostraron rangos coherentes con las condiciones de un entorno controlado: temperatura entre 20.5 °C y 24.8 °C, humedad entre 46.1 % y 65.6 %, sonido entre 0 y 60.7 dB y voltajes de batería entre 2.81 V y 3.30 V.

La base de datos presentó distribuciones estables en las variables ambientales, con desviaciones estándar bajas (ej. temperatura = 0.81 °C), lo que indica homogeneidad en las condiciones de

prueba, asimismo, las correlaciones revelaron asociaciones moderadas entre la batería y variables ambientales como temperatura y sonido, lo que sugiere posibles efectos del entorno sobre el consumo energético. Finalmente, la detección de anomalías mediante métodos clásicos (Z-score e IQR) evidenció que, si bien los registros son consistentes, la variable de sonido presenta un mayor número de valores extremos, lo que se interpreta como un fenómeno esperable en entornos hospitalarios simulados y que motiva el desarrollo de modelos más avanzados de clasificación de fuentes sonoras.

A partir de la revisión de la literatura inicial, se estableció que el análisis de la fuente del sonido en entornos clínicos era un aspecto crítico, dado que solo cuantificar decibeles no permite discriminar entre ruidos ambientales, alarmas de equipos médicos u otros ruidos relevantes [23, 35, 36]. Posteriormente, el análisis de las variables registradas en el laboratorio de ingeniería clínica confirmó esta necesidad: mientras temperatura, humedad y batería mostraron comportamientos relativamente estables, la variable de sonido presentó alta variabilidad, numerosos valores atípicos y fluctuaciones bruscas.

El rendimiento del sistema se evaluó a partir del tiempo de actividad y la velocidad de respuesta, entendidos como indicadores fundamentales en el marco de proyectos de IoT. En cuanto al tiempo de actividad el análisis de los registros mostró un porcentaje de disponibilidad del 94.23 %, con una tasa de inactividad del 5.77 %. Se identificaron nueve fallos de transmisión, con un tiempo medio entre fallos (MTBF) de aproximadamente 32 horas y un tiempo medio de recuperación (MTTR) de dos horas. En cuanto a la velocidad de respuesta, aunque no se midió latencia de red de manera directa, la frecuencia real de envío de datos funcionó como indicador indirecto, la mediana de los intervalos de transmisión fue de 2 minutos, en concordancia con lo esperado, mientras que la media fue de 2.33 minutos, lo que refleja ligeros retrasos. Además, se detectaron nueve intervalos prolongados (gaps), superiores a 6 minutos, que representan momentos críticos en los que la información no estuvo disponible en tiempo real.

Durante el periodo de monitoreo se identificaron diversos eventos asociados a la dinámica del sistema y las condiciones ambientales registradas. En primer lugar, la detección de anomalías mediante métodos estadísticos evidenció diferencias en sensibilidad: el enfoque basado en Z-score identificó 60 valores atípicos en la variable de temperatura, 30 en humedad y 134 en sonido; mientras que el método IQR detectó un mayor número de casos, con 89 en temperatura, 253 en humedad y 1.555 en sonido.

En segundo lugar, se registraron interrupciones en la transmisión de datos y variaciones en la alimentación energética. Específicamente, se identificaron 9 gaps de transmisión superiores al umbral establecido y 4 recargas de batería durante el periodo de análisis.

Finalmente, el análisis temporal de las series mostró comportamientos diferenciados entre las variables: la temperatura presentó oscilaciones leves dentro de un rango estable, la humedad reflejó picos y descensos puntuales, el sonido exhibió variaciones abruptas y frecuentes, y la batería mostró un patrón de descarga progresiva intercalado con eventos de recarga. Estos hallazgos complementan el análisis estadístico y permiten caracterizar de manera detallada la evolución del sistema en condiciones reales de operación.




Figura 14 Línea temporal de las variables de temperatura, humedad, sonido y batería.

En la línea temporal se observa que la temperatura exhibe oscilaciones cíclicas, demostrando siempre en un rango seguro (21–24 °C), pero humedad presenta picos y descensos, confirmando la variabilidad ya vista en histogramas mostrando que el ambiente no siempre mantuvo un ambiente homogéneo. De manera similar en el sonido se evidencia picos frecuentes, lo que confirma su alta variabilidad, esta es la variable más inestable, reforzando la necesidad de un análisis más avanzado. Ya en cuanto a la batería esta desciende progresivamente con caídas y recuperaciones, reflejando recargas o reconexiones lo cual se relaciona con el análisis de uptime/downtime y la confiabilidad energética.

6.4. Implementación y entrenamiento del modelo de IA para el análisis acústico

Para el entrenamiento de la IA para identificación de sonido el primer entrenamiento del modelo se realizó a partir de un *impulse* configurado con audio como señal de entrada, utilizando una ventana de análisis de 1000 ms y un *stride* de 500 ms, con frecuencia de muestreo de 16 kHz. Para la extracción de características se empleó la técnica de Mel Frequency Energy (MFE), dado que permite representar de manera eficiente la información espectral relevante para la discriminación de eventos sonoros.

El clasificador implementado correspondió a una CNN, compuesta por capas convolucionales 2D con 8 y 16 filtros, seguidas de una capa de *dropout* del 50% para reducir el riesgo de sobreajuste, una capa de *flatten* y una capa de salida configurada para reconocer ocho clases de eventos acústicos: *agua*, *alarma de monitor*, *alarma de ventilador*, *basura*, *pasos*, *ruido de fondo*, *sillas* y *voces*.

El proceso de entrenamiento se desarrolló durante 100 ciclos (épocas), con una tasa de aprendizaje de 0,005 y un *batch size* de 25. Adicionalmente, se activó la opción de auto-weight para balancear

las clases durante el entrenamiento y se utilizó una versión cuantizada del modelo en formato int8, optimizada para su posterior implementación en dispositivos de cómputo embebido.

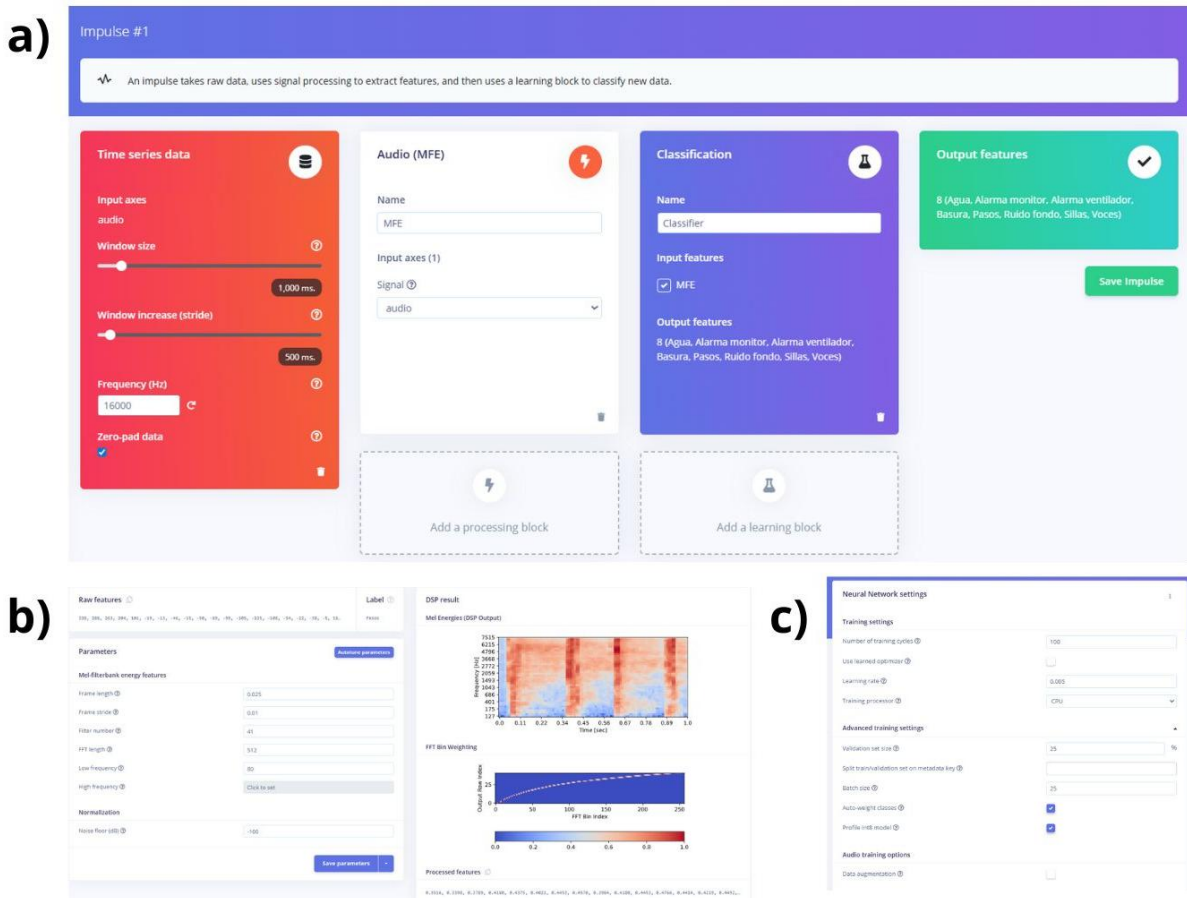


Figura 15 Entrenamiento del primer impulso. a) Bloques de aprendizaje. b) Extracción de características Mel Frequency Energy. c) Entrenamiento de la CNN

