

***Desarrollo de un Modelo Predictivo Piloto Basado en Aprendizaje Automático para
Evaluar el Estrés o Deterioro Cognitivo debido a la Privación del Sueño:
Análisis de Correlaciones entre Señales EEG y EDA con Base en una
Muestra Acotada.***

Yohan Mauricio Rodríguez Garzón

Julio 24 del 2025

Universidad Pedagógica Nacional

Facultad De Ciencia y Tecnología

Licenciatura en Electrónica

***Desarrollo de un Modelo Predictivo Piloto Basado en Aprendizaje Automático para
Evaluar el Estrés o Deterioro Cognitivo debido a la Privación del Sueño: Análisis
de Correlaciones entre Señales EEG y EDA con Base en una Muestra Acotada.***

Trabajo de grado para optar por el título de Licenciado en Electrónica

Yohan Mauricio Rodríguez Garzón

Autor del trabajo de investigación

David Alejandro Martínez Vásquez

Doctor en ingeniería eléctrica

Director de Trabajo de Grado

Yohan Mauricio Rodríguez Garzón

Julio 24 del 2025

Universidad Pedagógica Nacional

Facultad De Ciencia y Tecnología

Licenciatura en Electrónica

Tabla de contenido

1.	Introducción	8
2.	Problema / Necesidad	9
3.	Justificación	12
4.	Objetivos.....	15
4.1.	Objetivo general.....	15
4.2.	Objetivos específicos	15
5.	Antecedentes.....	16
5.1.	Revisión literaria.....	16
5.2.	Investigaciones previas sobre el tema.....	16
6.	Marco teórico	19
6.1.	Señales cerebrales EEG	19
6.1.1.	Electroencefalografía (EEG).....	19
6.1.2.	Componentes de la señal EEG.....	19
6.2.	Bandas de frecuencia de la señal EEG.....	20
6.2.1.	Banda de frecuencia delta (δ).....	21
6.2.2.	Banda de frecuencia theta (θ).....	21
6.2.3.	Banda de frecuencia alfa (α)	22
6.2.4.	Banda de frecuencia beta (β).....	22
6.2.5.	Banda de frecuencia gamma (γ).....	23

6.3.	Densidad espectral de potencia de las bandas de frecuencia	23
6.4.	Asimetría alfa frontal (FAA - Frontal Asymmetric Alpha).....	25
6.5.	Señales fisiológicas de la actividad electrodérmica (EDA).....	26
6.5.1.	Componentes de la señal EDA	26
6.5.2.	Métricas de la señal EDA utilizadas	27
6.6.	Base estadística para el análisis de señales EEG y EDA	28
6.6.1.	Estadística descriptiva.....	28
6.6.2.	Coefficiente de correlación de Spearman.....	29
6.6.3.	Distribuciones de probabilidad	30
6.7.	Aprendizaje automático supervisado	31
6.7.1.	Aprendizaje automático supervisado por clasificación.....	31
6.7.2.	Balance de clases: Undersampling.....	32
6.7.3.	Regresión logística.....	32
6.7.4.	Máquinas de vectores de soporte (Support Vector Machines).....	33
6.7.5.	K-Vecinos más cercanos (K-Nearest Neighbors)	35
6.7.6.	Árboles de decisión.....	36
6.7.7.	Bosques aleatorios (Random Forest)	37
6.8.	Aprendizaje automático no supervisado	38
6.8.1.	Clustering con K-Means	38
6.8.2.	Funcionamiento del algoritmo K-Means	38

6.8.3.	Método del codo	39
6.9.	Métricas de evaluación para algoritmos de clasificación	40
6.9.1.	Exactitud (Accuracy)	40
6.9.2.	Precisión (Precision)	41
6.9.3.	Recall (Sensibilidad).....	41
6.9.4.	Puntuación F1 (F1-Score).....	42
6.9.5.	Curva ROC (Receiver Operating Characteristic)	42
6.9.6.	Área Bajo la Curva ROC (AUC)	43
6.9.7.	Matriz de confusión	43
6.9.8.	Validación cruzada (Cross-Validation)	44
7.	Metodología	46
7.1.	Tipo de investigación y diseño del estudio	46
7.2.	Conjunto de datos inicial	47
7.1.1.	EAT (<i>Error Awareness Task</i>).....	47
7.3.	Participantes	48
7.4.	Recolección de los datos	49
7.4.1.	Procedimiento	50
7.4.	Análisis de los datos.....	53
7.5.1.	Preprocesamiento.....	53

7.5.2. Modelado de los datos para el aprendizaje automático (fase inicial de etiquetado y evaluación individual)	58
7.5.3. Software utilizado	65
8. Resultados y análisis	67
8.1. Estadística descriptiva de los datos procesados	67
8.2. Correlaciones entre las variables	68
8.3. Resultados del Modelado de Aprendizaje Automático	70
8.4. Análisis del Clustering con K-Means para la Generación de Etiquetas	77
9. Conclusiones	81
10. Bibliografía	84

Índice de tablas

Tabla 1. Centros De Los Clústeres K-Means Y Su Interpretación Fisiológica.....	60
Tabla 2. Estadísticas Descriptivas De Las Variables Fisiológicas Y Cerebrales Clave En El Conjunto De Datos Depurado (N=72,000 Segmentos)	68
Tabla 3. Matriz De Correlación De Spearman (P) Entre Variables Fisiológicas Y Cerebrales Seleccionadas	69
Tabla 4. Rendimiento De Los Modelos De Clasificación Por Sujeto Individual (Accuracy Media De Validación Cruzada Con 3 Splits)	71
Tabla 5. Rendimiento De Los Modelos De Clasificación Con Datos Combinados De Sujetos 1, 6 Y 7 (Accuracy De Validación Cruzada Con 3 Splits).....	73

