

Identificación de Episodios de Estrés con Señales EEG y EDA Mediante Modelos de *Machine Learning*

YEFRI STIVEN BARRERO SOLANO

Universidad Santo Tomás
Facultad de Ingeniería Electrónica
Bogotá, Colombia
2025



Identificación de Episodios de Estrés con Señales EEG y EDA Mediante Modelos de *Machine Learning*

YEFRI STIVEN BARRERO SOLANO

Proyecto de grado presentado como requisito para optar al título de:

Ingeniero Electrónico

Director:

David Alejandro Martínez Vásquez PhD

Codirectores:

Billy Vladimir Toro Tovar PhD

Armando Mateus Rojas Msc

Grupo de Investigación GED
Línea de Investigación: *Machine Learning*
Universidad Santo Tomás
Facultad de Ingeniería Electrónica
Bogotá, Colombia
2025

Autoridades de la universidad

RECTOR GENERAL

FRAY. ALVARO JOSÉ ARANGO RESTREPO, O.P.

VICERRECTOR ADMINISTRATIVO Y FINANCIERO GENERAL

FRAY, HENDER ALVEIRO RODRÍGUEZ PÉREZ, O.P.

VICERRECTOR ACADÉMICO GENERAL

FRAY, MAURICIO ANTONIO CORTÉS GALLEGO, O.P.

SECRETARIA GENERAL

LINA MARCELA CAMARGO MARTÍNEZ

DECANO DIVISIÓN DE INGENIERÍAS

FRAY JAVIER ANTONIO HINCAPIÉ ARDILA, O.P.

SECRETARIA DE DIVISIÓN

LUZ PATRICIA ROCHA CAICEDO

DECANO FACULTAD DE INGENIERÍA ELECTRÓNICA

LEONARDO FABIO YEPES ARBELÁEZ

Nota de aceptación

Firma del tutor

Firma del jurado

Firma del jurado

BOGOTÁ D.C. _____ DE 2025

ADVERTENCIA

La Universidad Santo Tomás no se hace responsable de las opiniones y conceptos expresados en el trabajo de grado, solo velará por qué no se publique nada contrario al dogma ni a la moral católica y porque el trabajo no tenga ataques personales y únicamente se vea el anhelo de buscar la verdad científica.

Capítulo III –Art. 46 del Reglamento de la Universidad Santo Tomás.

Contenido

Resumen	VIII
Abstract.....	IX
Lista de Figuras.....	X
Lista de Tablas	XI
Glosario.....	XII
1. Introducción	1
1.1. Planteamiento del Problema	1
1.2. Objetivos	2
1.2.1. Objetivo General	2
1.2.2. Objetivos Específicos.....	3
1.3. Justificación.....	3
1.4. Impacto Social.....	5
2. Estado del Arte	6
2.1. Reconocimiento de emociones a través de señales fisiológicas	6
2.2. Señales EDA y EEG.....	7
2.3. Modelos de machine learning en la detección de estados emocionales	8
3. Marco Teórico.....	9
3.1. Estrés como respuesta fisiológica	9
3.1.1. Definición y Mecanismos Neurobiológicos.....	9
3.1.2. Impacto de la carga Alostática en la Salud	9
3.1.3. Respuestas del estrés: Reactividad y Recuperación	10
3.2. Señales Fisiológicas.....	10
3.2.1. Actividad Electroencefalográfica (EEG)	11
3.2.2. Actividad Electrodérmica (EDA).....	11
3.3. Modelos de Machine Learning	13
3.3.1. Paradigmas de Aprendizaje y Preparación de Datos.....	13
3.3.2. Algoritmos de Clasificación	14
3.3.3. Métricas de Evaluación de Rendimiento	15
4. Diseño Metodológico.....	17
4.1. Fases y Metodología	17
4.1.1. Fase 1: Preprocesamiento de los datasets	17
4.1.2. Fase 2: Creación de los modelos de machine learning	17

4.1.3.	Fase 3: Validación de los modelos de machine learning	17
4.2.	Cronograma	18
5.	Desarrollo Conceptual	20
5.1.	Información de los <i>datasets</i>	20
5.2.	Extracción de Características.....	22
5.3.	Etiquetado y estructura del <i>dataset</i> resultante	26
5.4.	Implementación de los Modelos	27
5.5.	Evaluación de los Modelos.....	29
6.	Resultados y Discusión	31
6.1.	Árbol de Decisión	31
6.1.1.	Tarea 1	31
6.1.2.	Tarea 2	34
6.2.	SVM	37
6.2.1.	Tarea 1	37
6.2.2.	Tarea 2	40
6.3.	KNN.....	43
6.3.1.	Tarea 1	43
6.3.2.	Tarea 2	46
6.4.	Comparativa entre los Modelos y Contraste con la Literatura	49
7.	Conclusiones y Trabajos Futuros	51
8.	Referencias Bibliográficas	53

Resumen

Contexto: El estrés es un estado emocional crítico con impactos significativos en la salud física y cognitiva. Su evaluación tradicional se basa en métodos subjetivos como cuestionarios, que presentan sesgos y falta de precisión temporal. Aunque señales fisiológicas como la electroencefalografía (EEG) y la actividad electrodérmica (EDA) ofrecen mediciones objetivas, su uso individual enfrenta limitaciones técnicas y de variabilidad interindividual. La integración multimodal de estas señales mediante modelos de *machine learning* (ML) surge como una alternativa prometedora para la detección confiable de episodios de estrés.

Método: Este estudio implementó un enfoque multimodal que integró señales de EDA, EEG y electrocardiografía (ECG) de 10 participantes sometidos a tareas cognitivas y privación de sueño. Tras un preprocesamiento que incluyó segmentación temporal y extracción de características (p. ej., componentes fásicos de EDA, potencias espectrales de EEG), se generaron etiquetas binarias (estrés/no estrés) mediante el algoritmo no supervisado *k-means*. Se entrenaron y optimizaron tres modelos de clasificación supervisada (Árbol de Decisión, SVM, KNN) utilizando únicamente características de EDA, evaluando su rendimiento con métricas como precisión, F1-score y AUC-ROC.

Resultados: En la tarea con clases balanceadas, los modelos mostraron un rendimiento aceptable, con AUC-ROC de hasta 0.8119 (KNN). En la tarea con desbalance de clases (85% estrés), se observó una caída en la capacidad discriminativa real (AUC-ROC de 0.4862 para KNN), a pesar de métricas globales engañosamente altas (ej. accuracy del 82.35%). Las características fásicas de la EDA (amplitud media y conteo de SCR) fueron identificadas como las más determinantes.

Conclusiones: Se demostró que las características fásicas de la EDA contienen información suficiente para la identificación de estrés agudo, ofreciendo una base para el desarrollo de sistemas portátiles de bajo costo. La investigación subraya la criticalidad del balance de clases en los datos y la necesidad de utilizar métricas robustas como el AUC-ROC para una evaluación fiable. Este trabajo sienta las bases para futuros desarrollos de sistemas de monitorización de estrés aplicables en entornos clínicos y cotidianos.

Palabras clave: Estrés, Actividad Electrodérmica (EDA), Machine Learning, Clasificación, Señales Fisiológicas, K-means, AUC-ROC.

Abstract

Context: Stress is a critical emotional state with significant impacts on physical health and cognitive performance. Its traditional assessment relies on subjective methods such as questionnaires, which are prone to bias and lack temporal precision. While physiological signals like electroencephalography (EEG) and electrodermal activity (EDA) offer objective measurements, their individual use faces technical limitations and interindividual variability. The multimodal integration of these signals through machine learning (ML) models emerges as a promising alternative for the reliable detection of stress episodes.

Method: This study implemented a multimodal approach integrating EDA, EEG, and electrocardiography (ECG) signals from 10 participants undergoing cognitive tasks and sleep deprivation. After preprocessing, which included temporal segmentation and feature extraction (e.g., EDA phasic components, EEG spectral powers), binary labels (stress/no stress) were generated using the unsupervised *k-means* algorithm. Three supervised classification models (Decision Tree, SVM, KNN) were trained and optimized using only EDA features, with performance evaluated using metrics such as accuracy, F1-score, and AUC-ROC.

Results: In the task with balanced classes, the models showed acceptable performance, with an AUC-ROC of up to 0.8119 (KNN). In the task with class imbalance (85% stress), a drop in real discriminative capacity was observed (AUC-ROC of 0.4862 for KNN), despite deceptively high global metrics (e.g., 82.35% accuracy). Phasic EDA features (mean SCR amplitude and count) were identified as the most determinant.

Conclusions: It was demonstrated that phasic EDA features contain sufficient information for the identification of acute stress, providing a basis for the development of low-cost wearable systems. The research underscores the criticality of class balance in data and the need to use robust metrics such as AUC-ROC for reliable evaluation. This work lays the foundation for future developments of stress monitoring systems applicable in clinical and everyday environments.

Keywords: Stress, Electrodermal Activity (EDA), Machine Learning, Classification, Physiological Signals, K-means, AUC-ROC.

Lista de Figuras

Figura 4.1. Diseño Metodológico	18
Figura 4.2. Cronograma del Proyecto.....	19
Figura 6.1. Curva Validación Árbol de Decisión Tarea 1.....	32
Figura 6.2. Curvas ROC entre Árboles de Decisiones Tarea 1.....	32
Figura 6.3. Matriz de Confusión Árbol de Decisión Tarea 1.	33
Figura 6.4. Árbol de Decisión Tarea 1.	33
Figura 6.5. Curva de Validación Árbol de Decisión Tarea 2.	35
Figura 6.6. Curvas ROC entre Árboles de Decisiones Tarea 2.....	35
Figura 6.7. Matriz de Confusión Árbol de Decisión Tarea 1.	36
Figura 6.8. Árbol de Decisión Tarea 2.	36
Figura 6.9. Curva de Validación Modelo SVM Tarea 1.	38
Figura 6.10. Curvas ROC entre Modelos SVM Tarea 1.....	38
Figura 6.11. Matriz de Confusión Modelo SVM Tarea 1.....	39
Figura 6.12. Regiones de Decisión Modelo SVM Tarea 1.....	39
Figura 6.13. Curva de Validación Modelo SVM Tarea 2.	41
Figura 6.14. Curvas ROC entre Modelos SVM Tarea 2.....	41
Figura 6.15. Matriz de Confusión Modelo SVM Tarea 2.....	42
Figura 6.16. Regiones de Decisión Modelo SVM Tarea 2.....	42
Figura 6.17. Curva de Validación Modelo KNN Tarea 1.	44
Figura 6.18. Curvas ROC entre Modelos KNN Tarea 1.....	44
Figura 6.19. Matriz de Confusión Modelo KNN Tarea 1.....	45
Figura 6.20. Regiones de Decisión Modelo SVM Tarea 1.....	45
Figura 6.21. Curva de Validación Modelo KNN Tarea 2.	47
Figura 6.22. Curvas ROC entre Modelos KNN Tarea 2.....	47
Figura 6.23. Matriz de Confusión Modelo KNN Tarea 2.....	48
Figura 6.24. Regiones de Decisión Modelo SVM Tarea 2.....	48

Lista de Tablas

Tabla 3.1. Información Bandas de Frecuencias señal EEG.	11
Tabla 5.1. Información de los Datasets	22
Tabla 6.1. Rendimiento del Árbol de Decisión en la Tarea 1.	34
Tabla 6.2. Rendimiento del Árbol de Decisión en la Tarea 2.	37
Tabla 6.3. Rendimiento del Modelo SVM en la Tarea 1.	40
Tabla 6.4. Rendimiento del Modelo SVM en la Tarea 2.	43
Tabla 6.5. Rendimiento del Modelo KNN en la Tarea 1.	46
Tabla 6.6. Rendimiento del Modelo KNN en la Tarea 2.	49
Tabla 6.7. Resumen Comparativo entre los Modelos.	49

Glosario

AUC-ROC (Area Under the Curve - Receiver Operating Characteristic): Área Bajo la Curva Característica de Operación del Receptor. Métrica que evalúa la capacidad de discriminación de un modelo de clasificación a través de todos los umbrales de decisión posibles. Un valor cercano a 1.0 indica un excelente desempeño.

CV (Cross-Validation): Validación Cruzada. Técnica de evaluación de modelos en la que el conjunto de datos de entrenamiento se divide en k subconjuntos o *folds*. El modelo se entrena k veces, utilizando cada vez un *fold* diferente para validación y el resto para entrenamiento.

ECG (Electrocardiograma): Señal fisiológica que registra la actividad eléctrica del corazón. Se utiliza para analizar la variabilidad de la frecuencia cardíaca (HRV), un marcador de la actividad del sistema nervioso autónomo.

EDA (Electrodermal Activity): Actividad Electrodérmica. Medida de las variaciones en las propiedades eléctricas de la piel, influenciada por la actividad de las glándulas sudoríparas y considerada un indicador directo de la activación del sistema nervioso simpático.

EEG (Electroencephalography): Electroencefalografía. Técnica no invasiva que mide la actividad eléctrica del cerebro mediante electrodos colocados en el cuero cabelludo.

FN (False Negative): Falso Negativo. En una matriz de confusión, representa los casos positivos que el modelo incorrectamente clasifica como negativos.

FP (False Positive): Falso Positivo. En una matriz de confusión, representa los casos negativos que el modelo incorrectamente clasifica como positivos.

GridSearchCV: Técnica de optimización de hiperparámetros que prueba sistemáticamente todas las combinaciones de una grilla predefinida, evaluando cada una mediante validación cruzada para encontrar la configuración óptima de un modelo.

GSR (Galvanic Skin Response): Respuesta Galvánica de la Piel. Término histórico y sinónimo de Actividad Electrodérmica (EDA).

HRV (Heart Rate Variability): Variabilidad de la Frecuencia Cardíaca. Medida de la variación en el tiempo entre latidos cardíacos consecutivos. Es un indicador clave del equilibrio entre los sistemas nerviosos simpático y parasimpático.

ICA (Independent Component Analysis): Análisis de Componentes Independientes. Técnica computacional de procesamiento de señales utilizada para

separar fuentes multivariadas en componentes estadísticamente independientes. Comúnmente empleada para remover artefactos (ej., movimientos oculares) de señales de EEG.

KNN (K-Nearest Neighbors): K-Vecinos más Cercanos. Algoritmo de aprendizaje automático que clasifica un punto de datos basándose en la clase mayoritaria de sus k puntos de datos más cercanos en el espacio de características.

ML (Machine Learning): Aprendizaje Automático. Campo de la inteligencia artificial que se centra en el desarrollo de algoritmos que pueden aprender patrones a partir de datos.

Overfitting (Sobreajuste): Situación en la que un modelo de aprendizaje automático se ajusta demasiado a los datos de entrenamiento, incluyendo su ruido y fluctuaciones aleatorias, lo que perjudica su capacidad para generalizar a datos nuevos.

PCA (Principal Component Analysis): Análisis de Componentes Principales. Técnica de reducción de dimensionalidad que transforma las características originales en un nuevo conjunto de variables no correlacionadas, llamadas componentes principales.

SCR (Skin Conductance Response): Respuesta de Conductancia de la Piel. Componente fáxico de la señal EDA; representa una fluctuación rápida y discreta asociada a una respuesta específica del sistema nervioso simpático a un estímulo.

SCL (Skin Conductance Level): Nivel de Conductancia de la Piel. Componente tónico de la señal EDA; representa el nivel basal o de fondo de la conductancia cutánea.

SNA (Sistema Nervioso Autónomo): Parte del sistema nervioso periférico que controla las funciones involuntarias de los órganos y glándulas. Se divide en simpático (activación, "lucha o huida") y parasimpático (relajación, "descanso y digestión").

SVM (Support Vector Machine): Máquinas de Vectores de Soporte. Algoritmo de aprendizaje supervisado que encuentra un hiperplano óptimo para separar clases de datos en un espacio de características.

TN (True Negative): Verdadero Negativo. En una matriz de confusión, representa los casos negativos que el modelo correctamente clasifica como negativos.

TP (True Positive): Verdadero Positivo. En una matriz de confusión, representa los casos positivos que el modelo correctamente clasifica como positivos.

cvxEDA: Algoritmo específico para la descomposición de la señal EDA en sus componentes tónico (SCL) y fáxico (SCR), basado en optimización convexa. Es ampliamente citado en la literatura por su robustez.

Arousal (Activación): En el contexto de la psicología y la computación afectiva, se refiere a la dimensión de la emoción relacionada con el nivel de activación fisiológica y psicológica, que va desde la calma (bajo arousal) hasta la excitación (alto arousal).

Valencia: En el contexto de la psicología y la computación afectiva, se refiere a la dimensión de la emoción que caracteriza lo agradable o desagradable de un estímulo, desde negativo (desagradable) hasta positivo (agradable).

1. Introducción

1.1. Planteamiento del Problema

La computación afectiva (*affective computing*), definida como el campo interdisciplinario que busca dotar a los sistemas computacionales de la capacidad de reconocer, interpretar y responder a las emociones humanas [1], ha revolucionado la forma de abordar el estudio de las respuestas emocionales. Su relevancia trasciende ámbitos como la salud mental, la educación y la interacción humano-máquina, al permitir mediciones objetivas y continuas de estados emocionales mediante el análisis de señales fisiológicas [2-3]. Entre estas, la actividad electrodérmica (EDA) y la electroencefalografía (EEG) se destacan como biomarcadores clave, al reflejar respectivamente la activación del sistema nervioso simpático (mediante cambios en la conductividad cutánea) y la dinámica cortical asociada a procesos emocionales [4-5].