Durante el entrenamiento del modelo de clasificación de sonidos se obtuvo un desempeño excelente. En el conjunto de validación, el modelo alcanzó una precisión global (accuracy) del 99,0% con una pérdida (loss) final de 0,03. Al analizar las métricas ponderadas, la precisión promedio fue de 0,99, el recall de 0,99 y la F1-score de 0,99, lo que indica un equilibrio prácticamente perfecto entre la capacidad del modelo para identificar correctamente las clases y la detección de todas las instancias relevantes.

La matriz de confusión en la figura 16 mostró un desempeño óptimo en las clases agua, alarma de monitor, basura, pasos, ruido de fondo y voces, que alcanzaron valores de identificación del 100%. Se observaron únicamente pequeñas imprecisiones en dos categorías: la clase alarma de ventilador presentó 97,1% de aciertos y una leve confusión (2,9%) con la categoría de alarma de monitor; la clase sillas alcanzó 93,8% de aciertos y mostró una confusión del 6,3% con la clase pasos. Estas trazas de confusión son menores y no afectan la solidez general del modelo.



ACCURACY
99.0%



LOSS
0.03

Confusion matrix (validation set)

	AGUA	ALARMA	ALARMA	BASURA	PASOS	RUIDO FONDO	SILLAS	VOCES
AGUA	100%	0%	0%	0%	0%	0%	0%	0%
ALARMA	0%	100%	0%	0%	0%	0%	0%	0%
ALARMA	0%	0%	97.1%	2.9%	0%	0%	0%	0%
BASURA	0%	0%	0%	100%	0%	0%	0%	0%
PASOS	0%	0%	0%	0%	100%	0%	0%	0%
RUIDO FONDO	0%	0%	0%	0%	0%	100%	0%	0%
SILLAS	0%	0%	0%	0%	6.3%	0%	93.8%	0%
VOCES	0%	0%	0%	0%	0%	0%	0%	100%
F1 SCORE	1.00	1.00	0.99	0.98	0.97	1.00	0.97	1.00

Figura 16. Matriz de confusión primer impulso

Al desglosar las métricas por clase, en la tabla 4 las categorías con mejor desempeño fueron agua, alarma de monitor, ruido de fondo y voces (F1-score = 1,00). Las demás alcanzaron F1-scores muy altas: alarma de ventilador 0,99; basura 0,98; pasos 0,97; sillas 0,97. En conjunto, los resultados reflejan una capacidad de discriminación excepcional para la detección de fuentes sonoras en unidad de cuidados intensivos, con solo pequeñas superposiciones en clases acústicamente parecidas.





Tabla 5. Métricas por clase matriz entrenamiento

Clase	F1-score	Precision	Recall	Specificity	FNR
Agua	1.00	1.00	1.00	1.00	0.00
Alarma monitor	1.00	1.00	1.00	1.00	0.00
Alarma ventilador	0.99	1.00	0.97	1.00	0.03
Basura	0.95	0.95	0.95	0.995	0.05
Pasos	0.90	1.00	0.82	0.994	0.18
Ruido fondo	1.00	1.00	1.00	1.00	0.00
Sillas	0.93	0.90	0.95	0.995	0.05
Voces	0.97	1.00	0.95	0.995	0.05

Tras el reentrenamiento del modelo con parámetros conocidos, el desempeño global se mantuvo en un nivel muy alto. En el conjunto de validación, el modelo alcanzó una precisión global (accuracy) del 96,35%, con un área bajo la curva ROC (AUC) de 1,00, lo cual confirma su sobresaliente capacidad discriminativa en términos generales. Las métricas ponderadas reflejaron valores consistentes con este desempeño: precisión 0,98, recall 0,97 y F1-score 0,97, evidenciando un equilibrio adecuado entre la correcta identificación de las clases y la cobertura de las instancias relevantes.

 ACCURACY
96.35%

Metrics for Classifier

METRIC	VALUE
Area under ROC Curve 	1.00
Weighted average Precision 	0.98
Weighted average Recall 	0.97
Weighted average F1 score 	0.97

Confusion matrix

	AGUA	ALARMA M	ALARMA VE	BASURA	PASOS	RUIDO FON	SILLAS	VOCES	UNCERTAIN
AGUA	100%	0%	0%	0%	0%	0%	0%	0%	0%
ALARMA M	0%	100%	0%	0%	0%	0%	0%	0%	0%
ALARMA VE	0%	0%	97.1%	0%	0%	0%	0%	0%	2.9%
BASURA	0%	0%	0%	94.7%	0%	0%	5.3%	0%	0%
PASOS	0%	0%	0%	5.9%	82.4%	0%	0%	0%	11.8%
RUIDO FON	0%	0%	0%	0%	0%	100%	0%	0%	0%
SILLAS	0%	0%	0%	0%	0%	0%	95%	0%	5%
VOCES	0%	0%	0%	0%	0%	0%	5.3%	94.7%	0%
F1 SCORE	1.00	1.00	0.99	0.95	0.90	1.00	0.93	0.97	

Figura 17 Desempeño del primer impulso. Primer impulso desempeño post-entrenamiento con variables conocidas

El análisis de la matriz de confusión de validación mostró que las clases agua, alarma de monitor y ruido de fondo se clasificaron de manera perfecta (100% de aciertos y F1-score de 1,00). Asimismo, la mayoría de categorías presentaron un reconocimiento elevado, con ligeras confusiones: alarma de ventilador obtuvo 97,1% de aciertos, con un 2,9% de registros clasificados como uncertain; la clase basura alcanzó un 94,7% de aciertos, mostrando confusión marginal con sillas (5,3%); la clase pasos presentó un desempeño menor (82,4%), con errores distribuidos hacia basura (5,9%) y uncertain (11,8%); por su parte, sillas obtuvo 95% de aciertos con un 5% de muestras clasificadas como uncertain, mientras que voces registró 94,7% de aciertos y un 5,3% de confusión con sillas.

Tabla 6. Métricas por clase matriz validación

Clase	F1-score	Precision	Recall	Specificity	FNR
Agua	1.00	1.00	1.00	1.00	0.00
Alarma monitor	1.00	1.00	1.00	1.00	0.00
Alarma ventilador	0.99	1.00	0.97	1.00	0.03
Basura	0.95	0.95	0.95	0.995	0.05
Pasos	0.90	1.00	0.82	0.994	0.18
Ruido fondo	1.00	1.00	1.00	1.00	0.00
Sillas	0.93	0.90	0.95	0.995	0.05
Voces	0.97	1.00	0.95	0.995	0.05

Al desglosar las métricas por clase, se observaron F1-scores elevados: agua, alarma de monitor y ruido de fondo 1,00; alarma de ventilador 0,99; voces 0,97; basura 0,95; sillas 0,93; pasos 0,90. Estos resultados indican que, aunque algunas categorías acústicamente similares como pasos y sillas representan un mayor reto, el modelo conserva un nivel de precisión y generalización sobresaliente para la clasificación de eventos sonoros en unidad de cuidados intensivos.

El segundo entrenamiento del modelo se llevó a cabo mediante la implementación de un bloque de transfer learning (Keyword Spotting) en Edge Impulse, diseñado específicamente para trabajar con características de audio procesadas mediante Mel Frequency Energy (MFE) con una ventana de 1000 ms a 16 kHz. Este enfoque aprovecha un modelo preentrenado optimizado para tareas de clasificación de audio, permitiendo reutilizar el conocimiento adquirido en grandes bases de datos para mejorar el desempeño en contextos con conjuntos de datos más reducidos.

