

## Datos generales

Nombre del proyecto: *Breath - Dispositivo para el monitoreo y alerta de ataques de asma nocturnos en infantes.*

Nombre del proponente/equipo: *Future Minds*

Carrera: *Ingeniería Biomédica*

Semestre: *Quinto*

Asignatura: *Proyectos V*

Integrantes:

- *Caballero Córdova Mario Tadeo*
- *Cabrera Rodríguez Itzel del Carmen*
- *Chávez Gómez Jorge Alejandro*
- *Martínez Vargas Emiliano*
- *Monterrubio Antonio María Fernanda*
- *Rivero Gómez Gabriel*

## Idea del proyecto

A pesar de los avances que se han dado en el área farmacológica, no existe un tratamiento curativo para el asma. Por ello, la prioridad médica ha sido el manejo y control personalizado de cada paciente, con el objetivo de reducir síntomas nocturnos, prevenir crisis, disminuir visitas a urgencias y evitar limitaciones en la vida diaria. Se ha potenciado el autocontrol del paciente, es decir, que éste monitorice sus síntomas y siga rigurosamente el tratamiento establecido (Alcántara, 2025). No obstante, esto se dificulta en niños, ya que ellos dependen de sus cuidadores para la administración de medicamentos, el reconocimiento temprano de síntomas y la reducción de factores ambientales desencadenantes (Moral et al., 2021), esto hace a los menores más vulnerables. Ante esta problemática y tomando en cuenta que la IA ha demostrado ser una gran herramienta para el diagnóstico de varias enfermedades, como puede ser el asma (Aliyu, D. A, et al., 2025), se propone desarrollar un software basado en redes neuronales que analice ciertos parámetros fisiológicos, detecte patrones tempranos y alerte de posibles ataques de asma durante la noche.

## Objetivo

### Objetivos generales

- Desarrollar un software capaz de predecir posibles crisis asmáticas mediante el análisis de variables fisiológicas utilizando redes neuronales, con el fin de brindar apoyo a pacientes y profesionales de la salud en la toma de decisiones.

### Objetivos específicos

- Implementar un sistema de adquisición y registro de las principales variables fisiológicas.
- Entrenar un modelo de redes neuronales para identificar patrones que anteceden a un ataque de asma. - Validar el modelo predictivo con datos reales de pacientes asmáticos.
- Diseñar una interfaz que presente la información de manera clara y accesible, tanto para médicos como para pacientes.
- Generar un sistema de alertas que notifique sobre el riesgo de una posible crisis asmática.

## Diseño del proyecto

### Metodología (Generalidades) y Software

- Procesamiento y envío de los datos: El procesamiento de datos se hará de forma digital en tiempo real y estos serán enviados a una base de datos mediante comunicación UART y Wifi
- Adquisición de los datos fisiológicos: La adquisición del SpO2 será mediante un sensor MAX 30102.
- Análisis de datos mediante la IA: La red neuronal a utilizar para el análisis de datos será de tipo LSTM debido a que es la que más se adapta al análisis que queremos lograr (El monitoreo de cómo van cambiando los parámetros a lo largo del día).
- Toma de decisión de acuerdo al análisis de los datos: De acuerdo con la información impartida por parte del sensor se buscará un monitoreo y una alarma, esto dependerá de acuerdo a los valores leídos para tomar una decisión, como el de avisar cuando se presentará un ataque de asma.
- Almacenamiento de los datos: Los datos serán almacenados en base de datos SQL.
- Visualización de los datos del SpO2: La visualización de los datos será mediante una interfaz de usuario que será desarrollada en HTML, CSS y JavaScript a la que se podrá acceder desde una computadora.
- Repetición del análisis: El análisis se repetirá cada intervalo de tiempo definido (por ejemplo, cada 30 segundos) para actualizar los resultados y mantener una monitorización continua durante el sueño.

### Simulación y/o adelante del proyecto

Para este proyecto se seleccionó una red neuronal híbrida CNN + LSTM, ya que combina la capacidad de las redes convolucionales (CNN) para extraer patrones relevantes en señales fisiológicas como las variaciones del nivel de oxigenación (SpO<sub>2</sub>) o del ritmo cardíaco con la fortaleza de las redes recurrentes LSTM para modelar la dependencia temporal y evolución de esos datos en el tiempo. En el contexto del asma nocturno, los síntomas suelen manifestarse de forma progresiva y con comportamientos periódicos, por lo que una CNN + LSTM permite identificar tanto características locales (microvariaciones en la señal) como tendencias secuenciales (descensos sostenidos del SpO<sub>2</sub> o cambios en la frecuencia). Esta combinación ofrece una predicción más robusta y sensible ante eventos respiratorios, superando en desempeño a modelos puramente convolucionales o puramente recurrentes.