En este contexto, el estrés emerge como un estado emocional crítico. Estudios evidencian que el estrés crónico no solo deteriora la salud física (aumentando el riesgo de hipertensión y trastornos inmunológicos), sino que también impacta el rendimiento cognitivo, reduciendo la capacidad de atención y memoria de trabajo en hasta un 40% [5-6]. Tradicionalmente, su evaluación se ha basado en métodos subjetivos como cuestionarios (PSS-10), los cuales, aunque validados, carecen de precisión temporal y están sujetos a sesgos de autopercepción [7-8].

De esta manera, la detección objetiva del estrés mediante señales fisiológicas enfrenta desafíos críticos que limitan su aplicabilidad práctica. Aunque la EEG ha identificado patrones neurofisiológicos asociados al estrés, como el aumento de potencia espectral en bandas teta (4-8 Hz) en regiones frontales [9-10], su implementación se ve obstaculizada por equipos costosos, protocolos rigurosos de preprocesamiento (filtrado ICA para remover artefactos oculares [11]) y sensibilidad a interferencias electromagnéticas que restringen su uso en entornos cotidianos [12]. Estas limitaciones técnicas, perpetúan la dependencia de métodos subjetivos como cuestionarios, los cuales, según estudios, subestiman o sobrestiman el estrés en hasta un 35% de los casos [8].

Si bien la EDA ha ganado relevancia por su portabilidad y bajo costo, además de su eficacia en la detección de estrés agudo, logrando un alto porcentaje de precisión mediante modelos de machine learning [6-7], su utilidad se ve disminuida por la variabilidad interindividual en las respuestas simpáticas, ya que cada persona muestra un patrón único en la activación de su sistema nervioso simpático, y la dificultad para distinguir entre estrés cognitivo y emocional [4-5]. Además, la ausencia de una metodología estandarizada para la descomposición tónico/fásica, clave para aislar respuestas específicas al estrés, sigue siendo un obstáculo [4,6], teniendo resultados pocos comparables y, por consiguiente, dificultando la interpretación de las respuestas específicas al estrés.

Aunque estudios recientes han identificado correlaciones temporales entre señales EEG y EDA durante episodios de estrés (actividad delta en EEG [0.5-4 Hz] vinculada a cambios fásicos en EDA con retardo de 12-14 segundos [3,13]), la integración de ambas enfrenta desafíos críticos que limitan su aplicabilidad práctica. La literatura carece de protocolos estandarizados para el preprocesamiento adaptativo en entornos realistas (ruido, movimiento) [11-12], lo que compromete la calidad de los datos fuera de un entorno controlado. Además, los modelos actuales no explican cómo interactúan EEG y EDA a nivel fisiológico [24], reduciendo su utilidad clínica, y su diseño no prioriza la escalabilidad en dispositivos portátiles de bajo consumo [12], perpetuando métodos fragmentados.

Ante la complejidad y altos requerimientos técnicos que implica la utilización de la señal EEG para identificar el estrés, surge la necesidad de explorar alternativas que faciliten la monitorización de este estado emocional. De esta manera, la señal EDA se posiciona como una opción atractiva, debido a que se ha destacado previamente que la portabilidad de sus equipos, menor costo y facilidad de adquisición permiten un seguimiento adecuado en la activación del sistema nervioso simpático. Así, integrando técnicas de *machine learning* a través de la medición de señales EDA, se busca desarrollar modelos predictivos que permitan detectar episodios de estrés, superando así las limitaciones asociadas a otros biomarcadores.

Con base a lo anterior, surge la pregunta problema:

¿Cómo se pueden integrar técnicas de *machine learning* al procesamiento de señales EDA para identificar episodios de estrés?

Nota de Terminología: En este estudio, el término "identificación de episodios de estrés" hace referencia a la capacidad del sistema para detectar operativamente la presencia de estrés, utilizando señales EEG y EDA. Técnicamente, este proceso se implementa mediante algoritmos de clasificación supervisada, donde se asignan etiquetas categóricas (por ejemplo "estrés"/"no estrés") y se evalúa el rendimiento con métricas estándar (precisión, F1-score, curvas ROC). La elección de "identificación" busca enfatizar la aplicación práctica en entornos clínicos o cotidianos, priorizando la detección confiable de episodios sobre la mera categorización teórica.

1.2. Objetivos

1.2.1. Objetivo General

Identificar episodios de estrés en señales EEG y EDA mediante la implementación de modelos de *machine learning*.

1.2.2. Objetivos Específicos

- Preprocesar los *datasets* de las señales EEG y EDA para la extracción de características (estadísticas, temporales, espectrales, no lineales, etc.) asociadas con el estrés.
- Crear modelos de *machine learning* que incorporen las características de las señales EEG y EDA.
- Validar los modelos mediante métricas de rendimiento (precisión, *F1-score*, sensibilidad, curvas ROC, matriz de confusión, etc.).

1.3. Justificación

El estrés, que como fenómeno multifacético ya que sus efectos y manifestaciones se extienden a diferentes niveles del ser humano y que para Colombia se presenta en un 66% para las mujeres en comparación del 58% de los hombres, no solo se limita únicamente a una respuesta emocional o física aislada, sino que involucra aspectos fisiológicos (respuestas neuroendocrinas, activación del sistema nervioso autónomo y modulaciones en el sistema inmunológico), cognitivos (impactos en funciones como la atención, la memoria y la toma de decisiones) y emocionales (generación de sentimientos como ansiedad, irritabilidad o tristeza), que puede llegar a casos extremos como el suicidio, causando al menos 100.000 muertes al año en Latinoamérica, según cifras de la Organización Mundial de la Salud (OMS), demanda métodos de detección que superen las limitaciones de los enfoques tradicionales. Si bien cuestionarios como el PSS-10 han sido ampliamente utilizados, su dependencia de la autopercepción introduce sesgos críticos: estudios revelan que el 35% de los individuos subestiman o sobrestiman sus niveles de estrés generando así millones de diagnósticos incorrectos, lo que dificulta intervenciones precisas en contextos clínicos o educativos [8]. Esta subjetividad, sumada a la falta de medición continua, resalta la necesidad de adoptar biomarcadores fisiológicos objetivos, como EEG y EDA, que capturen respuestas neurofisiológicas en tiempo real [7,5].

La EEG ha demostrado ser una herramienta poderosa para identificar patrones corticales asociados al estrés, como la desincronización alfa frontal y el incremento de actividad teta parietal [9-10]. Sin embargo, su implementación aislada enfrenta barreras prácticas: la complejidad técnica para mitigar artefactos (movimientos oculares, interferencias), se requieren equipos especializados los cuáles se encuentran en precios que van desde los 1.000 hasta los 25.000 USD junto con la poca infraestructura que solo el 15% de los hospitales públicos en Colombia cuentan para implementarlos y protocolos de preprocesamiento computacionalmente costosos [11-12], limitando su adopción en entornos cotidianos o dispositivos portátiles. Por su parte, la EDA ofrece ventajas operativas al ser una técnica no invasiva y de bajo costo, con aplicaciones validadas en la detección de estrés agudo mediante análisis de componentes fásicos [6-7]. No obstante, su utilidad se ve comprometida por la variabilidad interindividual de hasta un 50% en las respuestas simpáticas y la incapacidad para diferenciar entre fuentes de estrés (cognitivo vs.

emocional) reduciendo la confiabilidad diagnóstica en 3 de cada 10 pasos [4-5], además de la falta de consenso en métodos de descomposición tónico/fásica, lo que dificulta la estandarización de umbrales diagnósticos [4,6].

Adicionalmente, la implementación de modelos de *machine learning* en aplicaciones basadas en EDA debe considerar desafíos emergentes en seguridad y confiabilidad. Estudios recientes [26] advierten que la adopción de técnicas de ML en sistemas de análisis fisiológico puede introducir vulnerabilidades críticas, como ataques adversariales que manipulan datos de entrenamiento o inferencias maliciosas para reconstruir información confidencial. Estos riesgos, aunque tradicionalmente subestimados en la literatura biomédica, resaltan la necesidad de incorporar protocolos de seguridad robustos (como por ejemplo la regularización de curvatura) durante el diseño de modelos, garantizando no solo precisión sino también integridad en aplicaciones clínicas o educativas.

De esta manera, la integración de señales EEG y EDA emerge como una solución técnicamente viable y científicamente respaldada. Evidencia reciente sugiere que la combinación de ambas señales no solo compensa sus debilidades individuales, sino que enriquece la interpretación fisiológica del estrés. Por ejemplo, estudios identifican que los picos fásicos en EDA preceden en 12-14 segundos a cambios en la banda delta de la EEG durante tareas de memoria de trabajo, lo que permitiría detectar respuestas simpáticas tempranas antes de que se manifiesten a nivel cortical [3]. Asimismo, investigaciones demuestran que modelos que fusionan EEG y EDA mediante redes neuronales hipercomplejas superan en un 15% la precisión de enfoques unimodales (métodos que utilizan únicamente una fuente de datos para analizar o segmentar el fenómeno de estudio) en la clasificación del nivel de activación neuronal (*arousal*), gracias a la captura simultánea de activación autonómica y cortical [13].

La relevancia de esta propuesta radica en su capacidad para ofrecer una medición objetiva del estrés, superando la subjetividad de cuestionarios y la fragmentación de enfoques unimodales. Para ello, se podrían considerar estrategias como protocolos adaptativos de preprocesamiento, incluyendo técnicas validadas para el manejo de señales EEG (descomposición independiente de componentes [11]) y enfoques de descomposición tónico-fásica para EDA [7]. Asimismo, la integración de herramientas interpretativas de *machine learning* que cuantifiquen la contribución relativa de cada señal fisiológica en la identificación de episodios de estrés [15]. Técnicamente, este proceso se aborda como un problema de clasificación supervisada (etiquetas "estrés"/"no estrés"), evaluado mediante métricas como precisión, F1-score y curvas ROC. Sin embargo, el término "identificación" enfatiza su aplicación práctica: la detección operativa y confiable en tiempo real, esencial para intervenciones en contextos clínicos o cotidianos.

Para garantizar escalabilidad, se evaluarán métodos de optimización computacional, como selección de características relevantes y algoritmos eficientes en recursos [6], estrategias que ya han demostrado éxito en estudios previos. Estas aproximaciones buscan equilibrar precisión, interpretabilidad y aplicabilidad

práctica, abordando el vacío crítico en la literatura: la falta de marcos unificados que expliquen cómo interactúan EEG y EDA a nivel fisiológico durante el estrés [14]. Así, la sinergia entre clasificación técnica e identificación aplicativa no solo resuelve limitaciones metodológicas, sino que sienta las bases para sistemas portátiles de bajo costo, capaces de transformar datos fisiológicos en alertas accionables para mejorar la calidad de vida y reducir los costos asociados al estrés crónico.

1.4. Impacto Social

El presente proyecto, enfocado en la identificación de episodios de estrés mediante el análisis conjunto de señales EEG y EDA, tiene el potencial de generar un impacto social significativo en diversos sectores. Esta iniciativa no solo responde a la necesidad de contar con métodos más precisos para la detección del estrés, sino que también se alinea con varios Objetivos de Desarrollo Sostenible (ODS), lo que refuerza su relevancia y alcance.

La detección temprana del estrés es fundamental para prevenir problemas de salud mental y física. Al implementar un sistema basado en señales fisiológicas objetivas, se posibilita una intervención más oportuna y efectiva, lo cual puede mejorar la calidad de vida de los individuos y reducir la carga sobre los sistemas de salud, apuntando así al ODS número 3 “Salud y Bienestar”

De igual manera, al implementar modelos de *machine learning* para la detección del estrés, el proyecto impulsa el uso de tecnologías avanzadas y el desarrollo de soluciones prácticas que pueden ser adoptadas por el sector empresarial y organismos gubernamentales. Esto favorece la optimización de procesos y la reducción de costos asociados al monitoreo continuo del bienestar emocional y así, aportar con el ODS número 9 “Industria, innovación e infraestructura”

En la Universidad Santo Tomás, este proyecto impulsará la actualización y capacitación en áreas emergentes como la computación afectiva, *machine learning* aplicado a señales fisiológicas y análisis de datos biomédicos, contribuyendo así a la mejora en competencias y capacidades para enfrentar desafíos en estas áreas.

2. Estado del Arte

El estudio del estrés mediante señales fisiológicas ha evolucionado significativamente en la última década, impulsado por avances en sensores portátiles [27], técnicas de procesamiento de señales y algoritmos de inteligencia artificial [12]. A continuación, se analizan los aportes y desafíos en tres ejes fundamentales: el reconocimiento de emociones mediante señales fisiológicas, el uso de EEG y EDA como biomarcadores, y la aplicación de modelos de *machine learning* en este campo.

2.1. Reconocimiento de emociones a través de señales fisiológicas

La identificación de emociones mediante señales fisiológicas ha permitido superar las limitaciones de los métodos subjetivos tradicionales. Estudios han demostrado que la integración multimodal de biomarcadores (EEG, EDA, frecuencia cardíaca) mejora la precisión en la clasificación de dimensiones afectivas como la valencia y el *arousal* [16-17]. Por ejemplo, [16] comparó clasificadores como kELM y sSOM en el *dataset* DEAP, logrando una precisión del 82% en la detección de *arousal*, mientras que [17] propuso un enfoque basado en características estadísticas de EEG, alcanzando un 90% de exactitud en la distinción de emociones positivas y negativas. Estos trabajos subrayan la importancia de extraer características espectrales y temporales (potencia en bandas alfa, entropía de muestra) para capturar la complejidad de las respuestas emocionales.

La revisión sistemática de [25] consolida avances en clasificación de *arousal* mediante EDA, destacando que etapas como el preprocesamiento adaptativo (normalización, descomposición tónico-fásica) y la extracción de características morfoespectrales son determinantes para alcanzar precisiones superiores al 85% con SVM y ANN. Este trabajo subraya, además, la superioridad de enfoques supervisados frente a métodos no supervisados (~75% de precisión), reforzando la necesidad de conjuntos de datos etiquetados para entrenar modelos generalizables.

Sin embargo, persisten desafíos críticos. [8] evidenció que, aunque la combinación de EDA y variabilidad de la frecuencia cardíaca (HRV) permite clasificar emociones con un 86% de precisión, la falta de estandarización en protocolos de adquisición genera variabilidad interdataset, dificultando la replicabilidad. Asimismo, [3] destacó que las correlaciones entre señales cerebrales y periféricas (EDA) no son lineales, lo que exige métodos avanzados de fusión de datos. Estos hallazgos resaltan la necesidad de marcos metodológicos que integren múltiples señales fisiológicas, considerando tanto su complementariedad como sus limitaciones inherentes.

Estudios como [18], que analizan dinámicas emocionales mediante transiciones en redes y EDA, evidencian que la variabilidad temporal en las respuestas simpáticas puede modularse mediante intervenciones específicas, como la exposición a estímulos estresantes controlados. Por otro lado, [19] propone un análisis

estadístico espacial de EEG multicanales para identificar correlaciones entre regiones cerebrales durante episodios de estrés, destacando la importancia de métricas como la desviación estándar y la potencia en bandas beta.

2.2. Señales EDA y EEG

La EDA se ha consolidado como un indicador confiable de la activación simpática asociada al estrés. [7] demostró que modelos basados en SVM y descomposición *cvxEDA* pueden detectar estrés agudo con un 94.6% de precisión, utilizando únicamente EDA. Por otro lado, [6] aplicó *clustering* no supervisado (*K-means*) en características temporales de EDA, logrando clasificar tres niveles de estrés (bajo, moderado, alto) con un 93% de exactitud mediante *Random Forest*. Estos resultados respaldan la utilidad de la EDA en aplicaciones portátiles y de bajo costo. No obstante, su utilidad se ve limitada por la variabilidad interindividual en las respuestas simpáticas y la dificultad para diferenciar entre estrés cognitivo y emocional, como señaló [5] en un estudio con 65 participantes sometidos a tareas de memoria de trabajo.

En el ámbito de dispositivos portátiles, [27] validaron la eficacia de sensores EDA en muñeca para detección de estrés, demostrando que SVM logra un 92.9% de precisión en el *dataset* VerBIO. Este estudio también reveló diferencias significativas en rendimiento según género, con mayor precisión en mujeres, lo que sugiere variabilidad fisiológica en respuestas al estrés. Estos hallazgos respaldan la viabilidad de integrar EDA en *wearables* (dispositivos electrónicos que se pueden llevar puestos y que interactúan con el usuario) comerciales, aunque resaltan la importancia de considerar factores demográficos en el diseño de modelos.

En contraste, la EEG ofrece una visión directa de la actividad cortical vinculada al estrés. [10] identificó que características espectrales en bandas teta (4-8 Hz) y beta (12-30 Hz) permiten distinguir estados de estrés con un 97% de precisión usando KNN. Por su parte, [20] comparó *Random Forest* y redes neuronales recurrentes (RNN) en EEG, mostrando que las RNN superan a los modelos tradicionales (87% vs. 83%) al capturar dependencias temporales en las señales. Sin embargo, la adopción del EEG en entornos realistas enfrenta barreras técnicas: la adquisición de señales limpias requiere equipos costosos y protocolos rigurosos para mitigar artefactos, como el filtrado ICA y la remoción de línea base [11]. Además, [12] advirtió que la sensibilidad del EEG a interferencias electromagnéticas limita su uso en dispositivos portátiles, un desafío crítico para aplicaciones en movilidad.

Investigaciones como [21] han explorado el uso de redes neuronales recurrentes (LSTM) en EEG para clasificar emociones positivas y negativas, logrando un 93.75% de precisión al capturar dependencias temporales en características espectrales. Adicionalmente, [22] introduce técnicas de análisis tiempo-frecuencia de alta resolución (VFCDM) para EEG, demostrando que la extracción de características en bandas delta y gamma mejora la clasificación de *arousal* (71.8% F1-score). Por su parte, [23] valida el uso de LSTM en EEG multicanal, alcanzando

un 93% de precisión en reconocimiento de emociones mediante interacciones no lineales entre electrodos.