El modelo entrenado incluyó una arquitectura Tiny Conv2D sin capa densa final y con una capa de dropout del 50%, manteniendo la salida configurada para ocho clases acústicas (agua, alarma de monitor, alarma de ventilador, basura, pasos, ruido de fondo, sillas y voces). El entrenamiento se ejecutó en un total de 100 épocas, con una tasa de aprendizaje de 0,005 y un batch size de 35, lo cual proporcionó un mayor control sobre el rendimiento en datos no vistos durante la fase de aprendizaje.

Los resultados del modelo evidenciaron un desempeño con una exactitud global del 72,2% y una pérdida de validación de 1,05. El análisis de métricas adicionales mostró un área bajo la curva ROC (AUC) de 0,91, un promedio ponderado de precisión del 0,80, un recall del 0,72 y un F1-score de 0,72, lo que refleja un equilibrio aceptable entre las predicciones correctas y la capacidad de detección de las distintas clases. La matriz de confusión de validación indicó un reconocimiento óptimo de clases como agua y ruido de fondo (100% de aciertos), mientras que se observaron mayores confusiones en las categorías de alarma ventilador, pasos y voces, lo cual sugiere la necesidad de refinar la representatividad de estas clases en la base de datos para mejorar su discriminación.

El entrenamiento del bloque de *transfer learning* (Keyword Spotting) mostró un desempeño global sólido. En el conjunto de validación el modelo alcanzó una exactitud (accuracy) del 92,5% y una pérdida (loss) de 0,24. La capacidad discriminativa quedó reflejada en un AUC de 0,99, y las métricas ponderadas fueron precision 0,92, recall 0,92 y F1-score 0,92, lo que indica un buen equilibrio entre precisión y cobertura en la predicción de las distintas clases.

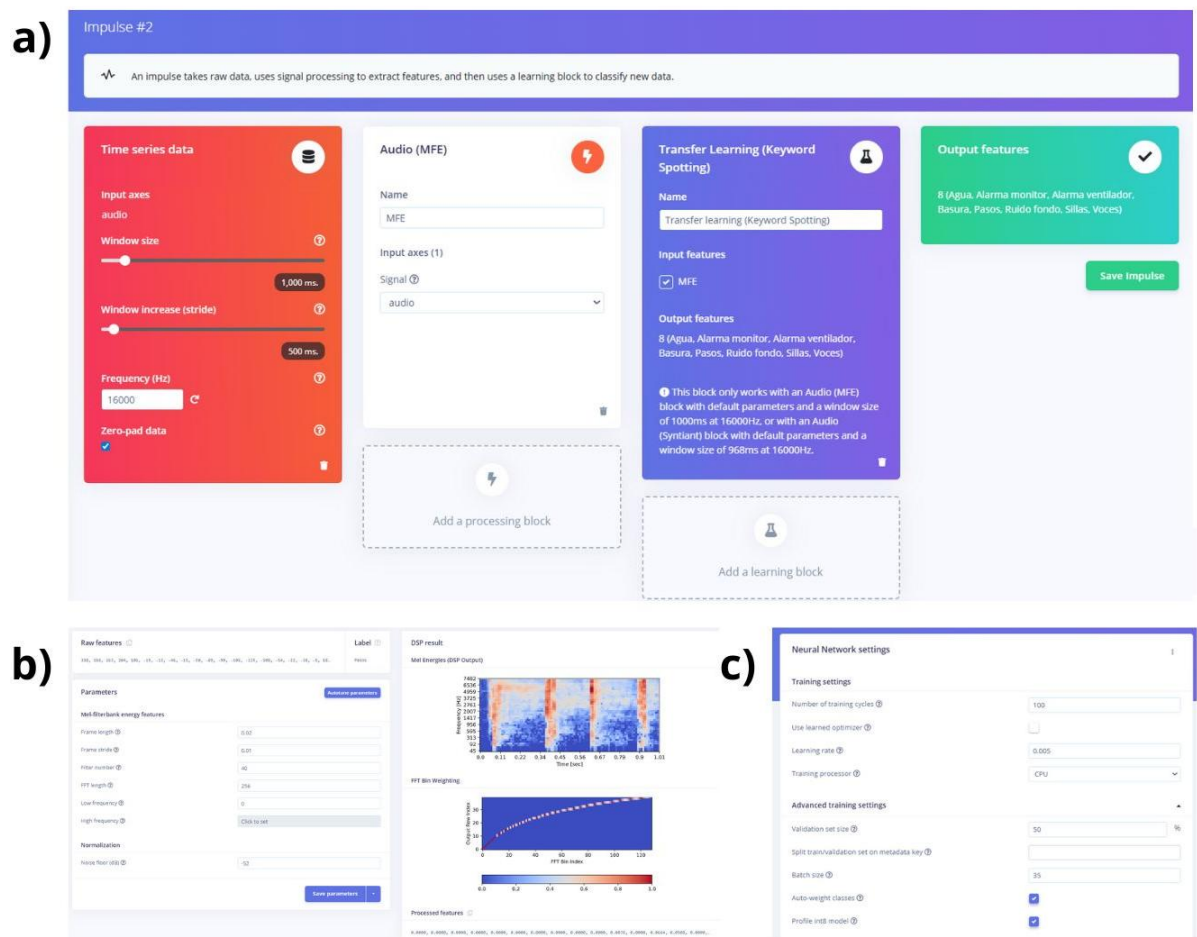


Figura 18 Entrenamiento del segundo impulso. a) Bloques de aprendizaje con Keyword Spotting. b) Extracción características Mel Frequency Energy. c) Entrenamiento del Keyword Spotting

El análisis de la matriz de confusión evidencia un comportamiento heterogéneo por clase. Clases claramente diferenciadas acústicamente como Agua y Ruido de fondo obtuvieron 100% de aciertos.

Alarma monitor y Alarma ventilador también mostraron alto desempeño (96,9% y 98,7% aciertos respectivamente), con pequeñas confusiones puntuales (por ejemplo, 1,6% de alarma monitor confundida con alarma ventilador y 1,6% con ruido de fondo; 1,3% de alarma ventilador confundida con voces). En contraste, categorías con patrones similares mostraron mayor solapamiento: Basura alcanzó 77,5% de aciertos (17,5% confundida con Pasos y 5% con Sillas) y Pasos 69,4% (22,2% confundida con Basura, 2,8% con Ruido de fondo y 5,6% con Sillas). Sillas y Voces presentaron aciertos de 91,4% y 89,2% respectivamente, con confusiones menores (ej. voces 10,8% confundida con ruido de fondo).

Desglosando por F1-score por clase: Agua 1,00; Alarma monitor 0,98; Alarma ventilador 0,99; Basura 0,78; Pasos 0,74; Ruido fondo 0,96; Sillas 0,90; Voces 0,92. Estos resultados indican que, si bien el modelo es fiable para detectar eventos claramente distintivos, sigue presentando limitaciones en la discriminación de sonidos acústicamente cercanos (especialmente Basura vs. Pasos), lo que se traduce en F1-scores más bajos en esas categorías.

En el entrenamiento de este con parámetros conocidos el accuracy global alcanzó el 88,54% y el AUC llegó a 0,99, asimismo, los valores ponderados de precisión (0,93), recall (0,92) y F1-score (0,92) muestran un equilibrio sólido entre la capacidad de identificar correctamente los sonidos y la consistencia en su clasificación. Al revisar el desempeño por clases, se observa que los sonidos de Agua y Alarma monitor fueron clasificados con un 100% de acierto, mientras que la Alarma ventilador obtuvo un 97,1%, con algunos errores mínimos al confundirse con Pasos. El Ruido de fondo también presentó una clasificación casi perfecta (F1 de 0,97).

ACCURACY
88.54%

Metrics for Transfer learning (Keyword Spotting)



METRIC	VALUE
Area under ROC Curve [?]	0.99
Weighted average Precision [?]	0.93
Weighted average Recall [?]	0.92
Weighted average F1 score [?]	0.92

Confusion matrix

	AGUA	ALARMA M	ALARMA VE	BASURA	PASOS	RUIDO FON	SILLAS	VOCES	UNCERTAIN
AGUA	100%	0%	0%	0%	0%	0%	0%	0%	0%
ALARMA M	0%	100%	0%	0%	0%	0%	0%	0%	0%
ALARMA VE	0%	0%	97.1%	0%	2.9%	0%	0%	0%	0%
BASURA	0%	0%	0%	63.2%	5.3%	0%	10.5%	0%	21.1%
PASOS	0%	0%	0%	0%	82.4%	5.9%	0%	0%	11.8%
RUIDO FON	0%	0%	0%	0%	0%	100%	0%	0%	0%
SILLAS	0%	0%	0%	5%	5%	5%	60%	0%	25%
VOCES	0%	0%	0%	0%	0%	0%	0%	84.2%	15.8%
F1 SCORE	1.00	1.00	0.99	0.75	0.82	0.97	0.71	0.91	

Figura 19 Desempeño del segundo impulso post-entrenamiento con variables conocidas

Por otro lado, las categorías con mayor dificultad fueron Basura y Sillas, con tasas de acierto del 63,2% y 60% respectivamente, mostrando confusión principalmente con Pasos y un porcentaje relevante asignado a la categoría uncertain, finalmente, sonidos como Pasos y Voces alcanzaron desempeños intermedios, con aciertos del 82,4% y 84,2%, y con proporciones importantes de clasificaciones en uncertain, el entrenamiento con parámetros conocidos permitió que el modelo alcanzara una mayor estabilidad, precisión y generalización, consolidando un rendimiento adecuado para la detección de sonidos críticos en ambientes hospitalarios, aunque persisten retos en la diferenciación de sonidos similares como Basura y Sillas.

