

Propuesta de Sistema de Monitorización de Confort y Estrés en el entorno Laboral

Edgar Mauricio Ortiz Albarracín, Eduardo Franco Russi y Daniel José Gutiérrez Vargas

Trabajo de Grado para Optar al Título de Ingeniero Electrónico

Director

José David Cortés Torres

Magister en ingeniería Eléctrica

Codirector

Oscar Arnulfo Quiroga Quiroga

Doctor en tecnología

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones

Ingeniería Electrónica

Bucaramanga

2025

Dedicatoria

A Dios, quien ha sido mi refugio en la tormenta y mi guía en cada paso. Gracias por darme la fuerza para seguir adelante cuando el camino se tornó difícil, por llenarme de fe cuando la duda intentó detenerme y por concederme la oportunidad de alcanzar esta meta.

A mis padres, cuyo amor, sacrificio y entrega inquebrantable me han enseñado el verdadero significado del esfuerzo y la perseverancia. Su apoyo ha sido mi mayor fortaleza, y este logro es tanto suyo como mío. Gracias por creer en mí y por darme siempre el ejemplo de que, con dedicación y paciencia, todo se puede alcanzar.

A mis profesores, por compartir su conocimiento y guiarme en este proceso de aprendizaje.

A mis compañeros y amigos, por su apoyo incondicional, por cada consejo y por hacer este camino más llevadero.

A quienes, con palabras, gestos o simplemente con su presencia me brindaron ánimo y confianza en este recorrido. Su apoyo ha sido invaluable y lo llevo en el corazón.

Edgar Mauricio Ortiz Albarracín

A Dios, por ser mi guía y fortaleza en este camino lleno de desafíos. Su amor y sabiduría me brindaron esperanza en los momentos más oscuros y me dieron la fuerza para seguir adelante.

A mis padres, Odix y Camilo, cuya paciencia, amor incondicional y apoyo constante fueron mi mayor motivación. Gracias por cada sacrificio y por creer en mí incluso en los momentos en que dudé de mí mismo. Son y siempre serán mi pilar.

A mi hermana Tatiana, por su cariño y palabras de aliento que llenaron mis días de inspiración. Tu compañía convirtió cada dificultad en una oportunidad para sonreír y seguir adelante.

A mi familia, por su amor y respaldo en cada paso de este proceso. Su presencia fue un recordatorio constante de que no estaba solo.

Este logro es el reflejo de días arduos, noches largas y momentos de incertidumbre, pero también de lucha, fe y determinación. Es un sueño alcanzado que comparto con todos ustedes, quienes fueron mi razón para nunca rendirme.

Eduardo Franco Russi

A Dios, por su inmenso amor hacia mí, por acompañarme en los buenos y malos momentos, y mostrarme el camino para alcanzar este logro, todo es gracias a él.

A mis padres, por su amor incondicional, su confianza y su inquebrantable apoyo. Han sido un pilar fundamental en mi vida, guiándome con su ejemplo y fortaleza. Siempre me he sentido orgulloso de los padres que la vida me regaló, y hoy, con este logro, quiero retribuirles un poco de ese orgullo.

A mi abuela, mi segunda madre, quien me entrega su amor cada día. Su apoyo incondicional y su presencia han sido un regalo invaluable, haciéndome la vida más fácil.

A mis hermanos, cuya presencia y cariño han sido una fuente constante de inspiración en mi vida. Es un orgullo para mí demostrarles que, con esfuerzo y determinación, los sueños pueden hacerse realidad.

A mi pareja y mejor amiga, Natalia Román. Para ambos, este día fue siempre un sueño que imaginamos juntos., sin su apoyo y su amor nada de esto sería posible, su perseverancia y constancia por verme salir adelante me hicieron afrontar con firmeza cualquier situación, este es un logro que construimos juntos y que me honra dedicárselo y compartirlo a su lado.

A mis amigos, por ser parte fundamental en mi vida, por darme tantas alegrías, aconsejarme y apoyarme cuando lo necesitaba.

Daniel José Gutiérrez Vargas

Agradecimientos

A la Universidad Industrial de Santander, por ser el espacio donde crecí académica y personalmente.

A mi director de trabajo de grado, por su orientación y cada consejo que me ayudó en este proceso.

A mis profesores, por su enseñanza y guía a lo largo de mi formación.

A mi familia, por su amor incondicional y por ser mi mayor apoyo en cada paso.

A mis amigos y compañeros, por su compañía, apoyo y por hacer este camino más llevadero.

A todos los que, de alguna manera, fueron parte de este logro.

Edgar Mauricio Ortiz Albarracín

A la Universidad Industrial de Santander y a mis profesores, por brindarme las herramientas, el conocimiento y la orientación que han sido fundamentales en mi formación académica y profesional.

A mis padres, por su apoyo incondicional, su amor y sus enseñanzas, que han sido mi guía en cada paso de este camino.

A mi hermana Tatiana, por estar siempre a mi lado, brindándome su ánimo y compañía en los momentos más importantes.

A todos aquellos que, de una u otra manera, han contribuido a la realización de este proyecto.

Eduardo Franco Russi

A la Universidad Industrial de Santander, por ser el espacio donde me forme personal y académicamente.

A mi director de trabajo de grado, por su acompañamiento continuo y por cada orientación que marcó la diferencia en este camino.

A mis profesores, por transmitir su saber con dedicación y por estar presentes a lo largo de mi proceso formativo.

Daniel José Gutiérrez Vargas

Tabla de Contenido

	Pág.
Introducción	11
1. Objetivos	12
1.1 Objetivo general	12
1.2 Objetivos Específicos.....	12
2. Marco conceptual.....	13
2.1 Definición y conceptualización del Estrés	13
2.2 Definición de confort	14
2.3 Definición de monitoreo	14
2.4 Relación del estrés con el sistema nervioso.....	14
2.5 Electrocardiograma (ECG) y variabilidad de la frecuencia cardíaca (HRV)	14
2.6 Fotopletismografía (PPG)	15
2.7 Actividad electrodérmica (EDA/GSR)	15
2.8 Frecuencia respiratoria (RR).....	15
2.9 Temperatura corporal (TEMP)	16
2.10 Variables ambientales que influyen en el estrés laboral en oficinas.....	16
2.10.1 Calidad del aire	16
2.10.2 Ruido ambiental	17
2.10.3 Iluminación y temperatura ambiental	17
2.11 Plataformas de integración.....	17
3. Antecedentes	18
3.1 Revisión de la literatura	19

3.1.1 Filtros aplicados para la selección de los artículos	19
3.1.2 Variables fisiológicas seleccionadas y su relación con el estrés.....	20
3.2 Sensores biométricos para la medición del estrés.....	23
3.3 Plataformas de integración.....	25
3.4 Sensores fisiológicos y de entorno.....	26
3.5 Dataset WESAD	27
4. Desarrollo de la propuesta de monitorización	27
4.1 Descripción general de la propuesta	28
4.2 Metodología para la identificación de variables fisiológicas.....	29
4.3 Metodología para la búsqueda de información de bases de datos estandarizadas	29
4.4 Metodología para la búsqueda de instrumentos de medición	30
4.5 Metodología para la búsqueda de plataformas de integración.....	30
4.6 Posible estrategia de monitorización del estrés	30
4.7 Caso de estudio	35
4.7.1 Análisis de datos del WESAD con Python	36
5. Resultados	37
5.1 Decisiones tomadas.....	37
5.2 Resultados del caso de estudio.....	38
6. Conclusiones	39
7. Recomendaciones	41
Referencias Bibliográficas	42

Lista de Tablas

	Pág.
Tabla 1 <i>Artículos y variables fisiológicas seleccionadas en la detección de estrés</i>	22
Tabla 2 <i>Comparación de sensores para la detección del estrés en entornos laborales</i>	24
Tabla 3 <i>Arquitectura de la red neuronal convolucional</i>	32
Tabla 4 <i>Matriz de confusión de la clasificación de estados afectivos</i>	33
Tabla 5 <i>Clasificación porcentual de estados afectivos para el sujeto dos</i>	37

Lista de Figuras

	Pág.
Figura 1 <i>Arquitectura General del Sistema de Monitorización</i>	28
Figura 2 <i>Proceso de Análisis de Señales</i>	31
Figura 3 <i>Dashboard de Monitoreo en Tiempo Real</i>	34
Figura 4 <i>Representación del Flujo de Procesamiento de Señales</i>	36

Lista de Apéndices

(Los apéndices pueden ser consultados en la base de datos de la biblioteca UIS)

Apéndice A. Síntesis de variables

Apéndice B. Análisis Comparativo de Plataformas IoT

Apéndice C. Comparativa de Sensores Fisiológicos y Ambientales

Resumen

Título: Propuesta de Sistema de Monitorización de Confort y Estrés en el entorno laboral*

Autor: Edgar Mauricio Ortiz Albarracín, Eduardo Franco Russi y Daniel José Gutiérrez Vargas**

Palabras Clave: Confort, estrés, sensores fisiológicos, monitoreo, WESAD.

Descripción: Esta investigación propone un sistema de monitoreo de confort y estrés en entornos laborales mediante el uso de tecnologías avanzadas como sensores fisiológicos y plataformas de integración de datos. El sistema mide indicadores asociados al estrés, como variabilidad de frecuencia cardíaca (HRV), respuesta galvánica de la piel (GSR/EDA), frecuencia respiratoria (RR) y temperatura corporal, con el objetivo de promover el bienestar de los empleados en sus entornos laborales.