2.3. Modelos de machine learning en la detección de estados emocionales

Los avances en *machine learning* han permitido desarrollar modelos cada vez más precisos y adaptativos. Enfoques unimodales, como la arquitectura EEG-MLP propuesta por [1], lograron un 95.3% de precisión en la clasificación de *arousal* al procesar características intra e intercanales de EEG, superando a redes convolucionales (CNN) y grafos (GCN). En aplicaciones multiclase (estos sistemas de clasificación que deben distinguir entre tres o más categorías o clases diferentes), estudios recientes [15] exploraron la clasificación de estados como estrés, meditación y diversión mediante datos multimodales, donde RNN alcanzaron un F1-score del 93% en generalización inter-sujeto, mientras que XGBoost y *Random Forest* lograron un 99.8% en evaluación intra-sujeto, aunque con riesgo de sobreajuste. Este trabajo también destacó que sensores en muñeca, pese a su menor frecuencia de muestreo, son prometedores para aplicaciones en entornos no controlados, equilibrando precisión y portabilidad.

La fusión de EEG y EDA ha abierto nuevas posibilidades. [13] diseñó una red neuronal hipercompleja que fusiona ambas señales, mejorando en un 15% la precisión respecto a modelos unimodales en el reconocimiento de *arousal*. Este enfoque aprovecha las ventajas complementarias de cada señal: la EDA captura respuestas autonómicas rápidas, mientras el EEG proporciona información cortical detallada. Sin embargo, persisten brechas clave. [3] señaló que la mayoría de los modelos operan como "cajas negras", sin explicar cómo interactúan las señales a nivel fisiológico, lo que limita su adopción clínica. Además, [6] evidenció que, aunque algoritmos como *Random Forest* son eficientes, su implementación en dispositivos portátiles exige optimizar la dimensionalidad de los datos y priorizar características computacionalmente ligeras.

En el ámbito de intervenciones prácticas, [24] propone un enfoque innovador que combina EEG con técnicas de reducción de estrés (yoga y música), logrando una disminución del 75% en niveles de estrés mediante modelos SVM y LSTM. Este trabajo resalta el potencial de integrar soluciones tecnológicas con estrategias de bienestar emocional.

3. Marco Teórico

3.1. Estrés como respuesta fisiológica

El estrés es comúnmente percibido como una experiencia subjetiva de tensión emocional o mental. Sin embargo, desde una perspectiva científica, constituye un fenómeno fisiológico complejo y medible que desencadena una cascada de respuestas en el organismo. La comprensión de sus mecanismos biológicos es de importancia estratégica para el desarrollo de métodos de detección objetivos. Estos enfoques, basados en biomarcadores cuantificables, tienen el potencial de superar las limitaciones inherentes a la autoevaluación, como los sesgos de percepción y la falta de precisión temporal, abriendo la puerta a intervenciones más tempranas, precisas y personalizadas en el ámbito de la salud y el bienestar [28-29].

3.1.1. Definición y Mecanismos Neurobiológicos

Científicamente, el estrés se define como una respuesta evocada cuando el organismo percibe estímulos (estresores) que exceden su capacidad adaptativa y alteran su equilibrio interno u homeostasis. Esta respuesta no es intrínsecamente negativa; es un mecanismo de supervivencia fundamental [30]. Para orquestar esta reacción, el cuerpo activa dos sistemas neurobiológicos principales que operan en diferentes escalas de tiempo:

Sistema Nervioso Autónomo (SNA): Este sistema media la respuesta inmediata, conocida popularmente como "lucha o huida" (*fight-or-flight*). Ante un estresor agudo, la rama del Sistema Nervioso Simpático (SNS) se activa, liberando hormonas como la adrenalina. Esto provoca un aumento de la frecuencia cardíaca, la presión arterial y la conductancia de la piel, preparando al cuerpo para una acción rápida y enérgica [31-32].

Eje Hipotalámico-Pituitario-Adrenal (HPA): Este eje gobierna las respuestas a mediano y largo plazo. El hipotálamo libera hormonas que instruyen a la glándula pituitaria para que, a su vez, estimule las glándulas suprarrenales. Estas últimas liberan cortisol, una hormona que ayuda a movilizar recursos energéticos y a regular la inflamación, sosteniendo la respuesta del cuerpo al estrés más allá de la reacción inicial [30,32].

3.1.2. Impacto de la carga Alostática en la Salud

Es crucial diferenciar entre el estrés agudo, que es una respuesta adaptativa y beneficiosa a corto plazo, y el estrés crónico, que resulta de la exposición prolongada o repetida a estresores. Para comprender el impacto del estrés crónico, se introducen dos conceptos clave:

Alostasis: Es el proceso dinámico a través del cual el cuerpo mantiene la estabilidad y se adapta a los desafíos ambientales mediante la activación coordinada de los sistemas fisiológicos [28].

Carga Alostática: Representa el "desgaste" acumulado en el cuerpo debido a la activación sostenida o repetida de las respuestas alostáticas. Una carga alostática elevada significa que los sistemas fisiológicos que deberían proteger al organismo comienzan a causar daño [29].

La exposición prolongada a una alta carga alostática tiene consecuencias negativas significativas para la salud. La literatura científica ha establecido vínculos sólidos entre la carga alostática y un mayor riesgo de desarrollar enfermedades cardiovasculares, diabetes tipo 2, susceptibilidad al cáncer y trastornos mentales como los trastornos del sueño y la ansiedad [29,33-34].

3.1.3. Respuestas del estrés: Reactividad y Recuperación

La forma en que cada individuo responde al estrés varía considerablemente, y esta variabilidad se puede caracterizar a través de dos dimensiones fundamentales:

Reactividad al estrés (*Stress Reactivity*): Se define como los cambios fisiológicos y psicológicos agudos que ocurren durante la exposición a un estresor. Refleja diferencias individuales en la magnitud, duración y frecuencia de la respuesta del organismo. Una persona con alta reactividad puede experimentar un aumento más pronunciado de la frecuencia cardíaca o de los niveles de cortisol ante un mismo desafío [32].

Recuperación del estrés (*Stress Recovery*): Se define como el proceso mediante el cual el cuerpo y la mente regresan al equilibrio homeostático una vez que el estresor ha desaparecido. Una recuperación eficiente es tan importante como la reactividad inicial; la incapacidad para desactivar la respuesta al estrés de manera oportuna contribuye significativamente a la carga alostática [30,32].

La caracterización precisa de la reactividad y la recuperación de un individuo es fundamental para el desarrollo de intervenciones personalizadas y efectivas en el manejo del estrés. Para cuantificar estas complejas respuestas fisiológicas de manera fiable, es indispensable el uso de biomarcadores objetivos [35].

3.2. Señales Fisiológicas

La transición desde la comprensión conceptual del estrés hacia su medición objetiva requiere el uso de herramientas que capturen sus manifestaciones biológicas. Las señales fisiológicas, que reflejan la actividad del sistema nervioso central y autónomo, emergen como biomarcadores superiores a los métodos subjetivos como los cuestionarios. Su principal ventaja radica en la capacidad de registrar la dinámica temporal de la respuesta al estrés en tiempo real, proporcionando una

ventana directa y sin sesgos a las fluctuaciones del estado interno de un individuo, algo que los autoinformes no pueden lograr [28-29,34].

3.2.1. Actividad Electroencefalográfica (EEG)

La Electroencefalografía (EEG) es una técnica no invasiva que mide la actividad eléctrica del cerebro mediante electrodos colocados sobre el cuero cabelludo. Esta señal refleja la suma de los potenciales eléctricos postsinápticos de una gran cantidad de neuronas, ofreciendo una visión de alta resolución temporal sobre la dinámica cortical asociada a procesos cognitivos y emocionales complejos [36-38].

Bandas de Frecuencias del EEG

En el contexto de la detección de estrés, resulta particularmente relevante el análisis de la potencia espectral en las distintas bandas de frecuencia de la señal EEG, ya que se han reportado incrementos en las bandas beta y gamma, y decrementos en la banda alpha durante estados de estrés agudo [36-37]. Las principales bandas de frecuencia EEG, sus rangos y los estados mentales asociados se resumen en la Tabla 3.1.

Tabla 3.1. Información Bandas de Frecuencias señal EEG.

Banda de Frecuencia	Rango (Hz)	Estado Mental Asociado
Delta (δ)	0.5 - 4 Hz	Sueño profundo, estados de relajación intensa
Theta (θ)	4 - 8 Hz	Meditación, somnolencia, procesos de memoria
Alfa (α)	8 - 13 Hz	Relajación en estado de vigilia, calma
Beta (β)	12 - 38 Hz	Concentración activa, ansiedad, pensamiento activo
Gamma (γ)	38 - 42 Hz	Procesamiento cognitivo de alto nivel, percepción

En respuesta a estresores, la señal EEG exhibe patrones de cambio característicos. La investigación ha identificado de manera consistente que el estrés mental induce un aumento en la potencia de la banda Beta (β), particularmente en su rango más alto (22-38 Hz). Este incremento se asocia con un estado de alerta elevado, ansiedad y procesamiento cognitivo activo, típico de una respuesta de afrontamiento [37-38]. Adicionalmente, se han observado cambios en la potencia de la banda Theta (θ) en las regiones frontales del cerebro, lo que sugiere una modulación de las funciones ejecutivas y de la memoria de trabajo bajo condiciones de estrés [36]. Estos patrones neurofisiológicos sirven como indicadores fiables para la detección objetiva del estrés.

3.2.2. Actividad Electrodérmica (EDA)

La Actividad Electrodermica (EDA), también conocida como Respuesta Galvánica de la Piel (GSR), es una medida de las variaciones continuas en las propiedades eléctricas de la piel. Estas variaciones son el resultado directo de la actividad de las glándulas sudoríparas eccrinas, las cuales están inervadas exclusivamente por el Sistema Nervioso Simpático (SNS). Por esta razón, la señal EDA es considerada un indicador directo, fiable y no invasivo de la activación simpática y de las respuestas emocionales y cognitivas [31,35,39].

Descomposición de la señal EDA

La señal EDA total se compone de dos elementos fundamentales que reflejan diferentes aspectos de la actividad simpática:

Componente Tónico (Nivel de Conductancia de la Piel - SCL): Este es el componente de variación lenta de la señal, que actúa como una línea base. El SCL está principalmente relacionado con procesos de fondo como la termorregulación, el estado de hidratación y el nivel general de activación o *arousal* de un individuo [35].

Componente Fásico (Respuesta de Conductancia de la Piel - SCR): Corresponde a fluctuaciones rápidas y discretas que se superponen al nivel tónico. Los SCR son ráfagas de actividad del SNS que ocurren en respuesta a estímulos específicos, ya sean externos (un sonido fuerte) o internos (un pensamiento estresante), y reflejan la respuesta de "lucha o huida" a nivel cutáneo [31,39].

Modelado Matemático de la EDA

El modelo conceptual de la EDA puede representarse matemáticamente mediante la ecuación (1). La señal de conductancia de la piel observada, $y(t)$, se considera la suma de sus componentes principales y el ruido inherente a la medición.

$$y(t) = y_p(t) + y_s(t) + v(t) \quad (1)$$

Donde:

$y(t)$ es la señal de la conductancia de la piel (SC) medida.

$y_p(t)$ es el componente fásico (SCR).

$y_s(t)$ es el componente tónico (SCL)

$v(t)$ es el término de ruido.

Conceptualmente, el componente fásico $y_p(t)$ se modela como la salida de un sistema fisiológico a un estímulo neuronal subyacente $u(t)$. Este sistema puede ser descrito por una ecuación diferencial de segundo orden, cuya función de respuesta al impulso (la forma de un SCR individual) a menudo se aproxima con funciones como la función de Bateman [49]. En la práctica, algoritmos avanzados como **cvxEDA**, basados en optimización convexa, son ampliamente utilizados para

descomponer la señal $y(t)$ en sus componentes tónico y fásico de manera robusta y fisiológicamente plausible. La extracción de características significativas a partir de estas señales complejas y multidimensionales requiere el uso de modelos computacionales avanzados para su interpretación y clasificación [35,39].

3.3. Modelos de Machine Learning

El análisis de datos fisiológicos para la detección de estrés presenta desafíos significativos debido a su alta dimensionalidad, complejidad y variabilidad interindividual. El Machine Learning (ML) se ha convertido en una herramienta indispensable para abordar estos desafíos. Los modelos de ML son capaces de aprender patrones complejos y sutiles a partir de grandes volúmenes de datos, permitiendo la clasificación automática y objetiva de estados emocionales, como el estrés, con una precisión que supera a los métodos tradicionales [33-34,40].

3.3.1. Paradigmas de Aprendizaje y Preparación de Datos

En el contexto de la clasificación de estrés, el paradigma predominante es el aprendizaje supervisado. A diferencia del aprendizaje no supervisado, que busca patrones en datos sin etiquetas, el aprendizaje supervisado entrena un modelo utilizando un conjunto de datos donde cada muestra ha sido previamente etiquetada. En este caso, las etiquetas corresponderían a las clases de interés, como "estrés" y "no estrés". El modelo aprende a asociar las características extraídas de las señales fisiológicas con su etiqueta correspondiente [41-42].

El rendimiento de cualquier modelo de ML depende críticamente de la calidad de los datos con los que se entrena. Por ello, la preparación de datos es un paso previo fundamental. Los procesos clave incluyen:

Preprocesamiento: Implica la gestión de datos para asegurar su integridad y compatibilidad con los algoritmos. Esto incluye el manejo de valores faltantes (imputación) y la transformación de datos categóricos (si los hubiera) en representaciones numéricas que los modelos puedan procesar [40, 46].

Normalización de Datos: Este proceso ajusta la escala de las diferentes características para que todas tengan un rango similar (ej. entre 0 y 1). Esto es crucial porque muchos algoritmos, como las Máquinas de Vectores de Soporte (SVM) y los Perceptrones Multicapa (MLP), son sensibles a la escala de las características de entrada. La normalización asegura que ninguna característica domine el proceso de aprendizaje debido a su magnitud, lo que mejora significativamente el rendimiento y la convergencia del modelo [40,48].

Estandarización (Normalización Z-score) La estandarización transforma los datos de manera que tengan una media de 0 y una desviación estándar de 1. A diferencia de la normalización, no limita los valores a un rango específico, lo que la hace menos sensible a los valores atípicos. Es la técnica preferida cuando los datos siguen una distribución gaussiana [45, 48].

Segmentación Temporal: Las señales fisiológicas son continuas en el tiempo. Para analizarlas, es una práctica común dividir las en segmentos o "ventanas" de tiempo de una duración fija (por ejemplo, 100, 200 o 300 segundos). A partir de cada ventana, se extrae un conjunto de características. Esta técnica permite capturar la dinámica de la respuesta al estrés en sus diferentes fases: inicio, sostenimiento y finalización [30,34,47].

3.3.2. Algoritmos de Clasificación

Dentro del vasto campo del Machine Learning, existen algoritmos fundamentales que han demostrado ser efectivos para la clasificación de estados fisiológicos.

Máquinas de Vectores de Soporte (SVM)

El objetivo principal de una Máquina de Vectores de Soporte (SVM) es encontrar un hiperplano óptimo en un espacio de características de alta dimensionalidad que separe de la manera más clara posible las muestras de diferentes clases. Este "hiperplano óptimo" es aquel que maximiza el margen, es decir, la distancia entre el hiperplano y los puntos de datos más cercanos de cada clase (llamados vectores de soporte). Para manejar datos que no son linealmente separables en su espacio original, SVM utiliza una técnica conocida como el "truco del kernel" (*kernel trick*). Los kernels transforman los datos a un espacio de mayor dimensión donde sí es posible encontrar un hiperplano de separación. La utilización de kernels no lineales como la Función de Base Radial (RBF) es especialmente pertinente en este dominio, dada la compleja y no lineal relación que a menudo existe entre las características fisiológicas y los estados de estrés [34,43].

K-Vecinos más Cercanos (KNN)

El algoritmo K-Vecinos más Cercanos (KNN) es un método de aprendizaje "perezoso" o basado en instancias. No construye un modelo explícito durante el entrenamiento, sino que almacena todo el conjunto de datos de entrenamiento. Para clasificar un nuevo punto de datos, el algoritmo identifica los 'K' puntos de entrenamiento más cercanos a él en el espacio de características. La clase del nuevo punto se asigna en función de la clase mayoritaria entre sus 'K' vecinos [34,42]. La "cercanía" se mide comúnmente utilizando la norma euclidiana (también denominada norma L2 o distancia euclídea), que representa la longitud del vector diferencia entre dos puntos en el espacio de características, se calcula con base a la ecuación (2):

$$d(p, q) = \|p - q\|_2 = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (2)$$

Donde q_i y p_i son dos puntos de datos en el espacio de características de n dimensiones, el subíndice i recorre cada una de las dimensiones.

Árbol de Decisión

Un Árbol de Decisión es un modelo que toma decisiones siguiendo una estructura jerárquica similar a un árbol. En este modelo, los nodos internos representan una "prueba" sobre un atributo (ej. "¿Es la potencia Beta > 0.5?"), las ramas representan el resultado de esa prueba, y los nodos hoja representan la etiqueta de clase final (ej. "estrés"). Para construir el árbol, el algoritmo busca en cada paso la mejor división de los datos. Para ello, utiliza una medida de "impureza" como la Entropía, que cuantifica el desorden o la incertidumbre en un conjunto de datos. El objetivo del algoritmo es minimizar la entropía en los nodos resultantes de una división, logrando así subconjuntos de datos lo más "puros" u homogéneos posible. Este principio de minimización de la entropía permite al algoritmo identificar de manera jerárquica las características fisiológicas (ej. potencia en una banda de frecuencia específica) que son más discriminativas para diferenciar entre estados de 'estrés' y 'no estrés' [43-44]. La fórmula de la entropía se define mediante la ecuación (3):

$$H(S) = - \sum (p_i * \log_2 p_i) \quad (3)$$

Donde S es el conjunto de datos y p_i es la proporción de muestras que pertenecen a la clase i en ese conjunto.