Model: "sequential_2"		
Layer (type)	Output Shape	Param #
conv1d_4 (Conv1D)	(None, 29, 32)	128
max_pooling1d_4 (MaxPooling1D)	(None, 14, 32)	0
dropout_6 (Dropout)	(None, 14, 32)	0
conv1d_5 (Conv1D)	(None, 13, 64)	16,384
max_pooling1d_5 (MaxPooling1D)	(None, 13, 64)	0
dropout_7 (Dropout)	(None, 13, 64)	0
lstm_2 (LSTM)	(None, 64)	33,024
dense_4 (Dense)	(None, 64)	4,096
dropout_8 (Dropout)	(None, 64)	0
dense_5 (Dense)	(None, 1)	65
Total params: 83,496 (170.25 KB)		
Trainable params: 13,327 (170.25 KB)		

Figura 1. Estructura secuencial del modelo de Deep Learning diseñado para clasificación binaria.

En la figura 2, se puede apreciar la monitorización del proceso de entrenamiento inicial. Los valores de precisión cercanos al 50% (0.50) y una pérdida constante en torno a 0.69 sugieren que el modelo aún no ha comenzado a converger y se comporta actualmente como un clasificador aleatorio.

```

epoch: 7/100
90/100 - 8s: 3ms/step - accuracy: 0.5551 - loss: 0.6939409329049511: You are saving your model as an HDF5 file via 'model.h5'
100/100 - 8s: 2ms/step - accuracy: 0.5547 - loss: 0.6938 - val_accuracy: 0.5600 - val_loss: 0.6933
Epoch 2/50
100/100 - 4s: 3ms/step - accuracy: 0.4900 - loss: 0.6933 - val_accuracy: 0.4933 - val_loss: 0.6923
Epoch 3/50
100/100 - 16.3ms/step - accuracy: 0.5846 - loss: 0.6933 - val_accuracy: 0.4875 - val_loss: 0.6933
Epoch 4/50
100/100 - 1s: 3ms/step - accuracy: 0.5895 - loss: 0.6931 - val_accuracy: 0.4913 - val_loss: 0.6933
Epoch 5/50
100/100 - 16.3ms/step - accuracy: 0.4983 - loss: 0.6935 - val_accuracy: 0.4913 - val_loss: 0.6934
Epoch 6/50
100/100 - 1s: 3ms/step - accuracy: 0.5837 - loss: 0.6935 - val_accuracy: 0.4825 - val_loss: 0.6933
Epoch 7/50
100/100 - 8s: 3ms/step - accuracy: 0.5855 - loss: 0.6934: You are saving your model as an HDF5 file via 'model.h5'
100/100 - 16.3ms/step - accuracy: 0.5854 - loss: 0.6932 - val_accuracy: 0.5600 - val_loss: 0.6930
Epoch 8/50
100/100 - 1s: 3ms/step - accuracy: 0.5156 - loss: 0.6923 - val_accuracy: 0.4913 - val_loss: 0.6933
Epoch 9/50
97/100 - 8s: 3ms/step - accuracy: 0.4735 - loss: 0.6949409329049511: You are saving your model as an HDF5 file via 'model.h5'
100/100 - 2s: 3ms/step - accuracy: 0.4748 - loss: 0.6938 - val_accuracy: 0.5600 - val_loss: 0.6936
Epoch 10/50
100/100 - 16.3ms/step - accuracy: 0.4832 - loss: 0.6938 - val_accuracy: 0.4925 - val_loss: 0.6933
Epoch 11/50
100/100 - 1s: 3ms/step - accuracy: 0.5142 - loss: 0.6932 - val_accuracy: 0.4913 - val_loss: 0.6933
Epoch 12/50
100/100 - 16.3ms/step - accuracy: 0.4954 - loss: 0.6933 - val_accuracy: 0.4913 - val_loss: 0.6932
Epoch 13/50

```

Figura 2. Monitorización del proceso de entrenamiento inicial

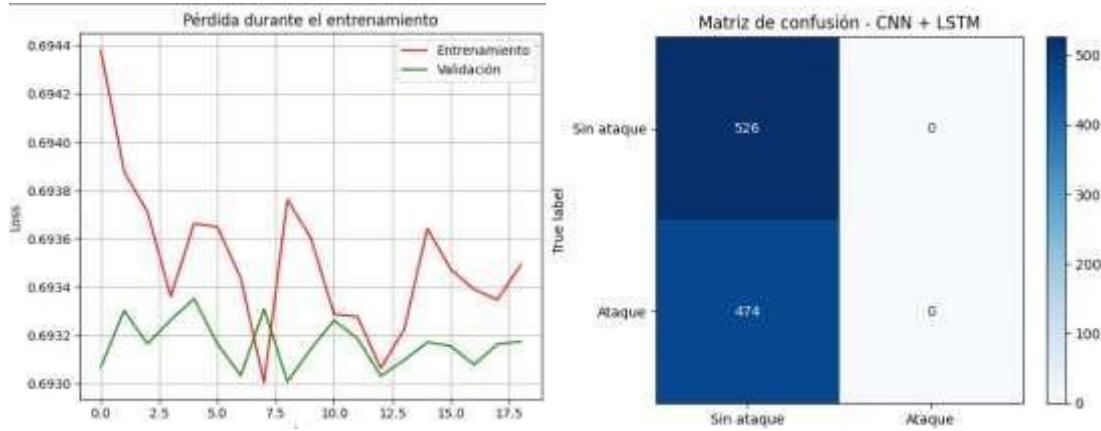


Figura 3. Resultados parciales del entrenamiento de la red convolucional.

