

2025

Dispositivo portátil basado en internet de las cosas médicas para análisis de la variabilidad de frecuencia cardíaca.

Ing. Rodrigo Mateo Reyes



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Dispositivo portátil basado en internet de las cosas
médicas para análisis de la variabilidad de
frecuencia cardíaca.

Que como parte de los requisitos para obtener el grado
Maestro en Ciencias Mecatrónica.

Presenta:

Ing. Rodrigo Mateo Reyes

Dirigido por:

Dr. Irving Armando Cruz Albarrán

Co-Director:

Dr. Luis Alberto Morales Hernández

San Juan del Río, Qro. a 20 de Julio

La presente obra está bajo la licencia:
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciante no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:



Atribución — Usted debe dar [crédito de manera adecuada](#), brindar un enlace a la licencia, e [indicar si se han realizado cambios](#). Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciante.



NoComercial — Usted no puede hacer uso del material con [propósitos comerciales](#).



SinDerivadas — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni [medidas tecnológicas](#) que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como [publicidad, privacidad, o derechos morales](#) pueden limitar la forma en que utilice el material.



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Maestría en Ciencias (Mecatrónica)



“Dispositivo portátil basado en internet de las cosas médicas para análisis de la variabilidad de frecuencia cardíaca.”

Opción de titulación

TESIS

Que como parte de los requisitos para obtener el grado de Maestro en Ciencias de la Mecatrónica

Presenta:

Ing. Rodrigo Mateo Reyes

Dirigido por:

Dr. Irving Armando Cruz Albarrán

Co-Dirigido por:

Dr. Luis Alberto Morales Hernández

Dr. Irving Armando Cruz Albarrán
Presidente

Dr. Luis Alberto Morales Hernández
Secretario

Dr. Emmanuel Reséndiz Ochoa
Vocal

Dr. Juan Primo Benítez Rangel
Suplente

Dr. Martín Valtierra Rodríguez
Suplente

Campus San Juan del Río, Querétaro
Julio 2025, México

RESUMEN

El estrés es un problema creciente entre los jóvenes universitarios, y su detección temprana es clave para prevenir consecuencias tanto en el bienestar mental como en el físico. Este trabajo de investigación describe el diseño y la implementación de un sistema portátil, inalámbrico e inocuo basado en el internet de las cosas médicas (IoMT), orientado a analizar la variabilidad de la frecuencia cardíaca (VFC) durante la prueba de estrés social Trier (TSST). El objetivo es detectar de forma automatizada el estrés psicológico a través de un enfoque no invasivo. La metodología propuesta incluye seis etapas: adquisición de la señal cardíaca, transferencia de datos vía Wi-Fi usando MQTT, conversión de la señal 1D a espectrogramas 2D mediante la transformada continua de wavelet, procesamiento en escala de grises con aumento de datos, entrenamiento de una red neuronal convolucional separable en profundidad para clasificación y generación de reportes. Las pruebas en ambientes reales validaron la funcionalidad del sistema y su eficacia para detectar estados de estrés a partir de señales fisiológicas. Los resultados muestran que este enfoque tecnológico es viable y ofrece una herramienta prometedora para el monitoreo del estrés en contextos clínicos y educativos.

Palabras clave: Variabilidad de frecuencia cardíaca, Red neuronal convolucional divisible en profundidad, Transformada wavelet continua, imagen.

SUMMARY

Stress is a growing problem among young university students and its early detection is key to prevent physical and mental health consequences. This thesis presents the design and implementation of a portable, wireless, and harmless Internet of Medical Things (IoMT)-based system for analyzing heart rate variability (HRV) during the Trier Social Stress Test (TSST). The aim is to automatically detect psychological stress through a non-invasive approach. The proposed methodology includes six steps: acquisition of the cardiac signal, data transfer via Wi-Fi using MQTT, conversion of the 1D signal into 2D spectrograms using continuous wavelet transform, gray scale processing with data enhancement, training of a depth-separable convolutional neural network for classification, and report generation. Tests in real environments validated the functionality of the system and its effectiveness in detecting stress states from physiological signals. The results show that this technological approach is feasible and offers a promising tool for stress monitoring in clinical and educational settings.

Keywords: Heart rate variability, Depth-splitting convolutional neural network, Continuous wavelet transform, image.

DEDICATORIA

Dedico este trabajo, en primer lugar, a mis padres, por su amor incondicional, por enseñarme el valor del esfuerzo y por apoyarme en cada paso de mi vida. Gracias por ser mi guía, mi refugio y mi mayor ejemplo.

A mis hermanos y a mi pareja, por estar presentes en los momentos más difíciles y celebrar conmigo cada logro, grande o pequeño. Su compañía ha sido un pilar fundamental a lo largo de este camino.

A mis amigos, seres queridos, que con palabras de aliento, paciencia y compañía me ayudaron a no rendirme en los momentos de incertidumbre.

Finalmente, me dedico este logro a mí mismo, por no rendirme, por confiar en mis capacidades y por seguir adelante a pesar de los desafíos. Esta tesis representa no solo un objetivo académico alcanzado, sino también un crecimiento personal profundo.

AGRADECIMIENTOS

Deseo expresar mi agradecimiento a la Universidad Autónoma de Querétaro, Facultad de Ingeniería, campus San Juan del Río, a la división de Posgrado en Ciencias (Mecatrónica), por el invaluable apoyo brindado a lo largo del desarrollo de este proyecto. La sólida formación académica recibida, los recursos puestos a mi disposición y el entorno propicio para la investigación fueron elementos fundamentales que me permitieron consolidar satisfactoriamente este trabajo. El firme compromiso de la institución con la excelencia educativa y el impulso a la innovación tecnológica fueron clave para alcanzar los objetivos propuestos. Cada clase, asesoría y espacio de trabajo a los que tuve acceso contribuyeron de manera significativa a mi crecimiento profesional y personal, facilitando enormemente el camino hacia la culminación de esta tesis.

Mi más sincero agradecimiento al Dr. Irving Armando Cruz Albarrán, por su invaluable guía, experiencia y acompañamiento constante a lo largo de esta investigación. Su compromiso, paciencia y visión crítica fueron fundamentales para consolidar cada etapa de este trabajo. Al equipo de investigación de Visión Artificial y a mis compañeros de generación, por su apoyo técnico, sus ideas, y por compartir el entusiasmo por la ciencia, la tecnología y la innovación

A la comunidad de la Facultad de Psicología de la UNAM, especialmente a los estudiantes voluntarios que participaron en las pruebas, por su disposición, interés y colaboración desinteresada.

A mi familia y amigos, por su comprensión durante los momentos de mayor exigencia y por brindarme siempre palabras de aliento y motivación.

Expreso también mi agradecimiento a la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (Secihti) por brindarme una beca para realizar mis estudios de Maestría en Ciencias (Mecatrónica). Extiendo mi reconocimiento a todas las personas e instituciones cuya colaboración, en cualquiera de sus formas, fue fundamental para la realización de este proyecto.

ÍNDICE

1. Introducción	1
1.1. ANTECEDENTES	2
1.1.1. Estrés y su impacto en la salud	2
1.1.2. Herramientas para evaluar la condición del estrés	3
1.1.3. Variabilidad de la frecuencia cardiaca (VFC)	5
1.1.4. Sistemas con inteligencia artificial, IoT, en el área médica (IoMT)	7
1.1.5. Investigación y desarrollo en dispositivos de monitoreo remoto de señales fisiológicas	8
1.2. Descripción del problema	11
1.3. Justificación	12
1.4. Hipótesis y objetivos	13
1.4.1. Hipótesis	13
1.4.2. Objetivo general	13
1.4.3. Objetivos específicos	13
1.5. Planteamiento general	14
2. FUNDAMENTACIÓN TEÓRICA	15
2.1. Relación entre el estrés, el sistema nervioso autónomo y la VFC	15
2.2. Frecuencia cardiaca vs. VFC	16
2.3. Metodologías de análisis de la VFC	17
2.3.1. Análisis de datos de la VFC usando métodos lineales	17
2.4. Protocolo de estrés social Trier (TSST)	19
2.5. Transformada Wavelet Continua (CWT)	20
2.6. Estructura general de IoMT	21
2.6.1. Dispositivos y sensores	23
2.6.1.1. Sensores en sistemas de salud basados en IoT	23
2.6.1.2. Sensores para medir VFC	23
2.6.1.3. Sensor de VFC Polar H10	24
2.6.2. Conectividad	25
2.6.2.1. Protocolos en sistemas IoMT	26
2.6.3. Plataformas de IoMT	27
2.6.4. Aplicaciones y servicios del IoMT en la atención médica	28

2.7.	Formación y representación de la imagen.....	29
2.8.	Aprendizaje profundo y aumento de datos.....	30
2.8.1.	Aumento de datos	30
2.9.	Redes neuronales convolucionales (CNN)	31
2.9.1.	Redes neuronales convolucionales divisible en profundidad (CNN).....	33
2.9.1.1.	Convolución Depthwise y Pointwise de una DSCNN.....	34
2.9.1.2.	Ventajas de la convolución Depthwise (separable en profundidad)	35
2.10.	Métricas de evaluación.....	36
2.11.	Software de código abierto para innovación tecnológica	40
2.12.	La inocuidad en sistemas de monitoreo fisiológico	40
2.13.	La comunidad universitaria como población clave para el estudio del estrés 41	
3.	METODOLOGÍA.....	42
3.1.	Adquisición de datos electrocardiográficos	43
3.2.	Transferencia de datos al servidor.....	45
3.3.	Transformación de datos 1D-2D con CWT	46
3.3.1.	Preprocesamiento de la señal ECG	47
3.3.2.	CWT a los datos electrocardiográficos segmentados.....	48
3.3.3.	Preprocesamiento de imagen (espectrograma): Escala de grises; aumento de datos.....	49
3.4.	Red neuronal convolucional divisible en profundidad (DSCNN).....	51
3.4.1.	Arquitectura de la DSCNN	51
3.4.2.	Entrenamiento del modelo	53
3.4.3.	Evaluación del modelo	54
3.5.	Reporte de identificación de estrés	55
3.6.	Matriz de experimentos y condiciones de evaluación	55
4.	RESULTADOS	57
4.1.	Pruebas de funcionalidad y adquisición de datos en ambientes reales	57
4.1.1.	Adquisición de datos electrocardiográficos	57
4.2.	Transferencia de datos al servidor.....	59
4.3.	Transformación de datos 1D-2D con CWT	60
4.3.1.	Preprocesamiento de la señal ECG	62
4.3.2.	CWT a los datos electrocardiográficos segmentados.....	62
4.4.	Preprocesamiento de imagen (espectrograma)	63

4.4.1.	Transformación a escala de grises	64
4.4.2.	Aumento de datos	65
4.5.	Análisis de ablación del modelo DSCNN.....	66
4.6.	Análisis del desempeño del modelo durante el entrenamiento y validación 69	
4.7.	Reporte de identificación de estrés	71
5.	CONCLUSIONES.....	73
6.	PROSPECTIVAS	75
	REFERENCIAS	76
	APENDICES	84
	Apéndice A. Artículo publicado.....	84

ÍNDICE DE FIGURAS

Figura 1.1. Planteamiento general de la Metodología (Autoría propia).	14
Figura 2.1. Variabilidad de la frecuencia cardiaca (autoría propia).	17
Figura 2.2. Esquema general de TSST (autoría propia).	20
Figura 2.3. Estructura general de un sistema IoMT (autoría propia).	22
Figura 2.4. Aumento de datos, espejo horizontal y vertical (Autoría propia).	31
Figura 2.5. La CNN secuencial (Autoría propia).	32
Figura 2.6. Arquitectura de la DSCNN (Autoría propia).	34
Figura 2.7. Matriz de confusión (Autoría propia).	37
Figura 3.1. Diagrama a bloques de la metodología (autoría propia).	43
Figura 3.2. Adquisición y transferencia de datos (autoría propia).	44
Figura 3.3. Transformación de datos 1D-2D con CWT (autoría propia).	47
Figura 3.4. Preprocesamiento de imagen (espectrograma): Escala de grises; aumento de datos (autoría propia).	50
Figura 3.6. DSCNN (autoría propia).	51
Figura 4.1. Sistema de adquisición y transferencia de datos implementado (autoría propia).	58
Figura 4.2. Vinculación sensor Polar h10-Aplicación (autoría propia).	58
Figura 4.3. Lectura de datos del Sensor Polar h10 (autoría propia).	59
Figura 4.4. Sistema MQTT de transferencia de datos implementado (autoría propia).	59
Figura 4.5 Botón para activar transferencia de datos a servidor (autoría propia).	60
Figura 4.6. GUI de cliente remoto (autoría propia).	61
Figura 4.7. Señal ECG segmentada (autoría propia).	62
Figura 4.8 Imagen espectrograma (autoría propia).	63
Figura 4.9. Estudio de ablación de hiperparámetros en el modelo DSCNN. (a) Impacto del tamaño de imagen de entrada y del tamaño del kernel sobre la exactitud de clasificación, (b) Efecto del número de filtros en el rendimiento del modelo.	67
Figura 4.10. Estudio de ablación de hiperparámetros en el modelo DSCNN. (c) Influencia del tamaño del lote (batch) sobre el rendimiento del modelo. (d) Evaluación del impacto del número de épocas de entrenamiento en la convergencia del modelo.	68
Figura 4.11. Evolución del modelo durante las fases de entrenamiento y validación.	69
Figura 4.12. Matriz de confusión obtenida durante la evaluación del modelo.	70
Figura 4.13. Informe de clasificación de estrés percibido generado a partir de los datos de ECG de un participante durante la prueba TSST.	72

ÍNDICE DE TABLAS

Tabla 1. Configuración del modelo base DSCNN.....	52
Tabla 2. Matriz de experimentos y condiciones de evaluación.....	55
Tabla 3. TSST de 15 minutos.....	64
Tabla 4. Ablacion de componentes de arquitectura.....	66
Tabla 5. Informe de clasificación del modelo DSCNN.	71

1.Introducción

El estrés es una preocupación cada vez más apremiante en la sociedad moderna, dado su impacto adverso en la salud física y mental de las personas. Por lo que este contexto, resulta fundamental explorar distintos aspectos del estrés en diferentes contextos para comprender mejor este fenómeno y desarrollar estrategias efectivas de manejo. Una de las herramientas más utilizadas para evaluar la respuesta fisiológica al estrés es la variabilidad de la frecuencia cardíaca (VFC), un indicador no invasivo del equilibrio entre las ramas simpática y parasimpática del sistema nervioso autónomo. Durante situaciones de estrés, este equilibrio se ve alterado, reduciendo generalmente la VFC, lo que refleja una disminución en la capacidad de adaptarse a las demandas externas. Por ello, la VFC se ha consolidado como un biomarcador confiable para detectar cambios asociados al estrés. En esta tesis se presenta el diseño y desarrollo (integración) de un sistema portátil, inocuo e inalámbrico basado en el Internet de las cosas médicas (IoMT del inglés Internet of Medical Things), destinado a analizar la variabilidad de la frecuencia cardíaca en jóvenes universitarios durante la aplicación de la prueba de estrés social Trier (TSST, del inglés Trier Social Stress Test), con el objetivo de detectar el estrés de manera oportuna. A través de una experimentación práctica y el análisis de sensores de VFC, se diseñó e implementó un sistema de adquisición de datos electrocardiográficos basado en IoMT. Se implementó el protocolo de transferencia de datos para establecer la comunicación entre el sistema de adquisición y un servidor web, que permite a un cliente remoto almacenar los datos para su posterior análisis. Se desarrolló una metodología para analizar la información recopilada y detectar niveles de estrés en jóvenes universitarios, y las pruebas de funcionalidad en ambientes reales validaron el desarrollo tecnológico durante la aplicación del protocolo TSST.

1.1.ANTECEDENTES

1.1.1. Estrés y su impacto en la salud

El estrés, según la Organización Mundial de la Salud, (2023), es una respuesta natural del organismo ante situaciones desafiantes que pueden provocar tensión mental. Esta reacción, esencial para abordar los desafíos de la vida, puede ser desencadenada por diversas situaciones, como el trabajo, las finanzas y las relaciones interpersonales. El estrés puede manifestarse tanto de manera temporal como prolongada, y su impacto abarca desde aspectos hormonales hasta el estado de ánimo, afectando la salud en su totalidad. Los efectos del estrés son diversos y pueden incidir tanto en la salud física como en la mental. Entre los efectos físicos se incluyen resfriados, gripe, dolores de cabeza, problemas cardíacos, trastornos del sueño, irritabilidad, entre otros (Cigna Healthcare, 2023).

Es importante comprender que el estrés afecta a personas de todas las edades y en diferentes contextos de la vida, y su influencia en la salud mental desde las primeras etapas de la vida ha sido poco estudiada. Como se muestra, en un estudio realizado por Monjarás et al. (2021), que exploraron las diferencias en el nivel de estrés y los mecanismos de afrontamiento según el sexo y la edad en niños preescolares. Los hallazgos revelaron que tanto los niños de 4 como de 5 años experimentan estrés de manera similar, aunque emplean diferentes estrategias de afrontamiento según su edad. A su vez, Cardozo et al. (2021) investigaron la relación entre el estrés laboral y el desempeño organizacional, concluyendo que el estrés es un factor determinante que afecta negativamente la productividad y el bienestar de los trabajadores. Se destaca la importancia de implementar estrategias que fomenten un equilibrio entre el trabajo y la vida personal para mitigar los efectos nocivos del estrés en el ámbito laboral. Así mismo, en el contexto educativo, Leonangeli et al. (2022) analizaron la relación entre los síntomas de ansiedad, depresión y estrés con el consumo de alcohol en estudiantes universitarios. Los resultados resaltan la necesidad de prestar una

atención especial a la salud mental de los universitarios, especialmente en situaciones de cambio como las impuestas por la pandemia.

Estos estudios subrayan la importancia de comprender y abordar el estrés en diferentes contextos de la vida, desde la infancia hasta la vida adulta, y resaltan la necesidad de desarrollar herramientas o instrumentos para detectar y evaluar el estrés percibido que ayuden en intervenciones preventivas y estrategias de manejo efectivas para promover el bienestar individual y social.

1.1.2. Herramientas para evaluar la condición del estrés

La medición del estrés ha sido un desafío constante en la investigación psicológica y biomédica debido a su naturaleza multifactorial. En la literatura, las herramientas desarrolladas para cuantificar el estrés se agrupan comúnmente en dos grandes enfoques: herramientas subjetivas, que se basan en la percepción del individuo sobre su estado emocional, y herramientas objetivas, que evalúan el estrés a través de indicadores fisiológicos o biomarcadores. Esta distinción permite una comprensión más integral del fenómeno, ya que ambas aproximaciones aportan perspectivas complementarias sobre la experiencia del estrés (Kim et al., 2018).

a) Herramientas subjetivas

Las herramientas subjetivas se fundamentan en la autopercepción del individuo sobre su nivel de estrés, a través de escalas, cuestionarios y pruebas psicométricas. Por ejemplo, León (2014) realizó una revisión de instrumentos aplicados al personal de enfermería, subrayando la necesidad de mejorar la validación psicométrica de estos en contextos especializados. La Escala de Estrés Percibido de Cohen, una de las más utilizadas, fue analizada por Reyna et al. (2019) utilizando la Teoría de Respuesta al Ítem (TRI), confirmando su validez estructural y precisión en diversas poblaciones. Asimismo, Patlán (2019) identificó diferentes instrumentos para medir el estrés laboral, agrupándolos según enfoques teóricos como el estímulo, la respuesta, la transacción y la interacción, destacando la necesidad de una base teórica y metodológica sólida para su aplicación. En el

ámbito académico, Silvia-Ramos et al. (2020) aplicaron el Inventario Sistemático Cognoscitivo (SISCO) para evaluar el estrés en estudiantes universitarios, hallando que el 86.3% de los participantes presentaban niveles de estrés moderado, sin diferencias significativas según el sexo.

b) Herramientas objetivas

Las herramientas objetivas emplean indicadores fisiológicos para medir el estrés, aportando una evaluación independiente de la percepción del individuo. Morera et al. (2019) abordaron el uso de biomarcadores como la FC, la presión sanguínea y el cortisol, vinculados a los sistemas simpático-adrenomedular e hipotalámico-hipófisis-adrenal, como medidas fiables de activación fisiológica ante el estrés. En la misma línea, Weber et al. (2024) analizaron la Escala de Reactividad al Estrés Percibido (PSRS) y su capacidad para predecir respuestas cardiovasculares en contextos reales y experimentales, como la prueba de Estrés Social Trier en realidad virtual, observando asociaciones relevantes entre presión arterial y factores estresantes diarios. Desde un enfoque tecnológico, Reséndiz-Ochoa et al. (2021) emplearon termografía infrarroja para identificar cambios de temperatura facial y en las yemas de los dedos, desarrollando un sistema experto que logró un 91% de precisión en la detección de signos de estrés en estudiantes universitarios.

La complejidad del estrés ha impulsado el desarrollo de herramientas objetivas basadas en biomarcadores fisiológicos, que permiten una evaluación más precisa y cuantificable del estado del individuo. Entre estos indicadores, destaca la variabilidad de la frecuencia cardíaca (VFC), ampliamente reconocida por su capacidad para reflejar el equilibrio autonómico y la respuesta del organismo frente a situaciones de estrés. Otros marcadores relevantes incluyen el ritmo cardíaco, la presión arterial y la termografía. Estas metodologías complementan las medidas subjetivas y resultan especialmente útiles en contextos donde se requiere una medición rigurosa y continua, como en entornos clínicos, laborales o de investigación.

1.1.3. Variabilidad de la frecuencia cardiaca (VFC)

La VFC se ha convertido en un método ampliamente utilizado para evaluar la modulación del sistema nervioso autónomo sobre el corazón. Esta técnica no invasiva proporciona información valiosa sobre el equilibrio entre la actividad simpática y parasimpática, lo que la convierte en una herramienta importante en la investigación clínica y fisiológica. Desde la publicación de la Fuerza de Tarea (del inglés Task Force) sobre la VFC en 1996, se han emitido recomendaciones importantes sobre su uso en diferentes condiciones fisiológicas y estudios clínicos. Por su parte, Catai et al. (2020) proporcionan una orientación exhaustiva sobre los métodos de estandarización aplicados en la obtención y evaluación de datos relacionados con la variabilidad de la frecuencia cardiaca, con énfasis en su uso dentro de la cardiología y los procesos de rehabilitación cardíaca. Su estudio identifica deficiencias comunes en la metodología de análisis, como no informar completamente sobre las características clínicas de la muestra, no caracterizar adecuadamente lo que se considera “normal,” “población general,” “saludable” y “aparentemente saludable”, no informar con precisión datos demográficos como peso corporal, altura e índice de masa corporal, y no considerar el rango de edad y géneros estudiados o evaluados. Además, proporcionan recomendaciones para minimizar estas deficiencias, como el uso de una lista de verificación específica para estos propósitos.