Después del entrenamiento se embebió en el microcontrolador XIAO ESP32S3 Sense el modelo de IA previamente entrenado para el reconocimiento de sonidos del entorno, la prueba se realizó mediante la interfaz de Arduino IDE, configurando manualmente etiquetas preestablecidas que indicaban al sistema qué tipo de sonido debía identificar (por ejemplo, “alarma”, “voz” o “ruido ambiental”) probando cada una de las etiquetas del modelo en el laboratorio de ingeniería clínica. Durante las pruebas en laboratorio, el microcontrolador activó una luz indicadora cuando el sonido correspondiente a la etiqueta configurada fue detectado, confirmando así el funcionamiento adecuado del modelo embebido, el dispositivo logró reconocer correctamente todos los sonidos previamente entrenados cuando se le indicó explícitamente la categoría a buscar.

7. Discusión

Los hallazgos de esta investigación permiten caracterizar de manera integral el comportamiento de un sistema de monitoreo basado en IoT en un entorno clínico simulado, considerando variables ambientales críticas como temperatura, humedad y sonido, así como parámetros de operación del sistema como batería, transmisión de datos y disponibilidad. La discusión se centra en la estabilidad del sistema, la variabilidad de las variables ambientales y la pertinencia de estrategias avanzadas de análisis mediante IA para la interpretación de eventos sonoros.

Durante el monitoreo, se identificaron variaciones puntuales en las variables ambientales registradas. La temperatura y la batería mostraron un comportamiento estable, mientras que la humedad presentó variabilidad esperable, influenciada principalmente por factores climáticos locales, como la alta humedad relativa promedio en Bogotá (75–80%), que puede intensificarse debido a fenómenos climáticos atípicos. Esta variabilidad es consistente con la literatura sobre entornos hospitalarios y sus efectos sobre la salud, dado que niveles elevados de humedad aumentan la proliferación de hongos y ácaros, deterioran estructuras físicas y pueden agravar enfermedades respiratorias o reumáticas [49]. En contraste, la variable de sonido exhibió una dispersión significativamente mayor, reflejando su carácter intrínsecamente inestable en entornos clínicos simulados y la complejidad asociada a la interpretación de eventos acústicos.

La detección de valores atípicos mediante métodos estadísticos clásicos, como Z-score e IQR, permitió identificar anomalías específicas en cada variable: 60 para temperatura, 30 para humedad y 134 para sonido con Z-score; mientras que IQR detectó un número mayor de casos, especialmente en sonido (1.555). Este comportamiento evidencia que, aunque los registros son consistentes en términos generales, la variable de sonido concentra la mayor frecuencia de picos y anomalías, lo que coincide con la naturaleza fluctuante del entorno hospitalario y resalta la necesidad de modelos más avanzados capaces de clasificar la fuente de ruido. De esta manera, la integración de IA permitiría discriminar entre sonidos ambientales, alarmas de monitor, voces humanas o llanto de bebé, mejorando la interpretación de datos y la toma de decisiones en tiempo real.

El análisis de la batería reveló un consumo uniforme, con un valor mínimo registrado de 2,81 V, que se encuentra en el límite inferior de operación segura tanto para la batería como para el microcontrolador ESP32. Esta observación refuerza la necesidad de implementar alertas tempranas antes de alcanzar este umbral, proyectando una autonomía superior a un mes en condiciones ideales sin recargas intermedias. Las correlaciones moderadas entre la batería y variables ambientales como temperatura y sonido sugieren que factores externos pueden influir en el consumo energético, especialmente cuando el dispositivo requiere mayor procesamiento y transmisión de datos.

En el análisis de las mediciones puntuales de voltaje y corriente se observó un patrón interesante: mientras en los primeros días de registro (28–29/08) la diferencia entre corriente máxima y mínima permaneció reducida ($\approx 2\text{--}5$ mA), a medida que avanzó el tiempo esta diferencia se amplió de manera progresiva, alcanzando hasta 24.5 mA en los últimos días (08–09/09). Este comportamiento puede hipotetizarse desde tres perspectivas: I) los procesos de transmisión y reintentos propios del dispositivo IoT, que en determinados momentos incrementan el esfuerzo energético; II) la influencia de variables ambientales como el ruido y la temperatura, que mostraron correlaciones moderadas con la batería y pueden inducir mayor procesamiento en situaciones específicas; y III) el efecto de la degradación de la batería y el descenso del voltaje hacia su límite inferior de operación.

De estos supuestos, el más plausible según el comportamiento observado es el tercero. A medida que la batería se aproxima a su umbral de descarga segura (≈ 2.8 V en baterías de litio tipo

RCR123A), la estabilidad de entrega de corriente disminuye. En estas condiciones, pequeñas variaciones en la carga interna generan oscilaciones más amplias entre los valores máximos y mínimos de corriente. Así, el aumento progresivo de la diferencia de corriente a lo largo de los días refleja el esfuerzo creciente de la batería para sostener el consumo del ESP32 en voltajes cercanos a su límite operativo. En términos prácticos, este hallazgo indica que la degradación del voltaje tiene un impacto directo en la variabilidad del consumo, constituyendo un marcador más confiable de desempeño que las condiciones ambientales o las rutinas de transmisión.

En cuanto a la disponibilidad del sistema, se registró un uptime del 94,23 %, con un downtime del 5,77 % correspondiente a nueve fallos de transmisión. El tiempo medio entre fallos (MTBF) fue de aproximadamente 32 horas y el tiempo medio de recuperación (MTTR) de 118 minutos. Estos indicadores reflejan un desempeño estable en términos de continuidad operativa, aunque sugieren la necesidad de optimizar la gestión de fallos para minimizar los periodos de inactividad y garantizar un monitoreo continuo, especialmente en entornos clínicos donde la temporalidad de la información es crítica.

La estabilidad operativa demostrada por el sistema respalda su potencial utilidad en una UCIN, donde la continuidad del monitoreo es fundamental para garantizar intervenciones oportunas. La combinación de un uptime elevado y la identificación temprana de fallos posibilita la implementación de alertas basadas en umbrales críticos, permitiendo que el personal clínico reaccione de manera inmediata ante variaciones que puedan comprometer el bienestar del neonato. Además, la capacidad del dispositivo para integrarse con prácticas propias del cuidado centrado en el desarrollo —como la modulación del ruido, el control térmico, la organización ambiental y la contención postural— amplía su pertinencia clínica. El seguimiento longitudinal de las variables ambientales ofrece una comprensión más precisa del entorno al que está expuesto el recién nacido, superando las limitaciones de las mediciones puntuales y aportando un panorama más realista de la calidad sensorial del ambiente.

La relevancia de estos hallazgos se refuerza al considerar la interpretación avanzada de los datos acústicos mediante modelos de IA. La comparación entre dos enfoques —una red neuronal convolucional clásica (Impulse 1) y un modelo basado en transfer learning con Keyword Spotting (Impulse 2)— mostró que la CNN clásica alcanza un desempeño superior y más estable. En su primer entrenamiento, Impulse 1 logró un accuracy del 99,0 %, con métricas prácticamente perfectas en precisión, recall y F1-score (0,99) y un AUC de 1,00. La matriz de confusión evidenció reconocimiento perfecto en categorías simples y desempeño sobresaliente en clases complejas, demostrando su robustez y capacidad de generalización. Tras reentrenamiento con parámetros conocidos, el modelo mantuvo un rendimiento alto (accuracy 96,35 %), confirmando su estabilidad frente a variaciones en los datos. Por su parte, Impulse 2 presentó un desempeño competitivo pero menor en términos globales (accuracy inicial 92,5 %; accuracy tras reentrenamiento 88,54 %), con mayor confusión en categorías acústicamente similares, lo que evidencia la necesidad de más datos de entrenamiento y estrategias de preprocesamiento específicas para alcanzar la robustez de la CNN clásica.