El desarrollo del proyecto incluyó una exhaustiva revisión bibliográfica que permitió identificar el data set WESAD como referencia para validar la precisión de las variables seleccionadas como indicadores de estrés. Además, se diseñó una plataforma basada en Python, que integra los datos recopilados y analiza en tiempo real los patrones fisiológicos relacionados con el estrés.

Se concluye que la combinación de sensores y plataformas de integración facilitan una monitorización efectiva para la detección de factores estresantes, permitiendo diseñar estrategias personalizadas que promuevan entornos laborales más saludables y sostenibles.

* Trabajo de Grado

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones. Ingeniería Electrónica. Director: M. Sc. José David Cortés Torres. Codirector: P. hD. Oscar Arnulfo Quiroga Quiroga.

Abstract

Title: Proposal for a Comfort and Stress Monitoring System in the Work Environment*

Author(s): Edgar Mauricio Ortiz Albarracín, Eduardo Franco Russi y Daniel José Gutiérrez Vargas**

Key Words: Comfort, stress, physiological sensor, monitoring, WESAD.

Description: This research proposes a system for monitoring comfort and stress in work environments through the use of advanced technologies such as physiological sensors and data integration platforms. The system measures indicators associated with stress, such as heart rate variability (HRV), galvanic skin response (GSR/EDA), respiratory rate (RR) and body temperature, with the objective of promoting the well-being of employees in their work environments.

The development of the project included an exhaustive literature review that allowed identifying the WESAD data set as a reference to validate the accuracy of the variables selected as stress indicators. In addition, a Python-based platform was designed, which integrates the collected data and analyses in real time the physiological patterns related to stress.

It is concluded that the combination of sensors and integration platforms facilitate effective monitoring for the detection of stressors, allowing the design of personalized strategies that promote healthier and more sustainable work environments.

* Degree Work

** Faculty of Physicmechanics Engineering. School of Electrical, Electronic and Telecommunications Engineering. Electronic Engineering. Director: M. Sc. José David Cortés Torres. Co-director: P. hD. Oscar Arnulfo Quiroga Quiroga.

Introducción

El ámbito laboral ha experimentado una evolución constante a lo largo de la historia, desde los inicios de la era industrial hasta la actualidad. En cada etapa, se ha buscado mejorar las condiciones de trabajo, tanto en términos de eficiencia como de bienestar de los trabajadores. En la era digital, la tecnología se ha convertido en un pilar fundamental para alcanzar estos objetivos, permitiendo desarrollar soluciones innovadoras que aborden de manera integral aspectos como el confort y el estrés en los entornos laborales. Este proyecto propone la creación de un sistema de monitorización avanzado que integre tecnologías de vanguardia tales como sensores que permitan obtener mediciones de ritmo cardiaco, la temperatura, la humedad en el ambiente, etc. Así como plataformas de análisis en la nube. La combinación de estas herramientas permitirá obtener una visión completa y precisa del estado físico y emocional de los empleados durante su jornada laboral, permitiendo identificar de manera correcta los factores que influyen en su bienestar y rendimiento, proporcionando información sobre el nivel de estrés.

Al hablar de tecnologías de vanguardia, se hace referencia a herramientas como el Internet de las Cosas (IoT), que posibilita la interconexión de dispositivos y la recopilación de datos en tiempo real. La combinación de sensores inteligentes, dispositivos portátiles y sistemas de análisis avanzados otorga la capacidad de monitorizar de forma continua y precisa diversos aspectos relacionados con el confort y el estrés en el entorno laboral.

La propuesta de sistema de monitorización de confort y estrés en el entorno laboral representa una iniciativa innovadora que busca optimizar el bienestar laboral y fomentar la eficiencia de las empresas, el uso inteligente de la tecnología y el enfoque centrado en las personas permiten avanzar hacia entornos laborales más saludables, equitativos y sostenibles en el futuro.

1. Objetivos

1.1 Objetivo general

Proponer un sistema de monitorización a través de sensores que permita la medición de indicadores fisiológicos y ambientales asociados al estrés para trabajadores de oficina en ambientes urbanos, con el fin de mejorar su bienestar laboral y favorecer un entorno más saludable.

1.2 Objetivos Específicos

Investigar cuales son las variables significativas asociadas al estrés en entornos laborales de oficina, analizando su impacto en el bienestar y rendimiento de los empleados a través de la revisión de literatura científica.

Explorar cuales son las tecnologías de sensores biométricos y de entorno que se adapten al sistema a proponer usando como referencia diversas bases científicas y soluciones comerciales.

Especificar que plataformas de integración de datos son capaces tanto de procesar como de sintetizar resultados de simulaciones de datos biométricos y de entorno.

Seleccionar tanto sensores como la plataforma de integración de datos, mediante un análisis de las características técnicas, capacidades de integración, precisión de las mediciones y compatibilidad con los requisitos del sistema a proponer.

Desarrollar una prueba de concepto mediante una plataforma de IoT, utilizando datos sintéticos para simular el funcionamiento del sistema.

2. Marco conceptual

El estrés es una reacción fisiológica provocada por alguna situación ya sea física o emocional por cuanto el organismo responde con diferentes reacciones de defensa. Muchas veces este mecanismo de defensa de constante tensión obliga a nuestro cuerpo a dar el máximo y que a la larga termina generalmente en forma de algún tipo de enfermedad o problema de salud.

Es también un proceso natural del cuerpo humano, que genera una respuesta automática ante condiciones externas que resultan amenazadoras o desafiantes, que requieren una movilización de recursos físicos, mentales y conductuales para hacerles frente, y que a veces perturban el equilibrio emocional de la persona (Orlandini, 1999).

Según Rodríguez Carvajal & De Rivas Hermosilla (2011) y la comisión europea de seguridad y salud en el trabajo “el estrés laboral se define como las nocivas reacciones físicas y emocionales que ocurren cuando las exigencias del trabajo no igualan las capacidades, los recursos o las necesidades del trabajador”.

2.1 Definición y conceptualización del Estrés

El estrés se define como “reacciones corporales a amenazas físicas o psicológicas percibidas” (Choi, Ahmed, & Gutierrez-Osuna, 2012). El pionero en el estudio del estrés Selye (1936) lo definió como la respuesta inespecífica del cuerpo ante cualquier demanda o estímulo que altere su equilibrio fisiológico. Más adelante, Selye (1956) desarrolló el concepto del Síndrome de Adaptación General (GAS, por sus siglas en inglés), proponiendo que el estrés sigue tres fases: alarma, resistencia y agotamiento. En la fase de alarma, el cuerpo reacciona con cambios fisiológicos que facilitan la respuesta de lucha o huida. Si el estresor persiste, el organismo entra en la fase de resistencia, en la que intenta adaptarse. Sin embargo, una exposición prolongada puede llevar a la fase de agotamiento, lo que puede resultar en enfermedad o incluso la muerte.

2.2 Definición de confort

Kolcaba (2003) define el confort como “El estado inmediato de ser fortalecido por tener las necesidades de alivio, facilidad y trascendencia atendidas en los cuatro contextos de la experiencia humana holística: físico, psicoespiritual, sociocultural y ambiental”.

2.3 Definición de monitoreo

El término monitorización incluye tanto la evaluación visual como el uso de dispositivos para medir parámetros fisiológicos (Cohen, y otros, 2007).

2.4 Relación del estrés con el sistema nervioso

El estrés afecta directamente el funcionamiento del sistema nervioso autónomo (SNA), el cual regula las funciones corporales involuntarias según lo mencionado por Taskasaplidis, Fotiadis, & Bamidis (2024):

En respuesta al estrés, puede desencadenar (a) el sistema nervioso simpático (SNS), que es parte del sistema nervioso autónomo (SNA), y (b) la producción de hormonas. El SNS puede controlar la llamada respuesta de "lucha o huida" y, por ejemplo, puede aumentar la frecuencia cardíaca, la presión arterial y el agrandamiento de la pupila de los ojos. Además, el hipotálamo puede provocar la producción de hormonas a través del eje hipotálamo-hipófisis-suprarrenal (HPA) para contrarrestar el estrés. Por el contrario, en condiciones de recesión por estrés, el hipotálamo puede activar el sistema nervioso parasimpático (SNP), que forma parte del SNA. El SNP predomina en las llamadas condiciones de "descanso y digestión", relajando así el organismo, y a nivel del eje HPA, el hipotálamo inhibe la producción de hormonas del estrés.

2.5 Electrocardiograma (ECG) y variabilidad de la frecuencia cardíaca (HRV)

El **electrocardiograma (ECG)** permite medir la actividad eléctrica del corazón y extraer variables como la **frecuencia cardíaca (HR)**, la **variabilidad de la frecuencia cardíaca (HRV)**

y la **arritmia sinusal respiratoria (RSA)**. La HR está relacionada con la actividad emocional y el estrés, y se ha utilizado para diferenciar entre emociones positivas y negativas. Por otro lado, la HRV mide la variabilidad en los intervalos entre latidos consecutivos, disminuyendo en situaciones de estrés y aumentando en estados de relajación. Asimismo, la HRV se suprime con el esfuerzo mental, pero si la demanda cognitiva excede la capacidad de la memoria de trabajo, la HRV aumenta (Rowe, Sibert, & Irwin, 1998).