La VFC se ha establecido como un indicador fundamental para analizar el funcionamiento del sistema nervioso autónomo, responsable de controlar procesos involuntarios como el ritmo del corazón. En situaciones de estrés, se observa una activación predominante del sistema simpático y una inhibición del sistema parasimpático, lo que genera una disminución en la VFC. Esta reducción indica una menor capacidad del organismo para adaptarse a los estímulos y se asocia con una mayor reactividad emocional, fatiga y menor calidad del sueño. Por tanto, una baja VFC es comúnmente interpretada como un reflejo fisiológico del estrés agudo o crónico, según reportan múltiples estudios (Ishaque et al., 2021; Mateos-Salgado et al., 2023; da Estrela et al., 2021).

Por otra parte, la VFC se utiliza para analizar el sistema nervioso autónomo (SNA), que regula diversas funciones autónomas del organismo, incluyendo la función cardíaca. Ishaque et al. (2021) presentan una revisión detallada de la bibliografía existente sobre la VFC y su asociación con la morbilidad, el dolor, la somnolencia, el estrés y el ejercicio. Sus hallazgos resaltan la importancia de la VFC como biomarcador y su impacto en el bienestar general y la salud integral. Así mismo, Mateos-Salgado et al. (2023) examinan la relación entre la VFC y el estrés, utilizando el análisis espectral de la VFC en estudiantes universitarios, observando reducciones significativas en la VFC durante situaciones estresantes. También, Pham et al. (2021) ofrecen una visión general de los índices de VFC más utilizados y su aplicación en la psicología, junto con una guía paso a paso sobre cómo realizar análisis de VFC utilizando herramientas neurofisiológicas integradoras. Además, la relación entre la VFC y la calidad del sueño ha recibido atención significativa. da Estrela et al. (2021) investigan cómo la baja VFC, como indicador de una mayor reactividad del sueño al estrés, se relaciona con una mala calidad del sueño y mayores síntomas depresivos. Sus hallazgos subrayan la importancia de la VFC como predictor de trastornos del sueño y depresión en respuesta al estrés crónico.

Estos estudios resaltan el papel fundamental de la VFC como herramienta de investigación y su relevancia en la comprensión de la salud cardiovascular, los trastornos psicológicos y el estrés. Como lo mencionan Mateos-Salgado et al., (2023), el análisis espectral de la VFC es crucial para estudiar la interacción entre los mecanismos psicológicos y neurofisiológicos del estrés. No obstante, persiste la necesidad de diseñar nuevas metodologías analíticas que permitan detectar patrones que vinculen la variabilidad de la frecuencia cardíaca con el estrés. Finalmente, es imprescindible estandarizar las unidades de la VFC debido a las inconsistencias en su evaluación. Aún se requiere investigar, para optimizar metodologías de evaluación del estrés, además de considerar factores contextuales, así como, analizar respuestas individuales o grupales para mejorar la precisión y aplicabilidad de la VFC en la evaluación del estrés.

1.1.4. Sistemas con inteligencia artificial, IoT, en el área médica (IoMT)

La incorporación de tecnologías emergentes como la Inteligencia Artificial (IA) y el Internet de las Cosas (IoT, del inglés Internet of Things) en el desarrollo de dispositivos médicos ha impulsado una transformación profunda en el ámbito sanitario. Esta convergencia tecnológica ha dado lugar a la evolución de la salud digital hacia un ecosistema interconectado, denominado Internet de las Cosas Médicas (IoMT, por sus siglas en inglés, Internet of Medical Things), donde los equipos médicos inteligentes pueden recopilar, procesar y transmitir datos clínicos de manera remota, optimizando tanto la atención al paciente como la toma de decisiones médicas. Este enfoque tiene como propósito ofrecer atención médica de alta calidad directamente en el entorno doméstico, lo que permite a los pacientes ser atendidos de forma más cómoda y eficaz. Su principal meta es anticipar condiciones críticas de salud con suficiente antelación, lo cual no solo puede salvar vidas, sino también reducir la presión sobre los servicios de salud convencionales, como los hospitales (Shafik, 2024). Por otro lado, el IoT ha emergido como una solución prometedora para superar las limitaciones tecnológicas en los centros sanitarios. Los dispositivos portátiles IoT están siendo utilizados en diversas aplicaciones de salud, desde la detección hasta el seguimiento y tratamiento de enfermedades, permitiendo que los pacientes reciban el tratamiento adecuado de manera más accesible. Sin embargo, las redes de comunicación convencionales enfrentan desafíos como la latencia, la capacidad de cálculo limitada y la duración de la batería. La llegada de la tecnología 5G ha abierto nuevas posibilidades al proporcionar una conectividad ultrarrápida y una gestión inteligente de datos, ofreciendo una base vital para la próxima generación de IoT en el ámbito de la salud (Verma et al., 2022).

En el escenario actual marcado por la pandemia mundial, la transmisión acelerada de enfermedades infecciosas plantea un reto considerable para los sistemas de salud pública. La insuficiencia de herramientas de diagnóstico convencionales resalta la necesidad de pruebas en el sitio donde se brinda la atención (POCT del inglés *Point-of-Care Testing*) para la detección rápida de

enfermedades infecciosas. Aquí es donde loMT juega un papel crucial al proporcionar operación y conectividad inalámbrica de dispositivos POCT con expertos en salud y centros médicos. Estos sistemas POCT asistidos por loMT pueden llenar el vacío entre la generación de datos, el análisis rápido y la validación clínica, facilitando un diagnóstico oportuno y una respuesta efectiva frente a enfermedades infecciosas emergentes y reemergentes (Jain et al., 2021).

En cuanto a la evaluación del estrés, sí existen dispositivos diseñados específicamente para ello. Diversos estudios han demostrado que dispositivos portátiles que monitorean señales fisiológicas como la VFC, la VFC, la conductancia de la piel (EDA), la temperatura corporal y la actividad electroencefalográfica pueden ser utilizados para detectar y monitorear el estrés en tiempo real. Estos dispositivos, integrados con técnicas de inteligencia artificial, permiten una detección continua y no invasiva tanto en entornos controlados como en la vida cotidiana (González et al., 2023; Biel et al., 2018).

La convergencia de la IA, el IoT y el loMT está revolucionando la manera en que se brindan los servicios de salud, haciéndolos más adaptados a las necesidades individuales, eficaces y fácilmente accesibles. Estas innovaciones tecnológicas no solo tienen el potencial de optimizar la eficiencia en la atención médica, sino también de mejorar considerablemente la calidad de vida de los pacientes, al ofrecer una atención más inteligente y enfocada en su bienestar.

1.1.5. Investigación y desarrollo en dispositivos de monitoreo remoto de señales fisiológicas

El desarrollo y la implementación de dispositivos portátiles basados en el IoT han revolucionado la monitorización de parámetros fisiológicos, ofreciendo soluciones innovadoras para el diagnóstico, seguimiento y tratamiento de diversas condiciones médicas. Barrios (2015) presentó una inicial estimación de un aparato portátil para evaluar la fluctuación en la función cardíaca, basado en tecnología analógica de electrocardiografía de una derivación y tres electrodos, simplificando la detección y monitoreo de enfermedades de largo plazo, así como la valoración del estrés tanto físico como mental. Destaca por su retroalimentación interna y

algoritmos simples de procesamiento. Por otro lado, Palao (2017) diseñó un sistema de comunicaciones para pacientes con problemas cardiovasculares, permitiéndoles supervisar de manera continua su FC y de esta forma identificar irregularidades. Mediante el uso del kit e-Health de Libelium y la placa Arduino, este sistema captura señales electrocardiográficas y las procesa para detectar variabilidades cardíacas. Además, Pérez (2018) investigó un dispositivo de monitorización cardíaca utilizando el ADAS1000 como front-end para el ECG, explorando la integración y comunicación con otros dispositivos. De igual forma, Vilorio et al. (2019) diseñaron un sistema de monitoreo de actividad cardíaca con transmisión inalámbrica a través de Zigbee, facilitando la visualización y análisis de señales electrocardiográficas. Mientras tanto, Burgos & Buendía, (2021) implementaron un sistema de monitoreo cardíaco y envío de alertas a través de una aplicación móvil, permitiendo seguimientos precisos a pacientes con problemas cardíacos. Además, Aguilar & López (2021) propuso un sistema de supervisión instantánea de señales electrocardiográficas. utilizando IoT, transmitiendo datos del electrocardiograma (ECG) a una plataforma para su visualización y obtención de informes. Cabrera et al. (2022), diseñaron una pulsera para detectar convulsiones tónico-clónicas, ofreciendo alertas visuales y auditivas para facilitar la atención médica. Vilorio & Bracho, (2022) desarrollaron un aparato de seguimiento cardíaco para uso ambulatorio basado en IoT, con la capacidad de analizar la FC empleando tecnología de vanguardia para amplificar, filtrar y procesar la señal cardíaca utilizando tecnología avanzada para amplificar, filtrar y acondicionar la señal cardíaca. Por otra parte, Ocampo & Ruiz (2024) diseñó un sistema para el seguimiento de la VFC mediante tecnologías IoT, transmitiendo datos a la nube y visualizándolos en un panel de control. Finalmente, Anuhya et al. (2024) presentaron un innovador método de clasificación para datos de ECG de manera inmediata, implementando un filtrado basado en el rango intercuartílico y un método de clasificación de características para identificar segmentos clave y optimizar la precisión predictiva del modelo.

En la monitorización de la frecuencia cardíaca, existen diversos dispositivos y tecnologías disponibles que han contribuido significativamente a la salud digital.

Algunos de estos dispositivos utilizan tecnologías como Zigbee, Bluetooth u otras plataformas especializadas para la transmisión de datos, mientras que otros se basan en sistemas tradicionales. Sin embargo, muchos de estos dispositivos pueden ser costosos, requieren componentes específicos y no siempre son accesibles para todos los usuarios. Para abordar estas limitaciones y ofrecer una solución más accesible y versátil, se propone desarrollar un sistema basado en aplicaciones móviles con conexión Wi-Fi y Bluetooth lo que facilita la conexión a redes inalámbricas para identificar y evaluar el nivel de estrés. Esta elección de tecnología no solo proporciona una conexión inalámbrica más amplia y flexible, sino que también ofrece la posibilidad de utilizar código abierto, lo que permite una mayor personalización y adaptabilidad del dispositivo. Asimismo, el uso de un enfoque de código abierto asegura la transparencia y promueve la colaboración en el proceso de desarrollo, lo que puede impulsar la innovación y facilitar la mejora constante del sistema. Este sistema no solo será más económico y accesible, sino que también permitirá una monitorización efectiva de la VFC en condiciones estresantes, como es la vida en la escuela o durante el protocolo TSST. Este dispositivo mecatrónico proporcionará información valiosa para comprender y tratar los impactos del estrés en el bienestar psicológico de los estudiantes. Su diseño práctico y portátil, junto con su capacidad para medir el estrés de manera efectiva, promete contribuir significativamente al estudio en el área del bienestar psicológico.

1.2. Descripción del problema

El estrés es una enfermedad que afecta tanto la salud física como la mental de las personas en todo el mundo. De acuerdo con datos de la Universidad del Valle de México, (2020) más de 73% de los mexicanos tiene estrés. Su prevalencia incrementa por los estilos de vida modernos, caracterizados por demandas crecientes y un ritmo acelerado. Entre los síntomas físicos y psicológicos asociados con el estrés se incluyen dolores de cabeza, hipertensión, alteraciones del sueño y sensaciones de ahogo, entre otros. A pesar de su impacto generalizado, la detección y el tratamiento del estrés sigue siendo un reto, especialmente en poblaciones marginadas con recursos limitados. La falta de dispositivos de vanguardia limita el acceso a una atención adecuada para quienes padecen estrés y otras condiciones relacionadas.

Uno de los problemas clave en la medición del estrés es la falta de consideración de la variabilidad de la frecuencia cardíaca (VFC), un indicador crucial para evaluar el estado de estrés de un individuo. Aunque la literatura científica reconoce su importancia, muchos dispositivos actuales no integran efectivamente la información de la VFC en sus algoritmos de análisis, lo que limita su precisión y utilidad.

Además, en el contexto nacional, existe una escasez notable de investigación científica en el desarrollo de dispositivos basados en el IoMT para la prevención y diagnóstico de enfermedades cardiovasculares y condiciones psicológicas. Esta brecha de conocimiento dificulta aún más la implementación de soluciones efectivas para abordar el estrés y sus consecuencias. Actualmente, la falta de un dispositivo inalámbrico, de código abierto y de bajo costo para monitorear la VFC en la comunidad estudiantil durante situaciones estresantes, como la aplicación del protocolo TSST, representa una limitación significativa. La ausencia de dispositivos portátiles y la dependencia de la conexión a energía eléctrica obstaculizan su uso en entornos hostiles y limitan su accesibilidad económica.

En resumen, esta investigación aborda la carencia de dispositivos de medición precisos y accesibles, particularmente aquellos que consideran la VFC un elemento clave para optimizar la identificación y el tratamiento del estrés, tanto en los estudiantes como en la sociedad en su conjunto.

1.3. Justificación

Este estudio se centrará en el desarrollo e implementación de un sistema inalámbrico basado en el IoMT, que permita portabilidad en ambientes desfavorables y sea de bajo costo. Este sistema de vanguardia facilitará la detección temprana y confiable del estrés, así como su tratamiento oportuno, especialmente en ambientes desafiantes con limitaciones económicas. De igual forma, este proyecto contribuirá al progreso en la investigación científica y la innovación tecnológica en el campo de los sistemas médicos sustentados en IoMT, especialmente en lo que respecta a la prevención y diagnóstico de condiciones psicológicas de estrés. Permitirá el desarrollo de una metodología donde el principal parámetro a evaluar, observar, medir, y caracterizar será la VFC de manera confiable, considerando factores contextuales y respuestas individuales y personalizadas, por medio de algoritmos de análisis basados en IA, ya que la VFC ha demostrado ser un indicador crucial para evaluar el estrés y su implicación en el bienestar mental y físico de los individuos. La investigación sobre la relación entre la VFC y trastornos como la depresión o la ansiedad puede generar un impacto positivo. La falta de sistemas accesibles así mismo, precisos para medir el estrés limita su evaluación, por lo que este estudio busca transformar su gestión en ámbitos educativos y sociales. Esto podría mejorar la calidad de vida y el bienestar general, al tratarse de una plataforma de desarrollo abierto, se fomenta además la colaboración interdisciplinaria y la mejora continua, facilitando su escalabilidad y adaptación a diversas poblaciones. Esta iniciativa se alinea con los objetivos de los Programas Nacionales Estratégicos (PRONACES) impulsados por la Secretaría de Ciencias, Humanidades, Tecnología e Innovación (SECIHTI), que reconocen la salud mental como un eje prioritario para el desarrollo del país. En consecuencia, este proyecto no solo aporta al avance científico y tecnológico en el

campo del IoMT, sino que también contribuye al fortalecimiento de las capacidades nacionales en investigación aplicada, con un impacto potencial en la calidad de vida y el bienestar emocional de la población.

1.4. Hipótesis y objetivos

1.4.1. Hipótesis

El desarrollo de un sistema inalámbrico, de código abierto y accesible basado en el Internet de las Cosas Médicas permitirá analizar la variabilidad de la frecuencia cardíaca mediante la Transformada Wavelet Continua y una Red Neuronal Convolucional (CNN), logrando así la detección inteligente del estrés para su monitorización y gestión oportunas.

1.4.2. Objetivo general

Durante la investigación, se diseñará y desarrollará un sistema portátil, inocuo e inalámbrico basado en el Internet de las cosas médicas que permita analizar la variabilidad de la frecuencia cardíaca de los jóvenes universitarios durante la aplicación del TSST para detectar el estrés.

1.4.3. Objetivos específicos

- Adquirir datos electrocardiográficos utilizando un sensor inalámbrico, asequible e inocuo, para la medición de la variabilidad de la frecuencia cardíaca.
- Implementar un protocolo de transferencia de datos para la comunicación eficiente entre el dispositivo móvil y un servidor web, permitiendo la transmisión de la información al especialista.
- Desarrollar una metodología que permita el análisis de la información proveniente del servidor web para la detección de estrés en jóvenes universitarios, la cual se visualizará en un reporte de clasificación.

- Realizar pruebas de funcionalidad en ambientes reales para validar el desarrollo tecnológico durante la aplicación del TSST

1.5. Planteamiento general

La metodología para el diseño e integración de un sistema basado en el Internet de las Cosas Médicas (IoMT) para el monitoreo de la variabilidad de la frecuencia cardíaca (VFC) se compone de varias etapas clave, representadas en la Figura 1.1. La primera etapa contempla el diseño del sistema de adquisición de datos, lo que incluye la selección del sensor más adecuado para la medición precisa y no invasiva de la VFC. En la segunda etapa, se desarrolla una aplicación móvil destinada a la captura de señales electrocardiográficas. La tercera etapa corresponde a la implementación de un protocolo de transferencia de datos eficiente, que garantice la comunicación entre el dispositivo móvil y un servidor web. Finalmente, en la cuarta etapa, se lleva a cabo la validación del sistema en un entorno real de aplicación, lo que permite evaluar su funcionalidad y desempeño en condiciones prácticas.

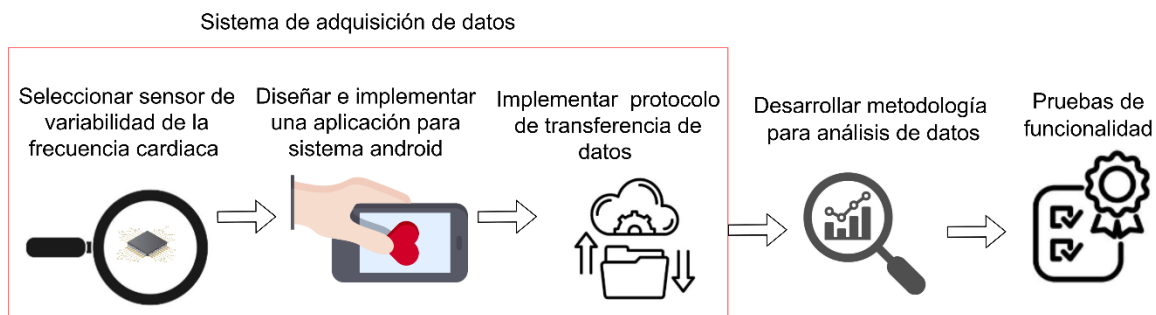


Figura 1.1. Planteamiento general de la Metodología (Autoría propia).

2.FUNDAMENTACIÓN TEÓRICA

Los principios presentados aquí conforman el fundamento teórico para llevar a cabo la metodología de monitoreo de la variabilidad de la frecuencia cardiaca (VFC) a través de un dispositivo inalámbrico basado en IoMT. Este dispositivo permitirá analizar de manera remota y determinará si se experimenta estrés o no durante la aplicación de la prueba social de estrés Trier (TSST, por sus siglas en inglés, *Trier Social Stress Test*) en jóvenes universitarios. A continuación, se presentan los fundamentos que sustentan esta metodología, incluyendo el concepto de estrés psicológico, la VFC y sus metodologías de análisis para la determinación del nivel de estrés, así como la estructura de un sistema IoMT y su aplicación en el monitoreo de señales biomédicas.

2.1.Relación entre el estrés, el sistema nervioso autónomo y la VFC

La palabra "estrés" proviene del griego *stringere*, que significa inducir tensión, y fue adoptada por primera vez en el siglo XIV. En 1935, Hans Selye introdujo el concepto de estrés en el ámbito de la salud, describiéndolo como un conjunto de respuestas fisiológicas inespecíficas del organismo ante demandas externas. El estrés surge cuando las demandas del entorno superan o no alcanzan el nivel óptimo de presión para cada individuo, generando un desequilibrio entre lo percibido y la capacidad de afrontamiento. Esta respuesta puede causar ansiedad, tensión y una variedad de síntomas físicos (Alarcón, 2018). Las manifestaciones del estrés varían según la persona e incluyen indicadores cognitivos (como dificultad para concentrarse o pensamientos obsesivos), fisiológicos (como dolores musculares, hipertensión, trastornos digestivos o del sueño) y conductuales (como el aumento de hábitos compulsivos o la evitación de situaciones estresantes) (Ávila, 2014).

Para comprender cómo el cuerpo responde al estrés, es esencial analizar el papel del sistema nervioso autónomo (SNA), que regula funciones internas involuntarias. El SNA está compuesto por dos ramas principales: el sistema simpático, encargado de activar la respuesta de "lucha o huida" ante amenazas, y el sistema parasimpático, responsable de restaurar el equilibrio y promover la

relajación (Redolar, 2015). La frecuencia cardíaca y la variabilidad de frecuencia cardíaca (VFC) son reguladas directamente por este sistema. Bajo estrés, se activa el sistema simpático, lo que tiende a aumentar la frecuencia cardíaca y reducir la VFC. Por el contrario, en estados de reposo o relajación, el sistema parasimpático domina, promoviendo una VFC más alta. Por ello, la VFC se ha consolidado como un biomarcador fisiológico clave para evaluar el impacto del estrés sobre el organismo, ya que refleja con precisión la capacidad del cuerpo para adaptarse a situaciones externas mediante la regulación del SNA.

La variabilidad de la frecuencia cardíaca (VFC) se ha consolidado como un indicador clave para el análisis del sistema nervioso autónomo (SNA), el cual regula funciones corporales involuntarias como la frecuencia cardíaca. La VFC refleja el equilibrio dinámico entre las ramas simpática y parasimpática del SNA, permitiendo evaluar el estado fisiológico ante diversos estímulos. Según Ishaque et al. (2021), la VFC se relaciona directamente con condiciones como el dolor, la somnolencia, el ejercicio físico y, en particular, el estrés, constituyéndose como un biomarcador robusto de bienestar.

2.2. Frecuencia cardíaca vs. VFC

La frecuencia cardíaca (FC) es el número de latidos del corazón por minuto y es esencial para su funcionamiento adecuado. En adultos, la FC normal en reposo está entre 50 y 100 latidos por minuto. En los recién nacidos, es más alta y disminuye gradualmente en el primer mes. El ejercicio o el estrés pueden aumentar la FC, pero es considerado normal. Se recomienda medirla en reposo y en un ambiente tranquilo, evitando el consumo de cafeína antes de la medición. Una FC elevada se asocia con un mayor riesgo de mortalidad en diversas poblaciones, lo que sugiere una reducción en la expectativa de vida (Fundación Española del Corazón, 2023).