Aunque el modelo embebido logró identificar los sonidos para los cuales fue entrenado, su funcionamiento actual presenta limitaciones relevantes para su aplicación práctica, en primer lugar, el sistema requiere que el usuario defina previamente una única etiqueta para detectar, lo que restringe su capacidad para analizar varios sonidos simultáneamente o adaptarse a condiciones cambiantes del entorno, adicionalmente el modelo únicamente indica la presencia del sonido (“detectado” o “no detectado”) sin ofrecer información contextual sobre su intensidad o relevancia. Esto implica que, si bien cumple su función de reconocimiento puntual, el sistema no permite generar

alarmas significativas para la toma de decisiones informadas dentro de un entorno clínico o sensorialmente controlado, esto subraya la necesidad de evolucionar hacia modelos más complejos y autónomos de detección sonora.

El análisis de estas variables adquiere una dimensión aún más profunda al considerar el impacto que tienen sobre el neurodesarrollo temprano, en este sentido, la caracterización de la temperatura, la humedad y el sonido realizada en el entorno controlado adquiere especial relevancia al considerar su relación directa con los requerimientos ambientales de una Unidad de Cuidado Intensivo Neonatal (UCIN). Estas variables constituyen componentes fundamentales del ambiente sensorial del neonato, y su adecuada regulación es indispensable para mantener la estabilidad fisiológica y prevenir condiciones adversas derivadas de la sobreestimulación, la exposición a niveles excesivos de ruido o la formación de microclimas inapropiados dentro de las incubadoras. Un sistema capaz de monitorear de manera continua la temperatura, la humedad y el sonido permite anticipar desviaciones antes de que generen riesgos clínicos, contribuyendo a la construcción de entornos protectores y más homogéneos, acordes con los lineamientos de cuidado centrado en el desarrollo, así, el sistema de monitoreo no solo cumple una función técnica, sino que se proyecta como una herramienta con potencial para apoyar la toma de decisiones en el contexto del neurodesarrollo.

En síntesis, los resultados indican que, mientras la temperatura y la batería del sistema se mantienen estables, la humedad refleja la dinámica ambiental y el sonido constituye la variable más crítica y propensa a valores extremos. La integración de análisis avanzado mediante IA se presenta como una estrategia clave para mejorar la interpretación de eventos acústicos y optimizar la confiabilidad del monitoreo, pero requiere para su funcionamiento embebido en el dispositivo otras formas de detección en tiempo real. Además, la caracterización del consumo energético, la autonomía de la batería y la disponibilidad del sistema proporcionan evidencia sólida de su viabilidad para aplicaciones de monitoreo continuo en entornos clínicos, al tiempo que destacan áreas de mejora, particularmente en la gestión de fallos y en la discriminación de eventos sonoros complejos.

8. Conclusiones

Los resultados obtenidos permiten concluir que el sistema de monitoreo basado en IoT mostró un desempeño sólido y confiable en condiciones simuladas de un entorno hospitalario. En contraste, el sonido se presentó como la variable más inestable y crítica, concentrando la mayor cantidad de valores extremos, lo que evidencia su complejidad y la necesidad de estrategias avanzadas de análisis para discriminar entre ruido ambiental, alarmas clínicas o eventos fisiológicamente relevantes.

El análisis energético demostró un consumo uniforme, con valores mínimos dentro del rango seguro de operación del ESP32 y la batería, proyectando una autonomía superior a un mes en condiciones ideales. Las variaciones observadas en la carga, así como la influencia de factores ambientales sobre el consumo, reflejan la importancia de implementar alertas tempranas y optimizar la gestión de energía para garantizar continuidad operativa. Durante el periodo de monitoreo, el sistema alcanzó un uptime del 94,23 %, con nueve fallos de transmisión registrados, un MTBF de 32 horas y un MTTR de aproximadamente dos horas, lo que indica un desempeño estable, pero con oportunidades de mejora en la gestión de fallos para reducir los periodos de inactividad y asegurar un monitoreo continuo en entornos críticos.

La detección de anomalías mediante métodos estadísticos clásicos permitió identificar picos y valores atípicos en todas las variables, siendo la variable de sonido la más afectada. Esto evidencia la necesidad de integrar modelos de IA capaces de clasificar la fuente del ruido y contextualizar su impacto, mejorando la interpretación de los datos y la toma de decisiones en tiempo real. En este sentido, la red neuronal convolucional clásica (Impulse 1) mostró un rendimiento superior y más estable que el modelo basado en transfer learning con Keyword Spotting (Impulse 2), alcanzando métricas altas de precisión, recall y F1-score, y demostrando robustez y capacidad de generalización frente a distintas clases de sonido. Por su parte, el modelo de Keyword Spotting, aunque competitivo, presentó mayor confusión en categorías acústicamente similares y dependió más de los parámetros de entrenamiento, indicando que requiere ajustes y más datos para alcanzar la misma consistencia. Para la implementación del modelo de IA en el dispositivo XIAO ESP32S3 Sense demostró la viabilidad técnica de integrar un sistema de reconocimiento de sonido directamente en hardware embebido, operando sin necesidad de conexión a la nube, no obstante, su funcionamiento dependiente de etiquetas únicas y su salida binaria limitan su aplicabilidad en contextos clínicos reales pero los resultados obtenidos confirman que el sistema es capaz de identificar los sonidos previstos, aunque requiere una ampliación funcional que le permita procesar y clasificar múltiples estímulos sonoros de forma autónoma y contextualizada.

En conjunto, estos hallazgos confirman que el sistema es capaz de monitorear de manera confiable variables ambientales críticas en entornos hospitalarios simulados, con un desempeño energético y operativo adecuado. Sin embargo, la interpretación de eventos sonoros complejos sigue siendo un desafío, por lo que la implementación de modelos de IA constituye una estrategia esencial para aumentar la confiabilidad, optimizar la toma de decisiones y garantizar la continuidad y pertinencia del monitoreo en escenarios clínicos reales.

Los sistemas IoT aplicados al cuidado neonatal han demostrado ser una alternativa tecnológica efectiva para el monitoreo remoto y continuo de variables críticas, especialmente en incubadoras. Su capacidad para funcionar de manera accesible, eficiente y a bajo costo los convierte en una herramienta valiosa para fortalecer la seguridad del paciente y apoyar prácticas de cuidado centrado en el desarrollo. En esta propuesta, aunque el dispositivo se evalúe únicamente en un ambiente

controlado, su diseño orientado al monitoreo de temperatura, humedad y sonido permite visualizar su potencial futuro en la generación de alertas tempranas basadas en umbrales críticos, favoreciendo la detección de condiciones ambientales adversas antes de que impacten la estabilidad fisiológica del neonato. Además, este tipo de sistemas podría integrarse con estrategias clínicas como el control del ruido, protocolos de mínima manipulación, manejo térmico y medidas de contención, aportando a los equipos médicos información longitudinal del ambiente—no solo mediciones aisladas—para tomar decisiones más precisas y alineadas con las necesidades sensoriales del bebé prematuro. Así, el desarrollo y prueba del sistema en un ambiente controlado permite no solo validar su funcionamiento, sino también abrir posibilidades de investigación clínica fundamentales para el campo neonatal.

9. Recomendaciones y trabajos futuros

Los resultados obtenidos sugieren varias líneas de acción para optimizar el desempeño del sistema y ampliar su aplicabilidad en entornos hospitalarios reales. En primer lugar, se recomienda fortalecer la gestión de fallos y la continuidad operativa, implementando mecanismos de recuperación automática ante interrupciones de transmisión y alertas tempranas ante descargas críticas de la batería, esto permitiría reducir los periodos de inactividad, garantizaría un monitoreo continuo y confiable, especialmente en entornos clínicos donde la disponibilidad de datos es fundamental. Asimismo, se sugiere explorar estrategias de optimización energética que consideren la influencia de variables ambientales sobre el consumo del dispositivo, con el fin de prolongar la autonomía y mejorar la eficiencia del sistema.