2.6 Fotopletismografía (PPG)

La fotopletismografía (PPG), también conocida como volumen del pulso sanguíneo (BVP), se obtiene mediante un oxímetro de pulso que emplea una fuente de luz y un fotodetector en la superficie de la piel. Este tipo de dispositivos son generalmente de bajo costo, de tamaño reducido y fáciles de usar, lo que permite un monitoreo confiable de la frecuencia del pulso (Gedam & Paul, 2021).

2.7 Actividad electrodérmica (EDA/GSR)

La actividad electrodérmica (EDA) también conocida como respuesta galvánica de la piel (GSR) es un indicador utilizado para estimar el estado del sistema nervioso autónomo, ya que se ha demostrado que está relacionada con el estrés mental. Esto se debe a que las glándulas sudoríparas están controladas por el sistema nervioso simpático (SNS), el cual regula la cantidad de sudor liberado. Dado que la activación del SNS también está vinculada con el nivel de estrés, el GSR puede utilizarse como un indicador del estado de estrés (Park, y otros, 2020).

2.8 Frecuencia respiratoria (RR)

Los patrones respiratorios también cambian en situaciones de estrés. Mientras que en un estado de relajación la respiración suele ser más lenta e irregular, bajo estrés se vuelve ligeramente más rápida e irregular. Por esta razón, las señales respiratorias pueden utilizarse para monitorear

el estrés y proporcionar información sobre la actividad del sistema nervioso simpático (Tripathi & Mishra, 2017).

2.9 Temperatura corporal (TEMP)

La tasa de cambio de la temperatura corporal en un periodo de tiempo determinado puede proporcionar información relevante. En particular, la temperatura de la piel se utiliza con frecuencia como un indicador del confort térmico o del nivel de estrés, ya que presenta mayores variaciones en comparación con la temperatura central (Al-Atawi, y otros, 2023). Para medirla, se utilizan sensores infrarrojos o de contacto, los cuales están diseñados para medir la temperatura de la piel sin ser invasivos. Tiene como ventaja la capacidad de medir la temperatura en tiempo real, lo que permite detectar las variaciones rápidas que ocurren cuando el cuerpo experimenta estrés.

2.10 Variables ambientales que influyen en el estrés laboral en oficinas

Los sensores de entorno desempeñan un papel clave en la mejora del bienestar de los empleados, ya que permiten monitorear y ajustar factores ambientales que pueden contribuir al estrés laboral.

2.10.1 Calidad del aire

Altos niveles de CO₂ en oficinas pueden inducir fatiga, disminución de la concentración y aumento del estrés. Esto se debe, en parte, a la reducción en la disponibilidad de oxígeno y la acumulación de otros compuestos en el aire (Satish, y otros, 2012). Un estudio realizado por Satish y colaboradores (2012) encontró que incluso concentraciones moderadas de CO₂ pueden afectar negativamente el rendimiento en tareas de toma de decisiones, lo que sugiere un impacto directo en la función cognitiva y el potencial aumento del estrés laboral.

2.10.2 Ruido ambiental

El ruido ambiental es un factor clave que afecta la concentración y el estrés en los lugares de trabajo. Niveles elevados de ruido pueden inducir distracción, incomodidad y fatiga mental, provocando una disminución en el rendimiento cognitivo y aumentando la probabilidad de estrés psicológico.

2.10.3 Iluminación y temperatura ambiental

Las variaciones en la iluminación y temperatura de la oficina pueden influir significativamente en el estrés emocional y físico de los empleados. La iluminación deficiente o excesiva puede generar fatiga visual y molestias, mientras que una temperatura incómoda puede provocar distracción y estrés térmico.

2.11 Plataformas de integración

Node-Red: El objetivo de Node-RED es permitir que cualquier persona cree aplicaciones que recopilen, transformen y visualicen sus datos; construyendo flujos que puedan automatizar su mundo (Node-RED). Es utilizada ampliamente en proyectos de IoT, automatización e integración de datos en tiempo real.

ThingSpeak: ThingSpeak es un servicio de plataforma de análisis de IoT que permite agregar, visualizar y analizar flujos de datos en directo en la nube. Puede enviar datos a ThingSpeak desde sus dispositivos, crear visualizaciones instantáneas de datos en directo y enviar alertas (MathWorks). Es utilizada en aplicaciones de monitoreo remoto, predicción de tendencias y control de dispositivos IoT.

AWS IoT: AWS ofrece servicios y soluciones del Internet de las cosas (IoT) para conectar y administrar miles de millones de dispositivos. Recopile, almacene y analice los datos de IoT de las cargas de trabajo industriales, de consumo, comerciales y automotrices (Amazon Web

Services). Su arquitectura distribuida y su compatibilidad con múltiples protocolos lo convierten en una opción robusta para el manejo de datos biométricos y ambientales en entornos de simulación.

Google Cloud IoT: Es un conjunto completo de herramientas para conectar, procesar, almacenar y analizar datos tanto en dispositivos locales como en la nube. La plataforma consta de servicios en la nube escalables y totalmente gestionados; una pila de software integrada para informática perimetral o local con capacidades de aprendizaje automático para todas sus necesidades de IoT (Google Cloud). Su integración con BigQuery, TensorFlow y Google AI la convierte en una plataforma potente para el análisis predictivo y la toma de decisiones basada en datos.

IBM Watson IoT: plataforma en la nube diseñada para la administración, análisis y procesamiento de datos provenientes de dispositivos IoT y simulaciones biométricas, ambientales e industriales (IBM Watson). IBM Watson IoT aprovecha el poder de Watson AI, IBM Cloud Functions y Cognos Analytics para la gestión avanzada de datos provenientes de entornos de simulación.

Python: se trata lenguaje de programación ampliamente utilizado en el análisis y procesamiento de datos de simulaciones debido a su flexibilidad, amplia comunidad y compatibilidad con múltiples herramientas de análisis (Python Software Foundation). Su integración con bibliotecas especializadas lo convierte en una opción poderosa para el modelado de datos, machine learning y análisis predictivo.

3. Antecedentes

El presente apartado detalla la metodología utilizada para la identificación de las variables fisiológicas más relevantes en la monitorización del estrés en entornos laborales de oficina. Con

este objetivo se propuso el desarrollo de un sistema de medición confiable, se llevó a cabo una revisión exhaustiva de la literatura científica en bases de datos especializadas. Este proceso permitió el análisis de los enfoques previos en la medición del estrés y la selección de las variables más recurrentes en estudios previos.

En un contexto donde las exigencias laborales y el ritmo acelerado del trabajo pueden generar efectos negativos en la salud de los trabajadores, es fundamental contar con herramientas que permitan detectar y gestionar el estrés de manera eficaz. La monitorización fisiológica basada en sensores biométricos ofrece una alternativa prometedora para la evaluación en tiempo real del estrés en entornos laborales, proporcionando datos objetivos que pueden ser utilizados para mejorar la calidad de vida y el bienestar de los empleados.

3.1 Revisión de la literatura

Para esta investigación, se consultaron diversas bases de datos académicas reconocidas por su rigor científico, tales como IEEE Xplorer, Springer y ScienceDirect. Además, se revisaron redes académicas como ResearchGate para identificar publicaciones relevantes compartidas por sus autores. La búsqueda se centró en artículos que abordaran la medición del estrés a través de variables fisiológicas en distintos contextos, con énfasis en aplicaciones para entornos laborales. El criterio de selección inicial incluyó artículos publicados en los últimos años, que utilizaran sensores biométricos para la medición del estrés y que presentaran resultados experimentales. A partir de una primera búsqueda amplia, se recopilaron 30 artículos relevantes.

3.1.1 Filtros aplicados para la selección de los artículos

Para garantizar la relevancia y calidad de los artículos incluidos en la investigación, se aplicaron los siguientes filtros:

Relevancia temática: Se descartaron estudios que no estuvieran directamente relacionados con la medición del estrés mediante variables fisiológicas y ambientales. Se priorizaron aquellos que abordaran el estrés en contextos laborales, asegurando que la información recopilada fuera aplicable al proyecto.

Calidad de la fuente: Se seleccionaron artículos indexados en bases de datos científicas de alto impacto y revistas especializadas en fisiología, psicología y tecnología aplicada a la salud.

Aplicabilidad al proyecto: Se eligieron estudios cuya metodología y resultados pudieran ser replicables en un sistema de monitorización en entornos laborales. Además, se priorizaron aquellos que utilizaban sensores biométricos portátiles y tecnologías de Internet de las Cosas (IoT) para la medición del estrés. Tras la aplicación de estos filtros, el número de artículos se redujo a 14, los cuales proporcionaban información detallada sobre las variables fisiológicas utilizadas en la medición del estrés.

En la tabla 1 del Apéndice A, se resume el material analizado, organizando la información según el nombre del artículo, la base de datos de origen, las variables monitoreadas, los sensores y dispositivos empleados, y los métodos de análisis de datos aplicados. Esta recopilación de información permite validar la selección de las variables que serán consideradas en el desarrollo del sistema de monitorización propuesto en esta investigación.