La VFC, un método no invasivo utilizado para evaluar la modulación del sistema nervioso autónomo en el nodo sinusal cardíaco describe las oscilaciones entre intervalos R-R consecutivos del electrocardiograma, como se muestra en la Figura 2.1. Niveles altos de índices de VFC son generalmente signos de

mecanismos autonómicos eficientes que caracterizan a un individuo sano, mientras que una VFC baja o reducida a menudo muestra un mal funcionamiento del sistema nervioso autónomo y puede implicar un deterioro de la salud. La VFC es una opción atractiva y una herramienta clínica prometedora para evaluar e identificar el deterioro de la salud debido a su amplia gama de usos, el hecho de que es rentable adoptar la técnica y es fácil adquirir datos (Catai et al., 2020; Jandackova et al., 2019).



Figura 2.1. Variabilidad de la frecuencia cardíaca (autoría propia).

2.3. Metodologías de análisis de la VFC.

Los métodos de análisis de la VFC pueden ser divididos en métodos lineales y métodos no lineales.

2.3.1. Análisis de datos de la VFC usando métodos lineales.

La VFC se puede evaluar utilizando métodos lineales, analizados en los dominios del tiempo y de la frecuencia. Los métodos de dominio del tiempo se denominan así al expresar los resultados en unidad de tiempo (milisegundos). En el dominio del tiempo, se obtienen índices estadísticos y geométricos utilizando

técnicas matemáticamente simples que miden la variabilidad presente en la serie temporal de intervalos R-R (por ejemplo, intervalos R-R promedio, variaciones de la desviación estándar de los intervalos R-R, o mediana de la frecuencia cardíaca, intervalo Inter cuartil, intervalo de confianza del 95% e índices derivados del histograma o mapeo de coordenadas cartesianas de los intervalos R-R) y proporcionan índices que interpretan las fluctuaciones a lo largo de los ciclos cardíacos (Catai et al., 2020).

Entre los índices estadísticos, se pueden citar: La desviación estándar de todos los intervalos NN (normal a normal) o intervalos R-R (SDNN del Inglés Standard Deviation of NN intervals). Proporciona una medida global de la variabilidad de la frecuencia cardíaca durante un período de tiempo específico. Un valor más alto de SDNN indica una mayor variabilidad y es considerado un indicador de buena salud del sistema nervioso autónomo (McCraty & Shaffer, 2015; Catai et al., 2020), este valor se calcula mediante la ecuación 1 donde: x_i es el i-ésimo intervalo NN o intervalos RR; \bar{x} es el valor promedio de todos los intervalos NN o intervalos RR; N es el número total de intervalos.

$$SDNN = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}} \quad (1)$$

La desviación estándar de los promedios de intervalos NN (SDANN del Inglés Standard Deviation of Average NN intervals) se calcula en segmentos más largos, usualmente en intervalos de 5 minutos y proporciona información sobre la variabilidad a largo plazo de la frecuencia cardíaca. Este indicador se utiliza para evaluar la variabilidad diurna y nocturna de la frecuencia cardíaca (McCraty & Shaffer, 2015; Catai et al., 2020) y se representa en la ecuación 2.

$$SDANN = \sqrt{\frac{\sum_{i=1}^N (\bar{x}_i - \bar{\bar{x}})^2}{N}} \quad (2)$$

La raíz cuadrada de la media de los cuadrados de las diferencias entre intervalos R-R consecutivos (RMSSD del inglés Root Mean Square of Successive Differences) es una medida de la variabilidad a corto plazo de la frecuencia cardíaca. Este indicador es particularmente sensible a las variaciones respiratorias y se utiliza como un marcador de la actividad del sistema nervioso parasimpático

(McCraty & Shaffer, 2015; Catai et al., 2020). En esta métrica x_i y x_{i-1} son intervalos R-R consecutivos, y N es el número total de intervalos.

$$RMSSD = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (x_i - x_{i-1})^2} \quad (3)$$

pNN50 es el porcentaje de intervalos R-R sucesivos que difieren en más de 50 milisegundos entre sí (pNN50 del inglés Percentage of successive R-R intervals differing by more than 50 ms). Similar al RMSSD, pNN50 es también un indicador de la actividad del sistema nervioso parasimpático y de la variabilidad de corto plazo de la frecuencia cardíaca (McCraty & Shaffer, 2015; Catai et al., 2020), ecuación 4, donde: *Número total de intervalos R-R*; *Número de intervalos RR sucesivos con diferencia > 50 ms* es el número de pares de intervalos R-R sucesivos que cumplen con el criterio de diferencia de tiempo.

$$pNN5 = \frac{\text{Numero de intervalos RR sucesivos con diferencia} > 50 \text{ ms}}{\text{Total de intervalos RR}} \times 100 \quad (4)$$

2.4. Protocolo de estrés social Trier (TSST)

El protocolo TSST, es reconocida como una herramienta efectiva para inducir estrés agudo en laboratorios, mediante entornos controlados. Este protocolo se estructura en cuatro fases, tal como se ilustra en la figura 2.2. La primera fase consiste en un segmento de pre-Test de 5 minutos. En la segunda fase, el participante debe preparar un discurso sobre por qué es el candidato ideal para su empleo soñado. Durante la tercera fase, que dura también 5 minutos, el participante debe presentar este discurso ante un público. Finalmente, en la cuarta fase, el participante debe completar una tarea matemática durante 5 minutos (Allen et al., 2017; Labuschagne et al. 2019).

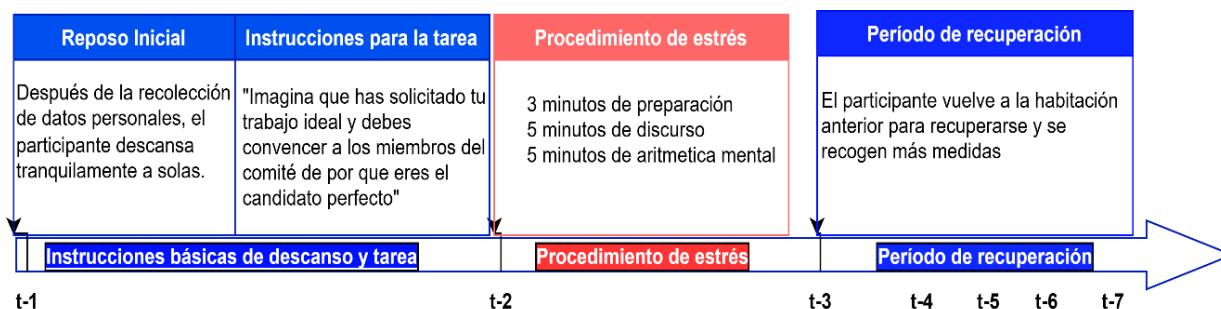


Figura 2.2. Esquema general de TSST (autoría propia).

Por lo que, Allen et al. (2017) realizaron una evaluación crítica de diferentes marcadores biológicos y psicológicos utilizados en estudios relacionados con la TSST. Además, discutieron la posibilidad de que los tratamientos farmacológicos y psicológicos pudieran atenuar las respuestas al estrés inducidas por la TSST. Este estudio también exploró protocolos modificados de la TSST y comparó su efectividad con otros métodos de inducción de estrés agudo. A su vez, Johnson et al. (2017) se enfocaron en adaptar la TSST de manera culturalmente sensible para adolescentes de 14 años, lo que incluyó modificaciones en las indicaciones de las tareas, el uso de compañeros étnicamente similares como confederados y la presencia de un examinador juvenil desconocido. Los resultados de este estudio piloto indicaron que esta versión modificada de la TSST logró provocar respuestas significativas de cortisol, aunque con variabilidad debido a las diferencias individuales.

2.5. Transformada Wavelet Continua (CWT)

La transformada wavelet se clasifica principalmente en dos tipos: la transformada wavelet continua (CWT) y la transformada wavelet discreta (DWT). La CWT es una técnica de análisis multiescala que permite descomponer una señal en coeficientes de aproximación y de detalle en distintas escalas. Los coeficientes de aproximación reflejan las componentes de baja frecuencia, mientras que los coeficientes de detalle capturan las variaciones de alta frecuencia de la señal (Ciupe et al., 2015).

Aunque la CWT demanda un mayor costo computacional en comparación con la DWT, ofrece una mejor localización tanto en el dominio del tiempo como de la frecuencia, así como una resolución variable que la hace especialmente adecuada para el análisis de señales no estacionarias como las del electrocardiograma (ECG). Por estas razones, se adopta en este estudio para transformar las señales de ECG en mapas de características tiempo-frecuencia (Rivero et al., 2016; Barajas, 2016). El cálculo de la CWT se expresa mediante la ecuación 5.

$$c_{a,b} = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (5)$$

Dónde $x(t)$ es la señal de entrada, $\psi(t)$ es la función base wavelet, a y b son los parámetros de escala y traslación, y $*$ denota el conjunto conjugado. $c_{a,b}$ son los coeficientes de wavelet que representan los componentes de la señal a escala a y posición b . CWT tiene una mejor capacidad de adaptación en términos de resolución de tiempo-frecuencia, lo que puede resaltar mejor la característica local de la señal de ECG real.

En este estudio se utiliza la wavelet Morlet como función base debido a su capacidad para capturar patrones relevantes en las señales de ECG, particularmente aquellos vinculados con estados de estrés. La CWT permite representar la señal en el dominio tiempo-frecuencia, lo que facilita la visualización y análisis de las variaciones en las frecuencias fisiológicas asociadas al estrés.

2.6. Estructura general de IoMT

Un sistema IoMT es un conjunto integrado de dispositivos, sensores, software y servicios diseñados para recopilar, transmitir y analizar datos médicos en tiempo real. Estos sistemas buscan mejorar la atención médica, el monitoreo de pacientes, el diagnóstico y el tratamiento mediante la automatización y la recopilación de datos (Huang et al., 2023; Wagan et al., 2022).

En la figura 2.3 se presenta una estructura general de un sistema IoMT, que se compone de cuatro fases o capas principales interrelacionadas para integrar efectivamente el sistema IoMT. La primera fase involucra la adquisición de señales fisiológicas, seguida por la transmisión de estos datos utilizando protocolos rentables y eficientes. En la fase de la plataforma IoT, se facilita el manejo de los datos recopilados. Finalmente, los datos son utilizados, ya sea por algoritmos o por especialistas en análisis de datos, para extraer información útil (Huang et al., 2023; Rahman et al., 2023).

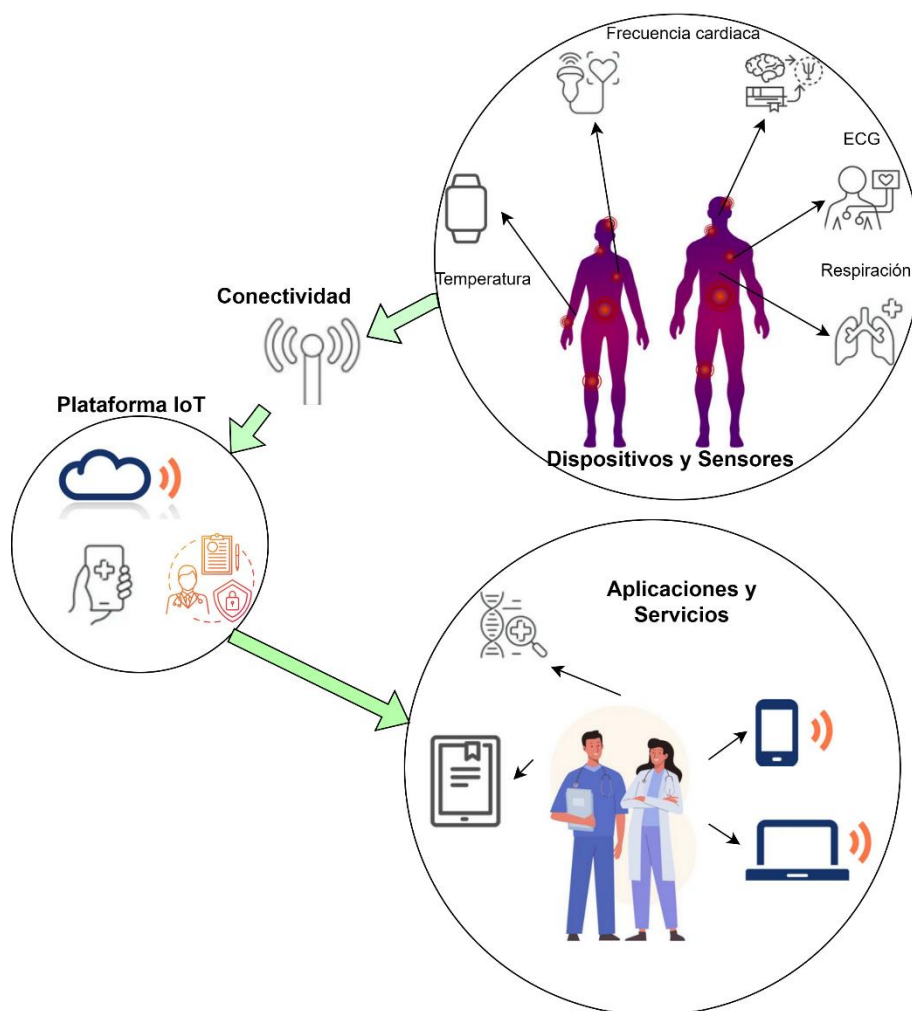


Figura 2.3. Estructura general de un sistema IoMT (autoría propia).

2.6.1. Dispositivos y sensores

2.6.1.1. Sensores en sistemas de salud basados en IoT

En los sistemas de salud modernos, los sensores juegan un papel clave al permitir la monitorización continua de parámetros fisiológicos, reduciendo así la necesidad de equipos médicos convencionales costosos y el número de visitas hospitalarias. En el contexto del Internet de las Cosas (IoT), estos sensores registran datos en tiempo real y facilitan una comunicación eficiente entre dispositivos, mejorando la atención médica, especialmente en entornos domiciliarios. Entre los sensores más utilizados se encuentran los de temperatura, los de electrocardiografía (ECG) y los que miden la frecuencia de pulso cardíaco (Ashfaq et al., 2022).

Ray et al. (2020) proponen una taxonomía de sensores IoT utilizados en puntos de atención médica, clasificándolos en cuatro grupos principales: Sensores desechables de e-salud; sensores conectados de e-salud; sensores IoT para e-salud; sensores emergentes con capitalización de mercado en IoT

2.6.1.2. Sensores para medir VFC

Para la evaluación de la VFC, se emplean principalmente tres tipos de sensores: electrodos, ópticos de muñeca y ópticos de brazo, cada uno con características distintas en cuanto a precisión y aplicabilidad.

a) Sensores de Electrodos

Estos sensores miden directamente la actividad eléctrica del corazón mediante bandas con electrodos colocadas en el pecho. Son altamente precisos y confiables en contextos deportivos o clínicos, aunque su uso puede resultar incómodo para algunas personas. Dispositivos como el Polar H10 y el Garmin HRM-Pro Plus son referencias destacadas por su precisión y datos adicionales (Schaffarczyk et al., 2022).

b) Sensores Ópticos de Muñeca

Utilizan la técnica de fotopleletismografía (PPG) para detectar cambios en el volumen sanguíneo bajo la piel mediante luces LED. Son populares por estar integrados en relojes inteligentes y pulseras de actividad, lo que los hace prácticos y fáciles de usar. Sin embargo, factores como el movimiento intenso, la

contracción muscular o ciertas características de la piel pueden afectar su precisión. Ejemplos comunes incluyen el Polar Vantage V3 y el Garmin Pacer Pro (Lamberts et al., 2024).

c) Sensores Ópticos de Brazo

Funcionan también con PPG, pero se colocan en el antebrazo o la parte superior del brazo, ofreciendo mayor estabilidad y precisión que los sensores de muñeca durante actividades intensas. Dispositivos como el Polar Verity Sense y el Scosche Rhythm 24 destacan por su versatilidad, comodidad y autonomía.

2.6.1.3. Sensor de VFC Polar H10

En 1983, la empresa Polar Electro lanzó al mercado el primer monitor de frecuencia cardíaca, el cual consistía en una correa pectoral como sensor y un reloj de pulsera que funcionaba como interfaz de usuario, pantalla de frecuencia cardíaca y dispositivo de almacenamiento (Laukkanen & Virtanen, 1998). En ese entonces, la principal duda giraba en torno a la precisión de este tipo de sensor, especialmente si podía equipararse con los monitores de electrocardiograma (ECG) utilizados en entornos clínicos. Estudios científicos demostraron que, en efecto, la medición obtenida mediante la correa pectoral era comparable en exactitud a la realizada con equipos médicos especializados (Kingsley et al., 2005). Desde entonces, este tipo de solución técnica se ha consolidado como una herramienta confiable para la medición de la frecuencia cardíaca.

En la actualidad, dispositivos como el sensor Polar H10 representan la evolución de esta tecnología, al integrar la quinta generación de sistemas de medición de frecuencia cardíaca desarrollados por Polar, destacándose por su alta precisión (Gilgen-Ammann et al., 2019). Además, este sensor ofrece acceso abierto a la señal de ECG, permitiendo su utilización por parte de desarrolladores externos a través del SDK proporcionado por la marca.

El electrocardiograma (ECG) mide la actividad eléctrica del corazón y cada latido genera una fase particular en la señal, caracterizada por distintos componentes. Entre ellos, el complejo QRS es el más relevante para el cálculo de la frecuencia cardíaca, ya que refleja la contracción de los ventrículos.

En teoría, detectar con precisión la frecuencia cardíaca es un proceso relativamente sencillo, pues solo requiere identificar con exactitud los cambios en la polaridad eléctrica del corazón. Sin embargo, mantener esta precisión durante la actividad física presenta importantes retos debido a las condiciones variables que afectan la señal. Por esta razón, Polar ha desarrollado la banda ProStrap, especialmente diseñada para su uso deportivo. Esta incorpora soluciones técnicas innovadoras que permiten mitigar las interferencias y garantizar una medición fiable, incluso en entornos exigentes.

Entre las especificaciones técnicas más relevantes del sistema ECG de Polar ProStrap se incluyen:

- Registro de ECG: derivación única
- Impedancia de entrada: $2\text{ M}\Omega$ (con ProStrap humedecido)
- Ancho de banda: 0,7 – 40 Hz (con ProStrap humedecido)
- Rango dinámico de entrada: $\pm 20\,000\text{ }\mu\text{V}$
- Frecuencia de muestreo: $130\text{ Hz} \pm 2\%$ (a temperatura ambiente entre $+20$
- $^{\circ}\text{C}$ y $+40\text{ }^{\circ}\text{C}$)
- $130\text{ Hz} \pm 5\%$ (a temperaturas entre $-20\text{ }^{\circ}\text{C}$ y $+70\text{ }^{\circ}\text{C}$)
- Disponibilidad de marcas de tiempo precisas por muestra

2.6.2. Conectividad

Las tecnologías de comunicación en un sistema IoMT se dividen principalmente en dos tipos: comunicación de corto alcance, que conecta la puerta de enlace con dispositivos en la capa de percepción usando tecnologías como Bluetooth, ZigBee, RFID, NFC, Wifi; y comunicación de largo alcance, que vincula la puerta de enlace con el servidor en la nube a través de tecnologías como 4G, 5G, WAN y satélite (Huang et al., 2022; Rahman et al., 2023).

2.6.2.1. Protocolos en sistemas IoMT

Los sistemas IoT intercambian datos con la red a través de protocolos específicos diseñados para este propósito. El protocolo de Internet (IP) es un grupo de normas que establece cómo se transmiten los datos en Internet. Los protocolos de IoT aseguran que un dispositivo, una puerta de enlace o un servicio puedan interpretar y comprender la información enviada por otro dispositivo o sensor. Se han creado y optimizado diversos protocolos de IoT para satisfacer diferentes escenarios y necesidades. Debido a la variedad de dispositivos IoT disponibles, es esencial utilizar el protocolo adecuado para cada contexto específico (Microsoft, 2024). En un sistema de Internet de las Cosas Médicas (IoMT), se utilizan diversos protocolos de comunicación, organizados por niveles, que garantizan la conexión eficiente y segura entre dispositivos médicos y plataformas de monitoreo.

En el nivel de aplicación, el protocolo MQTT (Message Queuing Telemetry Transport) es ampliamente adoptado por su eficiencia en dispositivos con recursos limitados. Este protocolo sigue un modelo de publicación-suscripción y está diseñado para conexiones ligeras, lo que lo hace ideal en entornos de baja capacidad y larga distancia.

El nivel de transporte se encarga de la transmisión confiable de los datos. En este nivel, se utiliza el Protocolo de Control de Transmisión (TCP), el cual fragmenta los datos en paquetes, los transmite y los reensambla, asegurando la integridad de la comunicación entre los dispositivos conectados.

En el nivel de red, el Protocolo de Internet (IP) —en sus versiones IPv4 o IPv6— permite la identificación y localización de cada dispositivo en la red, facilitando el enrutamiento del tráfico en entornos conectados.

El nivel físico, encargado del canal de comunicación entre dispositivos, incluye tecnologías como Bluetooth de Bajo Consumo (BLE) y WiFi (802.11). BLE se destaca por su bajo consumo energético, compatibilidad con sistemas móviles y creciente popularidad en dispositivos portátiles. Por su parte, el WiFi, aunque es

una opción asequible y ampliamente utilizada en hogares y oficinas, puede resultar limitado en alcance y dependiente de una fuente continua de energía.

Esta estructura por niveles permite adaptar los sistemas IoMT a diversas necesidades clínicas, garantizando una comunicación confiable, eficiente y segura entre dispositivos médicos y plataformas de monitoreo (Microsoft, 2024)..

2.6.3. Plataformas de IoMT

Las tecnologías Las plataformas de Internet de las Cosas Médicas (IoMT) se apoyan en tecnologías de computación paralela como la computación en la nube, en la niebla y en el borde. Inicialmente, los sistemas IoMT se implementaban mayoritariamente sobre computación en la nube, utilizando plataformas como Google Cloud IoT, AWS IoT y Azure IoT, debido a su escalabilidad y capacidad para manejar grandes volúmenes de datos. Sin embargo, para reducir la latencia, mejorar la seguridad y permitir una respuesta en tiempo real, ha emergido una tendencia hacia arquitecturas más distribuidas, como la computación en la niebla y en el borde.

Entre estas plataformas, Google Cloud IoT destaca por su integración fluida con otros servicios de Google, su infraestructura escalable y sus herramientas de análisis de datos. Es ideal para desarrolladores por su facilidad de uso y su capacidad de análisis avanzado, aunque los costos pueden aumentar con el uso intensivo de recursos (Hasan, 2022).