3.3.3. Métricas de Evaluación de Rendimiento

Para evaluar y comparar de manera objetiva el rendimiento de los diferentes modelos de clasificación, es indispensable utilizar un conjunto de métricas cuantitativas estandarizadas. Estas métricas nos permiten ir más allá de una evaluación cualitativa y entender las fortalezas y debilidades de cada modelo.

La base para calcular la mayoría de estas métricas es la **Matriz de Confusión** [33-34]. Esta tabla resume el rendimiento de un clasificador, contrastando las predicciones del modelo con las etiquetas reales. Sus cuatro componentes son:

Verdaderos Positivos (TP): Casos de "estrés" correctamente identificados como "estrés".

Verdaderos Negativos (TN): Casos de "no estrés" correctamente identificados como "no estrés".

Falsos Positivos (FP): Casos de "no estrés" incorrectamente identificados como "estrés" (Error Tipo I).

Falsos Negativos (FN): Casos de "estrés" incorrectamente identificados como "no estrés" (Error Tipo II).

A partir de esta matriz, se derivan las siguientes métricas clave [50]:

Exactitud (Accuracy): Mide la proporción de todas las predicciones que fueron correctas y se calcula con base a la ecuación (4). Aunque es intuitiva, puede ser engañosa si las clases están desbalanceadas.

$$Exactitud = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

Precisión (*Precision*): De todas las veces que el modelo predijo la clase positiva ("estrés"), ¿Qué proporción fue correcta? Es una métrica crucial cuando el costo de un falso positivo es alto, indicando la fracción de predicciones positivas que realmente fueron correctas, tal como presenta la ecuación (5):

$$Precisión = \frac{TP}{TP + FP} \quad (5)$$

Sensibilidad (*Recall*): De todos los casos que realmente eran positivos ("estrés"), ¿Qué proporción fue capaz de identificar el modelo? Es vital cuando el costo de un falso negativo es alto (ej. no detectar un episodio de estrés). Para medir esta proporción donde los casos positivos reales que el modelo ha identificado correctamente, se emplea la ecuación (6):

$$Sensibilidad = \frac{TP}{TP + FN} \quad (6)$$

Puntuación F1 (*F1-Score*): Es la media armónica de la Precisión y la Sensibilidad. Proporciona una única métrica que equilibra ambas, siendo especialmente útil en problemas con clases desbalanceadas donde la exactitud puede no ser un buen indicador [40], la ecuación (7) representa este resultado de la siguiente manera:

$$Puntuación F1 = 2 * \frac{(Precisión * Sensibilidad)}{(Precisión + Sensibilidad)} \quad (7)$$

Adicionalmente, la **curva ROC (*Receiver Operating Characteristic*)** y el **Área Bajo la Curva (AUC)** son herramientas importantes para evaluar la capacidad de discriminación de un clasificador a través de diferentes umbrales de decisión. Un valor de AUC cercano a 1.0 indica un excelente poder de clasificación. En conjunto, la selección rigurosa de algoritmos y su evaluación mediante estas métricas estandarizadas es lo que permite transformar las señales fisiológicas brutas en clasificadores de estrés robustos, objetivos y potencialmente trasladables a aplicaciones clínicas y de monitoreo en tiempo real [33].

4. Diseño Metodológico

4.1. Fases y Metodología

Para alcanzar el objetivo general de este estudio, se plantea una metodología estructurada en tres fases principales: preprocesamiento de los datasets, creación de los modelos de machine learning y la validación de estos mediante métricas de rendimiento, tal como se muestra en el diagrama de flujo representado en la figura 4.1. A continuación, se detallan las actividades correspondientes a cada fase.

4.1.1. Fase 1: Preprocesamiento de los datasets

Inicialmente se realizará la exploración y análisis inicial de los datos mediante un estudio preliminar de las señales EEG y EDA, con el objetivo de identificar patrones, tendencias y posibles inconsistencias. En seguida, se definirá un esquema adecuado de segmentación temporal para facilitar la extracción de información relevante, asegurando que el formato de los datos sea compatible con herramientas de análisis estadístico. Así mismo, en la extracción de información relevante, se identificarán y calcularán las características más representativas de las señales, considerando aspectos estadísticos y de dinámica de las respuestas fisiológicas. Es importante mencionar que el *dataset* es suministrado por el docente investigador que se encuentra acompañando el desarrollo del proyecto, este *dataset* fué tomado a 10 participantes los cuales realizaron 4 tareas cognitivas, la toma de estos datos se hizo cada dos horas durante 24 horas.

4.1.2. Fase 2: Creación de los modelos de machine learning

Durante la definición del enfoque de análisis, se evaluará la pertinencia de trabajar con modelos independientes (tales como árboles de decisión, *support vector machines*, KNN) a través de cada tipo de señal o de integrar ambas para mejorar la interpretación de los resultados. De esta manera, en la implementación de los modelos se establecerán los criterios para su selección y ajuste, considerando diferentes estrategias para la representación de los datos. Como resultado, los modelos serán orientados a implementar estrategias de optimización mediante el ajuste de hiperparámetros (usando métodos como validación cruzada, análisis de componentes principales, estandarización, normalización de datos, etc.) que mejoren el desempeño y, por consiguiente, se eviten problemas de sobreajuste (*overfitting*), asegurando una adecuada generalización.

4.1.3. Fase 3: Validación de los modelos de machine learning

Posteriormente, durante la medición de la efectividad se calcularán métricas de desempeño, permitiendo evaluar la capacidad del modelo en la detección de patrones asociados al estrés. Una vez realizado el análisis de resultados y optimización, se analizarán los errores y patrones identificados, con el fin de proponer posibles mejoras en la configuración del modelo. En tal sentido, para la

evaluación de la generalización se aplicarán técnicas de validación y así, estimar la robustez de cada modelo y su aplicabilidad en la detección de estrés. Para finalizar con la comparación con estudios previos, se contrastarán los hallazgos obtenidos con investigaciones similares y así contextualizar los resultados dentro de las conclusiones.




Figura 4.1. Diseño Metodológico

4.2. Cronograma

Para garantizar el cumplimiento de las tareas planteadas en la metodología dentro de los plazos establecidos, se ha estructurado el cronograma de la siguiente manera:

Fase 1: Preprocesamiento de los datasets

- **Semanas 1-2:**
 - Exploración y análisis inicial de los datos.
 - Estudio preliminar de las señales EEG y EDA para identificar patrones, tendencias e inconsistencias.
- **Semanas 3-4:**
 - Definición del esquema de segmentación temporal adecuado.
 - Adecuación del formato de los datos para su compatibilidad con herramientas de análisis estadístico.
- **Semanas 5-6:**
 - Extracción de la información relevante.
 - Identificación y cálculo de las características más representativas (aspectos estadísticos y de dinámica de las respuestas fisiológicas).
- **Semanas 7-8:**
 - Revisión y ajuste final del preprocesamiento para garantizar que los datos estén listos para la siguiente fase.

Fase 2: Creación de los modelos de machine learning

- **Semanas 9-10:**
 - Definición del enfoque de análisis.
 - Evaluación de la pertinencia de trabajar con modelos independientes (por ejemplo, árboles de decisión, SVM, KNN) o la integración de ambos tipos de señales para mejorar la interpretación de los resultados.
- **Semanas 11-12:**
 - Implementación de los modelos y establecimiento de criterios para su selección y ajuste.
 - Optimización de los modelos mediante el ajuste de hiperparámetros (usando técnicas como validación cruzada, análisis de componentes principales, estandarización, normalización de datos, etc.) para evitar el sobreajuste y mejorar el desempeño.

Fase 3: Validación de los modelos de machine learning

- **Semanas 13-14:**
 - Medición de la efectividad de los modelos mediante el cálculo de métricas de desempeño.
 - Evaluación de la capacidad de los modelos para detectar patrones asociados al estrés.
- **Semana 15:**
 - Análisis de los errores y patrones identificados en los resultados.
 - Propuesta de posibles mejoras en la configuración y ajustes del modelo.
- **Semana 16:**
 - Comparación de los hallazgos obtenidos con estudios previos para contextualizar los resultados.

Es importante tener en cuenta que el desarrollo del informe con toda la información se está realizando de manera transversal o a lo largo de todo el proyecto, de esta manera la documentación de los avances, métodos y resultados van a contar con un registro actualizado, dicha trazabilidad se evidencia en la figura 4.2.

CRONOGRAMA DE TRABAJO PARA EL DESARROLLO DEL PROYECTO																	
ACTIVIDADES / SEMANAS		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
FASE 1: PREPROCESAMIENTO DEL DATASET																	
1.1	Exploración y análisis de los datos																
1.2	Estudio preliminar señales EEG y EDA																
1.3	Definición del esquema de segmentación temporal adecuado																
1.4	Adecuación del formato de los datos para su compatibilidad con herramientas estadísticas																
1.5	Extracción de información relevante																
1.6	Identificación y cálculo de las características más representativas																
1.7	Revisión y ajuste final del preprocesamiento para garantizar que los datos estén listos para la siguiente fase																
FASE 2: IMPLEMENTACIÓN DE LOS MODELOS DE MACHINE LEARNING																	
2.1	Definición del enfoque de análisis																
2.2	Evaluación de los modelos a implementar																
2.3	Implementación de los modelos y establecimiento de los criterios para su selección y ajuste																
2.4	Optimización de los modelos mediante el ajuste de hiperparámetros																
FASE 3: VALIDACIÓN DE LOS MODELOS DE MACHINE LEARNING																	
3.1	Medición de la efectividad de los modelos mediante métricas de desempeño																
3.2	Evaluación de la capacidad de los modelos																
3.3	Análisis de los errores y patrones identificados en los resultados																
3.4	Propuesta de posibles mejoras en la configuración y ajustes del modelo																
3.5	Comparación de los hallazgos obtenidos con estudios previos para contextualizar resultados																
Documentación actualizada del documento con los avances, métodos y resultados correspondientes																	

Figura 4.2. Cronograma del Proyecto.

5. Desarrollo Conceptual

Aunque la investigación se centró inicialmente en las señales de actividad electrodérmica (EDA) y electroencefalográfica (EEG) para caracterizar respuestas fisiológicas al estrés, la disponibilidad de registros electrocardiográficos (ECG) dentro del conjunto de datos, motivó su incorporación al análisis. Esta decisión enriquece el modelo multimodal al integrar un marcador directo del control autonómico cardiovascular, complementando las dimensiones conductuales (EDA) y cortical (EEG) con una perspectiva sistémica de la regulación homeostática.

5.1. Información de los *datasets*

Los datasets empleados en este proyecto provienen de un estudio previo realizado por el docente director del trabajo, enfocado en la evaluación de la información mutua entre señales EDA y EEG bajo condiciones de tareas cognitivas múltiples y privación de sueño [14]. Estos datasets representan un conjunto de datos fisiológicos multimodales que capturan respuestas autonómicas y corticales en escenarios que simulan estrés inducido por fatiga cognitiva y falta de descanso, permitiendo modelar la dinámica temporal de la activación simpática y neuronal asociada al estrés.

El estudio involucró a 10 participantes sanos (7 hombres, edades entre 25 y 35 años), sin trastornos del sueño previos, quienes fueron sometidos a un protocolo de adquisición de datos que abarcó un período de 25 horas. Este diseño prioriza la monitorización continua para capturar variaciones fisiológicas inducidas por la privación de sueño, con sesiones de adquisición cada dos horas, resultando en 12 ensayos por participante. Los participantes llegaron al sitio experimental dentro de las dos horas posteriores a su despertar habitual y completaron un cuestionario para verificar la calidad y cantidad de sueño previo, asegurando una línea base controlada. La privación de sueño se implementó manteniendo la vigilia durante las horas nocturnas, lo que permite caracterizar el impacto acumulativo de la fatiga en las señales fisiológicas, diferenciando estados de alerta inicial de aquellos con deterioro cognitivo progresivo.

Las tareas cognitivas realizadas en cada sesión fueron diseñadas para inducir cargas mentales variables, simulando episodios de estrés cognitivo y emocional. Estas incluyen:

- **Tarea de Conciencia de Errores (EAT, por sus siglas en inglés):** Duración de 5 minutos, donde los participantes observan secuencias de nombres de colores impresos en letras coloreadas, presionando un botón para coincidencias ("Go") y absteniéndose en casos de no coincidencia o repetición ("No Go"). Las imágenes se presentan por 900 ms con intervalos de 600 ms, evaluando la inhibición y la atención selectiva.

- **Tarea N-Back:** Duración de 10 minutos, involucrando la identificación de tonos auditivos (de diferentes frecuencias y duraciones) que coinciden con el n -ésimo anterior, con complejidad ajustable basada en el rendimiento. Esto permite modelar la memoria de trabajo y la carga cognitiva.
- **Búsqueda de Barco:** Duración de 20 minutos, donde los participantes identifican verbalmente la posición de un barco en una pantalla interactiva que simula una vista de periscopio, presionando la barra espaciadora al detectarlo. Así, se evalúa la vigilancia sostenida y la respuesta motora bajo fatiga.
- **Tarea de Vigilancia Psicomotora (PVT):** Duración de 10 minutos, requiriendo una respuesta rápida al clic del ratón (*mouse*) ante la aparición de un número en pantalla (intervalos aleatorios entre 2 y 10 segundos). Esto caracteriza conceptualmente la velocidad de reacción y la habilidad atencional.

El orden de las tareas en cada sesión (EAT, Búsqueda de Barco, N-Back, PVT) se mantuvo constante, comenzando a las 10 a.m., para estandarizar la progresión de la fatiga. Los datasets se almacenan en formato “.mat”, uno por participante, facilitando la extracción modular de señales para análisis individual o agregado. Esta estructura permite un modelado matemático adaptable, donde se extraen segmentos temporales de las señales para caracterizar patrones de estrés, considerando la variabilidad interindividual en respuestas simpáticas y corticales.

Manipulación inicial de los datasets

Una vez cargados los datasets, se ha seleccionado un participante específico para facilitar un manejo preliminar de los datos, permitiendo una interpretación detallada de su estructura y contenido. Esta selección busca optimizar el proceso de exploración, identificando patrones fisiológicos individuales que puedan generalizarse posteriormente, alineándose con el objetivo específico de preprocesar los datasets para la extracción de características.

Las señales EDA y ECG se caracterizan por una matriz de dimensiones (15, 12), donde las filas representan las tareas cognitivas (desde la tarea 0 hasta la 14), y las columnas corresponden a las tomas temporales (desde la toma 0 hasta la 11). Esta estructura permite modelar la evolución de la activación simpática a lo largo de sesiones repetidas, facilitando la segmentación temporal para aislar respuestas fásicas y tónicas asociadas al estrés. Por su parte, la señal EEG presenta una dimensión inicial de (1, 9), con las columnas indicando los 9 canales de adquisición (desde el canal 0 hasta el 8). Al acceder a cada canal, se revela una submatriz de dimensiones (15, 12), alineada con las mismas tareas y tomas que la EDA y ECG, lo que habilita un análisis multimodal sincronizado, modelando interacciones entre actividad cortical y periférica mediante correlaciones temporales ajustadas.

Teniendo en cuenta lo anterior, se optó por seleccionar las tareas 1 y 2 para las tres señales, incorporando todas sus 12 tomas correspondientes, para conocer la dimensión de cada una de estas tomas, es necesario conocer la frecuencia de muestreo empleada en cada tipo de señal y así, se puede establecer la duración de estas (dicha información se evidencia en la tabla 5.1). Esta elección prioriza un subconjunto de datos que simula cargas cognitivas variables, permitiendo validar la extracción de características en escenarios controlados. Utilizando la librería Neurokit2 para la manipulación de la señal EDA y la señal ECG, se realiza la descomposición en componentes tónicos y fásicos, así como actividad cardiovascular, respectivamente, extrayendo características temporales como la media y desviación estándar. De manera similar, con la librería MNE para EEG, se diseña un preprocesamiento para calcular características espectrales en sus diferentes bandas y la asimetría frontal, con base a las regiones (canales) frontales de ambos hemisferios (izquierdo y derecho) cerebrales.

Tabla 5.1. Información de los Datasets

Dataset	Tarea	Dimensión	Frecuencia Muestreo [Hz]	Duración [s]
EDA	1	(144001, 1)	400	360
ECG	1	(144001, 1)	400	360
EEG	1	(72001, 1)	200	360
EDA	2	(120001, 1)	400	300
ECG	2	(120001, 1)	400	300
EEG	2	(60001, 1)	200	300

5.2. Extracción de Características

La selección y diseño de las características se realizó considerando tanto la validez fisiológica como la relevancia discriminativa frente a estados de estrés. Para ello, se implementó un procedimiento exploratorio donde se calcularon inicialmente múltiples métricas temporales, espectrales y no lineales a partir de cada ventana, evaluando su comportamiento en función de las tareas y tomas experimentales. Posteriormente, se descartaron aquellas variables redundantes o de baja variabilidad intersujeto, priorizando aquellas con evidencia científica de correlación con el arousal simpático (EDA), la modulación autonómica (ECG) y la activación cortical (EEG). Este filtrado inicial permitió reducir la dimensionalidad sin comprometer la representatividad fisiológica de cada modalidad.