3.1.2 Variables fisiológicas seleccionadas y su relación con el estrés

A partir del análisis de los artículos seleccionados, se identificaron cuatro variables fisiológicas principales que presentaban una recurrencia bastante significativa en los estudios revisados:

Variabilidad de la frecuencia cardiaca (HRV): Presente en los 14 artículos seleccionados, la HRV es ampliamente reconocida como un indicador fiable de estrés y de la

regulación del sistema nervioso autónomo. Estudios han demostrado que una disminución en la HRV indica una mayor activación del sistema simpático y menor actividad parasimpática, lo que se ha asociado con niveles elevados de estrés y riesgo cardiovascular.

Respuesta galvánica de la piel (GSR/EDA): Aparece en 12 de los 14 estudios y esta variable mide la actividad de las glándulas sudoríparas. La conductancia de la piel es un reflejo directo de la actividad del sistema nervioso simpático y ha sido ampliamente utilizada en la investigación del estrés, pues su ventaja principal radica en su alta sensibilidad a los estímulos cognitivos y emocionales, lo que la convierte en una herramienta de monitoreo eficaz para identificar situaciones de alta presión en el entorno laboral.

Temperatura corporal/piel (Temp): la medición de este parámetro es una técnica no invasiva y de fácil implementación en dispositivos de monitoreo portátil, lo que facilita su aplicación en entornos laborales dinámicos. Su integración en sistemas de monitorización permite correlacionar cambios térmicos con otras variables fisiológicas para mejorar la precisión en la evaluación del estrés.

Frecuencia Respiratoria (RR): En entornos laborales, donde la carga de trabajo y la presión puede alterar el ritmo respiratorio, la monitorización continua de la frecuencia respiratoria permite detectar de manera anticipada estados de tensión fisiológica antes de que se conviertan en problemas crónicos de salud. Además, la RR puede ser medida con sensores discretos y portátiles, favoreciendo su integración en plataformas de monitoreo sin afectar la movilidad del trabajador.

En conjunto, la combinación de estas cuatro variables fisiológicas ofrece una visión holística del estrés en el entorno laboral, permitiendo la identificación de patrones fisiológicos asociados a la fatiga mental y emocional. Su integración en plataformas de monitoreo continuo

facilitaría el desarrollo de intervenciones personalizadas para reducir el impacto del estrés en la productividad y el bienestar de los empleados, revisar Tabla 1.

Tabla 1

Artículos y variables fisiológicas seleccionadas en la detección de estrés

Artículo	Base de datos	Variables fisiológicas			
		HRV	GSR/EDA	RR	Temperatura corporal/Piel
Review of Stress Detection Methods Using Wearable Sensors	IEEE Xplorer	X	-	-	X
Wearable stress monitoring system using multiple sensors	IEEE Xplorer	X	X	-	X
Exploring Early Stress Detection from Multimodal Time Series with Deep Reinforcement Learning	IEEE Xplorer	X	X	-	X
Design and implementation of a real time stress monitoring system with the help of ECG using MATLAB tool	IEEE Xplorer	X	X	X	-
Continuous monitoring of stress on smartphone using heart rate variability	IEEE Xplorer	X	X	-	-
Wearable sensor based stress management using integrated respiratory and ECG waveforms	IEEE Xplorer	X	-	X	X
Stress Detection Using Context-Aware Sensor Fusion from Wearable Devices	Research Gate	X	X	-	X
A Novel Method of Stress Detection using Physiological Measurements of Automobile Drivers	Research Gate	X	X	X	-
Requirements and Design of Mental Health System for Stress Management of Knowledge Workers	IEEE Xplorer	X	X	-	X
AffectiveWall: Designing Collective Stress-Related Physiological Data Visualization for Reflection	IEEE Xplorer	X	X	-	-

A Sensitivity Analysis of Biophysiological Responses of Stress for Wearable Sensors in Connected Health	IEEE Xplorer	X	X	X	X
A Review on Mental Stress Detection Using Wearable Sensors and Machine Learning Techniques	IEEE Xplorer	X	X	X	X
A Survey of Machine Learning Techniques in Physiology-Based Mental Stress Detection Systems	Springer	X	X	-	X
Stress Detection Using ECG and EMG Signals: A Comprehensive Study	Science Direct	X	X	X	-

Nota. Se usó “X” para indicar que la variable fue utilizada en el estudio y “-” cuando no se menciona. Esta tabla resume 14 artículos seleccionados que utilizan variables fisiológicas relevantes (HRV, GSR/EDA, RR y temperatura corporal/piel) para la detección de estrés, priorizando su aplicación en contextos laborales.

3.2 Sensores biométricos para la medición del estrés

El monitoreo del estrés en entornos laborales ha cobrado relevancia en la investigación científica y el desarrollo de tecnologías portátiles. La utilización de sensores biométricos y ambientales permite evaluar indicadores fisiológicos y del entorno que afectan el bienestar de los trabajadores.

Para seleccionar los sensores más adecuados para este estudio, es fundamental analizar sus características, precisión y aplicabilidad en entornos de oficina. A continuación, se presenta la Tabla 2 que compara diferentes sensores extraídos de los artículos científicos con información en función del tipo de medición que realizan, así como sus principales ventajas y desventajas. Esto

con la idea de determinar cuáles de ellos son más apropiados para la monitorización del estrés en el contexto laboral.

Tabla 2

Comparación de sensores para la detección del estrés en entornos laborales

Sensor	Variable medida	Ventajas	Desventajas
Zephyr BioHarness	HR, Frec. Respiratoria, Temp. Corporal.	Alta precisión en HR. Monitoreo en tiempo real. Monitoreo multimodal. Transmisión en tiempo real.	Puede llegar a ser algo incomodo. Requiere calibración técnica. Costoso.
Empatica E4	PPG, EDA, Temp. Corporal.	Portátil y cómodo (muñeca). Integra múltiples sensores (PPG, GSR, Temp). Validado en estudios científicos.	Puede verse afectado por el movimiento. Relativamente Costoso. Curva de aprendizaje moderada.
RespiBan	ECG, Frec. Respiratoria	Monitoreo multimodal. portátil y cómodo. Respaldado científicamente.	Costo relativamente alto. autonomía limitada (batería). Curva aprendizaje baja.
Shimmer3 ECG	ECG, Frec. Respiratoria.	Alta precisión en mediciones. Compatible con otros sensores biométricos. Multicanal configurable.	Costo elevado. No permite la medición simultanea de señales. Curva aprendizaje alta.
Shimmer3 GSR+	HR, PPG, Respuesta Galvánica de la Piel (EDA/GSR).	Alta sensibilidad en mediciones. portátil y fácil de usar. Compatibilidad con sensores adicionales.	Incomodidad media. Curva de aprendizaje relativamente alta. Costo elevado.
Xiaomi Mi Band / Fitbit	HRV (PPG), Frecuencia Cardíaca	Económicos y accesibles. Cómodos para uso diario.	Menor precisión en HRV y HR comparado con ECG. No diseñado específicamente para estrés
Oxímetros de Pulso	HRV (PPG), Saturación de Oxígeno (SpO2)	Alta precisión en HRV y SpO2. Fácil de usar	No apto para monitoreo continuo en movimiento

Sensores de CO ₂ (SenseAir, Aeroqual)	Calidad del aire (CO ₂ , VOC)	Detectan contaminantes en tiempo real. Permiten ajustes en la ventilación.	No miden estrés directamente, sino factores ambientales.
Sensores de Ruido (Brüel & Kjær, NoiseMeter)	Nivel de presión sonora (SPL)	Detectan niveles de ruido en el ambiente. Permiten ajustar condiciones laborales.	No miden estrés fisiológico, solo factores externos.
Sensores de Temperatura (Empatica E4, Sensores Infrarrojos)	Temperatura de la piel / ambiente	No invasivos. Permiten identificar estrés crónico.	Pueden ser influenciados por la temperatura ambiental.

Nota. Esta tabla compara sensores utilizados en estudios sobre estrés, detallando su tipo de medición (HR, PPG, EDA, etc.), ventajas, desventajas y nivel de validación científica. Se incluyen sensores fisiológicos y ambientales, evaluados según su portabilidad, precisión, costo y facilidad de integración.

3.3 Plataformas de integración

Los sensores utilizados en el monitoreo biométrico y ambiental generan datos en tiempo real y para que estos sean de utilidad es necesario contar con plataformas que permitan su integración, procesamiento y análisis. De esta manera, la integración de datos provenientes de sensores es fundamental para el análisis y la toma de decisiones. La selección de plataformas capaces de procesar y sintetizar estos datos de manera eficiente permite mejorar la interpretación de la información recopilada, facilitando su utilización en sistemas de modelado, simulación y toma de decisiones. Para determinar la idoneidad de cada plataforma se definieron algunos criterios.

Capacidad de procesamiento: Evaluar la eficiencia y velocidad en el manejo de grandes volúmenes de datos provenientes de sensores biométricos y ambientales.

Capacidad de síntesis y visualización: Habilidad para transformar datos en información comprensible mediante reportes, gráficos y análisis avanzados.

Compatibilidad con datos biométricos y ambientales: Capacidad de integrar diferentes tipos de sensores utilizados en el monitoreo.