AWS IoT ofrece una mayor gama de servicios, seguridad robusta y una comunidad amplia, pero presenta una curva de aprendizaje más pronunciada. Azure IoT, por su parte, es adecuada para quienes ya trabajan en entornos Microsoft, aunque también puede implicar costos complejos. Para sectores específicos como el industrial o energético, plataformas verticales como Bárbara IoT ofrecen soluciones más personalizadas, aunque con herramientas más limitadas.

Adicionalmente, la capa de gestión de servicios en IoMT emplea frameworks como Flask o Apache 2 para escalabilidad, y bases de datos como MongoDB para almacenamiento flexible. Se implementan estándares de seguridad

como SSL API para proteger la comunicación. A futuro, se investiga el uso de blockchain y arquitecturas descentralizadas como edge cloud para incrementar la seguridad y la escalabilidad en entornos médicos (Dwivedi et al., 2022).

2.6.4. Aplicaciones y servicios del IoMT en la atención médica

El Internet de las Cosas Médicas (IoMT) está transformando la atención sanitaria mediante el monitoreo remoto en tiempo real de los pacientes, permitiendo la supervisión de signos vitales y condiciones críticas. Este monitoreo es complementado por alertas automáticas ante emergencias o cambios significativos en la salud (Ashfaq et al., 2022). Los algoritmos avanzados e inteligencia artificial (IA) en la capa de gestión del servicio optimizan el diagnóstico, el tratamiento y el seguimiento de la evolución del paciente.

Durante la pandemia de COVID-19, el IoMT avanzó hacia sistemas inteligentes que emplean IA para predicción y toma de decisiones sobre enfermedades. Estos sistemas recogen datos de signos vitales y los visualizan en plataformas especializadas como ThingSpeak, enviando alertas a familiares y médicos mediante correo electrónico, redes sociales y la ubicación GPS del paciente (Ashfaq et al., 2022).

El monitoreo de la salud mental también ha ganado relevancia, utilizando aprendizaje automático e IA para evaluar el bienestar emocional y medir el estrés. A pesar de desafíos en privacidad, este enfoque promete revolucionar el diagnóstico y tratamiento de trastornos mentales (Castañeda-Garza et al., 2023).

En resumen, las aplicaciones y servicios del IoMT en salud incluyen:

Monitoreo remoto de pacientes: Permite la supervisión continua de signos vitales, mejorando el acceso a la atención y reduciendo la necesidad de visitas físicas.

Análisis de datos clínicos: Facilita la toma de decisiones basadas en grandes volúmenes de datos, mejorando las intervenciones tempranas y los tratamientos personalizados.

Tecnología vestible (wearables): Dispositivos como relojes inteligentes permiten el seguimiento constante del estado de salud y la gestión proactiva del bienestar.

Telemedicina: La integración del IoMT en la telemedicina facilita consultas médicas seguras y en tiempo real, mejorando el acceso a la atención en áreas remotas (Rahman et al., 2023).

2.7. Formación y representación de la imagen

Una imagen puede entenderse como una forma visual que representa un objeto capturado desde su entorno físico. En la vida cotidiana, lo que observamos como imágenes proviene de la interacción de la luz con los objetos, específicamente de la luz que estos reflejan. Desde un punto de vista técnico, una imagen está determinada por una función matemática bidimensional, denotada como $f(x,y)$, la cual depende de dos factores esenciales: por un lado, la iluminación, es decir, la intensidad de la luz que incide sobre la superficie del objeto desde una fuente luminosa; y por otro lado, la reflectancia, que corresponde a la proporción de luz que el objeto refleja hacia el sensor de captura. Estas dos funciones se expresan comúnmente como $i(x,y)$, para la iluminación y $r(x,y)$ para la reflectancia, y su combinación da lugar a la imagen observada $f(x,y)$.

La creación de una imagen no es un fenómeno aislado, sino que involucra un conjunto de componentes: el objeto físico que se desea representar y además, es necesario un mecanismo de captura de imágenes que registre la interacción entre la luz y el objeto físico. Este sistema está integrado por elementos ópticos y un convertidor que digitaliza la señal captada. Una vez digitalizada, la imagen se almacena como una matriz de tamaño N por M , donde cada elemento de la matriz representa un valor de intensidad correspondiente a una coordenada específica (x,y) en la imagen, como se muestra en la ecuación 2.2. Esta representación matricial facilita su procesamiento, análisis y visualización en sistemas computacionales (Gonzalez & Woods, 2017).

$$f = \begin{bmatrix} f(1,1) & f(1,2) & \dots & f(1,M) \\ f(2,1) & f(2,2) & \dots & f(2,M) \\ \vdots & \vdots & \dots & \vdots \\ f(N,1) & f(N,2) & \dots & f(N,M) \end{bmatrix} \quad (2.2)$$

2.8. Aprendizaje profundo y aumento de datos

El aprendizaje automático es una rama de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos capaces de aprender y tomar decisiones a partir de datos, sin estar explícitamente programados para cada tarea. En particular, el aprendizaje profundo (*Deep Learning*), una subárea del aprendizaje automático ha sido ampliamente utilizado en aplicaciones como visión artificial, análisis de datos biomédicos y evaluación clínica. (Chollet, 2021).

2.8.1. Aumento de datos

Método frecuentemente empleado en el aprendizaje profundo para potenciar el desempeño de los modelos de aprendizaje automático, especialmente en casos donde la disponibilidad de datos es limitada o insuficiente. El objetivo primordial consiste en la generación de datos adicionales a partir de los existentes mediante la aplicación de modificaciones aleatorias o dirigidas.

Mediante técnicas que se basan en la transformación de imágenes a datos numéricos, se pueden aplicar operaciones matemáticas que modifican la relación espacial entre los píxeles de una imagen. Por ejemplo, la aplicación de un "espejo" virtual a una imagen altera la disposición espacial de los elementos que la componen. En relación con la operación de "espejo" ($IMB(i,j)$), esta transforma o invierte la imagen original ($IMA(i,j)$) Para reflejar una imagen digitalmente a lo largo del eje vertical, se puede aplicar la ecuación 2.9. Esta transformación matemática invierte la posición de los píxeles a lo largo del eje y, creando una imagen "espejo" que refleja la original verticalmente. Por otro lado, para reflejar la imagen a lo largo del eje horizontal, se puede utilizar la ecuación 2.10. Esta operación matemática invierte la posición de los píxeles a lo largo del eje x,

generando una imagen reflejada horizontalmente con respecto a la original, según lo descrito por González y Woods (2017).

$$IMB(i, j) = IMA(N - i, j) \quad (2.9)$$

$$IMB(i, j) = IMA(i, M - j) \quad (2.10)$$

En este contexto, i, j representan las coordenadas de cada píxel en la imagen, mientras que N corresponde al número total de columnas (ancho) y M al número total de filas (altura) de la imagen, como se muestra en la figura 2.4.

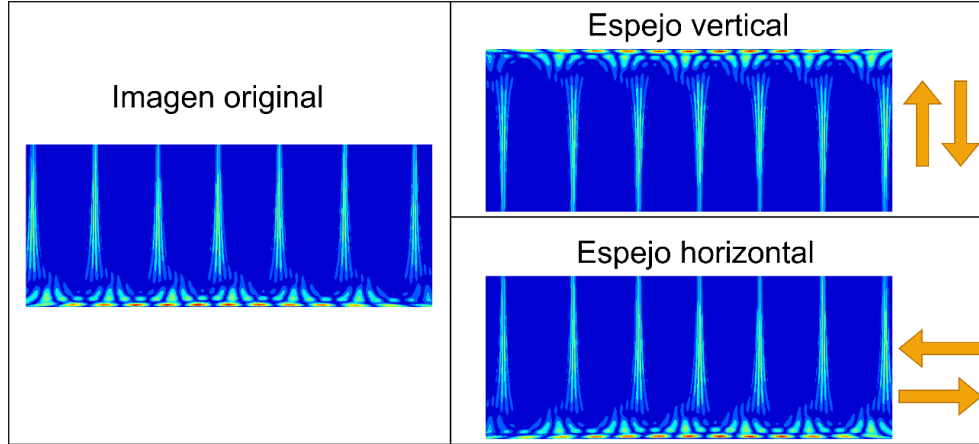


Figura 2.4. Aumento de datos, espejo horizontal y vertical (Autoría propia).

2.9. Redes neuronales convolucionales (CNN)

Las redes neuronales se han consolidado como una herramienta fundamental en el campo de la inspección visual. Son ampliamente utilizadas en diversas tareas como la clasificación de imágenes, la detección de objetos, el reconocimiento facial y la segmentación de imágenes. En particular, las redes neuronales convolucionales (CNN) se emplean con frecuencia en los sistemas de visión por computadora. Estas redes neuronales convolucionales poseen una arquitectura específica, tal como se ilustra en la figura 2.5. Dicha arquitectura se compone de múltiples capas, incluyendo capas de convolución, capas de agrupamiento máximo y capas totalmente conectadas. Esta estructura permite a las CNN identificar características a diferentes niveles de abstracción a medida que la información se propaga a través de la red (Goodfellow et al., 2016).

De esta manera, las redes neuronales convolucionales han demostrado ser una herramienta poderosa y versátil para abordar una amplia gama de

problemas relacionados con la visión por computadora, gracias a su capacidad de extraer y procesar eficazmente las características visuales relevantes.




Figura 2.5. La CNN secuencial (Autoría propia).

La función principal de la capa convolucional es identificar rasgos locales dentro de la imagen, tales como contornos y patrones de textura. Esta capa lleva a cabo una operación de convolución entre la imagen de entrada y un conjunto de filtros o núcleos. El resultado de esta operación es una nueva representación de la imagen, conocida como mapa de características o un conjunto de ellos. La ecuación 2.19 describe cómo se genera un valor y_{ij} en el mapa de características al aplicar un filtro W sobre una entrada x .

$$y_{ij} = (x * W)_{ij} + b \quad (2.19)$$

Una vez realizada la operación de convolución, el resultado se procesa mediante una función de activación, siendo la más utilizada la ReLU (Unidad Lineal Rectificada, por sus siglas en inglés). Esta función está definida por la ecuación 2.20.

$$ReLU(z) = \max(0, z) \quad (2.20)$$

En este contexto, z representa el valor obtenido en el mapa de características tras aplicar la operación de convolución y añadir el sesgo correspondiente. Posteriormente, la capa de *pooling* se encarga de disminuir la resolución espacial de la imagen, lo cual se logra mediante el muestreo y la combinación de las características extraídas en la capa convolucional anterior. Este proceso suele implementarse utilizando técnicas como el *max-pooling* o el *average-pooling*, de acuerdo con lo definido en la ecuación 2.21.

$$y_{ij} = \max (x_{m,n}: m, n \in \text{ventana}) \quad (2.21)$$

En este caso, *ventana* hace referencia a un subconjunto de la entrada x centrado en la posición (i, j) , mientras que y_{ij} representa el valor obtenido como resultado del proceso de *pooling* en dicha ubicación. Por último, la capa totalmente conectada emplea las características extraídas previamente para llevar a cabo funciones de clasificación o detección, conforme a lo expresado en la ecuación 2.22.

$$y = Wx + b \quad (2.22)$$

Durante el entrenamiento, la red neuronal compara sus predicciones con los valores reales de los datos de entrenamiento. Una de las métricas de error más comunes en problemas de clasificación es la entropía cruzada, representada por la ecuación 2.23. Esta función de costo cuantifica la divergencia entre la distribución de probabilidades predicha por la red y la distribución real de las clases. Al minimizar esta métrica durante el aprendizaje, la red ajusta sus parámetros internos para generar predicciones cada vez más precisas y alineadas con las etiquetas verdaderas. La entropía cruzada es fundamental para que las redes neuronales convolucionales puedan aprender eficazmente a realizar tareas de clasificación visual, optimizando su desempeño a través de la minimización de este error.

$$L(y, \hat{y}) = - \sum_i y_i \log (\hat{y}_i) \quad (2.23)$$

Donde, y corresponde al vector que contiene las etiquetas reales, mientras que \hat{y}_i representa el vector de salidas predichas por la red neuronal (Goodfellow et al., 2016).

2.9.1. Redes neuronales convolucionales divisible en profundidad (CNN)

Las DSCNN son técnicas eficaces dentro del área de la visión por computadora, y se emplean de forma extensiva en actividades como la

clasificación de imágenes, la detección de objetos, el reconocimiento de rostros y la segmentación de imágenes.

Así mismo, Figura 2.6, presentan una arquitectura optimizada que mantiene la precisión en la clasificación al tiempo que reduce significativamente el costo computacional y el número de parámetros, lo cual las hace especialmente adecuadas para dispositivos con recursos limitados, como los dispositivos móviles. A diferencia de las CNN estándar, las DSCNN descomponen las convoluciones en dos pasos: una convolución depthwise, que aplica filtros individualmente a cada canal de entrada, y una convolución pointwise, que utiliza filtros de 1×1 para combinar las características extraídas en cada canal. Este diseño permite obtener una mayor eficiencia sin comprometer la calidad de los resultados. En este trabajo, se emplea la DSCNN para clasificar el nivel de estrés, aprovechando su ventaja en términos de reducción de parámetros y eficiencia computacional frente a las CNN tradicionales (Waghumbare et al., 2024).




Figura 2.6. Arquitectura de la DSCNN (Autoría propia).

2.9.1.1. Convolución Depthwise y Pointwise de una DSCNN

Al emplear una DSCNN, se realizan convoluciones por canal (Depthwise Convolution), esto corresponde, a que se aplica un filtro $k \times k$ a cada canal de entrada de forma independiente. En una convolución estándar, un filtro se aplica a toda la entrada (a través de todos los canales), pero en la convolución depthwise, cada canal recibe su propio filtro, lo que reduce el número de cálculos requeridos. Por ejemplo, para la operación matemática de la convolución depthwise, con una

entrada x de tamaño $W \times H$ con C canales, la salida en la posición (i, j) de un canal específico está dada como se muestra en la ecuación (2.24) (Li et al., 2022; Chollet, 2017).

$$y_{i,j} = \sum_m \sum_n x_{i+m, j+n} \cdot f_{m,n} \quad (2.24)$$

Donde $y_{i,j}$ es el valor de salida en la posición (i, j) en un canal específico; $x_{i+m, j+n}$ es el valor de entrada en la posición $(i + m, j + n)$ del mismo canal; $f_{m,n}$ es el valor del filtro depthwise en la posición (m, n) de tamaño $k \times k$. Este proceso se realiza para cada canal de forma independiente, por lo que si tenemos C canales en la entrada, aplicamos C filtros, uno por canal. Y en el caso de la convolución pointwise (Chollet, 2017), usa un filtro de tamaño 1×1 para combinar las características obtenidas en cada canal de la convolución depthwise, lo que reduce la cantidad de parámetros sin sacrificar rendimiento. Por ejemplo, en la operación matemática de la convolución pointwise, dada una salida de la convolución depthwise con tamaño $W \times H \times C$, la convolución pointwise aplica un filtro 1×1 en cada posición espacial, realizando una combinación lineal de los canales de entrada. La operación en una posición (i, j) es según la ecuación (2.25):

$$y_{i,j} = \sum_c x_{i,j,c} \cdot w_c \quad (2.25)$$

Donde $y_{i,j}$ es el valor de salida en la posición (i, j) ; $x_{i,j,c}$ es el valor de la entrada en la posición (i, j) y canal c ; w_c es el valor del filtro 1×1 en el canal c . Finalmente, el resultado de la convolución pointwise es una combinación de los canales obtenidos en el paso de convolución depthwise, generando una salida con D canales, donde D es el número de filtros pointwise.

2.9.1.2. Ventajas de la convolución Depthwise (separable en profundidad)

Principalmente se tiene menor costo computacional, la separación en dos pasos reduce el número de multiplicaciones necesarias, ya que en lugar de aplicar

un filtro completo de tamaño $k \times k \times C$ a la entrada, se aplican filtros $k \times k$ individualmente en cada canal y luego una combinación 1×1 sobre el resultado [42,43]. También se tienen menos parámetros debido a que la convolución depthwise separable usa filtros independientes en cada canal y combina las características con convoluciones 1×1 , el número de parámetros es significativamente menor en comparación con una convolución estándar de tamaño $k \times k \times C \times D$ (Chollet, 2017; Z. Huang et al., 2022). En resumen, la convolución depthwise separable realiza el filtrado espacial de cada canal por separado (convolución depthwise) y luego combina los resultados en una representación más rica (convolución pointwise), lo que la hace muy eficiente para aplicaciones en redes neuronales profundas (Gupta et al., 2024).

2.10. Métricas de evaluación

Una herramienta clave para evaluar el rendimiento de un modelo de clasificación convolucional durante el entrenamiento es la matriz de confusión. Esta representación gráfica permite visualizar cómo se comporta el modelo al comparar sus predicciones con los valores reales de las muestras de prueba. La matriz de confusión se estructura de una manera específica (como se muestra en la Figura 2.7.) que facilita el análisis detallado del desempeño del clasificador. Esta herramienta proporciona una imagen clara de los aciertos y errores del modelo, lo que resulta fundamental para identificar áreas de mejora y ajustar los hiperparámetros de entrenamiento en consecuencia. El uso de la matriz de confusión es una práctica estándar en el desarrollo de redes neuronales convolucionales, ya que brinda información valiosa sobre la precisión, sensibilidad y especificidad del modelo a lo largo del proceso de aprendizaje.

		Valores actuales	
		Negativo	Positivo
Valores predichos	Negativo	TN	FN
	Positivo	FP	TP

Figura 2.7. Matriz de confusión (Autoría propia).

En este contexto, TN (Verdaderos Negativos) representa el número de instancias que han sido correctamente clasificadas como negativas, mientras que FN (Falsos Negativos) corresponde a aquellos casos que han sido erróneamente etiquetados como negativos, es decir, fallos en la detección. Por otro lado, FP (Falsos Positivos) hace referencia a los casos que fueron incorrectamente clasificados como positivos, también considerados errores en la predicción. Finalmente, TP (Verdaderos Positivos) indica el número de casos que fueron acertadamente clasificados como positivos. Más allá de la representación visual que ofrece la matriz de confusión, los valores numéricos que la componen pueden utilizarse para calcular métricas adicionales que profundizan en el análisis del desempeño del modelo de clasificación (Goodfellow et al., 2016). Estas métricas derivadas permiten evaluar con mayor detalle aspectos como la precisión, sensibilidad, especificidad y otras características clave del clasificador. Al disponer de este conjunto más amplio de indicadores, los investigadores pueden obtener una imagen más completa y matizada del comportamiento del modelo, lo que facilita la identificación de fortalezas, debilidades y oportunidades de mejora.

El cálculo de estas métricas complementarias a partir de la información contenida en la matriz de confusión se ha convertido en una práctica estándar en el campo del aprendizaje profundo. Esto permite aprovechar al máximo el potencial analítico de esta herramienta fundamental en el desarrollo y refinamiento de modelos de clasificación convolucionales.

Exactitud: Evalúa la fracción de predicciones acertadas, incluyendo tanto los casos positivos como negativos, en relación con el total de predicciones realizadas. Es decir, mide qué tan preciso ha sido el modelo al hacer predicciones en comparación con la cantidad total de predicciones que se han hecho, como se indica en la ecuación 2.26.

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.26)$$

Precisión: Evalúa la proporción de predicciones correctas que son verdaderos positivos, en relación con el total de predicciones que el modelo ha clasificado como positivas. En otras palabras, mide cuántas de las predicciones positivas realizadas por el modelo son realmente correctas, comparado con todas las predicciones positivas que ha hecho, tal como se define en la ecuación 2.27.

$$P = \frac{TP}{TP + FP} \quad (2.27)$$

Sensibilidad: También conocida como *recall* o *verdadera tasa positiva*, cuantifica la capacidad del modelo para identificar correctamente los casos positivos dentro del conjunto de datos. Específicamente, mide la fracción de instancias que fueron correctamente clasificadas como positivas, en relación con el total de casos que realmente son positivos en el conjunto de datos. En otras palabras, evalúa cuántos de los casos positivos verdaderos han sido detectados por el modelo, en comparación con la cantidad total de casos que deberían haber sido identificados como positivos. Esta métrica es fundamental para entender la efectividad del modelo en la detección de los casos positivos, tal como se describe en la ecuación 2.28.

$$Recall = \frac{TP}{TP + FN} \quad (2.28)$$

F1 Score: Es una métrica que calcula la media armónica entre la precisión y la sensibilidad, con el objetivo de proporcionar un balance entre ambas, según lo especificado en la ecuación 2.30.

$$F1 = \frac{2 * A * Recall}{A + Recall} \quad (2.30)$$

Una de las principales fortalezas de las redes neuronales convolucionales (CNN) es su habilidad para detectar automáticamente patrones relevantes a partir de los datos, lo que disminuye considerablemente la necesidad de intervención humana en el proceso de identificación de características. Esta capacidad de aprendizaje automático permite que las CNN trabajen de manera eficiente con datos complejos. Además, las CNN tienen la capacidad de procesar imágenes de alta resolución, lo que las hace especialmente útiles para aplicaciones que requieren un análisis detallado de imágenes, tal como se menciona en Goodfellow et al. (2016).

2.11. Software de código abierto para innovación tecnológica

El uso de software de código abierto ha impulsado significativamente la innovación en distintas áreas tecnológicas, gracias a su flexibilidad, comunidad activa y eficiencia en el desarrollo. Herramientas como Python y Android destacan como plataformas versátiles y ampliamente adoptadas. Python es un lenguaje de programación de alto nivel, de código abierto, conocido por su sintaxis sencilla y su extensa colección de bibliotecas para ciencia de datos, inteligencia artificial y automatización. Su facilidad de uso y comunidad activa lo convierten en una herramienta ideal para proyectos de investigación e innovación tecnológica (Laganiere, 2011). Android, por su parte, es un sistema operativo móvil de código abierto basado en Linux, desarrollado inicialmente por Android Inc. y adquirido por Google. Su arquitectura abierta y soporte para múltiples dispositivos lo hacen fundamental para el desarrollo de aplicaciones móviles, especialmente en el ámbito de soluciones tecnológicas portátiles e IoT (Android, 2023).