En términos de desarrollo de modelos de IA, con los hallazgos se propone como proyección de desarrollo, que el sistema embebido evolucione hacia una versión más autónoma e inteligente, capaz de operar con criterios de detección más cercanos a las condiciones reales de una unidad clínica, en esta nueva etapa, el dispositivo integraría umbrales dinámicos de nivel sonoro (en decibelios) que activen la detección automática únicamente cuando el ruido ambiental supere los límites clínicamente recomendados, garantizando así un monitoreo más eficiente y selectivo. Asimismo, el modelo de IA incorporaría un sistema de reconocimiento probabilístico multinivel, de manera que, en lugar de limitarse a confirmar la presencia de un solo tipo de sonido, pueda estimar la probabilidad asociada a diversas categorías, como alarmas médicas, voces humanas o ruidos ambientales, todo este procesamiento se realizaría de forma local en el microcontrolador XIAO ESP32S3 Sense, sin necesidad de conexión a la nube, fortaleciendo la respuesta en tiempo real y se plantea que la clasificación obtenida se vincule con mecanismos de alerta adaptativa, capaces de generar notificaciones o registros automáticos cuando se identifiquen sonidos críticos o prolongados, como alarmas médicas que excedan la duración o intensidad permitida en entornos neonatales.

A su vez, este tipo de tecnología abre oportunidades significativas para la investigación en entornos neonatales. El registro continuo y estructurado de variables ambientales permite el desarrollo de estudios correlacionales entre el ambiente sensorial de la UCIN y diversos indicadores clínicos, como la estabilidad cardiorrespiratoria, los patrones de sueño, el estrés neonatal y las respuestas conductuales. Aunque el dispositivo aún no se implementa en un hospital real, su evaluación en un entorno controlado constituye un paso fundamental para validar su funcionamiento y proyectar futuras aplicaciones clínicas. De esta manera, el sistema no solo aporta al monitoreo ambiental, sino que también constituye una plataforma útil para avanzar en la comprensión de cómo los entornos hospitalarios influyen en el bienestar y el neurodesarrollo de los neonatos.

Finalmente, se sugiere que trabajos futuros exploren la implementación del sistema en entornos hospitalarios reales y su interacción con equipos y el desarrollo neurosensorial del neonato, evaluando por un lado el impacto de la infraestructura física sobre la transmisión de datos y la calidad de las mediciones como por otro lado investigar la relación entre las variables ambientales monitoreadas y la salud de los pacientes recién nacidos, para validar la pertinencia clínica del monitoreo continuo y establecer protocolos que contribuyan a la prevención de riesgos asociados a humedad, ruido y temperatura para traer objetividad a el campo de la integración sensorial en UCIN. Estas líneas de investigación no solo fortalecerían la aplicabilidad del sistema, sino que también consolidarían su rol como herramienta de apoyo a la gestión ambiental y clínica en contextos hospitalarios complejos.

10. Anexos

Anexo 1. Aval Comité de Ética



COMITÉ DE ÉTICA EN INVESTIGACIÓN DE LA UNIVERSIDAD DEL ROSARIO
SALA DE CIENCIAS DE LA VIDA

- MEMBROS**
- Carlos Enrique Trillos Peña
Médico Cirujano, MSc, Epidemiología
Preventiva
- Alix Rocio Barríos Méndez
Médica, MSc, en Epidemiología
Sistémica Clínica
- Guillermo Sánchez Vanegas
Farmacología, MSc, PhD en Ciencias
- Rafael Franco Novales
En Epidemiología, PhD en Matemáticas
- Katherine Quintero Pineda
Química Farmacéutica
- Andrea Torres Ruiz
Ingeniería Biomédica, MSc, Inal. Bioinformática
y Bioestadística
- David Pineda Barrantes
Médico Radiólogo, MSc, Administración de
Especialidad, PhD en Ciencias de la Educación
- Tatiana María Barreto
Enfermería, MSc, en Salud Pública
- Jairo Osvaldo Luján
Licenciado en Biología (MSc) y Biología (MSc),
MSc, en Estudios Interdisciplinarios, PhD en
Estudios Humanísticos
- Paola Prada Sarmiento
Bióloga, MSc, Biología, PhD en Estudios
Evolucionarios
- Luzmeiro Becerra Arias
Médico, PhD en Salud Comunitaria, PhD en
Estudios Públicos
- Martha Isabel Barchiesi Duarte
enfermería

DV0005 2854 – CV1927
Bogotá D. C., 27 de febrero de 2025

Doctor
JEFFERSON SARMIENTO ROJAS
Investigador Principal
Estudio: "Cuidado Neonatal mediante Internet de las Cosas Medicas: Validación y Evaluación de un Sistema de Monitoreo en Incubadoras".
Bogotá, D. C.

Respetado Investigador:

El Comité de Ética en investigación de la Universidad del Rosario (CEI-UR), evaluó su proyecto de investigación "Cuidado Neonatal mediante Internet de las Cosas Medicas: Validación y Evaluación de un Sistema de Monitoreo en Incubadoras".

- Fecha de recepción primera versión del protocolo: 18 de octubre de 2024.
- Fecha de evaluación primera versión del protocolo: Sesión plena, 21 de noviembre de 2024.
- Fecha de recepción segunda versión del protocolo: 7 de febrero de 2025.
- Fecha de evaluación segunda versión del protocolo: Evaluación expedita; 27 de febrero de 2025.

El Comité de Ética en Investigación de la Universidad del Rosario (CEI-UR) acusa recibo de la respuesta a las observaciones emitidas por nosotros en el comunicado DV0005 2795-CV1927, y APRUEBA la realización del proyecto de investigación. La información quedará dispuesta en el archivo del CEI-UR

Para el Comité de Ética es importante acompañarlo durante la ejecución del estudio. Por favor no dude en contactarnos en caso de tener alguna inquietud o de necesitar apoyo para el análisis de alguna situación específica. De igual forma le recomendamos notificar cualquier modificación en la ejecución del estudio no expuesta en la aprobación inicial del proyecto.

Carrera 24 N° 63C-69 Bogotá
Teléfono: 2970200 Ext. 3295
E-mail: comite.etica@urosario.edu.co

DV0005 2854-CV1927
Página 1 de 2



COMITÉ DE ÉTICA EN INVESTIGACIÓN DE LA UNIVERSIDAD DEL ROSARIO
SALA DE CIENCIAS DE LA VIDA

- MEMBROS**
- Carlos Enrique Trillos Peña
Médico Cirujano, MSc, Epidemiología
Preventiva
- Alix Rocio Barríos Méndez
Médica, MSc, en Epidemiología
Sistémica Clínica
- Guillermo Sánchez Vanegas
Farmacología, MSc, PhD en Ciencias
- Rafael Franco Novales
En Epidemiología, PhD en Matemáticas
- Katherine Quintero Pineda
Química Farmacéutica
- Andrea Torres Ruiz
Ingeniería Biomédica, MSc, Inal. Bioinformática
y Bioestadística
- David Pineda Barrantes
Médico Radiólogo, MSc, Administración de
Especialidad, PhD en Ciencias de la Educación
- Tatiana María Barreto
Enfermería, MSc, en Salud Pública
- Jairo Osvaldo Luján
Licenciado en Biología (MSc) y Biología (MSc),
MSc, en Estudios Interdisciplinarios, PhD en
Estudios Humanísticos
- Paola Prada Sarmiento
Bióloga, MSc, Biología, PhD en Estudios
Evolucionarios
- Luzmeiro Becerra Arias
Médico, PhD en Salud Comunitaria, PhD en
Estudios Públicos
- Martha Isabel Barchiesi Duarte
enfermería

Cordialmente,

CARLOS ENRIQUE TRILLOS PEÑA.
Presidente
(CEI-UR)

Alix Rocio Barríos Méndez.
Secretaria Técnica
(CEI-UR)

v. e. Méthex
Pineda; Martha Isabel Barchiesi

Este comité se rige por los lineamientos jurídicos y éticos del país a través de las resoluciones RAD0 de 1993 y 1978 de 2008 del Ministerio de Salud y Promoción Social, igualmente, se rigen los acuerdos contemplados en la Resolución de Rectoría 01/2021 y en la Conferencia Internacional de Asociación para las Buenas Prácticas Clínicas.
Reservados todos los derechos. No se permite la explotación económica ni la transformación de esta obra. Queda permitida la impresión en su totalidad.
<https://www.urosario.edu.co/investigacion/comite-de-etica-en-investigacion>

Carrera 24 N° 63C-69 Bogotá
Teléfono: 2970200 Ext. 3295
E-mail: comite.etica@urosario.edu.co

DV0005 2854-CV1927
Página 2 de 2

Anexo 2. Certificado Tercer puesto en la categoría de Mejores Propuestas de Investigación en el VIII Encuentro CIMED – 2024



El Centro de Investigaciones de Méderi
le otorga el 3er lugar en el concurso de trabajos de investigación
en modalidad de "Propuesta de Investigación", al trabajo titulado:

Implementación de un Sistema Piloto para Garantizar la Seguridad Neonatal a través del Monitoreo de Variables Operativas de Incubadoras en el Hospital de Méderi

Jefferson Sarmiento Rojas, Pedro Antonio Aya, Valeria Tabares Sánchez, Viviana Rodríguez Torres, Nidia Patricia Córdoba

Para constancia se firma en la ciudad de Bogotá, Colombia
a los 12 días del mes de abril de 2024

Luis Carlos Venegas Sanabria
Jefe de Investigaciones
Méderi

Guillermo Sánchez Vanegas
Director Científico
Méderi



Anexo 3. Notificación resultados presentación poster en el XII Congreso Panamericano de Neonatología 2024



Informe sobre admisión de resúmenes enviados e instrucciones para elaboración de ePoster

Estimado usuario Jefferson Sarmiento Rojas (878)

Cordial saludo

La organización del congreso desea agradecer su participación. Su trabajo es altamente valorado por parte de los jurados que lo han evaluado. La evaluación de admisión ha arrojado resultados que se describen a continuación.