Integración con entornos de simulación: Posibilidad de interactuar con modelos computacionales para evaluar y predecir condiciones en el entorno de estudio.

A continuación, en el Apéndice B, se presenta una tabla que recopila y compara seis plataformas de integración de datos utilizadas en el monitoreo biométrico y ambiental. Node-RED, ThingSpeak, AWS IoT, Google Cloud IoT, IBM Watson IoT y Python. Esta tabla incluye información clave sobre la arquitectura, los lenguajes soportados, los protocolos compatibles, la escalabilidad, la latencia, la capacidad de integración, el costo, la disponibilidad y la curva de aprendizaje de cada plataforma. Además, se destacan sus principales ventajas y desventajas, permitiendo una evaluación detallada de sus características y facilitando la selección de la opción más adecuada según los criterios previamente establecidos.

3.4 Sensores fisiológicos y de entorno

Para asegurar una integración eficiente de los datos no basta solo con una plataforma adecuada, sino también es fundamental contar con sensores que proporcionen mediciones precisas y relevantes para el monitoreo del estrés en entornos laborales. Se definieron algunos criterios para su selección.

Precisión y fiabilidad: exactitud de las mediciones realizadas por cada sensor, verificando si han sido validados en estudios científicos.

Capacidad de integración: Se analizará la compatibilidad de los sensores con plataformas IoT y bases de datos en la nube, considerando protocolos como Bluetooth, Wi-Fi y MQTT.

Facilidad de uso y portabilidad: Se revisará si el sensor es cómodo para el usuario y si puede implementarse en una oficina sin ser invasivo.

Consumo energético: Se determinará el tipo de alimentación del sensor y su autonomía para garantizar su funcionamiento eficiente.

Costo y disponibilidad: Se examino si el sensor es asequible y fácil de adquirir en el mercado.

Compatibilidad con el requerimiento del proyecto: mide las variables de estrés relevantes, como la variabilidad de la frecuencia cardíaca (HRV), la respuesta galvánica de la piel (GSR) y la temperatura.

En el Apéndice C se presenta una tabla que detalla sus principales características, parámetros medidos por cada sensor, su precisión, capacidad de integración, facilidad de uso, consumo energético, costo aproximado, disponibilidad y su aplicación dentro del proyecto.

3.5 Dataset WESAD

Este conjunto de datos multimodal presenta datos fisiológicos y de movimiento, registrados desde un dispositivo de muñeca y otro en el pecho, de 15 sujetos durante un estudio de laboratorio. Se incluyen las siguientes modalidades de sensores: volumen sanguíneo, pulso, electrocardiograma, actividad electrodérmica, electromiograma, respiración, temperatura corporal y aceleración de tres ejes (Schmidt, Reiss, Dürichen, Marberger, & Van Laerhoven, 2018).

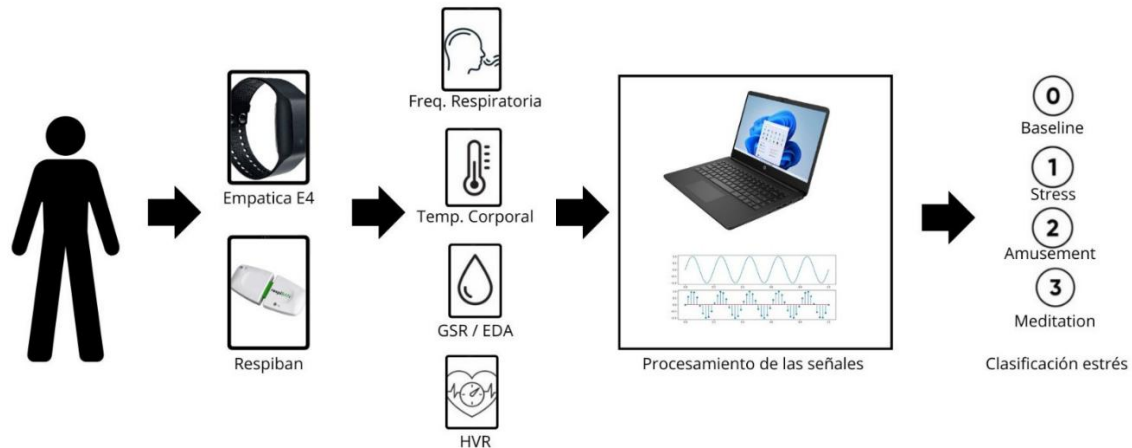
4. Desarrollo de la propuesta de monitorización

Para comprender la estructura del sistema, se presenta la Figura 1 organizando las diferentes etapas del proceso. La captura de datos mediante sensores fisiológicos hasta su procesamiento y análisis a través de una red neuronal. La arquitectura planteada busca integrar

diferentes módulos que permitan evaluar el estado de los empleados en tiempo real y generar información útil para la toma de decisiones orientadas al bienestar laboral.

Figura 1

Arquitectura General del Sistema de Monitorización



Nota. Este diseño busca optimizar la recolección y análisis de información para evaluar el confort y estrés en el entorno laboral.

4.1 Descripción general de la propuesta

Con base en los estudios realizados en este proyecto, se plantea la propuesta de investigar y monitorizar los factores que influyen en el estrés laboral mediante el uso de sensores fisiológicos y una plataforma de integración basada en una red neuronal. La implementación de sensores fisiológicos que permitan la medición de indicadores clave del estrés, tales como la variabilidad de la frecuencia cardíaca (HRV), la respuesta galvánica de la piel (GSR/EDA), la temperatura corporal (TEMP) y la frecuencia respiratoria (RR). Estos sensores proporcionarán datos en tiempo real que serán procesados y analizados a través de una plataforma de integración con capacidades de aprendizaje profundo (Deep learning), facilitando así la detección de patrones asociados al estrés en entornos laborales.

La propuesta busca proporcionar una herramienta que permita detectar si los empleados se encuentran estresados, ofreciendo una solución tecnológica basada en la adquisición, procesamiento y análisis de datos fisiológicos para generar información útil en la toma de decisiones orientadas a la mejora del entorno laboral.

4.2 Metodología para la identificación de variables fisiológicas

Para lograr identificar las variables fisiológicas que dentro del cuerpo humano son afectadas por la exposición frecuente al estrés laboral se realizaron una serie de consultas e investigaciones en donde se tuvieron en cuenta bases de datos que permitieron establecer los lineamientos y los procesos que se deben tener en cuenta al momento de mencionarlas, en este caso la metodología utilizada fue: revisión literaria y precisa de los artículos publicados en los últimos años sobre la exposición al estrés en el entorno laboral, consulta e investigación de sensores fisiológicos, selección de las variables fisiológicas más mencionadas (HRV, GSR/EDA, TEMP, RR) y estudiadas en la revisión literaria utilizada (véase en el apéndice A), estableciendo también equipos electrónicos que se pueden utilizar para monitorizar la medición del estrés en el entorno laboral.

4.3 Metodología para la búsqueda de información de bases de datos estandarizadas

Luego de establecer la idea de investigación se llevaron a cabo ciertos procesos de selección con el objetivo de identificar la plataforma de integración de datos más adecuada para el monitoreo del estrés en entornos laborales. Este proceso incluyó la evaluación de múltiples opciones tecnológicas en función de criterios como compatibilidad con sensores biométricos, escalabilidad, facilidad de integración, latencia, costo y disponibilidad, véase en el Apéndice B. A partir de este análisis, se identificaron las plataformas más viables, permitiendo una selección fundamentada en las necesidades específicas del proyecto.

4.4 Metodología para la búsqueda de instrumentos de medición

La metodología para la búsqueda de instrumentos de medición y registro se basó en una exhaustiva revisión bibliográfica y análisis de fuentes científicas y comerciales. Se recopilaron artículos científicos y estudios especializados que evaluaban diversas tecnologías de sensores, considerando criterios como la precisión, fiabilidad, capacidad de integración, facilidad de uso, consumo energético y costo. Este proceso permitió identificar y comparar las especificaciones técnicas de distintos dispositivos, lo que facilitó la selección de aquellos sensores que mejor se adaptan a los requisitos del sistema propuesto para el monitoreo del estrés y confort en entornos laborales.

4.5 Metodología para la búsqueda de plataformas de integración

La selección de la plataforma de integración de datos se realizó un análisis basado en criterios como especificaciones técnicas, capacidad de procesamiento, precisión en el análisis, integración con el sistema, costo y disponibilidad. Se evaluaron plataformas como Node-RED, ThingSpeak, AWS IoT, Google Cloud IoT, IBM Watson IoT y Python, comparando su rendimiento y compatibilidad con el sistema propuesto (véase Apéndice C).