2.12. La inocuidad en sistemas de monitoreo fisiológico

La inocuidad en sistemas de monitoreo fisiológico se refiere a la capacidad del sistema para operar sin causar daño al usuario, garantizando que su funcionamiento no comprometa la integridad física ni genere efectos secundarios adversos. En el presente proyecto, esta característica se asegurará mediante la integración de sensores no invasivos certificados, que permiten la recolección de señales electrocardiográficas sin penetrar la piel ni alterar procesos fisiológicos. Estos dispositivos, comúnmente utilizados en entornos clínicos y de investigación, están diseñados para ser seguros y cómodos para el usuario, minimizando riesgos como irritación dérmica o interferencias eléctricas (Seshadri et al., 2020). Los sensores de grado médico que se colocan sobre la piel han sido validados por su precisión y seguridad, lo cual los hace adecuados para aplicaciones ambulatorias y portátiles (Ma et al., 2024). Al utilizar tecnologías con historial comprobado de uso en humanos, el sistema propuesto no solo respeta principios éticos, sino que también garantiza una alta aceptabilidad por parte de

los usuarios y profesionales de la salud (Channa et al., 2021). De este modo, se asegura que el monitoreo de la variabilidad de la frecuencia cardíaca se realice de forma segura, sin comprometer el bienestar del usuario.

2.13. La comunidad universitaria como población clave para el estudio del estrés

La comunidad universitaria representa un grupo de interés prioritario en los estudios sobre estrés, ya que los estudiantes suelen enfrentarse a múltiples factores de presión, como la carga académica, la incertidumbre profesional y las exigencias sociales, lo que los convierte en una población especialmente vulnerable a alteraciones en su salud mental y fisiológica. Diversos estudios han evidenciado que este grupo experimenta niveles significativos de estrés que pueden afectar su rendimiento académico y bienestar general (Beiter et al., 2017).

3. METODOLOGÍA

Esta sección describe minuciosamente los diferentes componentes y etapas que conforman la metodología propuesta. Se explican con precisión los métodos, técnicas y herramientas utilizados para abordar el problema de estudio y alcanzar los objetivos planteados. El esquema general del proceso, ilustrado en la Figura 3.1, muestra las etapas necesarias para integrar un dispositivo portátil basado en el internet de las cosas médicas (IoMT). Este dispositivo permitirá la adquisición de datos electrocardiográficos con el fin de analizar la variabilidad de la frecuencia cardíaca y obtener un diagnóstico oportuno automatizado del estrés psicológico. La metodología propuesta se compone de seis etapas: en la etapa 1, se adquiere la señal cardíaca durante la prueba de inducción de estrés Trier (TSST), generando una base de datos personalizada del individuo. En la etapa 2, los datos del dispositivo de adquisición se transfieren al servidor web mediante Wi-Fi, utilizando el protocolo MQTT. En la etapa 3, los datos se descargan del servidor en lotes de un segundo y se transforman de una señal unidimensional (1D) a una representación bidimensional (2D) mediante la transformada continua de wavelet, obteniendo una imagen de la distribución de la energía en el dominio tiempo-frecuencia, denominada espectrograma. A partir de esta transformación, en la etapa 4 se convierte el espectrograma a escala de grises y se aplica aumento de datos mediante un espejo horizontal. Posteriormente, en la etapa 5, se entrena una red neuronal convolucional separable en profundidad con los espectrogramas en escala de grises para la clasificación del estado estresado o no estresado. Finalmente, en la etapa 6, el modelo entrenado se emplea para la detección del nivel de estrés psicológico, generando un reporte con los resultados obtenidos.

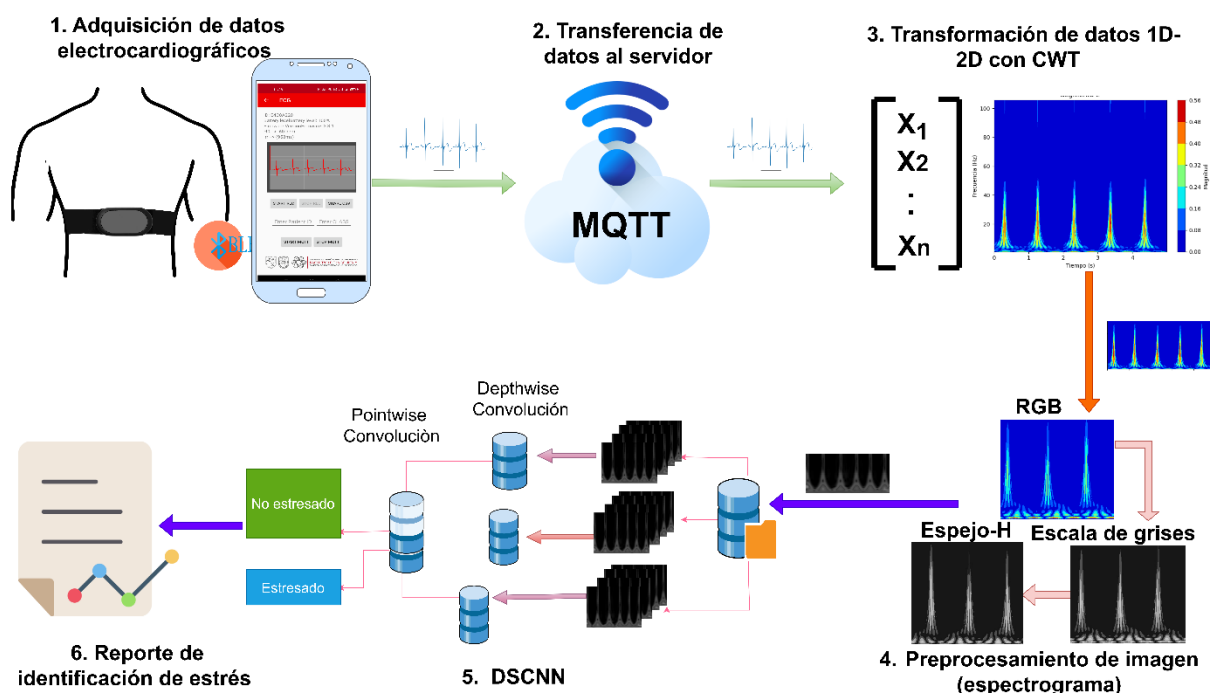


Figura 3.1. Diagrama a bloques de la metodología (autoría propia).

Las siguientes secciones detallan los aspectos clave del marco metodológico implementado.

3.1. Adquisición de datos electrocardiográficos

Para adquirir el registro del comportamiento eléctrico del corazón, se propone el uso del sensor de frecuencia cardíaca Polar H10, cuyo funcionamiento se detalla en la sección (2.5.1.2). Este sensor es una alternativa portátil, inalámbrica y no invasiva, lo que facilita su uso en estudios de monitoreo de la variabilidad de la frecuencia cardíaca (VFC).

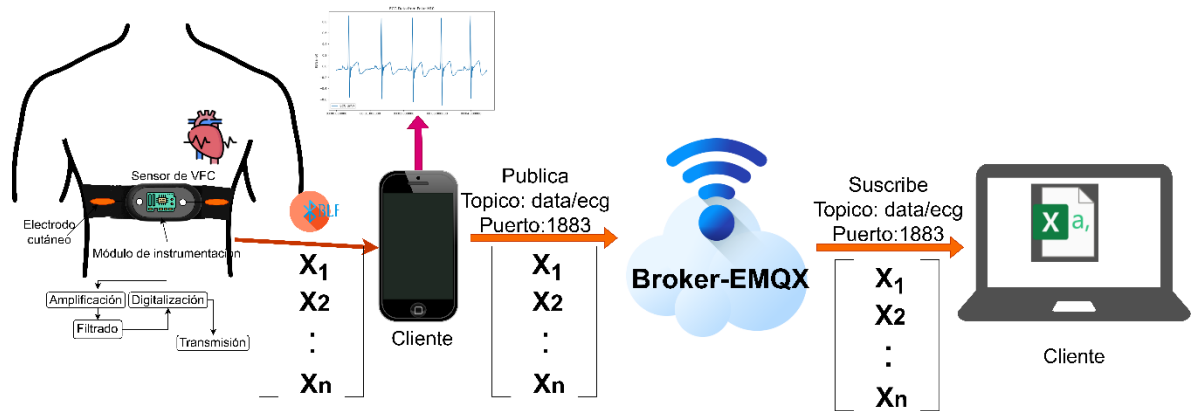


Figura 3.2. Adquisición y transferencia de datos (autoría propia).

La banda Polar H10 es un sensor de grado clínico que proporciona mediciones de ECG de alta precisión de un rango de lectura igual $\pm 20\,000\,\mu V$ con una frecuencia de muestreo de $130\,Hz$ con un error de $\pm 5\%$, siendo ideal para aplicaciones en el análisis de estrés. A diferencia de los monitores Holter, que requieren múltiples cables y electrodos adheridos al cuerpo, el Polar H10 ofrece una solución más cómoda y práctica, sin comprometer la calidad de los datos obtenidos.

En la figura 3.2 se muestra como que el sensor se coloca justo debajo de los pectorales, alrededor del pecho y en contacto directo con la piel. Para garantizar una correcta adquisición de la señal ECG, se recomienda utilizar los siguientes pasos:

1. Antes de colocarlo, se deben humedecer las áreas de los electrodos en la parte interna de la correa para mejorar la conductividad y asegurar un buen contacto con la piel.
2. La correa debe colocarse alrededor del pecho, de forma que este ajustada sin causar molestias.
3. El sensor debe empotrarse correctamente a la correa por medio de los conectores tipo botón, de tal forma que las letras del dispositivo estén hacia el frente y en posición vertical.

4. El sensor debe estar centrado en el pecho y alineado con el esternón para optimizar la calidad de la señal.

Para la adquisición de las señales ECG, es necesario contar con un dispositivo que utilice el mismo protocolo de comunicación que el sensor. El Polar H10 emplea Bluetooth Low Energy (BLE), lo que permite la transmisión inalámbrica de los datos a una aplicación móvil o un microcontrolador que integre BLE.

En este proyecto, se plantea desarrollar una aplicación Android que se encarga de:

- Establecer la conexión con el sensor mediante BLE.
- Visualizar la señal ECG.
- Enviar los datos a un servidor utilizando el protocolo MQTT para su posterior procesamiento.

El uso de BLE permite minimizar el consumo energético, lo que facilita el monitoreo continuo sin interrupciones prolongadas. Además, la integración con protocolos de comunicación eficientes garantiza una transmisión estable de la información.

3.2. Transferencia de datos al servidor

Como se muestra en la figura 3.2 los datos de ECG adquiridos mediante el sensor Polar H10 son transmitidos a un servidor utilizando el protocolo MQTT (MQTT del inglés Message Queuing Telemetry Transport) con ayuda de una aplicación móvil Android. Este protocolo de comunicación ligera es ampliamente utilizado en aplicaciones de Internet de las Cosas (IoT) debido a su bajo consumo de ancho de banda, eficiencia en la transmisión de datos y capacidad para operar en entornos con conectividad limitada.

Para realizar el proceso de transmisión de los datos de ECG se plantearon los siguientes pasos:

1. Captura de datos en el dispositivo móvil

- El sensor Polar H10 transmite la señal ECG mediante BLE a un dispositivo móvil Android con la aplicación “ECG móvilUAQ”. La aplicación procesa los datos y los convierte en un formato flotante para su envío.

2. Publicación de datos a través de MQTT

- Una vez adquiridos los datos, la aplicación actúa como un cliente MQTT y publica los datos en un broker MQTT (servidor intermediario) en un tópico específico. MQTT permite publicar los datos de manera continua o en paquetes periódicos, dependiendo de la configuración establecida.

Ventajas de usar MQTT en la transferencia de datos ECG

- Bajo consumo de ancho de banda, ideal para dispositivos con conexión intermitente o limitada.
- Permite la monitorización continua del ECG sin retrasos significativos.
- Facilita la escalabilidad del sistema, permitiendo que múltiples dispositivos o usuarios accedan a la información simultáneamente.
- Seguridad y eficiencia: Compatible con mecanismos de autenticación y cifrado para garantizar la privacidad de los datos médicos.

El uso de MQTT en combinación con BLE hace que la transferencia de datos ECG sea eficiente y adaptable a diferentes escenarios de monitoreo remoto, asegurando un flujo continuo y confiable de información biomédica.

3.3. Transformación de datos 1D-2D con CWT

Para analizar la variabilidad de la frecuencia cardíaca (VFC) y detectar signos de estrés, es necesario transformar la señal de electrocardiograma (ECG), que es originalmente unidimensional (1D), en una representación bidimensional (2D), figura 3.3. Este proceso es crucial porque las señales ECG contienen

variaciones que no son fácilmente observables en el dominio 1D, y su conversión a una representación 2D permite capturar patrones relevantes para la clasificación del estrés.




Figura 3.3. Transformación de datos 1D-2D con CWT (autoría propia).

3.3.1. Preprocesamiento de la señal ECG

La señal de ECG se segmenta en ventanas de 5 segundos para un análisis más efectivo figura 3.3.1. Esta segmentación permite examinar la señal de manera temporal, extrayendo eventos de interés que pueden ser indicativos de cambios en la variabilidad de la frecuencia cardíaca (VFC), lo cual es útil para la detección de estrés o arritmias. La VFC, que está relacionada con las fluctuaciones en el intervalo entre latidos cardíacos, es un indicador importante de la actividad autónoma y la respuesta al estrés.

Se optó por utilizar una ventana de 5 segundos debido a que ofrece un compromiso adecuado entre la obtención de información temporal suficiente para analizar de manera significativa la variabilidad del intervalo RR y la preservación de una resolución aceptable en el análisis tiempo-frecuencia. Ventanas más breves, como las de 1 o 2 segundos, pueden resultar insuficientes para detectar variaciones sutiles en la actividad cardíaca, mientras que ventanas más extensas, como las de 10 o 20 segundos, tienden a atenuar o enmascarar las respuestas rápidas asociadas a episodios de estrés agudo, dificultando la detección de fluctuaciones dinámicas (Phukan et al., n.d.; Cho et al., 2019; Koldijk et al., 2014).

Investigaciones previas respaldan el uso de ventanas de 5 segundos para el estudio de la VFC en escenarios relacionados con el estrés, ya que permiten

identificar con eficacia cambios rápidos en la señal cardíaca, sin perder los patrones característicos vinculados a estos estados fisiológicos (Kim et al., 2018; Mortensen et al., 2023; Dalmeida & Masala, n.d.). En consecuencia, esta decisión metodológica se alinea con los objetivos del presente trabajo, orientados a identificar de manera precisa las alteraciones en la señal ECG asociadas a condiciones de estrés.

3.3.2. CWT a los datos electrocardiográficos segmentados

La Transformada Continua de Wavelet (CWT) se aplica a cada segmento de la señal ECG para obtener una representación en el dominio tiempo-frecuencia, figura 3.3.1. En este caso, se elige la función wavelet madre Morlet, que es ideal para obtener una buena resolución tanto en el dominio del tiempo como en el de la frecuencia. La CWT descompone la señal en diferentes escalas, permitiendo observar cómo varían las frecuencias a lo largo del tiempo, lo que resulta útil para detectar oscilaciones específicas asociadas a la VFC. Además, al capturar la variabilidad en diferentes escalas, la CWT permite identificar fluctuaciones tanto rápidas (de alta frecuencia) como lentas (de baja frecuencia) en la señal.




Figura 3.3.1. Imagen de distribución de energía en tiempo frecuencia denominada espectrograma (autoría propia).

Los coeficientes obtenidos de la CWT se representan visualmente como un espectrograma en 2D, donde: El eje horizontal representa el tiempo (en segundos); El eje vertical representa la frecuencia o las escalas (relacionadas con la frecuencia cardíaca).

Los valores de los coeficientes de la CWT se mapean a una escala de colores, representando la energía o intensidad en cada punto en el tiempo y la frecuencia. Esta representación visual permite capturar de manera efectiva las variaciones de la VFC, las cuales son clave para identificar respuestas fisiológicas al estrés. Las variaciones en las frecuencias, como las oscilaciones en las bandas LF (Low Frequency) y HF (High Frequency), son indicativas de la influencia de los sistemas nerviosos simpático y parasimpático, respectivamente, y son cruciales en el análisis de la actividad autónoma del corazón.

3.3.3. Preprocesamiento de imagen (espectrograma): Escala de grises; aumento de datos

Las imágenes generadas mediante la transformada de wavelet continua (CWT) se almacenan en una base de datos, organizadas de acuerdo con las etiquetas correspondientes a las características de la señal original (por ejemplo, "Estrés" y "No Estrés"). Esta estructuración de los datos permite la aplicación de técnicas avanzadas de aprendizaje profundo, como las redes neuronales convolucionales separables en profundidad (DSCNN). Estos modelos de aprendizaje automático pueden ser entrenados para desarrollar un clasificador capaz de identificar patrones relevantes extraídos directamente de las imágenes CWT, lo que posibilita la predicción precisa de las características de interés presentes en nuevas señales.

El enfoque basado en DSCNN aprovecha la capacidad de estas arquitecturas neuronales para capturar eficientemente las relaciones espaciales y estructurales inherentes a las representaciones visuales de las señales, lo que las convierte en una herramienta poderosa para el análisis y clasificación de este tipo de datos. De esta manera, la organización de las imágenes CWT en una base de datos estructurada facilita la aplicación de técnicas de aprendizaje profundo que pueden extraer conocimiento relevante de manera automatizada a partir de los patrones presentes en los datos.




Figura 3.4. Preprocesamiento de imagen (espectrograma): Escala de grises; aumento de datos (autoría propia).

Antes de alimentar las imágenes al modelo, es necesario realizar una serie de pasos de preprocesamiento para asegurar que los datos sean adecuados para el aprendizaje Figura 3.4. :

- **Escala de grises:** Las imágenes 2D generadas por la CWT se convierten a escala de grises para reducir la complejidad de los datos. Esto asegura que la información relevante sobre la variabilidad de la frecuencia cardíaca esté concentrada en una sola capa de intensidad de píxeles, lo que mejora la eficiencia del procesamiento y el rendimiento del modelo. Al trabajar con imágenes en escala de grises, el modelo se enfoca mejor en los patrones esenciales, sin distracciones de colores adicionales, facilitando el aprendizaje de características importantes para la clasificación.
- **Redimensionamiento:** Las imágenes de diferentes tamaños generadas durante la transformada se redimensionan a un tamaño uniforme, que es compatible con las dimensiones esperadas por la red neuronal. El tamaño elegido se define en función de las características del modelo, asegurando un buen equilibrio entre la capacidad de la red y los recursos computacionales disponibles.
- **Aumento de datos:** A pesar de la naturaleza de las señales ECG, se aplican técnicas específicas de aumento de datos para evitar el sobreajuste y mejorar la capacidad de generalización del modelo. Las técnicas de aumento incluyen:
 - **Espejo Horizontal** de las imágenes en el espacio, para simular pequeñas variaciones en las señales. Y así aumentar la robustez del

modelo frente a variaciones en la orientación y tamaño de la señal ECG.

3.4. Red neuronal convolucional divisible en profundidad (DSCNN)

El modelo propuesto es una Red Neuronal Convolucional Separables en Profundidad (DSCNN), que se utiliza para procesar la representación 2D de la señal ECG obtenida mediante la Transformada Continua de Wavelet (CWT). A continuación, se describen los pasos específicos involucrados en el entrenamiento de este modelo figura 3.6.

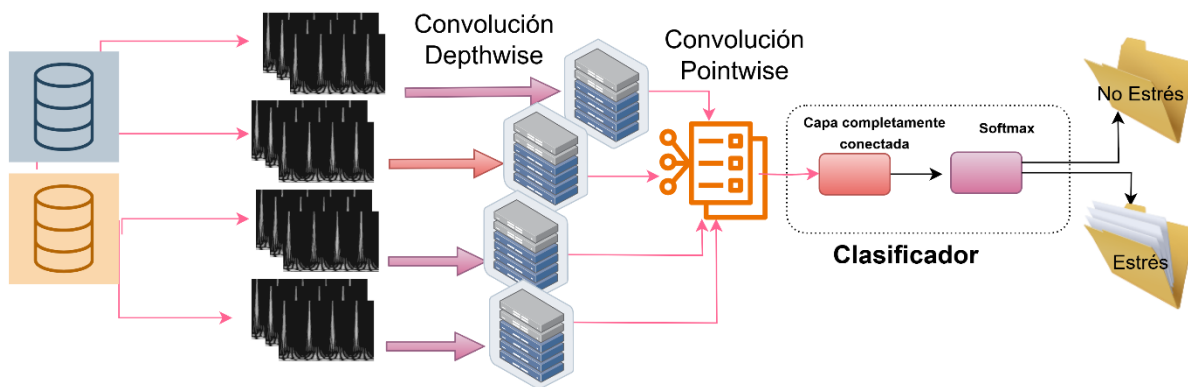


Figura 3.5. DSCNN (autoría propia).

3.4.1. Arquitectura de la DSCNN

La arquitectura de la DSCNN se seleccionó debido a su eficiencia en el procesamiento de imágenes con una menor carga computacional. Esta arquitectura está formada por los siguientes componentes clave:

- **Capas convolucionales separables en profundidad:** Estas capas aplican convoluciones de manera separada para cada canal de la imagen, lo que reduce significativamente el número de parámetros a entrenar sin perder la capacidad de extraer características relevantes. Este enfoque hace que la red sea más eficiente tanto en términos de tiempo de entrenamiento como en capacidad computacional.

- **Capas de activación:** Se emplea una función de activación no lineal, típicamente ReLU (Rectified Linear Unit), después de cada capa convolucional. Esto permite que el modelo aprenda representaciones complejas y no lineales de las características de la señal ECG, mejorando su capacidad de generalización.
- **Capas de agrupamiento (Max Pooling):** Estas capas permiten reducir la dimensionalidad de las imágenes, extrayendo las características más significativas mientras se preservan las variaciones esenciales de la señal ECG, lo que facilita la clasificación.
- **Capas densas:** Al final de la red, se utilizan capas densas para realizar la clasificación final. Estas capas conectan todos los nodos de la capa anterior con cada nodo de la capa final, generando una probabilidad para cada clase: estresado o no estresado.

La Tabla 1 resume la configuración del modelo base propuesto, utilizado para la detección de estrés a partir de señales ECG transformadas mediante la CWT. Este modelo fue entrenado con imágenes en escala de grises de 128×128 píxeles, utilizando tres bloques convolucionales separables en profundidad y técnicas estándar de regularización y normalización. Los parámetros clave se detallan a continuación.

Tabla 1. Configuración del modelo base DSCNN.