Nro. 151 - Sistema de monitoreo de variables operativas en incubadoras en el servicio de neonatología de un hospital de alta complejidad a través del Internet de las Cosas (IoT)

Estado: **ADMITIDO como ePOSTER**

Para los trabajos ADMITIDOS y como resultado de una nueva fase de evaluación que llevarán a cabo pares académicos es posible que su trabajo sea seleccionado para ser presentado también de forma oral. En caso de que suceda lo anterior, la decisión le será anunciada a más tardar el 30 de septiembre.

Anexo 4. Certificado de asistencia para el XIV Congreso Colombiano de Neurociencias y XV Seminario Internacional de Neurociencias COLNE 2025.

20 COLNE
Colegio Colombiano de Neurociencias

**XIV CONGRESO NACIONAL
XV SEMINARIO INTERNACIONAL
DE NEUROCIENCIAS**

**INTERNATIONAL BRAIN
IBRO
RESEARCH ORGANIZATION**

CERTIFICADO
de Asistencia

El Colegio Colombiano de Neurociencias -COLNE-
certifica que:

Valeria Tabares Sánchez

Participó en el evento en calidad de:

ASISTENTE

Bogotá D.C., [Colombia], Abril 24 al 26 de 2025

Pablo Reyes Gavilán, PhD
PRESIDENTE COLNE

Laura A. León Anhuamán, Ph.D.
DIRECTORA EJECUTIVA COLNE

www.colne.org.co

Anexo 5. Notificación de aceptación del póster para el XIV Congreso Colombiano de Neurociencias y XV Seminario Internacional de Neurociencias COLNE 2025.



Estimado/a Jefferson Sarmiento,

Nos complace informarle que su trabajo titulado "**Cuidado Neonatal mediante Internet de las Cosas Medicas: Validación y Evaluación de un Sistema de Monitoreo en Incubadoras**" ha sido aceptado para su presentación en formato **POSTER ON-LATE** en el **XIV Congreso Colombiano de Neurociencias - XV Simposio Internacional de Neurociencias**, que se llevará a cabo del **24 al 26 de abril en Bogotá**.

Detalles importantes:

- **Código de poster:** CN404.
- **Recomendaciones y detalles:** En la [página web del congreso](#) puede encontrar las recomendaciones para la presentación de posters. Desde la próxima semana se anunciará la hora y fecha en la cual esperamos que puedan exponer los posters.
- **Tamaño de póster:** Las dimensiones del póster deben ser de 70 cm de ancho por 100 cm de alto. Para su instalación, se recomienda utilizar cinta doble faz, ya que no se permiten tubos, barillas ni chinchas. Le recordamos que el formato es VERTICAL.
- **Recomendaciones durante la exhibición:** Los pósters serán exhibidos en jornadas de la mañana o la tarde. Durante cada jornada, se habilitará una hora especial en la que los jurados de evaluación pasarán a revisar los trabajos. Los mejores pósters serán premiados, por lo que su presencia en dicha actividad es indispensable.
- Para la exhibición de posters deberá estar inscrito/a al congreso.

XIV Congreso Colombiano de Neurociencias / XV Simposio Internacional de Neurociencias

- **CN401: DISTRIBUCIÓN DE RECURSOS EN NIÑOS CON DISCAPACIDAD INTELECTUAL LEVE, DESDE LA TEORÍA DE LA MENTE Y EL DESEMPEÑO EJECUTIVO FRIO Y CALIENTE** - Rolan Correa Lopez
- **CN402: Time-varying changes in visuocortical tuning during aversive conditioning: a trial-by-trial analyses using steady-state visual evoked potentials in human observers** - Judith Cristina Cediel Escobar
- **CN403: Efectos de la autoestimulación intracerebral sobre la ansiedad en ratas Wistar** - Yoly Carolina Rodriguez-Rojas
- **CN404: Cuidado Neonatal mediante Internet de las Cosas Medicas: Validación y Evaluación de un Sistema de Monitoreo en Incubadoras** - Jefferson Sarmiento
- **CN406: Conocimiento de síntomas y de factores riesgo de ataque cerebrovascular por parte de convivientes de personas con riesgo en el municipio de Villahermosa Tolima en 2024** - Daniel Felipe Loaiza Ruiz - Néstor Devia Diaz
- **CN407: Determinantes sociales de la salud y salud cerebral: una revisión sistemática enfocada en las mujeres** - Laura Mercedes Moreno Hernández

Anexo 6. Base de Datos Central en la nube

Link de acceso: https://drive.google.com/file/d/1LXZZJAQcUMgNtWxdJmc6kZsYcM4Q-alh/view?usp=drive_link

Bibliografía

- [1] Ohuma EO, Moller A-B, Bradley E, et al. National, regional, and global estimates of preterm birth in 2020, with trends from 2010: a systematic analysis. *The Lancet*. 2023;402(10409):1261-1271.
- [2] Mathers CD. History of global burden of disease assessment at the World Health Organization. *Archives of Public Health*. 2020; 78:1-13.
- [3] Jain N. Early diagnosis and intervention—On neonatal follow-up. In: *Principles of Neonatology*. Elsevier; 2024. p. 797-801.
- [4] El-Metwally DE, Medina AE. The potential effects of NICU environment and multisensory stimulation in prematurity. *Pediatr Res*. 2020;88(2):161-162.
- [5] Chung EH, Chou J, Brown KA. Neurodevelopmental outcomes of preterm infants: a recent literature review. *Transl Pediatr*. 2020;9(Suppl 1): S3.
- [6] Graven SN, et al. The high-risk infant environment. Part 2. The role of caregiving and the social environment. *J Perinatol*. 1992;12(3):267-275.
- [7] Als H, McAnulty GB. The newborn individualized developmental care and assessment program (NIDCAP) with kangaroo mother care (KMC): comprehensive care for preterm infants. *Curr Womens Health Rev*. 2011;7(3):288-301.
- [8] Balseiro-Almario L, et al. Prevención de alteraciones ambientales que inciden en el neurodesarrollo de los neonatos en la UCIN: Intervenciones de Enfermería Especializada. *Rev Enferm Neurol*. 2016;15(3):139-152.
- [9] Graven SN, Browne JV. Sensory development in the fetus, neonate, and infant: introduction and overview. *Newborn Infant Nurs Rev*. 2008;8(4):169-172.
- [10] Gubbi J, Buyya R, Marusic S, Palaniswami M. Internet of Things (IoT): A vision, architectural elements, and future directions. *Future Gener Comput Syst*. 2013;29(7):1645-1660.
- [11] Ray PAP. A review on TinyML: State-of-the-art and prospects. *J King Saud Univ Comput Inf Sci*. 2022;34(4):1595-1623.
- [12] Yap XHV, Tu KC, Chen NC, et al. Developing a high-performance AI model for spontaneous intracerebral hemorrhage mortality prediction using machine learning in ICU settings. *BMC Med Inform Decis Mak*. 2025;25(1):149.
- [13] Kim E, Kim J, Park J, Ko H, Kyung Y. TinyML-based classification in an-ECG monitoring embedded system. *Comput Mater Continua*. 2023;75(1).
- [14] Mala DJ, Padmavathy TV, Reynold AP, Meena M. Edge analytics with TinyML technique for MIoT applications for personalized healthcare in smart nation. In: *2023 Second International Conference on Smart Technologies for Smart Nation (SmartTechCon)*. IEEE; 2023. p. 39-54.
- [15] Mihigo IN, Zennaro M, Uwitonze A, Rwigema J, Rovai M. On-device IoT-based predictive maintenance analytics model: comparing TinyLSTM and TinyModel from Edge Impulse. *Sensors*. 2022;22(14):5174.
- [16] Mohino-Herranz I, García-Gómez J, Alonso-Díaz S, et al. Implementing transfer learning for sound event classification using the Realised Audio Database. *Measurement: Sensors*. 2025;101711.