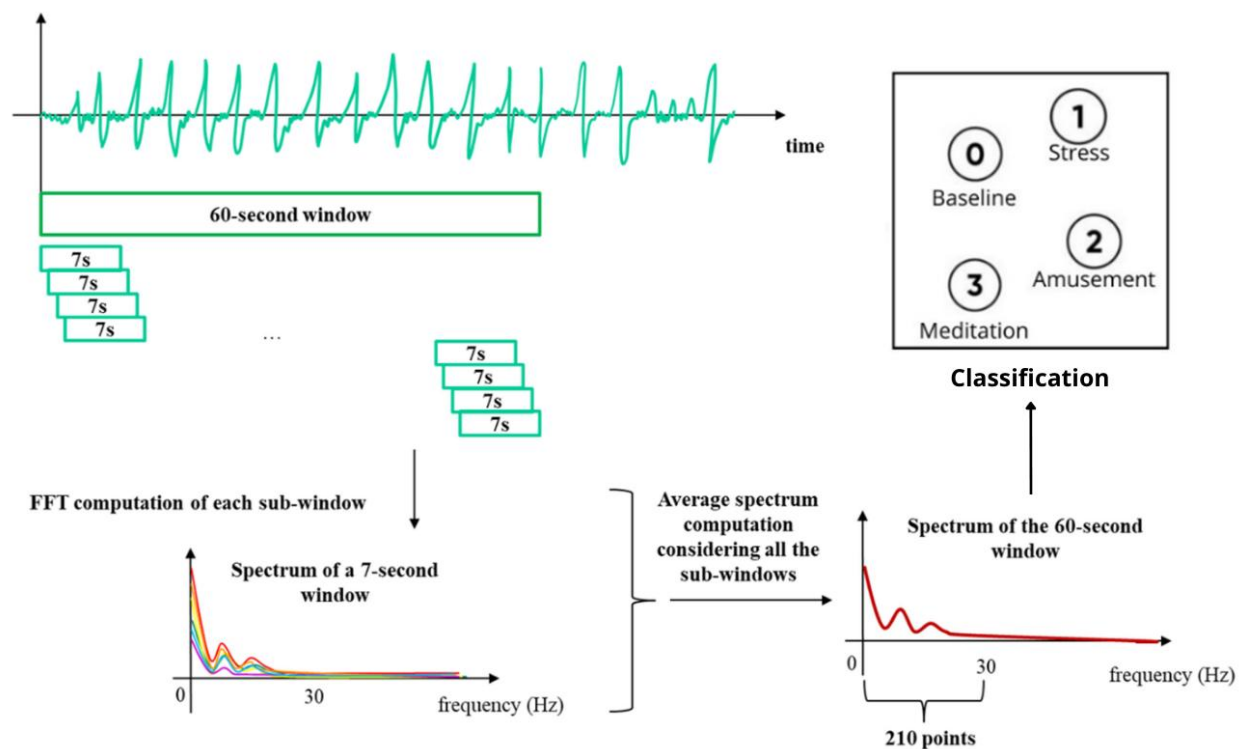
4.6 Posible estrategia de monitorización del estrés

Al revisar la investigación de Gil Martin, San Segundo, Mateos, & Ferreiros López (2022), se adopta una estrategia de procesamiento de señales basada en ventanas deslizantes de 60 segundos con un desplazamiento de 0.25 segundos. A diferencia de enfoques tradicionales que dependen de características diseñadas manualmente, esta propuesta trabaja directamente con el espectro de Fourier, promediado subdividiendo cada ventana para alimentar una red neuronal convolucional (CNN). Todas las señales fueron normalizadas para generar una entrada uniforme de 210 puntos espectrales por canal, ajustando el tamaño de cada ventana subdividida de acuerdo

con la naturaleza de cada señal. A continuación, se presenta la estructura de la red neuronal convolucional utilizada Figura 2, y la Tabla 3 detallando las componentes que incluye capas de convolución, max-pooling y capas densas para el procesamiento de señales, con el objetivo de realizar tareas de clasificación.

Figura 2

Proceso de Análisis de Señales



Nota. Proceso de análisis de señales de la base de datos WESAD. Adaptado de Human Stress Detection With Wearable Sensors Using Convolutional Neural Networks, por A. Gil-Martín, A. San-Segundo, S. Madrazo, y F. Fernández, 2022, IEEE Access. <https://doi.org/10.1109/ACCESS.2022.3183755>. Copyright 2022 por IEEE.

Tabla 3*Arquitectura de la red neuronal convolucional*

Capa	Tipo de operación	Tamaño del kernel	Número de filtros	Dimensión de salida (Forma)	Comentario
Input	Entrada	-	-	$N \times M$	N: número de señales, M: puntos espectrales
Layer 1	Convolución 1D	1×3	64	$N \times M \times 64$	Aprendizaje de patrones locales
Layer 2	Convolución 1D	1×3	64	$N \times M \times 64$	Segunda capa convolucional
Layer 3	MaxPooling 1D	1×2	-	$N \times M/2 \times 64$	Reducción de dimensionalidad
Layer 4	Convolución 1D	1×3	64	$N \times M/2 \times 64$	Extracción más profunda
Layer 5	MaxPooling 1D	1×2	-	$N \times M/4 \times 64$	Más compactación espacial
Dense 1	Capa totalmente conectada	-	128	128	Primera capa densa
Dense 2	Capa totalmente conectada	-	64	64	Segunda capa densa
Salida	Clasificación (Softmax)	-	P	P	P: número de clases

Nota. Se presentan las capas de la red neuronal, el tipo de operación, el tamaño del kernel, el número de filtros y la dimensión de salida, con una breve descripción funcional por etapa.

Las capas convolucionales emplean la función de activación ReLU (Rectified Linear Unit), una función no lineal que permite una propagación eficiente de gradientes y mejora la capacidad de aprendizaje no lineal del modelo. Durante la etapa de clasificación, las capas densas incorporan dropout como técnica de regularización, ayudando a prevenir el sobreajuste. La capa de salida

utiliza una función softmax, adecuada para tareas de clasificación multiclase, permitiendo interpretar las salidas como probabilidades normalizadas para cada clase. Esta arquitectura, aunque profunda, está diseñada de forma eficiente para procesar entradas espectrales multicanal, como las derivadas de señales fisiológicas (ECG, EDA, BVP, etc.), logrando un buen balance entre precisión y complejidad computacional.

Tras entrenar la red neuronal con entradas espectrales multicanal, se procedió a evaluar su precisión mediante una matriz de confusión. La Tabla 4 muestra los resultados obtenidos, donde se puede observar un alto nivel de precisión en las clases *Baseline* y *Stress*, y un rendimiento razonablemente bueno en las clases *Amusement* y *Meditation*.

Tabla 4

Matriz de confusión de la clasificación de estados afectivos


Clase Real / Predicha	Clase 1 (Baseline)	Clase 2 (Stress)	Clase 3 (Amusement)	Clase 4 (Meditation)	Total (%)
Clase 1 (Baseline)	100,00%	0,00%	0,00%	0,00%	100,00%
Clase 2 (Stress)	0,00%	100,00%	0,00%	0,00%	100,00%
Clase 3 (Amusement)	0,00%	1,72%	93,79%	4,48%	100,00%
Clase 4 (Meditation)	5,85%	2,28%	0,00%	91,87%	100,00%

Nota. La matriz de confusión muestra la comparación entre las clases reales y las predicciones del modelo de clasificación. Los valores en la diagonal principal representan los casos correctamente clasificados, mientras que los valores fuera de la diagonal reflejan errores de clasificación.

Una vez entrenado y validado el modelo de detección de estrés, se procedió a su implementación en una plataforma de integración desarrollada en Python, ver Figura 3. Esta plataforma está diseñada para recibir datos en tiempo real desde sensores fisiológicos y, de manera automática, realizar predicciones minuto a minuto utilizando el modelo previamente entrenado. En cada intervalo, el sistema calcula el promedio de las predicciones realizadas y presenta el porcentaje correspondiente a cada uno de los estados identificados por el modelo (baseline, estrés, diversión y meditación). Para esta prueba de concepto, se utilizó el 20 % del conjunto de datos original (segmento de testeo) con el fin de simular el flujo de entrada proveniente de los sensores en condiciones reales. Esta simulación permitió validar el funcionamiento del sistema de extremo a extremo, desde la recepción de señales hasta la visualización de los resultados.

Figura 3

Dashboard de Monitoreo en Tiempo Real



Nota. La figura muestra un dashboard de monitorización en tiempo real con valores fisiológicos promedio y la distribución de estados emocionales detectados en el último minuto. La gráfica circular representa la proporción de cada estado (Estado 0, Estado 1, Estado 2 y Estado 3), lo que permite visualizar la distribución del estado afectivo predominante en el periodo analizado.

4.7 Caso de estudio

En la literatura científica, se ha demostrado que las métricas fisiológicas son más confiables para la detección del estrés que las variables conductuales, como expresiones faciales y posturas corporales. Se respalda el uso de variables fisiológicas como indicadores fiables del estrés, y diversos estudios han utilizado estos bioindicadores para construir modelos predictivos con alta precisión que han sido efectivos en la clasificación del estrés (Mortensen, Mollov, Chatterjee, Ghose, & Li, 2023). Las investigaciones han establecido que el estrés genera un cambio fisiológico inmediato que puede ser cuantificado mediante sensores sin la influencia de interpretaciones subjetivas.

Las respuestas fisiológicas, como la HRV, GSR y temperatura corporal, están vinculadas directamente al sistema nervioso autónomo (SNA) y son más confiables como indicadores del estrés debido a su naturaleza automática e involuntaria. Dichas respuestas no dependen de la percepción consciente del individuo, lo que reduce el riesgo de sesgos o respuestas sociales. En cambio, las variables conductuales, como las expresiones faciales o posturas, son mucho más difíciles de interpretar de manera objetiva y pueden estar más influenciadas por factores externos, como el contexto social y las diferencias culturales (Bobade & Vani, 2020). Debido a su fiabilidad y menor susceptibilidad a influencias externas es una ventaja significativa para aplicaciones de monitoreo de la salud y el bienestar.