En cuanto al diseño de la interfaz, desarrolle un modelo preliminar utilizando Python unificando las propuestas del diseño conceptual. La interfaz cuenta con un diseño responsive y de momento utiliza valores aleatorios para actualizarse. No obstante, está diseñada para poder conectarse a la base de datos en SQL donde se registrarán los datos del paciente.

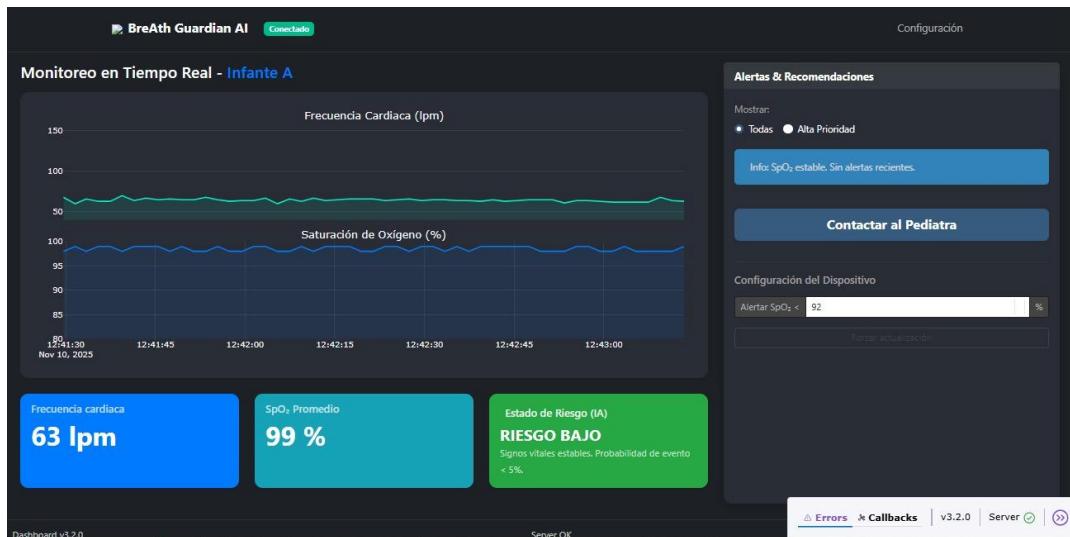


Figura 4. Visualización de la interfaz web en Python.

## Características

- Microcontrolador (Raspberry Pi 2w Zero): Es compacto, económico y de bajo consumo, integra Wi-Fi y Bluetooth, facilitando conectividad inalámbrica. Ofrece buen rendimiento para automatización, prototipos y aplicaciones educativas, con el respaldo de una gran comunidad y amplia compatibilidad con software como Python.
- Sensor de Oximetría y Pulso (MAX30102): Medirá la saturación de oxígeno en la sangre (SpO2) y la frecuencia cardíaca. Se conectarán al PSoC 5LP a través de la interfaz I2C.
- Módulo de Comunicación (Wi-Fi): Un módulo externo (como un ESP8266 o similar) se encargará de recibir los datos ya procesados por el PSoC 5LP y enviarlos de forma inalámbrica a la nube.
- Sistema de Alerta (Zumbador y LED): Notificará de forma sonora y visual a los cuidadores cuando se detecte un riesgo alto de crisis asmática, controlado directamente por los pines GPIO del PSoC 5LP.
- Firmware del Dispositivo (Programado en C/C++ con PSoC Creator): El software interno se diseñará en el entorno PSoC Creator. La mayor capacidad de procesamiento del PSoC 5LP permitirá implementar algoritmos de filtrado digital y preprocesamiento de datos más complejos en el propio dispositivo, optimizando la información que se envía a la nube.
- Plataforma IoT (Nube): Recibirá y almacenará de forma segura todos los datos enviados por el dispositivo para su análisis en tiempo real.
- Modelo de Inteligencia Artificial (Red Neuronal LSTM): Analizará los datos fisiológicos a lo largo del tiempo para identificar patrones y predecir la probabilidad de una crisis asmática antes de que ocurra.
- Interfaz Gráfica (Aplicación Web/Móvil): Un panel de control sencillo para que los cuidadores puedan ver los signos vitales del infante en tiempo real y recibir las alertas generadas por el sistema.