Además, se adoptó un enfoque de extracción guiado por interpretación, donde cada característica responde a un mecanismo fisiológico específico y medible. En el caso de la EDA, las métricas asociadas a la frecuencia y amplitud de las respuestas fásicas reflejan directamente la intensidad y frecuencia de la activación simpática. Para el ECG, las variables derivadas de la variabilidad de la frecuencia cardíaca (HRV) capturan la capacidad adaptativa del sistema nervioso autónomo frente al estrés. Finalmente, en la señal EEG, las potencias relativas en bandas alfa y beta y la asimetría frontal fueron seleccionadas por su relación comprobada con el esfuerzo cognitivo y la regulación emocional. Este proceso integral asegura que

cada conjunto de características no solo optimice el desempeño analítico de los modelos, sino que conserve una interpretación fisiológicamente coherente con la respuesta al estrés.

Para la extracción de características de las señales fisiológicas se implementó un esquema basado en ventanas deslizantes con una duración fija de 40 segundos y un solapamiento del 50% entre ventanas consecutivas. Este enfoque permite capturar la dinámica temporal de las señales sin perder continuidad en la información, al mismo tiempo que evita que los cálculos se vean afectados por cambios abruptos o ruido local. En términos generales, el uso de ventanas superpuestas contribuye a obtener un mejor balance entre resolución temporal y estabilidad de las características extraídas.

La selección de un tamaño de ventana de 40 segundos responde tanto a una recomendación metodológica del director del proyecto como a criterios técnicos derivados de la naturaleza de las señales empleadas. En este caso, las señales EDA, EEG y ECG fueron registradas de manera simultánea durante las tareas experimentales con duraciones de 360 s y 300 s, lo que asegura una sincronización temporal entre las tres señales. De esta forma, utilizar un mismo tamaño de ventana para todos los tipos de señal garantiza que las características calculadas sean comparables en el tiempo, facilitando su integración posterior en un *dataset* multimodal.

Adicionalmente, el tamaño seleccionado proporciona un equilibrio adecuado entre dos necesidades opuestas: por un lado, ventanas cortas permiten una alta resolución temporal, capturando variaciones rápidas en la respuesta fisiológica; por otro, ventanas más largas favorecen la estabilidad estadística de las métricas calculadas, especialmente en variables derivadas de la actividad autonómica o de ritmos neuronales. En el caso de la EDA, intervalos de 30 a 60 s suelen ser suficientes para reflejar cambios en la conductancia de la piel asociados al estrés o la excitación. De manera similar, para el análisis de EEG y ECG, un periodo de 40 s es suficiente para obtener medidas representativas de la actividad oscilatoria y del comportamiento cardíaco, respectivamente. Estas ventanas son procesadas de manera independiente para cada tipo de señal, y posteriormente los resultados se integran en un único conjunto de datos con el fin de realizar el análisis conjunto mediante técnicas no supervisadas como k-means, donde se busca identificar patrones fisiológicos asociados a la presencia o ausencia de estrés.

Características extraídas por tipo de señal

La etapa de extracción de características constituye un paso crítico en la construcción del modelo, ya que permite transformar las señales fisiológicas brutas en descriptores cuantificables del estado de activación del sistema nervioso. En este estudio, el proceso se realizó a partir de las señales EDA, EEG y ECG previamente preprocesadas, segmentadas mediante ventanas deslizantes de duración constante para garantizar la homogeneidad temporal en el análisis. Cada segmento fue procesado individualmente para calcular indicadores estadísticos, temporales y

espectrales, los cuales capturan tanto la dinámica general como las fluctuaciones rápidas asociadas a la respuesta al estrés. Este procedimiento busca representar de forma compacta la información contenida en cada señal, reduciendo el ruido y preservando los patrones fisiológicos relevantes para la clasificación posterior mediante modelos de machine learning.

Con el fin de asegurar una adecuada correspondencia fisiológica entre las variables extraídas y los mecanismos subyacentes al estrés, se seleccionaron parámetros respaldados por la literatura y validados en estudios previos sobre activación autonómica y carga cognitiva. Las características finales fueron agrupadas por tipo de señal, de acuerdo con su dominio de representación y su relación con los procesos fisiológicos involucrados.

Para la ejecución del proceso de extracción y cálculo de características se emplearon librerías especializadas en análisis de señales fisiológicas, seleccionadas por su robustez y amplia validación en entornos científicos. En el caso de la señal EEG, se utilizó el paquete MNE-Python, el cual ofrece un marco estandarizado para el manejo de datos multicanal y el procesamiento avanzado de neuroseñales. Esta herramienta permitió realizar operaciones fundamentales como la filtración en bandas de interés (delta, theta, alfa, beta y gamma), la referenciación común y la estimación de la Densidad Espectral de Potencia (PSD) mediante el método de Welch, con ventanas solapadas para reducir la varianza espectral y obtener una representación estable de la potencia en frecuencia. Este enfoque garantizó una cuantificación adecuada de las oscilaciones corticales asociadas al esfuerzo cognitivo y la activación emocional.

Para las señales EDA y ECG se utilizó la librería NeuroKit2, la cual facilita la extracción automatizada de parámetros fisiológicos mediante algoritmos validados en estudios psicofisiológicos recientes. En el caso de la EDA, se implementó la descomposición cvxEDA, que separa la señal en sus componentes tónico (SCL) y fásico (SCR) mediante optimización convexa, permitiendo obtener medidas como la amplitud media, la frecuencia de respuestas fásicas y el área bajo la curva de activación simpática. Para la ECG, NeuroKit2 permitió derivar métricas de variabilidad de la frecuencia cardíaca (HRV) tanto en el dominio temporal como en el frecuencial, asociadas al balance entre las ramas simpática y parasimpática del sistema nervioso autónomo.

Señal EDA

A partir de la descomposición en sus componentes tónico y fásico se extrajeron las siguientes características:

- **Media y desviación estándar:** representan el nivel promedio de conductancia y su variabilidad dentro de la ventana, ofreciendo una medida del tono autonómico basal.

- **scr_count:** número de respuestas fásicas (Skin Conductance Responses) detectadas en el intervalo, asociado con la frecuencia de activación simpática.
- **scr_amp_mean:** amplitud media de las SCRs, indicador de la intensidad de la respuesta fisiológica.
- **scr_rise_mean:** tiempo promedio de ascenso de las SCRs, relacionado con la rapidez del sistema simpático para reaccionar ante estímulos estresores.

Estas características fueron seleccionadas por su alta sensibilidad frente a variaciones del arousal emocional y cognitivo. No obstante, para el análisis multimodal y la posterior aplicación de *k-means*, se priorizaron las variables *scr_count*, *scr_amp_mean* y *scr_rise_mean*, las cuales encapsulan la dinámica fásica de la señal EDA con un balance adecuado entre información fisiológica y reducción de dimensionalidad.

Señal ECG

El electrocardiograma (ECG) permite evaluar la actividad cardiovascular modulada por el equilibrio entre los sistemas simpático y parasimpático. La variabilidad de la frecuencia cardíaca (HRV) se ha reconocido como un marcador robusto de estrés fisiológico, por lo cual se extrajeron los siguientes parámetros:

- **hr_mean:** frecuencia cardíaca media, que refleja la demanda metabólica global y el nivel general de activación.
- **hrv_rmssd:** raíz cuadrada de la media de las diferencias sucesivas entre intervalos RR, indicador de la actividad parasimpática y de la capacidad adaptativa del sistema nervioso autónomo.
- **hrv_lfhf:** relación entre las bandas de baja y alta frecuencia del espectro de HRV, que estima el balance simpático-parasimpático.

La combinación de estas tres métricas captura el comportamiento oscilatorio del ritmo cardíaco, integrando componentes de corto y largo plazo del control autónomo. Desde un punto de vista analítico, fueron seleccionadas para el dataset final por su complementariedad: *hr_mean* aporta una medida global de activación, mientras *hrv_rmssd* y *hrv_lfhf* permiten discriminar patrones de estrés a través de la regulación autónoma.

Señal EEG

La electroencefalografía (EEG) proporciona información directa sobre la actividad cortical y su modulación ante estímulos cognitivos. A partir de las nueve señales de canal disponibles, se calcularon las potencias relativas en las cinco bandas de frecuencia convencionales (delta, theta, alfa, beta y gamma), además de la asimetría frontal, como medida de desequilibrio entre hemisferios cerebrales. Entre todas las características derivadas, se priorizaron las siguientes para el análisis multimodal:

- **potencia_alfa_canal0 y potencia_alfa_canal1:** representan la energía promedio en la banda alfa (8–13 Hz) de los canales frontales izquierdo y derecho, respectivamente. La literatura reporta que la supresión de la actividad alfa está asociada con aumento del esfuerzo mental y estrés.
- **asim_frontal:** diferencia normalizada entre las potencias alfa de ambos hemisferios frontales, vinculada con la lateralización emocional y el procesamiento de la carga cognitiva.

La inclusión de estas variables permite capturar la modulación cortical relacionada con el estrés sin incrementar excesivamente la dimensionalidad del espacio de características.

Cada tipo de señal aporta una perspectiva complementaria sobre el estado fisiológico del individuo: EDA representa la respuesta periférica simpática, ECG la regulación autonómica y EEG la actividad cortical. Por ello, la integración de las tres modalidades en un único dataset posibilita una descripción multimodal coherente del fenómeno del estrés. La selección final de tres características por señal responde tanto a fundamentos fisiológicos (preservar los descriptores más representativos de cada sistema) como a criterios analíticos (reducir la dimensionalidad y evitar redundancias antes de aplicar *k-means*). Así, el dataset multimodal final mantiene un balance entre interpretabilidad y capacidad discriminativa, optimizando la identificación de posibles patrones de estrés mediante aprendizaje no supervisado.

5.3. Etiquetado y estructura del *dataset* resultante

Una vez obtenidas las características representativas de cada modalidad fisiológica (EDA, ECG y EEG), se procedió a la integración de la información en un único dataset estructurado. Para garantizar la correspondencia temporal entre las tres señales, la unión se realizó considerando tres columnas informativas comunes: tarea, toma y ventana. De esta manera, cada fila del dataset corresponde a un segmento temporal simultáneo de las tres señales, preservando la sincronía entre respuestas corticales, autonómicas y periféricas. Esta estrategia permitió aplicar la técnica de *merge* de la librería *pandas* con un criterio de combinación directa, obteniendo una base coherente y alineada.

Previo a la etapa de etiquetado, las variables fueron sometidas a un proceso de escalado mediante *StandardScaler*, con el fin de homogeneizar las magnitudes entre características de distinta naturaleza fisiológica. Este paso resulta esencial en algoritmos basados en distancia, como *k-means*, ya que evita que atributos de gran escala (por ejemplo, potencias espectrales o amplitudes fásicas) dominen el cálculo de similitud, garantizando una contribución equilibrada de todas las señales en el espacio de características.

Para la generación de etiquetas, se implementó el algoritmo de agrupamiento *k-means*, con un número de clústeres $k = 2$, correspondiente a la hipótesis binaria del estudio: presencia o ausencia de estrés. Este enfoque se fundamenta en que los

estados de estrés y no estrés generan patrones diferenciables en la combinación multimodal de las señales, incluso sin disponer de etiquetas previas. Así, el método *k-means* permite descubrir agrupamientos naturales en el espacio de nueve dimensiones (tres características por señal), empleando la distancia euclidiana como métrica de similitud. Cada instancia fue asignada a uno de los dos clústeres generados, los cuales se interpretaron como 0 = no estrés y 1 = estrés, de acuerdo con la distribución y coherencia fisiológica de los valores promedio por grupo.

El procedimiento se aplicó de manera independiente para cada tarea (Tarea 1 y Tarea 2), con el propósito de evaluar si los patrones obtenidos eran consistentes entre contextos experimentales de distinta duración y carga cognitiva. El resultado fueron dos datasets finales (uno por tarea), cada uno compuesto por:

- Tres columnas informativas (*tarea*, *toma*, *ventana*),
- Nueve columnas de características (las tres seleccionadas por cada tipo de señal), y
- Una columna de etiqueta binaria (*etiqueta_estres*).

Cabe destacar que durante la consolidación del dataset se identificaron valores faltantes en la característica *hrv_lfhf* de la señal ECG. Aunque estos fueron imputados para evitar pérdida de información, el impacto de dicha imputación y su posible influencia en la consistencia del etiquetado serán analizados en la sección de Resultados y Discusión.

5.4. Implementación de los Modelos

Una vez estructurados los datasets correspondientes a cada tarea, y generadas las etiquetas de estrés mediante el algoritmo *k-means*, se procedió con la implementación de modelos de clasificación supervisados, con el objetivo de determinar la capacidad discriminativa de las características extraídas de la señal EDA para la identificación de episodios de estrés. Este enfoque se plantea en coherencia con el objetivo principal del proyecto, el cual busca analizar el aporte de las respuestas electrodérmicas en la detección del estrés, considerando que las señales EEG y ECG ya cuentan con abundante evidencia en la literatura científica.

Selección de los modelos

Se seleccionaron tres algoritmos de clasificación ampliamente utilizados en el ámbito del aprendizaje automático y del análisis de señales fisiológicas: Árboles de Decisión, Máquinas de Vectores de Soporte (SVM) y K-Nearest Neighbors (KNN). Estos modelos fueron escogidos no solo por su efectividad comprobada en tareas de clasificación binaria, sino también por su capacidad de adaptación a datasets con un número moderado de muestras, como es el caso del presente estudio. El modelo de Árboles de Decisión se caracteriza por su naturaleza interpretativa y su habilidad para capturar relaciones no lineales entre las variables. Este enfoque es particularmente útil cuando se trabaja con características fisiológicas, ya que dichas variables no suelen mantener relaciones lineales estrictas. Por su parte, el modelo

SVM permite establecer fronteras de decisión óptimas en espacios de alta dimensionalidad mediante el uso de funciones núcleo (*kernel*), lo que lo convierte en una herramienta importante para distinguir patrones fisiológicos entre estados de estrés y no estrés. Finalmente, KNN se emplea como un modelo basado en similitud, el cual clasifica las observaciones de acuerdo con la cercanía a sus vecinos más próximos en el espacio de características. Su simplicidad y su enfoque en la distribución local de los datos lo convierten en un referente comparativo ideal frente a modelos más complejos.

Cabe resaltar que los tres modelos fueron entrenados únicamente con las características de la señal EDA (*scr_count*, *scr_amp_mean* y *scr_rise_mean*). Esta decisión responde a la necesidad de evaluar el potencial autónomo de dicha señal para representar de forma efectiva los cambios fisiológicos asociados al estrés, sin depender de información proveniente de otras modalidades. En este sentido, la EDA constituye el núcleo experimental del estudio.

Preparación de los datos

Previo al entrenamiento, los datasets fueron preprocesados mediante un escalamiento estándar utilizando el método `StandardScaler`, con el propósito de normalizar la distribución de las características y evitar sesgos derivados de diferencias en magnitud entre las variables. Este paso es esencial en modelos sensibles a la escala, como SVM y KNN, donde la distancia euclidiana y el margen de separación se ven directamente influenciados por la amplitud de las características.

Para garantizar la reproducibilidad de los experimentos y permitir una evaluación adecuada entre modelos, los datos se dividieron mediante la función `train_test_split` en dos subconjuntos: 80% para entrenamiento y 20% para validación. Esta proporción asegura un número suficiente de muestras para el ajuste del modelo, manteniendo al mismo tiempo un conjunto independiente para evaluar su rendimiento. Además, se realizaron los experimentos de manera independiente para los datasets correspondientes a la Tarea 1 y la Tarea 2, con el fin de analizar la consistencia de los modelos ante variaciones contextuales y temporales en la adquisición de las señales.

Optimización de hiperparámetros mediante `GridSearchCV`

Una parte fundamental del proceso de implementación consistió en la búsqueda y ajuste de hiperparámetros para cada modelo, empleando la herramienta `GridSearchCV` de la biblioteca *scikit-learn*. Este método realiza una búsqueda sobre un espacio predefinido de combinaciones de parámetros, evaluando el rendimiento de cada configuración mediante un esquema de validación cruzada. En este caso, se utilizó una validación cruzada *k-fold* con $k = 5$, lo que implica que el conjunto de entrenamiento se dividió en cinco subconjuntos (o “folds”) y, en cada iteración, uno de ellos se utiliza para validación mientras los cuatro restantes se destinan al entrenamiento. El rendimiento final del modelo se calcula como el promedio de las

cinco repeticiones, lo cual minimiza el efecto del azar y proporciona una estimación más estable del desempeño real.

La métrica seleccionada para la evaluación durante la búsqueda fue *roc_auc*, correspondiente al área bajo la curva ROC (*Receiver Operating Characteristic*). Esta métrica es ampliamente reconocida por su capacidad para medir la habilidad de un modelo en distinguir entre clases, especialmente cuando los datos presentan posibles desequilibrios o diferencias sutiles entre las etiquetas, como ocurre en fenómenos fisiológicos relacionados con el estrés.

Cada modelo contó con una grilla de hiperparámetros ajustada a su naturaleza:

- **Árbol de Decisión:** se exploraron parámetros como *max_depth* (profundidad máxima del árbol), *criterion* (función de impureza: *gini* o *entropy*) y *min_samples_split* (número mínimo de muestras requeridas para dividir un nodo).
- **SVM:** se variaron los parámetros *C* (regularización), *kernel* (lineal, polinómico, radial o sigmoidal) y *gamma* (coeficiente del kernel RBF), con el fin de ajustar el balance entre el margen y la complejidad del modelo.
- **KNN:** se probaron distintas combinaciones de *n_neighbors* (cantidad de vecinos considerados), *weights* (uniforme o ponderado por distancia) y *metric* (métrica de distancia euclidiana o manhattan).