Para aplicaciones de monitoreo continuo del estrés en entornos laborales o clínicos, el uso de sensores fisiológicos portátiles se presenta como la opción más viable y efectiva. Sensores como los empleados en el data set WESAD permiten una captura de datos en tiempo real sin interferir con las actividades diarias del usuario. Esto fundamental en entornos donde la no interrupción de las actividades es crucial para obtener mediciones precisas del estrés sin alterar el comportamiento


del individuo (Benita, Ebenezer, Susmitha, Subathra, & Priya, 2024). En estos estudios, especialmente aquellos que emplean redes neuronales convolucionales (CNN), se ha logrado una precisión superior al 96.6% en tareas de clasificación, como la diferenciación entre estrés y no estrés. Este rendimiento destaca la capacidad del data set para entrenar modelos predictivos robustos que pueden generalizar bien, incluso con nuevos datos no vistos durante el entrenamiento (Gil Martin, San Segundo, Mateos, & Ferreiros Lopez, 2022).

4.7.1 Análisis de datos del WESAD con Python

Este análisis se realizó exclusivamente con los datos del Sujeto dos (S2) del data set WESAD, aunque el conjunto de datos contiene información de varios sujetos, las pruebas y exploraciones están basadas únicamente en los registros de este individuo. Por lo tanto, las frecuencias de las etiquetas reflejan su distribución específica y no representan la totalidad del data set, la Figura 4 muestra la representación del flujo para el sujeto dos.

Figura 4

Representación del Flujo de Procesamiento de Señales



Nota. El diagrama representa el flujo para procesar los datos del sujeto dos del data set WESAD.

Según los resultados obtenidos en el procesamiento de la red neuronal y las etiquetas identificadas, la distribución del tiempo del sujeto dos se ve plasmado en la Tabla 5.

Tabla 5*Clasificación porcentual de estados afectivos para el sujeto dos*

Etiqueta	Estado	Porcentaje de tiempo	Descripción
0	No relevante para el análisis	50.35%	No considerada en el análisis según el README del data set. Puede representar un estado neutral o no significativo.
1	Estrés agudo	18.82%	Indica que el sujeto estuvo en una situación de estrés intenso.
2	Relajación	10.12%	Indica que el sujeto experimentó estrés, pero en un nivel menos intenso que en la etiqueta 1.
3	Diversión o estado positivo	5.95%	Representa un estado tranquilo o sin estrés
4	Estrés moderado	12.63%	Indica que el sujeto experimentó emociones positivas y bienestar.

Nota. Según el análisis del sujeto dos, el mayor tiempo fue clasificado como estrés agudo (Etiqueta 1), seguido de estrés moderado (Etiqueta 4). Los estados de relajación (2) y diversión (3) se presentaron en menor medida. La etiqueta 0 representa un estado neutro o no relevante, según el README del conjunto de datos.

5. Resultados

5.1 Decisiones tomadas

Tras analizar diversas opciones de sensores en la literatura científica, se identificó que el data set WESAD, utilizado como referencia en este estudio, empleó los dispositivos Empatica E4 y Respiban para la adquisición de señales fisiológicas. No obstante, otros sensores como Shimmer 3 ECG, Shimmer 3 GSR y Zephyr BioHarness han sido ampliamente utilizados en estudios previos, demostrando su eficacia en la medición de variables relacionadas con el estrés. Dado que

WESAD es la base de datos seleccionada para este proyecto, se prioriza el uso de Empatica E4 y Respiban, garantizando coherencia en la integración y análisis de datos, sin descartar la relevancia de los demás dispositivos en la literatura científica.

Posteriormente la selección de plataforma de integración fue Python, considerando su idoneidad para procesar y sintetizar los datos obtenidos del data set WESAD, también un factor clave se debe a que Python es una plataforma de código abierto contando con una comunidad que contribuye a su desarrollo y mejora, lo que hace que sea una plataforma robusta y dinámica, sin mencionar que no tiene costo lo que la hace accesible a todo público.

5.2 Resultados del caso de estudio

Este análisis se centró en una única transición para verificar que el código funcionara correctamente y que los cambios de estado se representaran de manera adecuada. De esta forma es posible observar cómo varían los estados del sujeto y en qué momentos exactos se producen los cambios, lo que resulta fundamental para la identificación de patrones y tendencias en los datos.

El conjunto de datos WESAD documenta un experimento diseñado para evaluar el estrés y otros estados emocionales a través de sensores fisiológicos. La duración total del experimento para cada sujeto es de aproximadamente 2 horas, aunque no todo este tiempo está etiquetado con estados específicos.

Para conocer el número de veces que un sujeto cambio de estado se debe contar los intervalos en los que permaneció en cada estado y restar uno, esto porque cada transición entre estados se considera un cambio. Basado en la cantidad de intervalos reportados, casi todos los sujetos tuvieron un total de dieciséis cambios de estado a lo largo del experimento, excepto el sujeto dos (S2) y el sujeto nueve (S9), quienes registraron trece y catorce cambios respectivamente.

Los cambios de estado reflejan lo que experimentan los sujetos durante el experimento, pero no todos los participantes mostraron la misma frecuencia de transiciones. Esto puede explicarse por diversos factores relacionados con la estabilidad emocional, el entorno y características individuales. La ausencia de cambios en cada estado de un sujeto puede estar relacionada con aspectos como su estabilidad emocional, ya sea en relajación o estrés prolongado. También influyen las condiciones del entorno y el diseño del experimento, ya que un ambiente estable o estímulos poco variados podrían reducir las transiciones entre estados. Además, las características de cada sujeto, como la personalidad, predisposición biológica o experiencias previas, pueden jugar un papel importante en la forma en que reaccionan ante los estímulos.

Por último, La deducción de un posible error en los datos se basa en la duración inusualmente larga de un estado sin cambios y en el contexto del experimento. Si el sujeto permanece en el estado 0 durante un tiempo prolongado, especialmente al inicio del registro, existen dos posibilidades: o bien el sujeto realmente se mantuvo estable sin alteraciones, o bien hubo un problema en la recolección de datos que impidió capturar los cambios correctamente.

Para identificar si se trata de un error, se pueden considerar varios aspectos. Primero, si todos los sujetos presentan un patrón similar en el inicio (permanecer en el estado 0 durante los primeros intervalos), podría indicar un retraso en la activación del sistema de medición o un error en la sincronización. Además, si la transición entre estados ocurre de manera abrupta después de este periodo largo sin cambios, es posible que los datos no hayan sido registrados correctamente en ese intervalo.

6. Conclusiones

El análisis de la literatura científica permitió identificar las variables fisiológicas más relevantes para la monitorización del estrés en entornos laborales. La variabilidad de la frecuencia

cardíaca (HRV), la respuesta galvánica de la piel (GSR/EDA), la temperatura corporal (TEMP) y la frecuencia respiratoria (RR) fueron seleccionadas debido a su alta recurrencia en estudios previos y su validación como indicadores clave de la respuesta fisiológica al estrés. En consecuencia, la selección de estas variables responde a un enfoque basado en evidencia científica y en la necesidad de herramientas eficientes para la gestión del estrés ocupacional. Su uso en sistemas de medición puede contribuir a la optimización de entornos de trabajo, favoreciendo la salud mental de los empleados y mejorando el desempeño organizacional.

La exploración de tecnologías de sensores biométricos y de entorno permitió identificar dispositivos adecuados para el monitoreo del estrés en oficinas. Los sensores de CO₂, ruido ambiental, iluminación y temperatura contribuyen a la mejora del ambiente laboral, mientras que los sensores fisiológicos como HRV, GSR/EDA, temperatura corporal y RR permiten evaluar la respuesta del organismo al estrés. La integración de estos dispositivos en plataformas IoT posibilita el análisis en tiempo real y la detección temprana de factores estresantes, favoreciendo estrategias de intervención efectivas.

La investigación de plataformas de integración de datos y sensores biométricos y ambientales permitió comprender cuáles tecnologías ofrecen mayor precisión y adaptabilidad en la monitorización del estrés laboral. Se analizaron diferentes opciones en función de su capacidad para procesar y sintetizar datos relevantes, identificando sus fortalezas y limitaciones. Esta exploración fue fundamental para determinar las herramientas más adecuadas para un sistema de monitoreo efectivo, asegurando que la selección final responda a las necesidades del estudio.

La propuesta no solo permite la identificación temprana de patrones de estrés, sino que también brinda la posibilidad de generar recomendaciones personalizadas y estrategias de mitigación, lo que representa un avance significativo en la aplicación de tecnologías de

monitorización para la optimización del bienestar organizacional. La capacidad del sistema para adaptarse a distintas condiciones laborales y su potencial de escalabilidad lo convierten en una herramienta de gran valor en la transformación digital del entorno laboral.

Las redes neuronales demostraron una alta precisión al identificar patrones complejos en señales fisiológicas, fortaleciendo el sistema propuesto especialmente en escenarios con alta variabilidad individual.