Parámetro	Valor Base
Numero de bloques de convolución	4 bloques Depthwise
Tamaño de filtro por bloque	5x5
Nº de filtros por bloque	[32, 64, 128, 256]
Función de activación	ReLU
Batch Normalization	Sí, después de cada convolución
Learning Rate	0.00001
Optimizador	Adam

Parámetro	Valor Base
Regularización	L2 con coeficiente 0.001
Tamaño del batch	32
Épocas	50
Tamaño de entrada	128x128 píxeles, escala de grises (1 canal)
Capa final	Flatten → Dense → Softmax
Conjunto de datos	Imágenes CWT de señales ECG
Preprocesamiento	CWT + Normalización (0-1)
Métricas de evaluación	Exactitud, Precisión, Sensibilidad, F1 Score

3.4.2. Entrenamiento del modelo

El proceso de entrenamiento del modelo sigue los siguientes pasos:

- **División del conjunto de datos:** El conjunto de datos etiquetado se divide en tres subconjuntos: entrenamiento (70%), validación (15%) y prueba (15%). La parte de entrenamiento se utiliza para ajustar los parámetros del modelo, la validación para ajustar los hiperparámetros y la prueba para evaluar el rendimiento final.
- **Función de pérdida:** Se utiliza la **entropía cruzada** como función de pérdida, la cual es común en problemas de clasificación binaria. Esta función mide la diferencia entre las predicciones del modelo y las etiquetas verdaderas de las clases, penalizando las predicciones incorrectas.
- **Optimización:** Se aplica el optimizador **Adam** (Adaptive Moment Estimation), que ajusta de manera eficiente los pesos del modelo para minimizar la función de pérdida. Adam es un algoritmo de optimización adaptativo que combina ventajas de otros algoritmos, como el gradiente estocástico y el descenso de gradiente de momento.
- **Métricas de evaluación:** Durante el entrenamiento, se monitorizan varias métricas para evaluar el rendimiento del modelo:

- **Exactitud (Accuracy):** Proporción de predicciones correctas sobre el total de predicciones realizadas.
- **Precisión (Precision):** Proporción de verdaderos positivos entre todas las predicciones positivas realizadas por el modelo.
- **Sensibilidad (Recall):** Capacidad del modelo para identificar correctamente los casos positivos (por ejemplo, casos de estrés).
- **F1 Score:** Media armónica entre la precisión y la sensibilidad; se utiliza para equilibrar ambos en contextos con clases desbalanceadas. Ajuste de hiperparámetros.

Para maximizar el rendimiento del modelo, se lleva a cabo un proceso de ajuste de hiperparámetros, que incluye:

- **Tamaño del batch:** Determina cuántas imágenes se procesan en cada paso del entrenamiento. Un tamaño de batch adecuado ayuda a estabilizar el proceso de entrenamiento y reduce el tiempo de cómputo.
- **Número de épocas:** Se establece el número de iteraciones en las que el modelo pasará por todo el conjunto de datos. Un número adecuado de épocas permite que el modelo aprenda efectivamente sin sobreajustarse a los datos de entrenamiento.
- **Tasa de aprendizaje:** Controla la velocidad con la que los pesos del modelo se actualizan durante el entrenamiento. Un valor muy alto puede hacer que el modelo no converja, mientras que un valor muy bajo puede ralentizar el proceso.

3.4.3. Evaluación del modelo

Una vez entrenado el modelo, se evalúa su rendimiento utilizando el conjunto de prueba, con el objetivo de comprobar la capacidad de la red para generalizar a nuevos datos. Durante la evaluación, se analizan los resultados obtenidos en términos de las métricas previamente mencionadas y se realizan análisis de los errores cometidos. Esto permite identificar posibles áreas de

mejora, como la necesidad de más datos, cambios en la arquitectura o ajustes adicionales en los hiperparámetros.

3.5. Reporte de identificación de estrés

Se propuso realizar un “reporte de identificación de estrés” (ANEXO de formato) con las siguientes características:

- Grafica de la señal ECG durante el tiempo monitoreado
- Datos generales del individuo (Nombre; edad; genero, fecha hora de inicio de la prueba y final de la prueba)
- Estado de estrés antes de la prueba
- Estado de estrés después de la prueba

El objetivo principal del reporte es indicar al individuo el estado de estres durante la aplicación del TSST

3.6. Matriz de experimentos y condiciones de evaluación

Tabla 2. Matriz de experimentos y condiciones de evaluación.

Condición	Línea base	TSST	Recuperación
Duración	5min	5min	5min
Características	Sentado con Ojos cerrados	Sentado con ojos cerrados pensando discurso (3min) Conteo mental (2min)	Sentado con Ojos cerrados
Mediciones	ECG FC	ECG FC	ECG FC

Para evaluar la respuesta fisiológica de los participantes ante una situación de estrés agudo inducido, se implementó un protocolo experimental estructurado

en tres condiciones principales: línea base, estrés agudo (TSST) y recuperación. Cada condición tuvo una duración de cinco minutos, y se diseñó con el propósito de capturar variaciones fisiológicas que permitieran validar el sistema de monitoreo propuesto.

Condición de línea base: Los participantes permanecieron sentados con los ojos cerrados durante 5 minutos en un entorno tranquilo, permitiendo establecer un estado de reposo fisiológico inicial.

Condición de estrés (TSST): Durante esta fase, los sujetos permanecieron sentados con los ojos cerrados mientras realizaban una tarea mentalmente demandante dividida en dos partes: la preparación de un discurso (3 minutos) y una tarea de conteo mental regresivo (2 minutos). Esta condición se basó en una adaptación del protocolo Trier Social Stress Test (TSST), ampliamente validado para inducir estrés de forma controlada (Liu et al., 2017).

Condición de recuperación: Finalizado el estímulo estresor, los participantes regresaron al estado de reposo con los ojos cerrados durante otros 5 minutos para registrar el retorno a la homeostasis fisiológica.

Durante todo el protocolo, se registraron continuamente señales ECG (electrocardiograma) y se extrajo la frecuencia cardíaca (FC), siendo estos indicadores sensibles a los cambios en la activación del sistema nervioso autónomo.

Este diseño experimental está orientado principalmente a la población universitaria joven, grupo que representa una muestra relevante debido a su vulnerabilidad al estrés académico y psicosocial (Dominguez-Lara et al., 2020).

4. RESULTADOS

Este capítulo presenta los hallazgos obtenidos a partir de la implementación y evaluación del sistema propuesto en escenarios reales, desde la adquisición de señales hasta su clasificación mediante técnicas de aprendizaje profundo.

4.1. Pruebas de funcionalidad y adquisición de datos en ambientes reales

Se evaluó la funcionalidad del sistema aplicando el protocolo descrito previamente (ver sección 3.6), basado en una versión modificada del Trier Social Stress Test (TSST), con una duración total de quince minutos. El experimento se llevó a cabo en un ambiente controlado dentro de la Facultad de Psicología de la UNAM, con la participación de diez estudiantes universitarios (seis hombres y cuatro mujeres) entre 18 y 25 años. Esta aplicación permitió observar las variaciones en la señal ECG y la VFC durante condiciones de reposo, estrés agudo y recuperación, validando el comportamiento del sistema en un entorno real.

4.1.1. Adquisición de datos electrocardiográficos

Para la adquisición de los datos electrocardiográficos (Figura 4.1), se desarrolló una aplicación móvil denominada *ECG móvilUAQ*, compatible con Android 11 o versiones anteriores. Esta aplicación fue diseñada para conectarse al sensor Polar H10 mediante el protocolo Bluetooth Low Energy (BLE), lo que permite una transmisión eficiente y en tiempo real de los datos fisiológicos. La inocuidad del sistema se garantiza mediante el uso del sensor Polar H10, un dispositivo no invasivo que emplea electrodos similares a los de botón, integrados en una banda torácica ajustable. Su diseño cómodo y seguro, aprobado para uso humano, evita riesgos físicos o molestias, permitiendo una adquisición confiable de señales ECG sin comprometer el bienestar de los participantes.

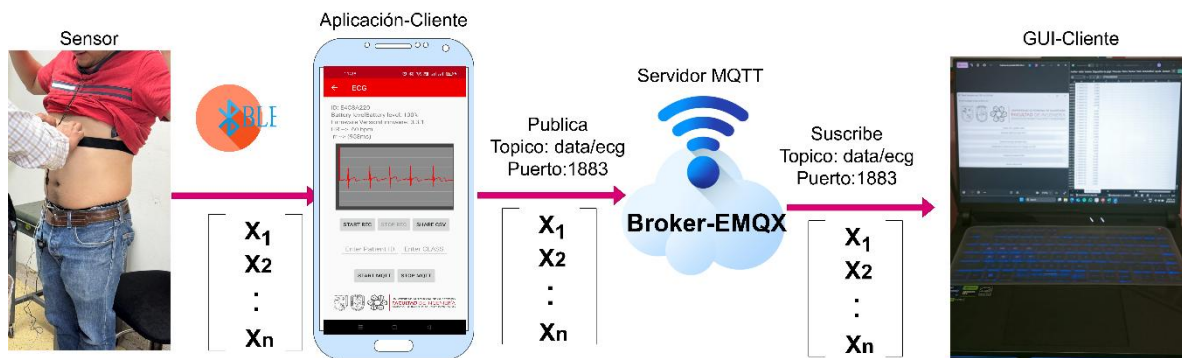


Figura 4.1. Sistema de adquisición y transferencia de datos implementado (autoría propia).

Al iniciar la aplicación (Figura 4.2), se solicitan permisos de acceso a la ubicación y al módulo Bluetooth. Una vez concedidos, se accede al menú principal, que presenta tres botones principales:

- **CHANGE DEVICE ID:** permite ingresar el identificador alfanumérico único del sensor Polar H10.
- **READ ECG AND PLOT:** habilita la lectura, visualización y almacenamiento/transmisión de los datos ECG.
- **READ HR/RR AND PLOT:** muestra los valores de frecuencia cardíaca y los intervalos RR en milisegundos.



Figura 4.2. Vinculación sensor Polar h10-Aplicación (autoría propia).

Tras ingresar el ID del sensor, la aplicación establece la conexión mediante BLE, desplegando un diálogo de conexión exitosa. A continuación, se inicia la lectura de los datos del sensor, incluyendo: estado de batería, versión de firmware, frecuencia cardíaca, intervalos RR y señal ECG cruda (Figura 4.3).




Figura 4.3. Lectura de datos del Sensor Polar h10 (autoría propia).

4.2. Transferencia de datos al servidor

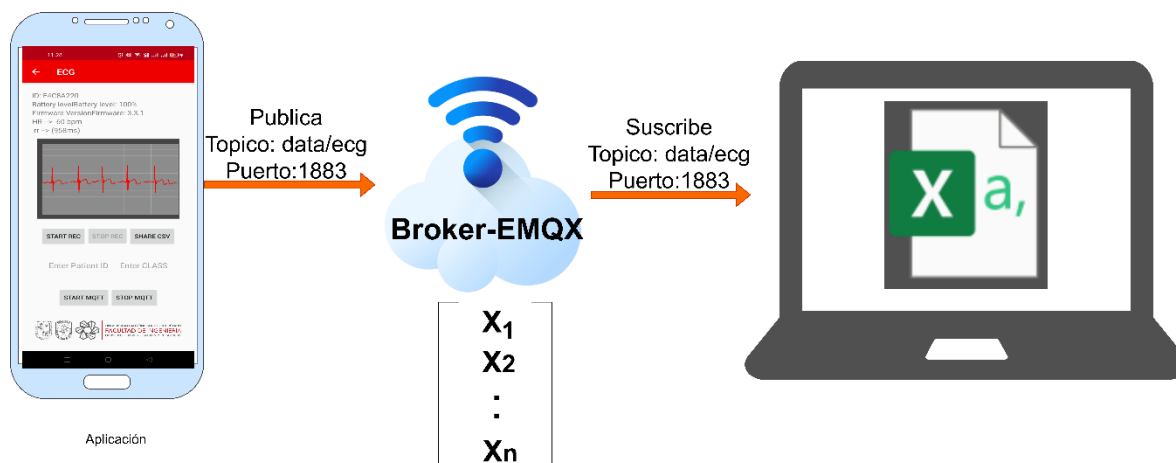


Figura 4.4. Sistema MQTT de transferencia de datos implementado (autoría propia).

Para la transmisión de los datos ECG a un servidor remoto (Figura 4.4), se implementó una arquitectura basada en el protocolo MQTT (Message Queuing Telemetry Transport). Se utilizó una instancia de máquina virtual en Google Cloud Platform, bajo las siguientes especificaciones:

- Tipo: e2-small (2 vCPU, 2 GB RAM)
- SO: Ubuntu 18.04 LTS
- Broker MQTT: EMQX, configurado con puertos estándar (1883, 8083, 8883, etc.) y una IP estática.

La aplicación ECG móvilUAQ fue programada para establecer comunicación con el broker mediante la librería paho.mqttv3, utilizando el puerto 1883. Al presionar el botón Start MQTT (Figura 4.5), los datos ECG se publican al tópico data/ecg con calidad de servicio QoS 1, asegurando la entrega al menos una vez.

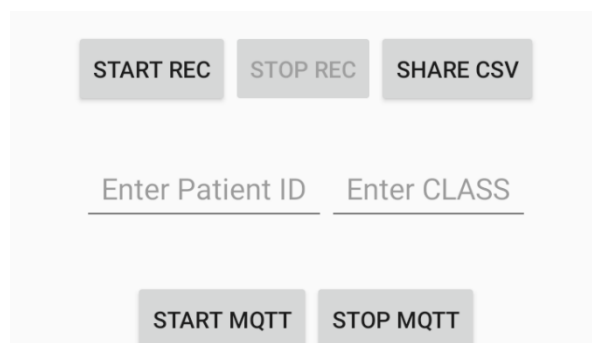


Figura 4.5 Botón para activar transferencia de datos a servidor (autoría propia).

4.3. Transformación de datos 1D-2D con CWT

Como se muestra en la Figura 4.6, la interfaz gráfica de usuario (GUI), desarrollada en Python, permite al especialista acceder de forma remota a los datos almacenados en el servidor. Desde esta interfaz, el usuario puede registrar a un nuevo sujeto de estudio mediante un formulario interactivo que solicita información como el nombre completo, género, peso aproximado, talla y edad.

Esta funcionalidad permite asociar de manera precisa los datos fisiológicos recolectados con cada participante del estudio, facilitando la trazabilidad y el análisis individualizado.

Una vez registrado el sujeto, el especialista puede conectarse al bróker MQTT a través del puerto previamente configurado y suscribirse al tópico de interés. Esto permite la descarga automática de los datos publicados por la aplicación, asegurando una adquisición eficiente y estructurada de la información biomédica.

MQTT data logger and CWT to DSCNN

Registrar sujeto de estudio

Ingresa el tópico MQTT:

Ejemplo: ecg/data

Descargar datos del Broker MQTT

Datos guardados: 0

Detener Descarga del Broker MQTT

No se ha cargado ningún archivo CSV

UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA
DIVISIÓN DE INVESTIGACIÓN Y POSGRADO

Cargar CSV y graficar señal

Transformar los datos del archivo CSV a Imagen con CWT

Entrenar el modelo DSCNN

Generar Informe PDF

Figura 4.6. GUI de cliente remoto (autoría propia).

Los datos obtenidos se almacenan en un archivo CSV (Comma-Separated Values), un formato de texto plano que se emplea para guardar información tabular. En este formato, cada línea representa un registro y los campos dentro de

cada registro están separados por comas, lo que facilita su análisis y procesamiento posterior.

4.3.1. Preprocesamiento de la señal ECG

La señal de ECG se segmenta en ventanas de 5 segundos para un análisis más efectivo. Esta segmentación permite examinar la señal de manera temporal, graficándola. Figura 4.7 donde se puede observar claramente el complejo QRS.




Figura 4.7. Señal ECG segmentada (autoría propia).

4.3.2. CWT a los datos electrocardiográficos segmentados

La Transformada Continua de Wavelet (CWT) se aplicó a cada segmento de la señal ECG utilizando la función wavelet madre Morlet. Esto permitió obtener una representación en el dominio tiempo-frecuencia, observando cómo varían las frecuencias a lo largo del tiempo. La CWT identificó fluctuaciones rápidas y lentas en la señal, útiles para detectar oscilaciones específicas asociadas a la VFC.

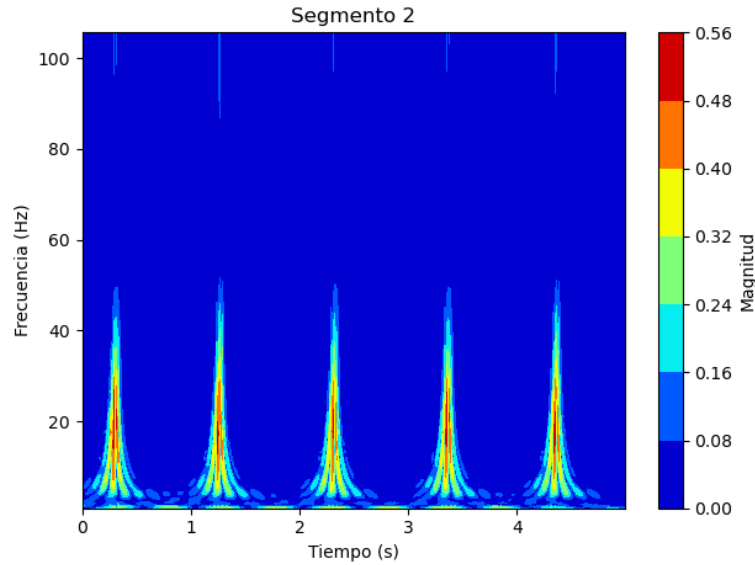


Figura 4.8 Imagen espectrograma (autoría propia).

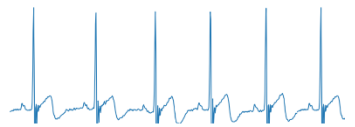
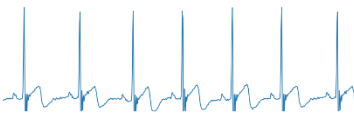
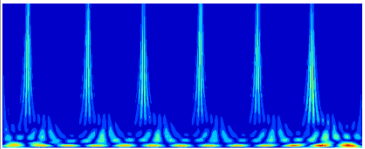
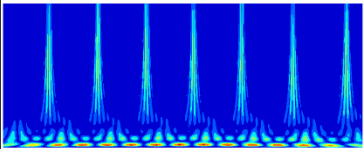
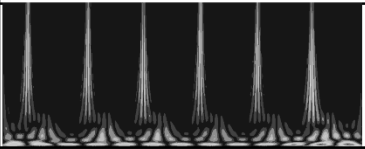
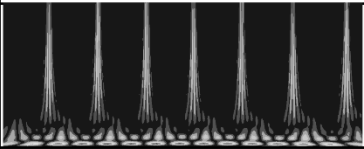
Los coeficientes obtenidos de la CWT se representaron visualmente como un espectrograma en 2D. El eje horizontal representó el tiempo (en segundos) y el eje vertical la frecuencia o las escalas. Los valores de los coeficientes se mapearon a una escala de colores, representando la energía o intensidad en cada punto en el tiempo y la frecuencia. Esta representación visual capturó efectivamente las variaciones de la VFC, clave para identificar respuestas fisiológicas al estrés.

4.4. Preprocesamiento de imagen (espectrograma)

Las señales ECG crudas fueron transformadas en imágenes mediante la aplicación de la transformada continua de wavelet (CWT), generando representaciones tiempo-frecuencia que capturan la dinámica espectral del ritmo cardíaco. Estas imágenes se almacenaron en una base de datos organizada por clases: “Estrés” y “No Estrés”, correspondientes a las fases del protocolo TSST modificado (línea base y fase de estrés, respectivamente). Tal como se ilustra en la Tabla 2, las imágenes generadas, tanto en formato RGB, revelan diferencias notables en los patrones de densidad espectral entre las condiciones de reposo (línea base) y estrés (TSST). Estas diferencias son particularmente visibles en la

concentración de energía espectral en ciertas bandas de frecuencia, las cuales se intensifican o se redistribuyen durante la exposición al estrés. La fase de recuperación fue excluida del conjunto de datos final, dado que no representaba un estado claramente definido. La elección de la CWT se justificó por su capacidad de capturar eventos transitorios y cambios locales en la señal, lo cual es esencial para analizar respuestas fisiológicas dinámicas como las inducidas por el estrés. Esta técnica permitió generar espectrogramas con alta resolución temporal y frecuencia, lo que resulta especialmente útil para la clasificación automática mediante algoritmos de aprendizaje profundo.

Tabla 33. TSST de 15 minutos.

TSST modificado (15 minutos)					
Condición	Linea base		TSST		Recuperacion
Duración	5min		5min		5min
Señal ECG 5s					NA
Imagen RGB 5s					NA
Escala de grises 5s					
Clase	No estresado		Estresado		NA

4.4.1. Transformación a escala de grises

Para reducir la complejidad computacional y mejorar la eficiencia del procesamiento, las imágenes 2D generadas por la CWT en formato RGB fueron convertidas a escala de grises (Tabla 3). Esta transformación permitió al modelo enfocarse en los patrones morfológicos esenciales relacionados con la variabilidad

de la frecuencia cardíaca, eliminando la información redundante del color sin afectar el contenido espectral. Además, se aplicó el redimensionamiento a todas las imágenes fueron normalizadas a un tamaño uniforme de 128×128 píxeles, garantizando la compatibilidad con la arquitectura del modelo CNN empleado y asegurando consistencia en el entrenamiento.

4.4.2. Aumento de datos

Con el objetivo de incrementar la cantidad de muestras de entrenamiento y mejorar la capacidad de generalización del modelo, se aplicaron técnicas de aumento de datos sobre las imágenes en escala de grises. Las transformaciones implementadas incluyeron:

- **Espejo horizontal:** Reflejo simétrico de la imagen para simular variabilidad temporal.
- **Rotación leve:** Rotaciones aleatorias dentro de un rango de $\pm 5^\circ$ para introducir diversidad en la orientación sin distorsionar la señal espectral.

Estas técnicas fueron aplicadas equitativamente a ambas clases ("Estrés" y "No Estrés"), duplicando el número de imágenes y mitigando riesgos de sobreajuste por desbalance de clases.

4.4.3. Generación del conjunto de datos

Inicialmente, se generaron 60 imágenes por fase por participante, considerando únicamente las fases de línea base y estrés (TSST), lo que resultó en un conjunto base de 1200 imágenes, con 600 correspondientes a la clase "No Estrés" y 600 a la clase "Estrés". Con el fin de ampliar la variabilidad de los datos y mejorar la capacidad de generalización del modelo, se aplicaron técnicas de aumento de datos descritas previamente, como espejo horizontal y rotación entre $\pm 5^\circ$, incrementando en un 100% el tamaño del conjunto original. Esto permitió obtener 1200 imágenes adicionales por clase, generando un total de 2400 imágenes aumentadas.

Finalmente, se construyó un conjunto de datos ampliado y balanceado compuesto por 4800 imágenes (2400 por clase). Este conjunto se dividió en

proporciones de 70% para entrenamiento (3360 imágenes), 15% para validación (720 imágenes) y 15% para prueba (720 imágenes), asegurando una distribución equitativa entre las clases en cada subconjunto. Esta estrategia permitió entrenar modelos de aprendizaje profundo con un conjunto más representativo.