La búsqueda de hiperparámetros permitió identificar la configuración óptima para cada modelo con base en el mayor valor promedio de *ROC AUC* obtenido en la validación cruzada. Posteriormente, los modelos con la mejor configuración fueron reentrenados sobre el conjunto completo de entrenamiento (80%) y evaluados sobre el conjunto de prueba (20%), obteniendo así las métricas de rendimiento.

El uso de GridSearchCV no solo contribuye a mejorar el rendimiento de los clasificadores, sino que también representa un mecanismo de control de sesgo y varianza. Al realizar múltiples particiones y evaluar sistemáticamente todas las combinaciones posibles de hiperparámetros, se reduce la probabilidad de seleccionar un modelo sobreajustado (*overfitted*) a un subconjunto específico de datos. Este proceso también permite comparar de manera objetiva los modelos bajo un mismo criterio de evaluación y con el mismo número de validaciones internas, garantizando la validez estadística de los resultados obtenidos.

5.5. Evaluación de los Modelos

El desempeño de los modelos implementados se evaluó a partir de un conjunto de métricas que permiten cuantificar la capacidad de discriminación entre los estados fisiológicos de *estrés* y *no estrés*, generados a partir del algoritmo no supervisado *k-means*. La evaluación se realizó de manera independiente para cada una de las tareas (Tarea 1 y Tarea 2), obteniendo así un total de seis resultados, correspondientes a cada uno de los tres modelos supervisados Árboles de Decisión, SVM y KNN con cada una de las tareas.

Las métricas seleccionadas fueron: Precisión (Accuracy), Precisión Positiva (Precision), Sensibilidad (Recall), F1-Score, ROC-AUC, así como los valores promedio de Precisión(Accuracy) y F1-Score calculados mediante validación cruzada con $cv = 5$. Estas métricas se calcularon sobre el conjunto de prueba (20% de los datos), utilizando las predicciones obtenidas por cada modelo tras su entrenamiento con los hiperparámetros óptimos determinados por *GridSearchCV*. En el caso de las métricas basadas en validación cruzada, se evaluó el desempeño global del modelo considerando todas las particiones de entrenamiento, lo cual aporta una estimación más amplia y menos dependiente de una sola división de los datos.

Adicionalmente, con el fin de representar de manera visual el desempeño de los modelos, se implementaron diversas gráficas que complementan el análisis cuantitativo. Entre ellas se incluyen:

- **Curvas ROC comparativas** para cada modelo, donde se contrasta el *train score* con el *cross-validation score* obtenido en el proceso de optimización, permitiendo observar el balance entre ajuste y generalización.
- **Curvas ROC finales** de los tres modelos entrenados con sus mejores hiperparámetros, mostrando la capacidad discriminativa de cada uno frente al conjunto de prueba.
- **Matriz de confusión**, que permite analizar la distribución de aciertos y errores en las predicciones, distinguiendo los verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos.
- **Regiones de decisión**, generadas mediante la reducción de dimensionalidad por *PCA* de las tres características de la señal EDA a un espacio bidimensional. Estas visualizaciones, construidas con la función *plot_decision_regions*, permiten ilustrar de forma aproximada la forma en que los modelos SVM y KNN delimitan las fronteras de clasificación entre estados de estrés y no estrés. En el caso del modelo de Árboles de Decisión, se empleó la función *plot_tree* para visualizar la estructura jerárquica y la profundidad de las divisiones generadas por el clasificador.

Este conjunto de métricas y visualizaciones permite no solo comparar el rendimiento entre modelos, sino también entre las dos tareas, identificando posibles diferencias en la calidad de las etiquetas o en la capacidad discriminativa de las características extraídas de la señal EDA.

6. Resultados y Discusión

Previo a la exposición de los resultados obtenidos en las diferentes tareas, es importante destacar la distribución de clases presente en cada conjunto de datos, dado que este aspecto puede incidir directamente en el desempeño de los modelos de aprendizaje automático implementados. En el caso de la Tarea 1, la clase 0 (No Estrés) cuenta con 103 muestras, mientras que la clase 1 (Estrés) presenta 101 muestras, configurando un conjunto de datos relativamente balanceado. En contraste, la Tarea 2 exhibe una desproporción notable, con 26 muestras para la clase No Estrés y 142 para la clase Estrés, lo que representa un desequilibrio de aproximadamente 84% a favor de la clase positiva. Esta diferencia en la cantidad de observaciones entre tareas implica que cada conjunto posee una densidad de datos distinta, situación que potencialmente puede afectar la capacidad de generalización y el comportamiento de las métricas de rendimiento de los modelos, especialmente en escenarios donde la clase minoritaria es relevante para la identificación del fenómeno de interés.

Adicionalmente, en los modelos SVM y KNN se realizó una representación gráfica de las regiones de decisión con el propósito de ofrecer una visualización del funcionamiento del clasificador en el espacio de características. Sin embargo, dado que ambos modelos fueron entrenados con tres características, se aplicó una reducción de dimensionalidad mediante Análisis de Componentes Principales (PCA) para proyectar los datos en dos dimensiones. En consecuencia, las gráficas obtenidas no reflejan de manera exacta el proceso de clasificación original en el espacio tridimensional, pero permiten observar de forma aproximada la distribución de las clases y los límites de decisión estimados por cada modelo, constituyéndose en un recurso visual de apoyo para la interpretación de los resultados

6.1. Árbol de Decisión

6.1.1. Tarea 1

La configuración óptima del Árbol de Decisión para la Tarea 1 fue: `criterion = 'gini'`, `max_depth = 3`, `min_samples_leaf = 2` y `min_samples_split = 10`. Esto significa que el modelo utiliza el índice de Gini para evaluar la calidad de cada división, buscando reducir la impureza entre las clases de estrés y no estrés de manera eficiente. Además, limita la profundidad del árbol a solo 3 niveles, lo que evita que se vuelva excesivamente complejo y se ajuste demasiado a los datos de entrenamiento (sobreajuste). También exige que cada hoja final contenga al menos 2 muestras, garantizando que las decisiones finales se basen en evidencia suficiente, y solo permite dividir un nodo si tiene al menos 10 muestras, previniendo divisiones en grupos pequeños y ruidosos.




Figura 6.1. Curva Validación Árbol de Decisión Tarea 1.

La curva presente en la figura 6.1 muestra el desempeño del modelo al variar la profundidad máxima del árbol. El score de entrenamiento (Train AUC) aumenta progresivamente hasta estabilizarse cerca de 1.0, mientras que el score de validación cruzada (Cross-val AUC) alcanza su máximo en `max_depth = 5` con un valor de 0.715. Este comportamiento sugiere que profundidades superiores no aportan mejoras significativas y, por el contrario, inducen un posible sobreajuste, dado que el rendimiento en validación disminuye pese al incremento en la complejidad del modelo.




Figura 6.2. Curvas ROC entre Árboles de Decisiones Tarea 1.

La figura 6.2 expone las curvas ROC para diferentes profundidades (3, 5, 7, 15). El modelo con profundidad 3 obtiene el mejor AUC (0.804), seguido por profundidad 5 (0.682) y 7 (0.638). Profundidades mayores (15) reducen el AUC a 0.661, este resultado confirma que la generalización del modelo se optimiza cuando se restringe su complejidad, evitando divisiones excesivas que tienden a ajustar ruido del conjunto de entrenamiento.




Figura 6.3. Matriz de Confusión Árbol de Decisión Tarea 1.

La matriz 3 revela 14 verdaderos negativos (TN), 16 verdaderos positivos (TP), 7 falsos positivos (FP) y 4 falsos negativos (FN). El modelo tiende a sobreclasificar la condición de estrés (30.43 % de falsos positivos), pero mantiene una alta tasa de detección de episodios reales (80 %) (Ver figura 6.3).




Figura 6.4. Árbol de Decisión Tarea 1.

La estructura del Árbol de Decisión resultante, cuyo esquema se evidencia en la figura 6.4, presenta una profundidad efectiva de tres niveles. El nodo raíz realiza la primera partición según el umbral $\text{scr_amp_mean} \leq 0.683$, correspondiente a una característica física de la señal EDA que cuantifica la amplitud media de las respuestas de conductancia de la piel (SCR). Los niveles subsiguientes incorporan las variables scr_count , scr_rise_mean y nuevamente scr_amp_mean , evidenciando que los parámetros asociados a las respuestas galvánicas físicas constituyen los principales predictores del estado de estrés en ventanas de análisis de cinco minutos. Este resultado coincide con la literatura que asocia un incremento en la frecuencia y amplitud de las SCR con una mayor activación simpática, reflejando así la respuesta fisiológica ante estímulos estresores.

Tabla 6.1. Rendimiento del Árbol de Decisión en la Tarea 1.

Métricas	Resultado
Accuracy	0.7317
F1-Score	0.7442
Sensibilidad	0.8000
Precisión	0.6957
ROC-AUC	0.8036
Precisión Media (CV)	0.6676
F1-Score Medio (CV)	0.5573

Los resultados obtenidos en el conjunto de prueba y que se presentan en la tabla 6.1 evidencian un rendimiento satisfactorio considerando el tamaño reducido del dataset. La precisión global (accuracy) alcanzó un valor de 73.17 %, mientras que el F1-score fue de 0.7442, reflejando un equilibrio adecuado entre precisión y sensibilidad. La sensibilidad (recall) del 80.00 % indica que el modelo identificó correctamente 16 de los 20 episodios de estrés reales, lo cual demuestra una adecuada capacidad para detectar la clase positiva. Asimismo, el AUC-ROC de 0.8036 confirma una capacidad discriminativa robusta entre los estados de estrés y no estrés. En cuanto a la validación cruzada (5-fold), se obtuvo una precisión media de 66.76 % y un F1-score medio de 0.5573, lo que sugiere una generalización moderada, posiblemente afectada por la variabilidad intersujeto y el número limitado de muestras disponibles para el entrenamiento del modelo.

6.1.2. Tarea 2

La configuración óptima del Árbol de Decisión para la Tarea 2 fue: $\text{criterion} = \text{'entropy'}$, $\text{max_depth} = 5$, $\text{min_samples_leaf} = 1$ y $\text{min_samples_split} = 2$. Esto refleja que, en esta tarea, el modelo necesitó mayor flexibilidad para capturar patrones más complejos y específicos en ventanas de 1 minuto. El uso de entropía permite divisiones más finas al penalizar de forma más estricta la mezcla de clases, mientras que una profundidad de 5 niveles y requisitos mínimos muy bajos (1 muestra por hoja y 2 para dividir) habilitan un árbol más detallado. Este resultado se explica por el desbalance de clases (85 % estrés), al haber más muestras de estrés, el modelo puede permitirse ramificaciones profundas sin riesgo inmediato de

sobreajuste, priorizando la detección precisa de la clase dominante a costa de generalización en la minoritaria.




Figura 6.5. Curva de Validación Árbol de Decisión Tarea 2.

La figura 6.5 ilustra el desempeño al variar la profundidad máxima. El score de entrenamiento (Train AUC) crece rápidamente hasta cerca de 1.0, mientras que el score de validación cruzada (Cross-val AUC) alcanza su mínimo en `max_depth = 5` con un valor de 0.564. Profundidades mayores no mejoran la generalización, confirmando la selección óptima.




Figura 6.6. Curvas ROC entre Árboles de Decisiones Tarea 2.

La figura 6.6 permite comparar las curvas ROC para profundidades 3, 5, 7 y 15. El modelo con profundidad 5 logra el mejor AUC (0.676), seguido por profundidad 3 (0.666) y 7 (0.624). La profundidad 15 reduce el AUC a 0.548, evidenciando sobreajuste. Todas las curvas se mantienen por debajo de 0.7, reflejando dificultad para discriminar la clase minoritaria.




Figura 6.7. Matriz de Confusión Árbol de Decisión Tarea 1.

La matriz de la figura 6.7 muestra 0 verdaderos negativos (TN), 26 verdaderos positivos (TP), 5 falsos positivos (FP) y 3 falsos negativos (FN). El modelo clasificó todas las muestras como estrés, fallando completamente en identificar la clase “No estrés”. Esto indica un sesgo severo hacia la clase mayoritaria, aunque mantiene una alta tasa de detección de episodios de estrés (89.66 %).




Figura 6.8. Árbol de Decisión Tarea 2.

El árbol resultante tiene una profundidad efectiva de 5 niveles y utiliza exclusivamente características físicas de la EDA, como se aprecia en la figura 6.8. El nodo raíz divide según $\text{scr_amp_mean} \leq 0.6761$, seguido por scr_rise_mean , scr_count y nuevamente scr_amp_mean . Los componentes amplitud media y tiempo de ascenso de las respuestas de conductancia de la piel (SCR) dominan las decisiones, reforzando su rol como marcadores rápidos de activación simpática en ventanas cortas.

Tabla 6.2. Rendimiento del Árbol de Decisión en la Tarea 2.

Métricas	Resultado
Accuracy	0.7647
F1-Score	0.8667
Sensibilidad	0.8966
Precisión	0.8387
ROC-AUC	0.6793
Precisión Media (CV)	0.7857
F1-Score Medio (CV)	0.8787

En la tabla 6.2 los resultados en el conjunto de prueba muestran un rendimiento superior al de la Tarea 1 en términos de precisión y F1-score. La precisión global (accuracy) alcanzó 76.47 %, con un F1-score de 0.8667 y una sensibilidad (recall) de 89.66 %, indicando que el modelo detectó correctamente 26 de los 29 episodios de estrés. Sin embargo, el AUC-ROC fue de 0.6793, menor que en la Tarea 1, reflejando una menor capacidad discriminativa global, posiblemente influida por el desbalance de clases (85 % de muestras de estrés). En validación cruzada, la precisión media fue de 78.57 % y el F1-score medio de 0.8787, valores superiores a los del conjunto de prueba, lo que sugiere una buena generalización a pesar del reducido número de muestras negativas.

6.2. SVM

6.2.1. Tarea 1

La configuración óptima del modelo SVM para la Tarea 1 fue: $\text{kernel} = \text{'poly'}$, $C = 0.1$ y $\text{gamma} = \text{'auto'}$. Esto indica que el clasificador utiliza un kernel polinómico para mapear los datos de EDA a un espacio de mayor dimensión donde las clases (estrés y no estrés) puedan separarse mediante un hiperplano no lineal. El valor bajo de $C = 0.1$ impone una penalización suave a los errores de clasificación, priorizando un margen amplio entre las clases en lugar de ajustarse estrictamente a cada punto, lo que reduce el riesgo de sobreajuste en un conjunto pequeño. Por su parte, $\text{gamma} = \text{'auto'}$ ajusta automáticamente la influencia de cada muestra de entrenamiento según la inversa del número de características, logrando un equilibrio adecuado para la escala de los datos fisiológicos.




Figura 6.9. Curva de Validación Modelo SVM Tarea 1.

La figura 6.9 ilustra el desempeño al variar el parámetro de regularización C en escala logarítmica. El score de entrenamiento (Train AUC) crece con C , alcanzando valores cercanos a 0.90, mientras que el score de validación cruzada (Cross-val AUC) tiene su máximo en $C = 0.1$ con 0.769, decreciendo posteriormente. Esto confirma que valores altos de C generan sobreajuste, especialmente con un kernel polinómico.




Figura 6.10. Curvas ROC entre Modelos SVM Tarea 1.

El mejor rendimiento corresponde al kernel polinómico con $C = 100$ ($AUC = 0.831$), seguido por RBF con $C = 10$ ($AUC = 0.824$) y $C = 1$ ($AUC = 0.812$). Sin embargo, la configuración seleccionada por GridSearchCV ($C = 0.1$, poly) obtuvo un AUC de 0.7655 en prueba, priorizando generalización sobre ajuste en entrenamiento (Figura 6.10).




Figura 6.11. Matriz de Confusión Modelo SVM Tarea 1.

En La figura 6.11 se observan 8 verdaderos negativos (TN), 17 verdaderos positivos (TP), 13 falsos positivos (FP) y 3 falsos negativos (FN). El modelo presenta una alta tasa de falsos positivos (61.90 % de las predicciones de estrés son erróneas), lo que reduce su especificidad, aunque mantiene una sensibilidad elevada (85 %).




Figura 6.12. Regiones de Decisión Modelo SVM Tarea 1.

La frontera de decisión del SVM con kernel polinómico visible en la figura 6.12 muestra una separación no lineal entre clases, aunque con cierta superposición en la región central.

Tabla 6.3. Rendimiento del Modelo SVM en la Tarea 1.

Métricas	Resultado
Accuracy	0.6098
F1-Score	0.6800
Sensibilidad	0.8500
Precisión	0.5667
ROC-AUC	0.7655
Precisión Media (CV)	0.5543
F1-Score Medio (CV)	0.4547

Teniendo en cuenta las métricas registradas en la tabla 6.3, el modelo alcanzó una precisión global (accuracy) de 60.98 %, con un F1-score de 0.6800 y una sensibilidad (recall) de 85.00 %, detectando 17 de los 20 episodios de estrés reales. La precisión positiva fue de 56.67 %, mientras que el AUC-ROC se situó en 0.7655, indicando una capacidad discriminativa aceptable. En validación cruzada, la precisión media fue de 55.43 % y el F1-score medio de 0.4547, reflejando una generalización limitada y alta variabilidad entre pliegues, posiblemente por el tamaño reducido del conjunto y la sensibilidad del modelo a la regularización.