7. Recomendaciones

Después de realizar la respectiva investigación del caso de estudio, se puede afirmar que la herramienta WESAD se recomienda como una base de datos confiable para llevar a cabo el análisis sobre el estrés. Su accesibilidad y validación en diversos estudios científicos la destacan como una fuente de datos fiable. Además, su popularidad en la comunidad científica facilita la replicabilidad de estudios y revisión de modelos.

Para proyectos futuros, se sugiere ampliar el análisis de clasificación utilizando otros modelos de Machine Learning, como Random Forest, Support Vector Machines (SVM) o K-Nearest Neighbors (KNN), con el objetivo de comparar su desempeño frente a la CNN implementada. Esto permitiría identificar alternativas que podrían ser más eficientes, adaptables o precisas en diferentes escenarios de medición de estrés.

Probar el sistema con datos recolectados en oficinas latinoamericanas, ya que las condiciones laborales, culturales y ambientales pueden diferir significativamente de las presentes en datasets europeos como WESAD.

Explorar el uso de sensores ambientales (temperatura ambiental, niveles de ruido) y/o conductuales (cámaras RGB, giroscopios) para enriquecer el análisis de estrés en tiempo real.

Referencias Bibliográficas

- Martínez-Sedas, G. (2024). *El oxímetro de pulso: más información de la que pensamos*. Rev Mex Anesthesiol.
- Al-Atawi, A. A., Alyahyan, S., Alatawi, M. N., Sadad, T., Manzoor, T., Farooq-i-Azam, M., & Khan, Z. H. (2023). *Stress monitoring using machine learning, IoT and wearable sensors*. Sensors.
- Amazon Web Services. (s.f.). *IoT Core – Amazon Web Services (AWS) [Software]*. Obtenido de AWS: <https://aws.amazon.com/es/iot/?nc=sn&loc=0>
- Benita, D. S., Ebenezer, A. S., Susmitha, L., Subathra, M. S., & Priya, S. J. (2024). *Stress Detection Using CNN on the WESAD Dataset*. IEEE.
- Biometric Systems Lab. (2020). *E4 user manual (Rev. 2.0)*. Obtenido de E4 user manual (Rev. 2.0): <https://www.utwente.nl/en/bmslab/infocenter/um-16-e4-usermanual-rev.2.0-20201020.pdf>
- Bobade, P., & Vani, M. (2020). Stress detection with machine learning and deep learning using multimodal physiological data. In *2020 Second International Conference on Inventive Research in Computing Applications (ICIRCA)*. IEEE.
- Chen, K., Fink, W., Roveda, J., Lane, R. D., Allen, J., & Vanuk, J. (2015). Wearable sensor based stress management using integrated respiratory and ECG waveforms. *2015 IEEE 12th International Conference on Wearable and Implantable Body Sensor Networks (BSN)* (págs. 1–6). Cambridge: IEEE.
- Choi, J., Ahmed, B., & Gutierrez-Osuna, R. (2012). *Development and Evaluation of an Ambulatory Stress Monitor Based on Wearable Sensors*. IEEE Transactions on Information Technology in Biomedicine .

- Cohen, L. B., Delege, M. H., Aisenberg, J., Brill, J. V., Inadomi, J. M., Kochman, M. L., & Piorkowski, J. D. (2007). *AGA Institute Review of Endoscopic Sedation*. Gastroenterology.
- Furia, L., Tortora, M., Soda, P., & Sicilia, R. (2023). Exploring early stress detection from multimodal time series with deep reinforcement learning. *2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)* (págs. 1917–1920). Istanbul: IEEE.
- Gedam, S., & Paul, S. (2021). *A Review on Mental Stress Detection Using Wearable Sensors and Machine Learning Techniques*. IEEE Access.
- Gil Martin, M., San Segundo, R., Mateos, A., & Ferreiros Lopez, J. (2022). *Human stress detection with wearable sensors using convolutional neural networks*. IEEE.
- Google Cloud. (s.f.). *Cloud IoT Solutions [Software]*. Obtenido de Google Cloud: <https://cloud.google.com/python/docs/reference/cloudiot/latest>
- IBM Watson. (s.f.). *IBM México [Software]*. Obtenido de IBM Watson IoT: <https://www.ibm.com/mx-es>
- Iqbal, T., Sadat, N., Zubair, M., Ullah, F., Alahi, M. E., Hossain, M. S., & Muhammad, G. (2021). A sensitivity analysis of biophysiological responses of stress for wearable sensors in connected health. *IEEE Access*, 93567–93579.
- Kolcaba, K. (2003). *Comfort theory and practice: a vision for holistic health care and research*. Ottawa: Springer Publishing Company.
- Lebepe, F., Niezen, G., Hancke, G., & Ramotsoela, T. (2016). Wearable stress monitoring system using multiple sensors. *2016 IEEE 14th International Conference on Industrial Informatics (INDIN)* (págs. 895–898). Poitiers, Francia: IEEE.

- MathWorks. (s.f.). *ThingSpeak – MATLAB & Simulink solutions [Software]*. Obtenido de MathWorks: <https://thingspeak.mathworks.com/>
- Mayya, S., Jilla, V., Tiwari, V. N., Nayak, M. M., & Narayanan, R. (2015). Continuous monitoring of stress on smartphone using heart rate variability. *2015 IEEE 15th International Conference on Bioinformatics and Bioengineering (BIBE)* (págs. 1–5). Belgrade: IEEE.
- Mortensen, J. A., Mollov, M. E., Chatterjee, Ghose, D., & Li, F. Y. (2023). *Multi-class stress detection through heart rate variability: A deep neural network based study*. IEEE Access.
- Node-RED. (s.f.). *Node-RED: Flow-based programming for the Internet of Things [Software]*. Obtenido de Node-RED: <https://nodered.org>
- Orlandini, A. (1999). *El estrés Que es y cómo superarlo*. México: La ciencia para todos. 2da. Edición.
- Panicker, S., & Gayathri, P. (2019). A survey of machine learning techniques in physiology based mental stress detection systems. *Biocybernetics and Biomedical Engineering*.
- Park, K., Jung Kim, M., Kim, J., Cheon Kwon, O., Yoon, D., & Kim, H. (2020). *Requirements and Design of Mental Health System for Stress Management of Knowledge Workers*. Jeju, Korea (South): IEEE.
- Pourmohammadi, S., & Maleki, A. (2020). Stress detection using ECG and EMG signals: A comprehensive study. *Computer Methods and Programs in Biomedicine*, 105482.
- Python Software Foundation. (s.f.). *Python [Software]*. Obtenido de Python Software Foundation: <https://www.python.org/>
- Queyam, A. B. (2013). *A novel method of stress detection using physiological measurements of automobile drivers*. Patiala: Thapar University.

- Rashid, N., Mortlock, T., & Faruque, M. A. (2023). Stress detection using context-aware sensor fusion from wearable devices. *IEEE Internet of Things Journal*, 14114–14127.
- Rodriguez Carvajal, R., & De Rivas Hermsilla, S. (2011). *LOS PROCESOS DE ESTRES LABORAL Y DESGASTE PROFESIONAL (BURNOUT), DIFERENCIACIÓN , ACTUALIZACIÓN Y LÍNEAS DE INTERVENCIÓN*. MADRID: Med. segur. trab. vol.57.
- Rowe, D., Sibert, J., & Irwin, D. (1998). *Heart rate variability: Indicator of user state as an aid to human-computer interaction*. Proceedings of the Conference on Human Factors in Computing Systems.
- Satish, U., Mendell, M. J., Shekhar, K. N., Hotchi, T., Utsumi, A., Tanabe, S., . . . Haveman, H. A. (2012). *Is CO₂ an indoor pollutant? Direct effects of low-to-moderate CO₂ concentrations on human decision-making performance*. Environmental health perspectives.
- Schmidt, P., Reiss, A., Dürichen, R., Marberger, C., & Van Laerhoven, K. (2018). *Introducing WESAD, a Multimodal Dataset for Wearable Stress and Affect Detection*. In Proceedings of the 20th ACM international conference on multimodal interaction.
- Selye, H. (1936). *A syndrome produced by diverse nocuous agents*. Nature.
- Selye, H. (1956). *The stress of life*. McGraw-Hill.
- Shimmer Sensing. (s.f.). *GSR User Guide (Rev. 1.13)*. Obtenido de Shimmer Sensing: https://shimmersensing.com/wp-content/docs/support/documentation/GSR_User_Guide_rev1.13.pdf
- Shimmer Sensing. (s.f.). *Shimmer3 ECG Unit*. Obtenido de Shimmer Sensing: <https://www.shimmersensing.com/product/shimmer3-ecg-unit-2/>

- Taskasaplidis, G., Fotiadis, D., & Bamidis, P. (2024). *Review of Stress Detection Methods Using Wearable Sensors*. IEEE Access.
- Tripathi, R. P., & Mishra, G. R. (2017). *Design and implementation of a real time stress monitoring system with the help of ECG using Matlab tool*. Jaipur, India: IEEE.
- Xue, M., Liang, R.-H., Yu, B., Funk, M., Hu, J., & Feijs, L. (2019). AffectiveWall: Designing collective stress-related physiological data visualization for reflection. *IEEE Access*, 131289–131303.
- Zephyr Technology. (s.f.). *OmniSense Software*. Obtenido de Zephyr Anywhere: <https://www.zephyranywhere.com/resources/omnisense-software>