4.5. Análisis de ablación del modelo DSCNN

Con el objetivo de analizar el impacto individual de distintos componentes de la arquitectura DSCNN, así como de los hiperparámetros clave del modelo, se llevó a cabo un análisis de ablación. Este consistió en modificar sistemáticamente tanto elementos estructurales como parámetros de entrenamiento del modelo base (descrito en la Tabla 1), con el fin de observar cómo cada variación afectaba el desempeño del clasificador. La evaluación se realizó sobre un conjunto de prueba independiente, utilizando métricas estándar: exactitud, precisión, sensibilidad y F1 Score. En todos los casos, se utilizó el mismo conjunto de datos preprocesados (imágenes CWT normalizadas de señales ECG) para asegurar una comparación justa entre configuraciones.

Tabla 44. Ablacion de componentes de arquitectura.

Configuración	Exactitud	Precisión	Sensibilidad	F1 Score
Modelo base (DSCNN)	0.89	0.90	0.88	0.89
Sin Batch Normalization	0.87	0.86	0.88	0.87
Sin capa densa final	0.84	0.85	0.82	0.83
ReLU reemplazada por Swish	0.82	0.83	0.81	0.82
Uso de imágenes RGB	0.86	0.87	0.86	0.86
Solo 3 bloques Depthwise	0.89	0.89	0.88	0.89

La Tabla 4 resume los resultados del análisis de ablación de componentes. El modelo base mostró un desempeño sólido (F1-score = 0.89), mientras que la eliminación de Batch Normalization y la capa densa final produjo deterioro notable en todas las métricas, lo cual resalta la importancia de estas capas en la

arquitectura. Por otro lado, reemplazar la activación ReLU por Swish no resultó beneficioso, evidenciando que ReLU sigue siendo más efectiva en este contexto. El uso de imágenes RGB mostró resultados competitivos, aunque sin superar al modelo original basado en imágenes en escala de grises. Curiosamente, reducir la cantidad de bloques convolucionales depthwise a tres no afectó negativamente al desempeño, e incluso ayudó a mantener una precisión elevada con menor complejidad computacional.

Durante la segunda fase del análisis de ablación, se examinó de forma sistemática el impacto individual de los hiperparámetros clave sobre el rendimiento del modelo. Esta etapa incluyó la exploración de cinco variables: tamaño de imagen de entrada, tamaño del kernel, número de filtros por capa, tamaño del lote (batch size) y número de épocas de entrenamiento.

En los análisis de los hiperparámetros, se optó por representar únicamente la exactitud (accuracy) en las gráficas, debido a su capacidad para reflejar de manera general el rendimiento del modelo en tareas de clasificación multiclase. Si bien métricas como la precisión, sensibilidad y F1-score aportan información complementaria, la exactitud ofrece una visión global del desempeño del modelo ante diferentes configuraciones, lo cual resulta adecuado para comparar el impacto de los hiperparámetros individuales. Además, al observar una alta correlación entre las métricas evaluadas en las pruebas anteriores (como se muestra en la Tabla 3), se consideró que el comportamiento de la exactitud era representativo del rendimiento general del modelo.

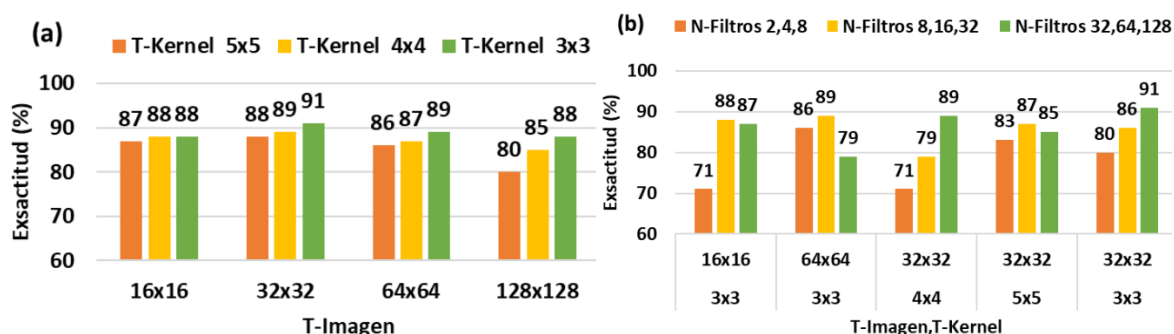


Figura 4.9. Estudio de ablación de hiperparámetros en el modelo DSCNN.
(a) Impacto del tamaño de imagen de entrada y del tamaño del kernel sobre la

exactitud de clasificación, **(b)** Efecto del número de filtros en el rendimiento del modelo.

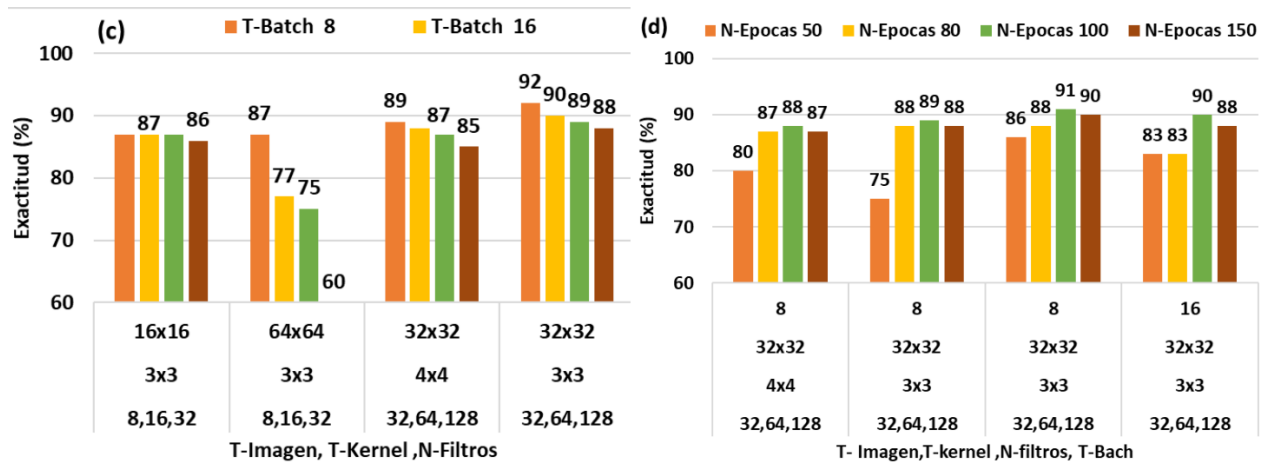


Figura 4.10. Estudio de ablación de hiperparámetros en el modelo DSCNN.

(c) Influencia del tamaño del lote (batch) sobre el rendimiento del modelo.

(d) Evaluación del impacto del número de épocas de entrenamiento en la convergencia del modelo.

Los resultados, representados gráficamente en las Figuras 4.9 y 4.10, permitieron identificar configuraciones óptimas en cada dimensión:

- Tamaño de imagen (T-Imagen): Un valor intermedio de 32×32 píxeles ofreció el mejor compromiso entre riqueza de información y eficiencia computacional [(Figura 4.9 a)].
- Tamaño del kernel (T-Kernel): Un filtro de 3×3 maximizó la precisión sin aumentar la complejidad del modelo [(Figura 4.9 a)].
- Número de filtros (N-Filtros): La estrategia de aumento progresivo [32, 64, 128] logró un equilibrio entre capacidad representacional y prevención del sobreajuste [(Figura 4.9 b)].
- Tamaño del batch (T-Batch): Se observó que tamaños pequeños (batch = 8) promovieron una mejor generalización, en especial en conjuntos de datos limitados [(Figura 4.10 c)].
- Número de épocas (N-Épocas): El modelo alcanzó convergencia estable a las 100 épocas, sin mejoras adicionales al incrementar este número [(Figura 4.10 d)].

Los hallazgos del análisis de ablación reflejan la importancia de una optimización cuidadosa y conjunta de los componentes arquitectónicos y los hiperparámetros. La arquitectura más eficiente se obtuvo manteniendo tres bloques convolucionales depthwise, utilizando filtros de 3×3 , una entrada de tamaño 32×32 píxeles, una política de filtros crecientes [32, 64, 128], y entrenando con un learning rate bajo (0.00001), batch size de 8 y 100 épocas. Esta configuración logró un rendimiento máximo del 92 % de exactitud, representando un equilibrio entre precisión, generalización y eficiencia computacional.

4.6. Análisis del desempeño del modelo durante el entrenamiento y validación

Los resultados obtenidos durante las etapas de entrenamiento, validación y prueba del modelo evidencian una convergencia estable tanto en la precisión como en la función de pérdida después de 100 épocas de entrenamiento, lo que respalda la solidez de la arquitectura desarrollada. Esta tendencia se muestra en la Figura 4.11. , donde se observa la evolución del rendimiento del modelo durante el proceso de entrenamiento y validación.

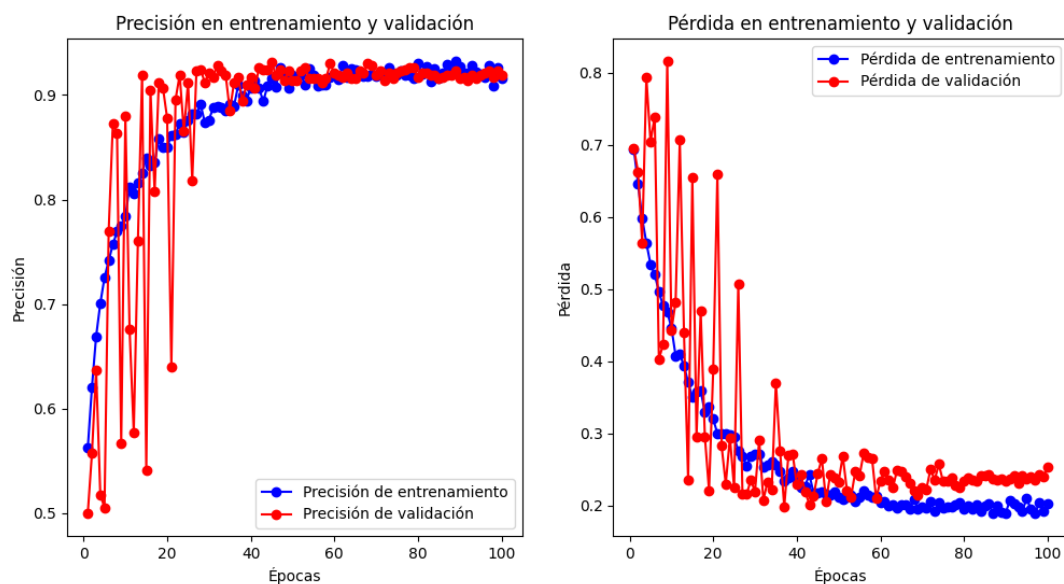


Figura 4.11. Evolución del modelo durante las fases de entrenamiento y validación.

Respecto al desempeño en la tarea de clasificación binaria (estrés frente a no estrés), la Figura 4.12. ilustra la matriz de confusión obtenida en la fase de prueba. El modelo logró clasificar correctamente 331 imágenes pertenecientes a la clase estrés y 329 imágenes de la clase no estrés, sobre un total de 720 muestras analizadas. Se detectaron únicamente 60 errores: 29 imágenes de la clase estrés fue mal clasificada como no estrés, mientras que 31 imágenes de la clase no estrés fueron identificadas incorrectamente como estrés. Estos resultados reflejan un rendimiento notable, con una precisión global del 92%.




Figura 4.12. Matriz de confusión obtenida durante la evaluación del modelo.

Como complemento, la Tabla 5 presenta un análisis detallado de desempeño por clase, incluyendo las métricas de precisión, sensibilidad y F1 Score. La clase estrés, que representa condiciones bajo presión temporal, obtuvo una sensibilidad del 92.00%, lo cual demuestra la alta sensibilidad del modelo para detectar correctamente este estado fisiológico. En contraste, la clase no estrés, correspondiente a situaciones de estado basal, alcanzó una precisión del 92.00%, lo que indica que el modelo rara vez confunde otras clases con esta.

Tabla 55. Informe de clasificación del modelo DSCNN.

Clase	Precisión (%)	Sensibilidad (%)	F1 Score (%)	Imágenes
Estrés	91.00	92.00	92.00	360
No estrés	92.00	91.00	92.00	360
Total				720
Exactitud			92.00 %	

En resumen, estas métricas demuestran la capacidad del modelo para distinguir de forma eficaz entre estados de estrés y no estrés, lo cual es crucial en el contexto del presente estudio. Esta diferenciación permite no solo identificar la presencia de estrés, sino también caracterizar su expresión fisiológica a partir de señales de electrocardiograma convertidas en representaciones tiempo-frecuencia.

4.7. Reporte de identificación de estrés

Como parte de la validación del sistema propuesto, se realizaron pruebas individuales con participantes sometidos al protocolo TSST (Trier Social Stress Test), con el objetivo de evaluar la capacidad del modelo para detectar episodios de estrés de manera personalizada a partir de señales fisiológicas. La Figura 4.13 muestra un ejemplo del informe automatizado generado para un participante del estudio tras la adquisición de la señal de ECG mediante el sensor Polar H10. En el informe se incluyen datos demográficos básicos del participante, el análisis de métricas de variabilidad de frecuencia cardíaca (VFC) y el resultado de clasificación automática del estado emocional. Para facilitar la interpretación por parte de profesionales de la salud mental, el informe presenta una evaluación general del estado de estrés basada en métricas VFC clásicas (SDNN, RMSSD y pNN50), interpretadas según rangos de referencia reportados en estudios previos (Kim et al., 2018). Esta evaluación se resume en una clasificación global: "Estrés" o "No estrés", de forma clara y directa.

Adicionalmente, el resultado del modelo de clasificación basado en redes neuronales convolucionales separables en profundidad (DSCNN) también se presenta como una categoría binaria, lo cual permite reforzar el diagnóstico mediante un sistema automatizado entrenado con representaciones tiempo-frecuencia de la señal ECG.

Este tipo de informes integrados representa una herramienta útil para el seguimiento del estado emocional en contextos clínicos, laborales o educativos, donde la detección temprana del estrés puede contribuir a mejorar la toma de decisiones en salud mental y prevenir riesgos asociados al estrés crónico. La implementación de este sistema automatizado para la detección temprana del estrés facilita un monitoreo continuo y personalizado del estado emocional, fortaleciendo la capacidad de profesionales y organizaciones para identificar situaciones de riesgo y promover estrategias de afrontamiento saludables. De esta forma, contribuye a la reducción de trastornos relacionados con el estrés y al mejoramiento general del bienestar psicológico en la sociedad.

Informe de clasificación del estrés.

Nombre: Rodrigo MR
Género: Masculino
Edad: 29 años
Peso: 76 kg
Talla: 1.58 cm

Análisis de métricas de Variabilidad de Frecuencia Cardíaca (VFC)

Estado fisiológico	SDNN (ms)	RMSSD (ms)	pNN50 (%)
No estrés (referencia)	> 50-70	> 30-40	> 20%
Estrés (referencia)	<= 50	<= 30	<= 20%
Resultados del paciente	45.67	48.85	25.00

Evaluación general con metricas VFC: Estrés

Resultado del clasificador con modelo DSCNN:

Clasificación automática: Estrés

Figura 4.13. Informe de clasificación de estrés percibido generado a partir de los datos de ECG de un participante durante la prueba TSST.

5. CONCLUSIONES

La adquisición de datos electrocardiográficos se logró de manera exitosa utilizando la cinta pectoral Polar H10, seleccionada tras una evaluación basada en criterios de asequibilidad, precisión y facilidad de transmisión. Este sensor inalámbrico demostró ser una alternativa eficaz e inocua para la medición de la variabilidad de la frecuencia cardíaca (VFC) en jóvenes universitarios. Gracias a su conectividad Bluetooth y compatibilidad con dispositivos Android, fue posible integrar una solución móvil práctica que permite la obtención continua de señales ECG sin necesidad de equipamiento especializado.

Para la transferencia eficiente de datos, se implementó el protocolo MQTT, el cual ofreció ventajas significativas como bajo consumo de ancho de banda, eficiencia energética y robustez en entornos con conectividad variable. Esta elección permitió establecer una comunicación estable entre la aplicación móvil y un servidor web, logrando que la información biomédica recolectada pueda ser transmitida de forma segura y en tiempo real hacia el especialista, lo cual representa un avance importante hacia soluciones de monitoreo remoto en contextos clínicos o de investigación.

En cuanto al análisis de los datos, se desarrolló una metodología basada en la transformación de señales ECG unidimensionales a representaciones en dos dimensiones utilizando la Transformada Continua de Wavelet (CWT), las cuales fueron procesadas con una Red Neuronal Convolutiva Separable en Profundidad (DSCNN). Esta estrategia alcanzó una precisión del 92% al clasificar los estados de 'estresado' y 'sin estrés'. La propuesta no solo demuestra un enfoque sólido para la detección automática de estrés, sino que también permite la generación de reportes de clasificación visuales, facilitando la interpretación de los resultados por parte de los profesionales de la salud.

Finalmente, se realizaron pruebas de funcionalidad en un entorno real con la aplicación del protocolo Trier Social Stress Test (TSST), llevadas a cabo en la Facultad de Psicología de la UNAM el 8 de abril de 2025. Participaron 10

voluntarios, lo que permitió validar el desempeño del sistema en condiciones controladas pero realistas. Los resultados confirmaron la viabilidad técnica del sistema, así como su potencial utilidad en contextos clínicos, académicos y de investigación. Como resultado de este trabajo, se elaboró un artículo científico que fue publicado en la revista *Experimental and Theoretical Analysis*, de la editorial MDPI (Apéndice A), lo que refuerza la relevancia y la validez científica del enfoque propuesto.

6. PROSPECTIVAS

En trabajos futuros, se propone explorar distintos enfoques de análisis de señales ECG y métodos alternativos de clasificación para el estado de estrés. Esto permitirá realizar comparaciones más amplias entre las métricas de desempeño obtenidas con diferentes arquitecturas y técnicas de procesamiento, como modelos basados en aprendizaje profundo, transformadas alternativas a la wavelet o métodos clásicos de extracción de características. La finalidad es validar la efectividad del enfoque actual frente a otros métodos del estado del arte y, eventualmente, perfeccionar el sistema propuesto.

Además, es importante realizar experimentaciones con una muestra poblacional más amplia y diversa, lo que permitiría generalizar los resultados del modelo y asegurar su robustez frente a la variabilidad fisiológica y conductual entre individuos. Una mayor cantidad de participantes ayudaría a entrenar modelos más representativos, capaces de adaptarse a distintos perfiles demográficos y contextos de uso.

Otra línea de trabajo valiosa consiste en desarrollar un sistema de entrenamiento personalizado, es decir, adaptar el modelo de clasificación al patrón específico de cada individuo. Dado que los datos electrocardiográficos pueden fluctuar significativamente entre personas debido a factores como edad, condición física o respuesta fisiológica al estrés, un enfoque personalizado podría mejorar la precisión y confiabilidad del sistema en aplicaciones reales.

Finalmente, se contempla la integración de mecanismos de seguridad que permitan la encriptación de los datos recogidos durante el monitoreo. Esto resulta fundamental para garantizar la privacidad y protección de la información sensible del usuario, especialmente en aplicaciones biomédicas y de monitoreo continuo. La incorporación de protocolos de seguridad robustos asegurará la confidencialidad de los datos en escenarios de transmisión o almacenamiento en la nube.

REFERENCIAS

- Aguilar, B. A., & Lopez, F. (2021). Diseño e implementación de un sistema IoMT para señales electrocardiográficas [Universidad Veracruzana]. https://www.uv.mx/veracruz/miaplicada/files/2021/07/Tesis_Bryan-Alexander-Aguilar-Figueroa.pdf
- Alarcón, M. E. B. (2018). Estrés Y Burnout Enfermedades En La Vida Actual (Palibrio, Ed.).
- Allen, A. P., Kennedy, P. J., Dockray, S., Cryan, J. F., Dinan, T. G., & Clarke, G. (2017). The Trier Social Stress Test: Principles and practice. *Neurobiology of Stress*, 6, 113–126. <https://doi.org/10.1016/j.ynstr.2016.11.001>
- Android. (2023). Android open source project. Android Open Source Project. <https://source.android.com>
- Anuhya, V., Ratnam Kolluru, V., Routray, S., Omkar Lakshmi Jagan, B., Kishore Kumar, A., Ramachandran, R., Hossain, M. A., & Nabih Zaki Rashed, A. (2024). Development of real time ECG monitoring and unsupervised learning classification framework for cardiovascular diagnosis. *Biomedical Signal Processing and Control*, 88(105553), 105553. <https://doi.org/10.1016/j.bspc.2023.105553>
- Ashfaq, Z., Rafay, A., Mumtaz, R., Hassan Zaidi, S. M., Saleem, H., Raza Zaidi, S. A., Mumtaz, S., & Haque, A. (2022). A review of enabling technologies for Internet of Medical Things (IoMT) Ecosystem. *Ain Shams Engineering Journal*, 13(4), 101660. <https://doi.org/10.1016/j.asej.2021.101660>
- Ávila, J. (2014). El estrés un problema de salud del mundo actual. *Revista CONCIENCIA*, 2(1), 117–125. http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S2310-02652014000100013&lng=es&nrm=iso&tlng=es http://www.scielo.org.bo/scielo.php?script=sci_abstract&pid=S2310-02652014000100013&lng=es&nrm=iso&tlng=es
- Barajas, J. G. (2018). Electrocardiograma desde una visión digital. Ediciones USTA.
- Barrios, I. (2015). Diseño de un Dispositivo Portable para la Medida de la Variabilidad de la Actividad Cardíaca [Universidad de Sevilla]. <http://hdl.handle.net/11441/36293>
- Bayevsky, R. M., Ivanov, G. G., Chireykin, L., Gavrilushkin, A., Dovgalevsky, P., Kukushkin, U., & Fleishmann, A. (2002). HRV analysis under the usage of different electrocardiography systems (Methodical recommendations). *Committee of New Medical Techniques of Ministry of Health of Russia*, 4, 2–67.