6.2.2. Tarea 2

La configuración óptima del modelo SVM para la Tarea 2 fue: kernel = 'rbf', C = 100 y gamma = 0.001. Esto implica que el clasificador emplea un kernel de función de base radial (RBF), ideal para capturar relaciones no lineales complejas y localizadas en los patrones de EDA, especialmente en ventanas cortas donde las respuestas fásicas son más esporádicas y variables. El valor alto de C = 100 aplica una penalización fuerte a los errores de clasificación, generando un hiperplano ajustado estrechamente a los datos de entrenamiento y priorizando la separación precisa de la clase mayoritaria (estrés). Por su parte, gamma = 0.001 limita el alcance de influencia de cada muestra, creando fronteras de decisión más suaves y evitando que puntos aislados dominen la clasificación.




Figura 6.13. Curva de Validación Modelo SVM Tarea 2.

La figura 6.13 se muestra el desempeño al variar C en escala logarítmica. El score de entrenamiento (Train AUC) crece con C , superando 0.95 para $C \geq 100$, mientras que el score de validación cruzada (Cross-val AUC) alcanza su máximo en $C = 1$ con 0.660, cayendo levemente para valores mayores. La configuración seleccionada ($C = 100$) prioriza ajuste en entrenamiento, pero mantiene un AUC aceptable en validación.




Figura 6.14. Curvas ROC entre Modelos SVM Tarea 2.

En la figura 6.14 se comparan diferentes configuraciones RBF. El mejor AUC corresponde a $C = 1$ (AUC = 0.676), seguido por $C = 10$ (AUC = 0.621) y $C = 100$ (AUC = 0.517). La configuración óptima seleccionada ($C = 100$, $\gamma = 0.001$) no aparece en la leyenda, pero su AUC en prueba (0.7862) sugiere que el GridSearchCV encontró un punto de equilibrio entre ajuste y generalización no capturado en esta gráfica de ejemplo.




Figura 6.15. Matriz de Confusión Modelo SVM Tarea 2.

Como se aprecia en la figura 6.15, se registran 4 verdaderos negativos (TN), 15 verdaderos positivos (TP), 1 falso positivo (FP) y 14 falsos negativos (FN). El modelo es extremadamente conservador: solo predice estrés cuando está muy seguro (93.75 % de precisión positiva), pero omite más de la mitad de los episodios reales (48.28 % de falsos negativos). Este comportamiento es típico de un modelo con alto C y bajo γ , que prioriza un margen estrecho y penaliza fuertemente los errores.




Figura 6.16. Regiones de Decisión Modelo SVM Tarea 2.

Se observa en la figura 6.16 una frontera de decisión RBF suave y no lineal que separa claramente la mayoría de los puntos de la clase “Estrés” (triángulos naranjas) en la región izquierda, mientras que los puntos “No estrés” (cuadrados azules) se concentran en la derecha. La separación es más limpia que en Tarea 1, aunque con menos puntos de la clase minoritaria.

Tabla 6.4. Rendimiento del Modelo SVM en la Tarea 2.

Métricas	Resultado
Accuracy	0.5588
F1-Score	0.6667
Sensibilidad	0.5172
Precisión	0.9375
ROC-AUC	0.7862
Precisión Media (CV)	0.6194
F1-Score Medio (CV)	0.7100

Con respecto a la información de la tabla 6.4, el modelo obtuvo una precisión global (accuracy) de 55.88 %, con un F1-score de 0.6667 y una sensibilidad (recall) de 51.72 %, detectando solo 15 de los 29 episodios de estrés. Sin embargo, la precisión positiva fue muy alta (93.75 %), indicando que casi todas las predicciones de estrés fueron correctas. El AUC-ROC alcanzó 0.7862, el más alto entre todos los modelos en esta tarea, demostrando una excelente capacidad discriminativa a pesar del bajo recall. En validación cruzada, la precisión media fue de 61.94 % y el F1-score medio de 0.7100, valores superiores al rendimiento en prueba, sugiriendo que el modelo generaliza mejor de lo que indica el conjunto de prueba, posiblemente por la alta variabilidad en la distribución de clases del split de test.

6.3. KNN

6.3.1. Tarea 1

La configuración óptima del modelo KNN para la Tarea 1 fue: $n_neighbors = 15$, $weights = 'uniform'$ y $metric = 'manhattan'$. Esto significa que el clasificador toma la decisión final basándose en la mayoría de los votos de los 15 puntos más cercanos en el espacio de características EDA, sin dar mayor peso a los vecinos más próximos (voto uniforme). La distancia de Manhattan mide la cercanía sumando las diferencias absolutas entre características, lo que la hace más robusta frente a valores atípicos y variaciones en escalas de las señales fisiológicas, como picos en SCR o cambios en el componente tónico.




Figura 6.17. Curva de Validación Modelo KNN Tarea 1.

La figura 6.17 muestra el desempeño al variar k (número de vecinos). El score de entrenamiento (Train AUC) disminuye progresivamente desde 1.0 ($k=1$) hasta ~ 0.8 ($k=20$), mientras que el score de validación cruzada (Cross-val AUC) alcanza su máximo en $k = 15$, estabilizándose alrededor de 0.75. Valores bajos de k generan sobreajuste; valores altos suavizan excesivamente la frontera.




Figura 6.18. Curvas ROC entre Modelos KNN Tarea 1.

A continuación, se comparan diferentes valores de k . El mejor AUC corresponde a $k = 15$ (AUC = 0.824), seguido por $k = 10$ (AUC = 0.830) y $k = 5$ (AUC = 0.754), como se observa en la figura 6.18. La configuración óptima ($k = 15$) logra AUC = 0.8119 en prueba, confirmando robustez frente a ruido y variabilidad.




Figura 6.19. Matriz de Confusión Modelo KNN Tarea 1.

Teniendo en cuenta los resultados de la figura 6.19, se observan 17 verdaderos negativos (TN), 15 verdaderos positivos (TP), 4 falsos positivos (FP) y 5 falsos negativos (FN). El modelo presenta un equilibrio sobresaliente entre clases: alta sensibilidad (75 %) y baja tasa de falsos positivos (19.05 % de las predicciones de estrés son erróneas), superando a Árboles de Decisión y SVM en especificidad.




Figura 6.20. Regiones de Decisión Modelo SVM Tarea 1.

Por otra parte, en la figura 6.20 se observa una frontera de decisión fragmentada y no lineal típica de KNN con $k = 15$. Las regiones azules (“No estrés”) y naranjas (“Estrés”) muestran enclaves locales, reflejando la naturaleza basada en instancias del algoritmo. La separación es clara en la mayoría de los puntos, aunque con pequeñas islas de error.

Tabla 6.5. Rendimiento del Modelo KNN en la Tarea 1.

Métricas	Resultado
Accuracy	0.7805
F1-Score	0.7692
Sensibilidad	0.7500
Precisión	0.7895
ROC-AUC	0.8119
Precisión Media (CV)	0.6776
F1-Score Medio (CV)	0.6205

La tabla 6.5 nos indica que el modelo alcanzó la mejor precisión global de todos los modelos en la tarea 1: 78.05 %, con un F1-score de 0.7692, sensibilidad de 75.00 % (15 de 20 episodios de estrés detectados) y precisión positiva de 78.95 %. El AUC-ROC fue de 0.8119, el más alto en esta tarea, demostrando una excelente capacidad discriminativa. En validación cruzada, la precisión media fue de 67.76 % y el F1-score medio de 0.6205, indicando una generalización moderada, influida por el tamaño reducido del conjunto y la alta variabilidad inter-sujeto.

6.3.2. Tarea 2

La configuración óptima del modelo KNN para la Tarea 2 fue: `n_neighbors = 6`, `weights = 'distance'` y `metric = 'euclidean'`. Esto indica que el clasificador basa su decisión en los 6 puntos más cercanos, otorgando mayor peso a los vecinos más próximos (ponderación por distancia inversa), lo que intensifica la influencia de patrones muy similares. La distancia euclidiana calcula la cercanía como la longitud de la línea recta entre puntos en el espacio de características EDA, siendo sensible a la magnitud y dirección de las diferencias, ideal para capturar variaciones rápidas en respuestas fásicas como SCR en ventanas cortas.




Figura 6.21. Curva de Validación Modelo KNN Tarea 2.

La figura 6.21 muestra el desempeño al variar k . El score de entrenamiento (Train AUC) disminuye desde 1.0 ($k=1$) hasta ~ 0.7 ($k=20$), mientras que el score de validación cruzada (Cross-val AUC) tiene un máximo local en $k \approx 6-8$, estabilizándose alrededor de 0.6. La configuración óptima ($k=6$) se alinea con este pico.




Figura 6.22. Curvas ROC entre Modelos KNN Tarea 2.

En la figura 6.22 se comparan diferentes k , obteniendo que el mejor AUC corresponde a $k = 15$ (AUC = 0.607), seguido por $k = 10$ (AUC = 0.555) y $k = 6$ (AUC = 0.486). Aunque GridSearchCV seleccionó $k=6$ por F1-score, el AUC disminuye con valores bajos de k , confirmando el sesgo hacia la clase mayoritaria.




Figura 6.23. Matriz de Confusión Modelo KNN Tarea 2.

Para esta matriz, se registran 0 verdaderos negativos (TN), 28 verdaderos positivos (TP), 5 falsos positivos (FP) y 1 falso negativo (FN), como se observa en la figura 6.23. El modelo clasifica todas las muestras como estrés, fallando completamente en identificar la clase “No estrés”. Aunque detecta casi todos los episodios de estrés (96.55 %), comete 5 falsos positivos (100 % de las 5 muestras negativas).




Figura 6.24. Regiones de Decisión Modelo SVM Tarea 2.

Con $k = 6$, se observa una región dominante de “Estrés” (naranja) que engloba casi todo el espacio, con pequeñas islas azules aisladas. La frontera es altamente irregular y fragmentada, típica de KNN con pocos vecinos y desbalance extremo (Ver Figura 6.24).

Tabla 6.6. Rendimiento del Modelo KNN en la Tarea 2.

Métricas	Resultado
Accuracy	0.8325
F1-Score	0.9032
Sensibilidad	0.9655
Precisión	0.8485
ROC-AUC	0.4862
Precisión Media (CV)	0.7975
F1-Score Medio (CV)	0.8868

Finalmente, para los valores consignados en la tabla 6.6, el modelo logró una precisión global de 82.35 %, la más alta de todos los modelos en la tarea 2, con un F1-score de 0.9032 y una sensibilidad extremadamente alta de 96.55 % (28 de 29 episodios de estrés detectados). La precisión positiva fue de 84.85 %. Sin embargo, el AUC-ROC fue de 0.4862, el más bajo registrado, indicando una capacidad discriminativa pobre a pesar del alto accuracy. En validación cruzada, la precisión media fue de 79.75 % y el F1-score medio de 0.8868, valores cercanos al rendimiento en prueba, lo que sugiere consistencia, pero también una limitación inherente del modelo en este escenario.

6.4. Comparativa entre los Modelos y Contraste con la Literatura

Para sintetizar los resultados obtenidos, en la Tabla 6.7 se presenta un resumen comparativo del rendimiento de los tres modelos evaluados (Árbol de Decisión, SVM y KNN) en ambas tareas, considerando las métricas más representativas: exactitud (Accuracy), F1-Score y AUC-ROC.

Tabla 6.7. Resumen Comparativo entre los Modelos.

Modelo	Tarea 1			Tarea 2		
	Accuracy (%)	F1-score	AUC-ROC	Accuracy (%)	F1-score	AUC-ROC
Árbol de Decisión	73.17	0.7442	0.6957	76.47	0.8667	0.6793
SVM	60.98	0.6800	0.7655	55.88	0.6667	0.7862
KNN	78.05	0.7692	0.8119	82.35	0.9032	0.4862

En la Tarea 1 (clases balanceadas), KNN obtuvo el mejor rendimiento global con un AUC-ROC de 0.8119 y una exactitud del 78.05 %, seguido por el Árbol de Decisión (AUC-ROC = 0.6957) y SVM (AUC-ROC = 0.7655). Esta superioridad de KNN se atribuye a su capacidad para capturar patrones locales en espacios de

características de dimensionalidad moderada, destacando especialmente las características fásicas de la EDA (amplitud media de SCR y número de picos), que resultaron ser las más discriminantes en todos los modelos.

En la Tarea 2 (desbalance 85 % estrés), se observa el efecto clásico del desbalance de clases: los modelos que priorizan la clase mayoritaria (KNN y Árbol de Decisión) alcanzan exactitudes altas (82.35 % y 76.47 % respectivamente) pero AUC-ROC muy pobres (0.4862 y 0.6993), lo que indica una capacidad discriminativa real casi nula o limitada. En contraste, SVM presenta la exactitud más baja (55.88 %), pero el mayor AUC-ROC (0.7862), revelando una mejor capacidad para discriminar la clase minoritaria (no estrés/recuperación) a pesar de penalizar la exactitud global. Este comportamiento confirma la capacidad del kernel RBF frente al desbalance de clases cuando se optimiza adecuadamente el parámetro C.

En relación con la literatura revisada en el capítulo 2 del presente trabajo, los resultados son coherentes con los estudios que emplean únicamente señales EDA o combinaciones similares. Varios autores reportan rendimientos entre 70-85 % de exactitud cuando se utilizan características temporales y frecuenciales de EDA en protocolos de estrés agudo [36, 37], aunque los valores más altos (>90 %) se logran con señales multimodales o técnicas de balanceo explícitas [38, 41]. El AUC-ROC máximo alcanzado aquí (0.8119 con KNN en clases balanceadas y 0.7862 con SVM en desbalance) se sitúa en el rango superior de lo reportado para clasificación binaria basada exclusivamente en EDA, confirmando la validez de las características fásicas seleccionadas y del preprocesamiento cvxEDA empleado [49].

7. Conclusiones y Trabajos Futuros

En relación con el primer objetivo específico (preprocesamiento y extracción de características), se implementó un enfoque multimodal que integró las señales EDA, EEG y ECG para la generación de etiquetas mediante el algoritmo no supervisado k-means. Este proceso fue fundamental para identificar patrones fisiológicos coherentes entre los tres sistemas de respuesta: la EDA representando la activación simpática periférica, el ECG reflejando la regulación autonómica cardiovascular, y el EEG capturando la actividad cortical asociada al procesamiento cognitivo. La combinación de estas nueve características (tres por cada modalidad) permitió crear etiquetas binarias (estrés/no estrés) basadas en correlaciones fisiológicas reales entre los sistemas, asegurando que los patrones identificados correspondieran a respuestas integradas del organismo. Sin embargo, para la implementación de los modelos de clasificación supervisada, se seleccionaron exclusivamente las características de la señal EDA (*scr_count*, *scr_amp_mean*, *scr_rise_mean*) por tres razones principales: primero, estas características fásicas demostraron alta sensibilidad para capturar respuestas autonómicas rápidas asociadas al estrés agudo; segundo, la EDA ofrece ventajas prácticas significativas en términos de portabilidad, costo y facilidad de adquisición comparada con la EEG; y tercero, los resultados validaron que las características fásicas de la EDA por sí mismas contienen información discriminativa suficiente para identificar episodios de estrés, lo que simplifica la implementación en dispositivos portables sin sacrificar capacidad predictiva.

Respecto al segundo objetivo específico (creación de modelos de machine learning), los tres algoritmos evaluados (Árbol de Decisión, SVM y KNN) lograron clasificar correctamente episodios de estrés agudo cuando las clases estaban balanceadas, alcanzando KNN el mayor AUC-ROC (0.8119), seguido de SVM (0.7655) y Árbol de Decisión (0.6957). Cada modelo aportó en diferentes aspectos, tales como:

- **KNN** obtuvo el mejor rendimiento en datos balanceados y es muy sencillo de implementar, pero resultó extremadamente sensible al desbalance de clases (AUC-ROC cayó a 0.4862 en Tarea 2) y tiene alto costo computacional en inferencia (predicción), esto debido a su naturaleza de ser un algoritmo perezoso (*lazy learner*).
- **SVM** demostró la mayor tolerancia frente al desbalance de clases, manteniendo el AUC-ROC más alto en la Tarea 2 (0.7862), lo que lo convierte en la opción más fiable en escenarios reales donde predomina el estado de estrés. Su principal desventaja es la dificultad de ajuste de hiperparámetros y la falta de interpretabilidad.
- **Árbol de Decisión** ofreció la mayor interpretabilidad, identificando consistentemente la amplitud media de SCR y el número de picos como las características más relevantes, lo que facilita la comprensión fisiológica de

los resultados. Sin embargo, presentó el menor rendimiento global y tendencia al sobreajuste.

En cuanto al tercer objetivo específico (evaluación del rendimiento de los modelos), se cumplió mediante la aplicación de validación cruzada estratificada con $k=5$ pliegues ($cv=5$) dentro de GridSearchCV para la selección automática de hiperparámetros, la separación train/test en proporción 80/20 % y la evaluación final mediante un conjunto completo de métricas complementarias (exactitud, precisión, recall, F1-score, AUC-ROC, curvas ROC y matrices de confusión).

La validación cruzada demostró ser crítica en este estudio, ya que reveló una clara tendencia al sobreajuste de los tres modelos cuando se entrenaban con el volumen limitado de datos disponible. Las métricas obtenidas durante la fase de validación cruzada fueron más conservadoras y realistas que las reportadas en el conjunto de prueba final, lo que pone en evidencia la necesidad de contar con muestras significativamente más grandes para lograr modelos con verdadera capacidad de generalización en entornos reales. A pesar de esta limitación estructural, los valores AUC-ROC alcanzados (máximo de 0.8119 con KNN en clases balanceadas y 0.7862 con SVM en el escenario desbalanceado realista) confirman que los modelos entrenados exclusivamente con características de EDA poseen una capacidad discriminativa aceptable y clínicamente útil.