- [17] Jung S, Park J, Lee S. Polyphonic sound event detection using convolutional bidirectional LSTM and synthetic data-based transfer learning. In: ICASSP 2019 IEEE International Conference on Acoustics, Speech, and Signal Processing. IEEE; 2019. p. 885-889.
- [18] Guilabert Torregrosa I. Modelado de entornos inteligentes para atención en las primeras etapas de vida. Universidad de Alicante; 2010.
- [19] Egan F. El ABC del cuidado de enfermería en los bebés prematuros extremos – Segunda parte –. Rev Enfer Neon. 2006.
- [20] Samartharam H, Vasudeva N, Ila SS. The role of humidity in the management of premature neonates in a rural incubator. Cureus. 2021;13(4).
- [21] Instituto Nacional de Salud. Manual para la realización de unidades de análisis de eventos de interés en salud pública priorizados. 2024. Disponible en: <https://www.ins.gov.co/BibliotecaDigital/manual-unidad-de-analisis-2024.pdf>
- [22] Fontes I, Melo A, Frery AC, Aquino A. Sensor sound classification in neonatal intensive care units based on multiple features and neural networks. In: 2024 IEEE 21st Consumer Communications & Networking Conference (CCNC). IEEE; 2024. p. 507-512.
- [23] Tailleux M, Lostenlen V, Rivière JP, Aumond P. Machine listening in a neonatal intensive care unit. arXiv preprint. 2024; arXiv:2409.11439.
- [24] Hutchinson G, Du L, Ahmad K. Incubator-based sound attenuation: active noise control in a simulated clinical environment. PLoS One. 2020;15(7): e0235287.
- [25] Fahmi F, et al. Design of an IoT-based smart incubator that listens to the baby. In: IOP Conference Series: Materials Science and Engineering. Vol. 1003. IOP Publishing; 2020. p. 012153.
- [26] Darniss, et al. An IoT-based vitals monitoring system for babies in neonatal intensive care unit. In: 2022 IEEE 10th Region 10 Humanitarian Technology Conference (R10-HTC). IEEE; 2022. p. 130-135.
- [27] Najib SM, et al. Intelligent neonatal monitoring system based on android application using multi sensors. In: 2019 IEEE 9th Symposium on Computer Applications & Industrial Electronics (ISCAIE). IEEE; 2019. p. 131-135.
- [28] Rassels K. Accurate body temperature measurement of a neonate using thermography technology. 2021. doi:10.1109/SSI52265.2021.9467024.
- [29] Abdulla R, Lai NS, Kalilani M. IoT-based neonatal incubator for the developing world and conflict zones. 2021.
- [30] Abd El Aziz R, Taloba A. Real-time monitoring and control of neonatal incubator using IoT. 2021.
- [31] Irianto B, Maghfiroh A, Sofie M, Kholiq. Baby incubator with overshoot reduction system using PID control equipped with heart rate monitoring based on the Internet of Things. Int J Technol. 2023;14(4). doi:10.14716/ijtech. v14i4.5678.
- [32] Jadhav P. Development of incubator monitoring system using IoT. 2024.
- [33] Lamidi L, Kholiq A, Ali M. A low-cost baby incubator design equipped with vital sign parameters. Indonesian J Electron Electromed Eng Med Inform. 2021. doi:10.35882/ijeeemi. v3i2.3

- [34] Ainiyah S, Andayani D, Pundji A, Shaib M. Development of incubator analyzer based on computer with temperature and humidity parameters. *J Electron Electromed Eng Med Inform*. 2020. doi:10.35882/jeeemi. v2i2.3
- [35] Althahab AQJ, Vuksanovic B, Al-Mosawi M, Ma H. *Acoustics Australia*. Reino Unido; 2024.
- [36] Raboshchuk G, Nadeu C, Ghahabi O, Solvez S, Mahamud BM, Veciana AR, Hervas SN. In: *Proc. Interspeech 2014*. España; 2014.
- [37] Ruiz J, Romero R, Buitrago A, Barragán C, Estrada D. *Guía de práctica clínica del recién nacido prematuro*. Colombia: Ministerio de Salud y Protección Social; 2013.
- [38] Asociación Colombiana de Neonatología. *Criterios de ingreso y egreso a las unidades de recién nacidos en Colombia*. 2020. Disponible en: <https://ascon.org.co/wp-content/uploads/2020/05/28.05.2020-CRITERIOS-INGRESO-Y-EGRESO-UNIDADES-DE-RECIÉN-NACIDOS.pdf>
- [39] Ohuma E, Moller A-B, Bradley E, et al. National, regional, and worldwide estimates of preterm birth in 2020, with trends from 2010: a systematic analysis. 2023. doi:10.1016/S0140-6736(23)00878-4.
- [40] Sarmiento-Guzmán MP, Pardo-Carrero R, Jaramillo-Bustamante JC, Fernández-Laverde M, Guzmán-Díaz MC, Izquierdo-Borrero LM, Benavidez MV. *Criterios de admisión y egreso para las unidades pediátricas de cuidados intensivos e intermedios en Colombia*. *Acta Colomb Cuid Intensivo*. 2016; 16:1-8.
- [41] Ceruti E. *Fisiología y patología respiratoria del feto y recién nacido*. *Rev Chil Pediatr*. 1973;44(6):503-522.
- [42] Ministerio de Salud Argentina. *Manejo hidroelectrolítico – Termorregulación – Cuidado de la piel – Atención y cuidado del recién nacido prematuro*. 2020. Disponible en: <http://argentina.gob.ar/sites/default/files/bancos/2020-09/he-piel-prematuros.pdf>
- [43] BatterySpace. *RCR-3.0V Rechargeable Lithium Cell Data Sheet*. 2010. Disponible en: <https://www.batteryspace.com/prod-specs/RCR3.00v.pdf?srsltid=AfmBOooyRf2APSH1kqkPetVJfShM9fdcTNZMfo0uvc2x1ncVQkv3DAMt>
- [44] Analog Devices. *ADMP401 Omnidirectional Microphone Data Sheet*. 2012; Rev D. Disponible en: <https://www.analog.com/media/en/technical-documentation/obsolete-data-sheets/admp401.pdf>
- [45] SparkFun Electronics. *DHT22 Digital Humidity and Temperature Sensor Data Sheet*. 2015. Disponible en: <https://cdn.sparkfun.com/assets/f7/d/9/c/DHT22.pdf>
- [46] Seeed Studio. *Seeed-Studio XIAO Series SOM Datasheet*. 2020. Disponible en: <https://files.seeedstudio.com/wiki/XIAO/Seeed-Studio-XIAO-Series-SOM-Datasheet.pdf>
- [47] Seeed Studio. *ESP32-S3 Series Datasheet*. 2023. Disponible en: https://files.seeedstudio.com/wiki/SeeedStudio-XIAO-ESP32S3/res/esp32-s3_datasheet.pdf
- [48] Edge Impulse. *Audio MFE. Edge Impulse Documentation*. 2022. Disponible en: <https://docs.edgeimpulse.com/studio/projects/processing-blocks/blocks/audio-mfe>
- [49] Correal, M. E., Marthá, J. E., & Sarmiento, R. *Influencia de la variabilidad climática en las enfermedades respiratorias agudas en Bogotá*. 2015. *Biomédica*, 35(SPE), 130-138.

[50] Klima, M., Rechtberger, V., Bures, M., Bellekens, X., Hindy, H., & Ahmed, B. S. Quality and reliability metrics for IoT systems: a consolidated view. 2020. In *International Summit Smart City 360°* (pp. 635-650).

[51] Scholtz, B., Kapeso, M., & Van Belle, J. P. An internet of things (iot) model for optimising downtime management: a smart lighting case study. 2018. In *IFIP International Internet of Things Conference* (pp. 89-104).

[52] Fathy, A., El-Sayed, N., & Salah, K. Enhancing System Reliability and Resilience through Advanced Anomaly Detection Techniques in Critical Infrastructures. *Quarterly Journal of Emerging Technologies and Innovations*. 2022;7(1):17-39.

[53] Parhizkari, S. Anomaly detection in intrusion detection systems. 2023. *Anomaly Detection-Recent Advances, AI and ML Perspectives and Applications*.

[54] Hanif, M. A., Wadood, A., Ahmad, R. W., Shah, S. A., & Khan, R. Real-Time Anomaly Detection in IoT Sensor Data Using Statistical and Machine Learning Methods. 2025. *ACADEMIA International Journal for Social Sciences*, 4(3), 5203-5227.