Beiter, R., Nash, R., McCrady, M., Rhoades, D., Linscomb, M., Clarahan, M., & Sammut, S. (2015). The prevalence and correlates of depression, anxiety, and stress in a sample of college students. *Journal of Affective Disorders*, 173, 90–96. <https://doi.org/10.1016/j.jad.2014.10.054>

Biel, J.-I., Martin, N., Labbe, D., & Gatica-Perez, D. (2018). Bites'n'bits: Inferring eating behavior from contextual mobile data. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 1(4), 1–33. <https://doi.org/10.1145/3161161>

Burgos, M. J., & Buendía, J. M. (2021). Sistema de monitoreo de ritmo cardíaco, utilizando la tecnología IoT [Universidad de Córdoba]. <https://repositorio.unicordoba.edu.co/handle/ucordoba/4227>

Cabrera, M., Domínguez, C. Y., & Landeros, C. (2022). Diseño de prototipo de pulsera con circuito para alertar una posible crisis convulsiva para jóvenes con epilepsia a partir de la variación del ritmo cardíaco. <https://repositorio.iberopuebla.mx/handle/20.500.11777/5580>

Cardozo, I. M. A., Morales, M. L. M., Soto, H. Y. O., & Ayala, N. R. (2021). El Estrés Laboral y su Influencia en el Desempeño Organizacional. *POLIANTEA*, 16(28), 8–12. <https://doi.org/10.15765/poliantea.v16i28.2326>

Castañeda-Garza, G., Ceballos, H. G., & Mejía-Almada, P. G. (2023). Artificial intelligence for mental health: A review of AI solutions and their future. In *What AI Can Do* (pp. 373–399). Chapman and Hall/CRC.

Catai, A. M., Pastre, C. M., Godoy, M. F. de, Silva, E. da, Takahashi, A. C. de M., & Vanderlei, L. C. M. (2020). Heart rate variability: are you using it properly? Standardisation checklist of procedures. *Brazilian Journal of Physical Therapy*, 24(2), 91–102. <https://doi.org/10.1016/j.bjpt.2019.02.006>

Channa, A., Popescu, N., Skibinska, J., & Burget, R. (2021). The rise of wearable devices during the COVID-19 pandemic: A systematic review. *Sensors (Basel, Switzerland)*, 21(17), 5787. <https://doi.org/10.3390/s21175787>

Cho, H.-M., Park, H., Dong, S.-Y., & Youn, I. (2019). Ambulatory and laboratory stress detection based on raw electrocardiogram signals using a convolutional neural network. *Sensors (Basel, Switzerland)*, 19(20), 4408. <https://doi.org/10.3390/s19204408>

Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.

Cigna Healthcare. (2023). Los efectos del estrés y su impacto en tu salud. Cigna.com. <https://www.cigna.com/es-us/knowledge-center/effects-of-stress-and-their-impact-on-your-health>

Ciupre, A. M., Ciupa, R. V., Roman, A. I., & Roman, N. M. (2015). Study of continuous wavelet transform used in ECG pre-diagnostic. In E-Health and Bioengineering Conference (EHB) (pp. 1–4).

da Estrela, C., McGrath, J., Booij, L., & Gouin, J.-P. (2021). Heart rate variability, sleep quality, and depression in the context of chronic stress. *Annals of Behavioral Medicine: A Publication of the Society of Behavioral Medicine*, 55(2), 155–164. <https://doi.org/10.1093/abm/kaaa039>

Dalmeida, K. M., & Masala, G. L. (n.d.). HRV Features as Viable Physiological Markers for Stress Detection Using Wearable Devices. *Sensors (Basel)* 2021, 21.

Dominguez-Lara, S. A., Sánchez-Villena, A. R., & Fernández-Arata, M. (2020). Psychometric properties of the UWES-9S in Peruvian college students. *Acta Colombiana de Psicología*, 23(2), 7–39. <https://doi.org/10.14718/acp.2020.23.2.2>

Dwivedi, R., Mehrotra, D., & Chandra, S. (2022). Potential of Internet of Medical Things (IoMT) applications in building a smart healthcare system: A systematic review. *Journal of Oral Biology and Craniofacial Research*, 12(2), 302–318. <https://doi.org/10.1016/j.jobcr.2021.11.010>

Fundación Española del Corazón. (2023). Frecuencia Cardíaca. <https://fundaciondelcorazon.com/prevencion/marcadores-de-riesgo/frecuencia-cardiaca.html>

Gilgen-Ammann, R., Schweizer, T., & Wyss, T. (2019). RR interval signal quality of a heart rate monitor and an ECG Holter at rest and during exercise. *European Journal of Applied Physiology*, 119(7), 1525–1532. <https://doi.org/10.1007/s00421-019-04142-5>

González, M. L., García Vázquez, J. P., Rodríguez, M. D., Padilla-López, L. A., Galindo-Aldana, G. M., & Cuevas-González, D. (2023). Wearables for stress management: A scoping review. *Healthcare (Basel, Switzerland)*, 11(17). <https://doi.org/10.3390/healthcare11172369>

Gonzalez, R. C., & Woods, R. E. (2017). *Digital Image Processing* (4th ed.). Pearson.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. [Deeplearningbook.org. https://www.deeplearningbook.org/front_matter.pdf](https://www.deeplearningbook.org/front_matter.pdf)

Gupta, V., Mittal, M., & Mittal, V. (2024). A simplistic and novel technique for ECG signal pre-processing. *IETE Journal of Research*, 70(1), 815–826. <https://doi.org/10.1080/03772063.2022.2135622>

Hasan, M. (2022, February 16). The IoT cloud: Microsoft Azure vs. AWS vs. Google Cloud. IoT Analytics; IoT Analytics GmbH. <https://iot-analytics.com/iot-cloud/>

- Huang, C., Wang, J., Wang, S., & Zhang, Y. (2023). Internet of medical things: A systematic review. *Neurocomputing*, 557(126719), 126719. <https://doi.org/10.1016/j.neucom.2023.126719>
- Huang, Z., Ma, Y., Wang, R., Yuan, B., Jiang, R., Yang, Q., Li, W., & Sun, J. (2022). DSCNN-LSTMs: A lightweight and efficient model for epilepsy recognition. *Brain Sciences*, 12(12), 1672. <https://doi.org/10.3390/brainsci12121672>
- Ishaque, S., Khan, N., & Krishnan, S. (2021). Trends in heart-rate variability signal analysis. *Frontiers in Digital Health*, 3, 639444. <https://doi.org/10.3389/fdgth.2021.639444>
- Jain, S., Nehra, M., Kumar, R., Dilbaghi, N., Hu, T., Kumar, S., Kaushik, A., & Li, C.-Z. (2021). Internet of medical things (IoMT)-integrated biosensors for point-of-care testing of infectious diseases. *Biosensors & Bioelectronics*, 179(113074), 113074. <https://doi.org/10.1016/j.bios.2021.113074>
- Jandackova, V. K., Scholes, S., Britton, A., & Steptoe, A. (2019). Healthy lifestyle and cardiac vagal modulation over 10 years: Whitehall II cohort study. *Journal of the American Heart Association*, 8(19), e012420. <https://doi.org/10.1161/JAHA.119.012420>
- Johnson, M. M., Deardorff, J., Parra, K., Alkon, A., Eskenazi, B., & Shirtcliff, E. (2017). A modified Trier Social Stress Test for vulnerable Mexican American adolescents. *Journal of Visualized Experiments: JoVE*, 125. <https://doi.org/10.3791/55393>
- Kim, H.-G., Cheon, E.-J., Bai, D.-S., Lee, Y. H., & Koo, B.-H. (2018). Stress and heart rate variability: A meta-analysis and review of the literature. *Psychiatry Investigation*, 15(3), 235–245. <https://doi.org/10.30773/pi.2017.08.17>
- Kingsley, M., Lewis, M. J., & Marson, R. E. (2005). Comparison of Polar 810s and an ambulatory ECG system for RR interval measurement during progressive exercise. *International Journal of Sports Medicine*, 26(1), 39–44. <https://doi.org/10.1055/s-2004-817878>
- Koldijk, S., Sappelli, M., Verberne, S., Neerincx, M. A., & Kraaij, W. (2014). The SWELL knowledge work dataset for stress and user modeling research. *Proceedings of the 16th International Conference on Multimodal Interaction*.
- Labuschagne, I., Grace, C., Rendell, P., Terrett, G., & Heinrichs, M. (2019). An introductory guide to conducting the Trier Social Stress Test. *Neuroscience and Biobehavioral Reviews*, 107, 686–695. <https://doi.org/10.1016/j.neubiorev.2019.09.032>
- Laganier, R. (2011). *OpenCV 2 Computer Vision Application Programming Cookbook*. Packt Publishing.

Lamberts, R. P., van Erp, T., Javaloyes, A., Eken, M. M., Langerak, N. G., & Tam, N. (2024). Reliability of recovery heart rate variability measurements as part of the Lamberts Submaximal Cycle Test and the relationship with training status in trained to elite cyclists. *European Journal of Applied Physiology*, 124(6), 1659–1668. <https://doi.org/10.1007/s00421-023-05385-z>

Laukkanen, R., & Virtanen, P. (1998). Heart rate monitors: State of the art". *J. Sport Sciences*, 16, 3–7.

León, M. (2018). ¿Qué tipo de instrumentos de medición del estrés psicológico se aplican en profesionales de enfermería y cuál es su validación psicométrica? <https://dspace.uib.es/xmlui/handle/11201/4110>

Leonangeli, S., Michelini, Y., & Montejano, G. R. (2022). Depression, anxiety and stress in college students before and during the first three months of COVID-19 lockdown. *Revista colombiana de psiquiatria*. <https://doi.org/10.1016/j.rcp.2022.04.008>

Li, M., Ma, C., Dang, W., Wang, R., Liu, Y., & Gao, Z. (2022). DSCNN: Dilated shuffle CNN model for SSVEP signal classification. *IEEE Sensors Journal*, 22(12), 12036–12043. <https://doi.org/10.1109/jsen.2022.3173433>

Liu, J. J. W., Ein, N., Peck, K., Huang, V., Pruessner, J. C., & Vickers, K. (2017). Sex differences in salivary cortisol reactivity to the Trier Social Stress Test (TSST): A meta-analysis. *Psychoneuroendocrinology*, 82, 26–37. <https://doi.org/10.1016/j.psyneuen.2017.04.007>

Ma, H., Ding, J., Zhang, Z., Gao, Q., Liu, Q., Wang, G., Zhang, W., & Fan, X. (2024). Recent advances in graphene-based humidity sensors with the focus on structural design: A review. *IEEE Sensors Journal*, 24(13), 20289–20311. <https://doi.org/10.1109/jsen.2024.3398003>

Mateos-Salgado, E. L., Pineda-Sánchez, J. E., Domínguez-Trejo, B., González-Hernández, B. M., & Guzmán-Saldaña, R. (2023). Influencia de la representación del poder espectral de la variabilidad cardiaca al evaluar el estrés. *Psicología y Salud*, 33(2), 397–406. <https://doi.org/10.25009/pys.v33i2.2822>

McCraty, R., & Shaffer, F. (2015). Heart rate variability: New perspectives on physiological mechanisms, assessment of self-regulatory capacity, and health risk. *Global Advances in Health and Medicine*, 4(1), 46–61. <https://doi.org/10.7453/gahmj.2014.073>

Microsoft. (2024). Protocolos y tecnologías de IoT. [Microsoft.com. https://azure.microsoft.com/es-mx/solutions/iot/iot-technology-protocols](https://azure.microsoft.com/es-mx/solutions/iot/iot-technology-protocols)

Monjarás, M. T. R., Lucio y Gómez-Maqueo, M. E., Romero Godínez, E., & Durán Patiño, C. (2021). Afrontamiento y Estrés en Preescolares: El Papel de la Edad y

el Sexo. *Acta de Investigacion Psicologica*, 11(3), 17–25. <https://doi.org/10.22201/fpsi.20074719e.2021.3.389>

Morera, L. P., Tempesti, T. C., Pérez, E., & Medrano, L. A. (2019). Biomarcadores en la medición del estrés: una revisión sistemática. *Ansiedad y estrés*, 25(1), 49–58. <https://doi.org/10.1016/j.anyes.2019.02.001>

Mortensen, J. A., Mollov, M. E., Chatterjee, A., Ghose, D., & Li, F. Y. (2023). Multi-class stress detection through heart rate variability: A deep neural network based study. *IEEE Access: Practical Innovations, Open Solutions*, 11, 57470–57480. <https://doi.org/10.1109/access.2023.3274478>

Ocampo, V., & Ruiz, A. F. (2024). Diseño e Implementación de un Sistema IoT para la Monitorización de la Variabilidad de la Frecuencia Cardíaca [Universidad Antonio Nariño]. <http://repositorio.uan.edu.co/handle/123456789/9034>

Organizacion Mundial de la Salud. (2023). Estrés. *Who.int*. <https://www.who.int/es/news-room/questions-and-answers/item/stress>

Palao, C. (2017). Desarrollo de un sistema IoT integrado con dispositivos de eHealth para la detección automática de la variabilidad cardíaca [Unoversidad Politecnica de Valencia]. <https://riunet.upv.es/handle/10251/91750>

Patlán, J. (2019). What is job stress and how to measure it? *Salud Uninorte*, 35, 156–184. <https://www.redalyc.org/journal/817/81762945010/html/#c1>

Pérez, A. (2018). Diseño de un electrocardiógrafo inalámbrico de reducidas dimensiones y elevada autonomía para uso diario [Unoversidad Politecnica de Valencia]. <https://riunet.upv.es/handle/10251/102982>

Pham, T., Lau, Z. J., Chen, S. H. A., & Makowski, D. (2021). Heart rate variability in psychology: A review of HRV indices and an analysis tutorial. *Sensors (Basel, Switzerland)*, 21(12), 3998. <https://doi.org/10.3390/s21123998>

Phukan, O. C., Ankita, D., Buduru, A. B., & Rajesh, S. (n.d.). SONIC: Synergizing VisiON Foundation Models for Stress Recog-Nition from ECG Signals.

Rahman, S. M. A., Ibtisum, S., Podder, P., & Hossain, S. M. S. (2023). Progression and Challenges of IoT in Healthcare: A Short Review. *International Journal of Computer Applications*, 185(37), 9–15. <https://doi.org/10.5120/ijca2023923168>

Ray, P. P., Dash, D., & Kumar, N. (2020). Sensors for internet of medical things: State-of-the-art, security and privacy issues, challenges and future directions. *Computer Communications*, 160, 111–131. <https://doi.org/10.1016/j.comcom.2020.05.029>

Redolar, D. (2016). El estrés Quiero saber (Editorial UOC, Ed.). <https://books.google.com.mx/books?hl=es&lr=&id=0ovLDAAAQBAJ&oi=fnd&pg=P>

T3&dq=estrés&ots=6vH2jKH89X&sig=5LnYm06r8_XmLhVb5YYRpwdtCAM&redir_esc=y#v=onepage&q&f=false

Resendiz-Ochoa, E., Cruz-Albarran, I. A., Garduño-Ramon, M. A., Rodriguez-Medina, D. A., Osornio-Rios, R. A., & Morales-Hernández, L. A. (2021). Novel expert system to study human stress based on thermographic images. *Expert Systems with Applications*, 178(115024), 115024. <https://doi.org/10.1016/j.eswa.2021.115024>

Reyna, C., Mola, D. J., & Correa, P. S. (2019). Escala de Estrés Percibido: análisis psicométrico desde la TCT y la TRI. *Ansiedad y estrés*, 25(2), 138–147. <https://doi.org/10.1016/j.anyes.2019.04.003>

Rivero, I., Valdés, E., & Valdés, F. E. (2016). Robust detection of AO and IM points in the seismocardiogram using CWT. *IEEE Latin America Transactions*, 14(11), 4468–4473. <https://doi.org/10.1109/tla.2016.7795816>

Schaffarczyk, M., Rogers, B., Reer, R., & Gronwald, T. (2022). Validity of the Polar H10 sensor for heart rate variability analysis during resting state and incremental exercise in recreational men and women. *Sensors (Basel, Switzerland)*, 22(17), 6536. <https://doi.org/10.3390/s22176536>

Schimpl, M. B. (2020, November 3). HRV (heart rate variability) - everything you need to know! Vitalmonitor. <https://www.vital-monitor.com/en/blogs/hrv/the-hrv-heart-rate-variability-everything-you-need-to-know?srsId=AfmBOopMIINh7pzs7vDL4iUZ1HpqlzIFfCQbGbHZAhtRocUC8uZCircR>

SECIHTI. (2021, April 5). Salud. SECIHTI; Consejo Nacional de Humanidades, Ciencias y Tecnologías. <https://secihtl.mx/pronaces/pronaces-salud/>

Seshadri, D. R., Davies, E. V., Harlow, E. R., Hsu, J. J., Knighton, S. C., Walker, T. A., Voos, J. E., & Drummond, C. K. (2020). Wearable sensors for COVID-19: A call to action to harness our digital infrastructure for remote patient monitoring and virtual assessments. *Frontiers in Digital Health*, 2, 8. <https://doi.org/10.3389/fdgth.2020.00008>

Shafik, W. (2024). Wearable Medical Electronics in Artificial Intelligence of Medical Things. *Handbook of Security and Privacy of AI-Enabled Healthcare Systems and Internet of Medical Things*. 21–40.

Silva-Ramos, M., López-Cocotle, J. J., & Meza-Zamora, M. E. C. (2020). Estrés académico en estudiantes universitarios. *Investigación y Ciencia de La Universidad Autónoma de Aguascalientes*, 28(79), 75–83. <https://doi.org/10.33064/IYCUEA2020792960>

Universidad del Valle de México. (2020, March 2). ESTRÉS. Centro de Opinión Pública UVM. <https://opinionpublica.uvm.mx/estudios/estres/>

Verma, D., Singh, K. R. B., Yadav, A. K., Nayak, V., Singh, J., Solanki, P. R., & Singh, R. P. (2022). Internet of things (IoT) in nano-integrated wearable biosensor devices for healthcare applications. *Biosensors & Bioelectronics*: X, 11(100153), 100153. <https://doi.org/10.1016/j.biosx.2022.100153>

Viloria, R., & Bracho, G. (2022). Prototipo de un monitor cardiaco implementando IOT: Desarrollo de un Prototipo de monitor cardiaco implementando IOT. *TECHNO REVIEW. International Technology, Science and Society Review /Revista Internacional De Tecnología, Ciencia Y Sociedad*, 12(Monográfico), 1–11. <https://doi.org/10.37467/revtechno.v11.4406>

Viloria, R., Bracho, G., Torres, M. L., & Torres, L. (2019). Construcción de un prototipo de monitoreo de señales cardíacas aplicando tecnología inalámbrica Zigbee e internet. *Investigaciones Andina*, 21(39), 185–207. <https://doi.org/10.33132/01248146.1564>

Wagan, S. A., Koo, J., Siddiqui, I. F., Attique, M., Shin, D. R., & Qureshi, N. M. F. (2022). Internet of medical things and trending converged technologies: A comprehensive review on real-time applications. *Journal of King Saud University - Computer and Information Sciences*, 34(10), 9228–9251. <https://doi.org/10.1016/j.jksuci.2022.09.005>

Waghumbare, A., Singh, U., & Kasera, S. (2024). DIAT-DSCNN-ECA-Net: separable convolutional neural network-based classification of galaxy morphology. *Astrophysics and Space Science*, 369(4). <https://doi.org/10.1007/s10509-024-04302-w>

Weber, J., Heming, M., Apolinário-Hagen, J., Liszio, S., & Angerer, P. (2024). Comparison of the Perceived Stress Reactivity Scale with physiological and self-reported stress responses during ecological momentary assessment and during participation in a virtual reality version of the Trier Social Stress Test. *Biological Psychology*, 186(108762), 108762. <https://doi.org/10.1016/j.biopsycho.2024.108762>

APENDICES

Apéndice A. Artículo publicado.



Article

Intelligent Stress Detection Using ECG Signals: Power Spectrum Imaging with Continuous Wavelet Transform and CNN

Rodrigo Mateo-Reyes , Irving A. Cruz-Albarran * and Luis A. Morales-Hernandez

Mecatrónica, Facultad de Ingeniería, Universidad Autónoma de Querétaro, Campus San Juan del Río, Río Moctezuma 249, Col. San Cayetano, San Juan del Río 76807, Querétaro, Mexico; rmateo13@alumnos.uaq.mx (R.M.-R.); luis.morales@uaq.mx (L.A.M.-H.)

* Correspondence: irving.cruz@uaq.mx

Abstract: Stress is a natural response of the organism to challenging situations, but its accurate detection is challenging due to its subjective nature. This study proposes a model based on depth-separable convolutional neural networks (DSCNN) to analyze heart rate variability (HRV) and detect stress. Electrocardiogram (ECG) signals are pre-processed to remove noise and ensure data quality. The signals are then transformed into two-dimensional images using the continuous wavelet transform (CWT) to identify pattern recognition in the time–frequency domain. These representations are classified using the DSCNN model to determine the presence of stress. The methodology has been validated using the SWELL-KW dataset, achieving an accuracy of 99.9% by analyzing the variability in three states (neutral, time pressure, and interruptions) of the 25 samples in the experiment, scanning the acquired signal every 5 s for 45 min per state. The proposed approach is characterized by its ability to transform ECG signals into time–frequency representations by means of short duration sampling, achieving an accurate classification of stress states without the need for complex feature extraction processes. This model is an efficient and accurate tool for stress analysis from biomedical signals.

Keywords: stress; CWT; heart rate variability; DSCNN



Academic Editors: Barry K. Lavine and Marco Rossi

Received: 12 December 2024

Revised: 23 January 2025

Accepted: 18 February 2025

Published: 26 February 2025

Citation: Mateo-Reyes, R.; Cruz-Albarran, I.A.; Morales-Hernandez, L.A. Intelligent Stress Detection Using ECG Signals: Power Spectrum Imaging with Continuous Wavelet Transform and CNN. *J. Exp. Theor. Anal.* **2025**, *3*, 6. <https://doi.org/10.3390/jeta3010006>

Copyright: © 2025 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Stress is the body's natural response to challenging situations. It causes mental and physical tension [1]. Although essential for coping with daily challenges, it can be triggered by factors such as work, finances, and interpersonal relationships [2–4]. Stress can be temporary or chronic and has a wide range of effects on physical and mental health. Physical effects include colds, headaches, heart problems, and sleep problems [5,6]. It is also considered to be the mental illness of the 21st century, triggering depression and sometimes suicide [7]. Worldwide, suicide is the second leading cause of death in the 15–29 age group, with more than 720,000 people taking their own lives each year [8]. Depression affects 121 million people worldwide. In addition, its early onset, functional impact, and tendency to be chronic and recurrent make it a leading cause of disability [9]. These figures underline the urgency of identifying stress early to avoid chronic consequences. Although significant progress has been made in its diagnosis, stress is subjective and expressed differently from person to person. Generic stress prediction models work in a rudimentary way, while only person-specific models offer reliable predictions. However, these models are not adaptive and are costly to implement in real-world settings, as reported in [10]. There is a need to develop classification methods that are more suitable for mobile devices by