Como trabajos futuros, se sugiere la exploración de estrategias alternativas de clustering (como DBSCAN o modelos de mezclas gaussianas) que permitan capturar de manera completa la estructura subyacente de los datos multimodales, incluso en presencia de ruido o distribuciones no esféricas. Asimismo, resulta esencial ampliar el tamaño y la diversidad de la muestra de participantes, actualmente limitada a un único individuo en la fase de análisis preliminar, para mejorar la generalización de los modelos y evaluar la variabilidad interindividual en las respuestas fisiológicas al estrés. En cuanto a la optimización de modelos, se sugiere profundizar en técnicas avanzadas de ajuste de hiperparámetros (como Bayesian Optimization o metaheurísticas) que complementen o superen el enfoque actual basado en GridSearchCV, especialmente en algoritmos complejos como SVM y potenciales redes neuronales. Adicionalmente, sería pertinente evaluar el rendimiento de otros algoritmos de machine learning, entre ellos XGBoost, LightGBM o arquitecturas profundas, que puedan modelar interacciones no lineales más complejas entre las características de la EDA y otras señales. Finalmente, se recomienda incorporar estrategias explícitas para el manejo del desbalance de clases (como técnicas de remuestreo o costes asimétricos) y validar los modelos en entornos realistas con dispositivos portátiles, avanzando hacia sistemas de detección de estrés continuos, confiables y aplicables en contextos cotidianos y clínicos.

8. Referencias Bibliográficas

- [1] D. Liu *et al.*, "EEG-MLP: An all-MLP Architecture for EEG Emotion Recognition," *2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, vol. 34, pp. 2655–2662, Dec. 2023, doi: <https://doi.org/10.1109/bibm58861.2023.10385434>.
- [2] I. Lefter *et al.*, "Affective computing for mental wellbeing: Challenges, opportunities, and promising synergies," *2023 11th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW)*, pp. 1–2, Sep. 2023. doi:10.1109/aciiw59127.2023.10388209
- [3] A. H. Hatteland *et al.*, "Exploring Relationships between Cerebral and Peripheral Biosignals with Neural Networks," *2021 IEEE International Conference on Digital Health (ICDH)*, Chicago, IL, USA, 2021, pp. 103-113, doi: 10.1109/ICDH52753.2021.00022.
- [4] Y. R. Veeranki, N. Ganapathy, R. Swaminathan and H. F. Posada-Quintero, "Comparison of Electrodermal Activity Signal Decomposition Techniques for Emotion Recognition," in *IEEE Access*, vol. 12, pp. 19952-19966, 2024, doi: 10.1109/ACCESS.2024.3361832.
- [5] A. Hsu, "Quantifying Exam Stress Progressions Using Electrodermal Activity and Machine Learning," *2023 IEEE 23rd International Conference on Bioinformatics and Bioengineering (BIBE)*, Dayton, OH, USA, 2023, pp. 434-438, doi: 10.1109/BIBE60311.2023.00077.
- [6] S. S. M, J. Medikonda and S. Rai, "Unsupervised Machine Learning Approach for Stress Level Classification Using Electrodermal Activity Signals," *2024 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)*, Bangalore, India, 2024, pp. 1-6, doi: 10.1109/CONECCT62155.2024.10677181.
- [7] A. Greco *et al.*, "Acute Stress State Classification Based on Electrodermal Activity Modeling," in *IEEE Transactions on Affective Computing*, vol. 14, no. 1, pp. 788-799, 1 Jan.-March 2023, doi: 10.1109/TAFFC.2021.3055294.
- [8] V. Motogna, G. Lupu-Florian and E. Lupu, "Strategy For Affective Computing Based on HRV and EDA," *2021 International Conference on e-Health and Bioengineering (EHB)*, Iasi, Romania, 2021, pp. 1-4, doi: 10.1109/EHB52898.2021.9657654.
- [9] R. Shashidhar, P. Kadakol, D. Sreeniketh, P. Patil, K. H. Krishnappa and R. Madhura, "EEG Data Analysis for Stress Detection using K-Nearest Neighbor," *2023 International Conference on Integrated Intelligence and Communication Systems*

(ICIICS), Kalaburagi, India, 2023, pp. 1-7, doi: 10.1109/ICIICS59993.2023.10420898.

[10] N. H. Saputra and N. Nafi'lyah, "Identification of Human Stress Based on EEG Signals Using Machine Learning," *2022 1st International Conference on Information System & Information Technology (ICISIT)*, Yogyakarta, Indonesia, 2022, pp. 176-180, doi: 10.1109/ICISIT54091.2022.9872815.

[11] J. M. Kumar and V. K. Mittal, "EEG Data Acquisition System and Analysis of EEG Signals," *2021 2nd International Conference for Emerging Technology (INCET)*, Belagavi, India, 2021, pp. 1-5, doi: 10.1109/INCET51464.2021.9456431.

[12] R. Fang, R. Zhang, E. Hosseini, C. Fang, S. Rafatirad and H. Homayoun, "Introducing an Open-Source Python Toolkit for Machine Learning Research in Physiological Signal based Affective Computing," *2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, Istanbul, Turkiye, 2023, pp. 1890-1894, doi: 10.1109/BIBM58861.2023.10385965.

[13] E. Lopez, E. Chiarantano, E. Grassucci and D. Comminiello, "Hypercomplex Multimodal Emotion Recognition from EEG and Peripheral Physiological Signals," *2023 IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops (ICASSPW)*, Rhodes Island, Greece, 2023, pp. 1-5, doi: 10.1109/ICASSPW59220.2023.10193329.

[14] Martínez Vásquez, D.A.; Posada-Quintero, H.F.; Rivera Pinzón, D.M. Mutual Information between EDA and EEG in Multiple Cognitive Tasks and Sleep Deprivation Conditions. *Behav. Sci.* 2023, 13, 707. <https://doi.org/10.3390/bs13090707>

[15] E. Abdelfattah, S. Joshi and S. Tiwari, "Machine and Deep Learning Models for Stress Detection Using Multimodal Physiological Data," in *IEEE Access*, vol. 13, pp. 4597-4608, 2025, doi: 10.1109/ACCESS.2024.3525459.

[16] S. F. Begum *et al.*, "Emotion Recognition from Physiological Signals Using Ensembled Machine Learning Strategy," *2024 International Conference on Electronics, Computing, Communication and Control Technology (ICECCC)*, Bengaluru, India, 2024, pp. 1-8, doi: 10.1109/ICECCC61767.2024.10593862.

[17] T. Kumar, R. C. Singh and R. Kumar, "Emotions Recognition Based on Physiological Signals Using Machine Learning Techniques," *2023 3rd International Conference on Technological Advancements in Computational Sciences (ICTACS)*, Tashkent, Uzbekistan, 2023, pp. 823-827, doi: 10.1109/ICTACS59847.2023.10390266.

[18] Y. R. Veeranki, R. Swaminathan and H. F. Posada-Quintero, "Analyzing Emotional Dynamics: Transition Network Insights from Electrodermal Activity," *2024 46th Annual International Conference of the IEEE Engineering in Medicine and*

Biology Society (EMBC), Orlando, FL, USA, 2024, pp. 1-4, doi: 10.1109/EMBC53108.2024.10781680.

[19] A. Roshdy *et al.*, "Statistical Analysis of Multi-channel EEG Signals for Digitizing Human Emotions," *2021 4th International Conference on Bio-Engineering for Smart Technologies (BioSMART)*, Paris / Créteil, France, 2021, pp. 1-4, doi: 10.1109/BioSMART54244.2021.9677741.

[20] M. R. Khan and M. Ahmad, "Mental Stress Detection from EEG Signals Using Comparative Analysis of Random Forest and Recurrent Neural Network," *2024 International Conference on Advances in Computing, Communication, Electrical, and Smart Systems (iCACCESS)*, Dhaka, Bangladesh, 2024, pp. 1-6, doi: 10.1109/iCACCESS61735.2024.10499496.

[21] Y. Pamungkas, A. D. Wibawa and Y. Rais, "Classification of Emotions (Positive-Negative) Based on EEG Statistical Features using RNN, LSTM, and Bi-LSTM Algorithms," *2022 2nd International Seminar on Machine Learning, Optimization, and Data Science (ISMODE)*, Jakarta, Indonesia, 2022, pp. 275-280, doi: 10.1109/ISMODE56940.2022.10180969.

[22] Y. R. Veeranki and H. F. Posada-Quintero, "High-Resolution Time-Frequency Analysis of EEG Signals for Affective Computing," *2024 46th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Orlando, FL, USA, 2024, pp. 1-4, doi: 10.1109/EMBC53108.2024.10782482.

[23] P. Lu, "Human emotion recognition based on multi-channel EEG signals using LSTM neural network," *2022 Prognostics and Health Management Conference (PHM-2022 London)*, London, United Kingdom, 2022, pp. 303-308, doi: 10.1109/PHM2022-London52454.2022.00060.

[24] S. Baliga, N. Ali, A. LS and V. P, "Emotion Recognition and Stress Reduction Based on Electroencephalograph (EEG) Signals validated by Machine Learning Algorithms," *2023 International Conference on Smart Systems for applications in Electrical Sciences (ICSSES)*, Tumakuru, India, 2023, pp. 1-6, doi: 10.1109/ICSSES58299.2023.10199291.

[25] Sánchez-Reolid, R.; López de la Rosa, F.; Sánchez-Reolid, D.; López, M.T.; Fernández-Caballero, A. Machine Learning Techniques for Arousal Classification from Electrodermal Activity: A Systematic Review. *Sensors* 2022, 22, 8886. <https://doi.org/10.3390/s22228886>

[26] Z. Xie, J. Pan, C. -C. Chang, J. Hu and Y. Chen, "The Dark Side: Security and Reliability Concerns in Machine Learning for EDA," in *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, vol. 42, no. 4, pp. 1171-1184, April 2023, doi: 10.1109/TCAD.2022.3199172.

- [27] L. Zhu *et al.*, "Stress Detection Through Wrist-Based Electrodermal Activity Monitoring and Machine Learning," in *IEEE Journal of Biomedical and Health Informatics*, vol. 27, no. 5, pp. 2155-2165, May 2023, doi: 10.1109/JBHI.2023.3239305.
- [28] A. Dasgupta and A. Basu, "Measurement and Instrumentation for Mental Stress Detection in Humans," in *IEEE Instrumentation & Measurement Magazine*, vol. 28, no. 2, pp. 10-17, April 2025, doi: 10.1109/MIM.2025.10946259.
- [29] G. Gupta, M. Khan, K. I. Sherwani and Manaullah, "Overview of the effect of physiological stress on different biological signals," *2023 International Conference on Recent Advances in Electrical, Electronics & Digital Healthcare Technologies (REEDCON)*, New Delhi, India, 2023, pp. 251-255, doi: 10.1109/REEDCON57544.2023.10150828.
- [30] G. G. Iyer, R. Udhayakumar, S. Gopakumar and C. Karmakar, "Optimizing Temporal Segmentation of Multi-Modal Non-EEG Signals for Human Stress Analysis," *2024 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAET)*, Kota Kinabalu, Malaysia, 2024, pp. 494-499, doi: 10.1109/IICAET62352.2024.10730226.
- [31] F. Baghestani, Y. Kong and K. H. Chon, "Comparative Analysis of ECG-derived Skin Nerve Activity and Electrodermal Activity for Assessing Sympathetic Activity," *2023 IEEE 19th International Conference on Body Sensor Networks (BSN)*, Boston, MA, USA, 2023, pp. 1-4, doi: 10.1109/BSN58485.2023.10331475.
- [32] J. Lee *et al.*, "Analysis of Acute Stress Reactivity and Recovery in Autonomic Nervous System Considering Individual Characteristics of Stress Using HRV and EDA," in *IEEE Access*, vol. 12, pp. 115400-115410, 2024, doi: 10.1109/ACCESS.2024.3437671.
- [33] M. S. Sharif, M. R. T. Tamang, W. Elmedany and C. H. Y. Fu, "Evaluating the Stressful Commutes Using Physiological Signals and Machine Learning Techniques," *2022 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)*, Sakheer, Bahrain, 2022, pp. 175-180, doi: 10.1109/3ICT56508.2022.9990849.
- [34] A. Hota and S. -W. Park, "Stress Detection Using Physiological Signals Based On Machine Learning," *2022 International Conference on Computational Science and Computational Intelligence (CSCI)*, Las Vegas, NV, USA, 2022, pp. 379-384, doi: 10.1109/CSCI58124.2022.00074.
- [35] S. KumarP and J. F. Agastinose Ronickom, "Investigating the Effects of Two-Class Categorical Emotion Classification Through Electrodermal Activity and Machine Learning," *2023 IEEE 5th International Conference on Cybernetics, Cognition and Machine Learning Applications (ICCCMLA)*, Hamburg, Germany, 2023, pp. 594-599, doi: 10.1109/ICCCMLA58983.2023.10346868.

- [36] P. Suveetha Dhanaselvam and C. Nadia Chellam, "A Review on Preprocessing of EEG Signal," *2023 International Conference on Bio Signals, Images, and Instrumentation (ICBSII)*, Chennai, India, 2023, pp. 1-7, doi: 10.1109/ICBSII58188.2023.10181071.
- [37] S. Bakare, S. Kuge, S. Sugandhi, S. Warad and V. Panguddi, "Detection of Mental Stress using EEG signals - Alpha, Beta, Theta, and Gamma Bands," *2024 5th International Conference for Emerging Technology (INCET)*, Belgaum, India, 2024, pp. 1-9, doi: 10.1109/INCET61516.2024.10592994.
- [38] K. R. Hole and D. Anand, "Spatial Feature Extraction based EEG Stress Detection System: Review," *2022 4th International Conference on Inventive Research in Computing Applications (ICIRCA)*, Coimbatore, India, 2022, pp. 1-10, doi: 10.1109/ICIRCA54612.2022.9985679.
- [39] M. R. Amin and R. T. Faghih, "Identification of Sympathetic Nervous System Activation From Skin Conductance: A Sparse Decomposition Approach With Physiological Priors," in *IEEE Transactions on Biomedical Engineering*, vol. 68, no. 5, pp. 1726-1736, May 2021, doi: 10.1109/TBME.2020.3034632.
- [40] C. T. Akpınar, Ö. Koşar and A. Durdu, "Enhancing the Performance of Machine Learning Classification Models," *2025 24th International Symposium INFOTEH-JAHORINA (INFOTEH)*, East Sarajevo, Bosnia and Herzegovina, 2025, pp. 1-6, doi: 10.1109/INFOTEH64129.2025.10959301.
- [41] A. Sharma, A. Kaur and A. Semwal, "Supervised and Unsupervised Prediction Application of Machine Learning," *2022 International Conference on Cyber Resilience (ICCR)*, Dubai, United Arab Emirates, 2022, pp. 1-5, doi: 10.1109/ICCR56254.2022.9996063.
- [42] H. Vaishnav and A. Choudhary, "Evolutional Study on KNN and K-means Algorithms," *2024 International Conference on Electrical Electronics and Computing Technologies (ICEECT)*, Greater Noida, India, 2024, pp. 1-4, doi: 10.1109/ICEECT61758.2024.10739058.
- [43] C. Zhu, "Learning and Application of Different Machine Learning Methods (KNN, SVM, Decision Tree) in Different Datasets," *2024 5th International Conference on Machine Learning and Computer Application (ICMLCA)*, Hangzhou, China, 2024, pp. 1-5, doi: 10.1109/ICMLCA63499.2024.10754404.
- [44] M. Mhaske, B. Gidhad, K. Maniyar and G. Ghuge, "The Role of Linear Algebra in Developing Machine Learning Solutions," *2024 3rd International Conference for Advancement in Technology (ICONAT)*, GOA, India, 2024, pp. 1-5, doi: 10.1109/ICONAT61936.2024.10775140.

- [45] S. Chippalakatti, C. H. Renumadhavi and A. Pallavi, "Comparison Of Unsupervised Machine Learning Algorithm For Dimensionality Reduction," *2022 International Conference on Knowledge Engineering and Communication Systems (ICKES)*, Chickballapur, India, 2022, pp. 1-7, doi: 10.1109/ICKES56523.2022.10060625.
- [46] M. Anita, A. Meena Kowshalya, B. Maheswari and A. Muthuram, "An Extensive Review of Machine Learning Techniques for EEG Signal Processing," *2022 International Conference on Automation, Computing and Renewable Systems (ICACRS)*, Pudukkottai, India, 2022, pp. 669-673, doi: 10.1109/ICACRS55517.2022.10029003.
- [47] Y. Zhao, G. Wang, M. Sun, Z. Zhao and Y. Yan, "Methods for Removing Artifacts from EEG signals:A review," *2024 IEEE 24th International Conference on Software Quality, Reliability, and Security Companion (QRS-C)*, Cambridge, United Kingdom, 2024, pp. 752-758, doi: 10.1109/QRS-C63300.2024.00100.
- [48] S. Tiwari, "Mathematics for Machine Learning," *2024 3rd International Conference for Innovation in Technology (INOCON)*, Bangalore, India, 2024, pp. 1-4, doi: 10.1109/INOCON60754.2024.10511475.
- [49] T. Chaspari, A. Tsiartas, L. I. Stein, S. A. Cermak and S. S. Narayanan, "Sparse Representation of Electrodermal Activity With Knowledge-Driven Dictionaries," in *IEEE Transactions on Biomedical Engineering*, vol. 62, no. 3, pp. 960-971, March 2015, doi: 10.1109/TBME.2014.2376960.
- [50] K. V, D. G, V. Sarveshwaran, J. J. Jayakanth, K. M and Y. Renu, "Comparative Analysis of Diverse Classification Algorithms of Machine Learning by Using Various Quality Metrics," *2023 IEEE 5th International Conference on Cybernetics, Cognition and Machine Learning Applications (ICCCMLA)*, Hamburg, Germany, 2023, pp. 551-556, doi: 10.1109/ICCCMLA58983.2023.10346683.