Índice de figuras

Figura 1. Descripción General De La Metodología Llevada A Cabo En El Proceso De Desarrollo Del Trabajo De Grado.....	50
Figura 2. Distribución Exponencial De La Característica Eda_Phasic_Std	56
Figura 3. Distribución Gaussiana De La Característica Eda_Tonic_Avg.....	56
Figura 4. Distribución Gaussiana De La Característica Faa	57
Figura 5. Matriz De Confusión Del Modelo Svm.....	76
Figura 6. Curva Roc Del Modelo Svm	77
Figura 7. Gráfica Del Método Del Codo Para 10 Clústeres	78
Figura 8. Diferenciación Entre Clústeres.....	79

1. Introducción

El presente estudio propone un análisis de datos sobre señales cerebrales EEG (Electroencefalografía) y señales físicas EDA (Actividad electrodérmica) para el análisis de la actividad cerebral en el contexto de la privación del sueño producido por agentes externos o internos (físicos o psicológicos) en las personas que sufren de este trastorno. Las señales mencionadas son el resultado de una investigación previa realizada en la universidad de Connecticut por los profesionales citados a continuación: David Alejandro Martínez Vásquez, y Hugo F. Posada Quintero, que han autorizado el uso de estos datos en el proceso planteado mediante el estudio propuesto.

Durante el documento se aborda la necesidad de desarrollar e innovar en herramientas tecnológicas adecuadas que involucren el análisis de señales EEG y EDA, y de igual manera, buscar nuevas formas de afrontar los beneficios que ofrecen dichas señales cerebrales y físicas en diversas áreas de la salud. El objetivo general del proyecto es desarrollar un sistema basado en aprendizaje automático para el análisis de señales cerebrales EEG y posibles relaciones con las señales dérmicas EDA que permitan una mejor comprensión de la actividad cerebral y cómo influye la privación del sueño en él.

2. Problema / Necesidad

La dificultad de concertar el sueño diario de manera óptima es un problema que afecta a un gran número de personas al rededor del mundo que se produce por diferentes causas psicológicas, físicas o sociales, dependiendo de cada individuo, llegando a estimar que uno de cada diez adultos no duerme lo suficiente derivando en graves consecuencias negativas (Pérez et al., 2022) para la salud física y mental de dichas personas que no obtienen un ritmo de sueño idóneo y recurrente durante largos periodos de tiempo.

Con el recorrido investigativo de las ciencias en la salud a través del tiempo, se han llegado a establecer unas consecuencias negativas presentes en un alto número de personas con problemas para conciliar el sueño, como lo son: un mayor riesgo de sufrir enfermedades crónicas como la obesidad, la diabetes, las enfermedades cardíacas y accidentes cerebrovasculares, esto en términos de consecuencias negativas físicas, al pasar al ámbito de las consecuencias negativas en la salud mental de las personas, se ha establecido dentro del conjunto de consecuencias negativas: la depresión, la ansiedad y los trastornos del sueño, finalizando con las consecuencias negativas a nivel social de los individuos que no obtienen un descanso nocturno placentero, se encuentran, entre otros, un bajo rendimiento laboral, bajo rendimiento académico, inseguridad consigo mismos y la calidad de vida en general.

Como punto de cierre sobre las consecuencias negativas sobre las personas que no logran conciliar el sueño de manera eficiente, se debe mencionar que la situación socioeconómica de los sujetos es un factor significativo a la hora de evaluar su estado mental y físico, ya que las circunstancias como los bajos ingresos económicos, la pobreza, el trabajo realizado bajo turnos nocturnos o rotativos o la falta de acceso a una vivienda adecuada, aumentan el riesgo de sufrir el trastorno del problema planteado.

A lo anterior, se resalta que solo se mencionaron aquellas consecuencias negativas más propensas a ser observadas en personas con problemas de sueño, pero no son las únicas, ya que se recalcó que la presencia de consecuencias negativas depende de la reacción física y mental de cada individuo al problema planteado en este documento que habla de los efectos producidos por la incapacidad de conciliar el sueño.

El área de la salud mental y física de las personas ha obtenido un gran número de avances en las últimas décadas desde la perspectiva tecnológica y la perspectiva social, en dirección de cuidar y prevalecer el ser humano como persona relevante y ente activo del bien común o colectivo, por eso, cada día se ve cómo se da acceso al público soluciones innovadoras relacionadas con estos desarrollos desde diferentes ángulos y durante los últimos años ha crecido el interés e inversión en cuanto a tiempo, personal y monetario, en la investigación sobre los posibles efectos negativos producidos por la privación del sueño. Esto ha ayudado a avanzar en la metodología destacada por su confiabilidad, precisión, además de reproducible en contextos con énfasis científico o investigativo, y que es eje de los objetivos de este documento, que radica en la experimentación con sujetos sanos exponiéndolos a largos periodos de tiempo sin acceso al descanso por medio del sueño y, por el contrario, evaluando reiteradamente el deterioro cognitivo durante el tiempo establecido.

El ritmo acelerado que se logra percibir en la vida diaria de las personas y el avance periódico y constante de la tecnología, hace imperativo el acrecentar y fortalecer la investigación sobre las causas y efectos de la incapacidad de lograr conciliar el sueño por largos periodos de tiempo en las personas que lo padecen, buscando comprender de manera óptima este problema en la salud física y mental, para desarrollar metodologías y procesos avanzados que logren

prevenir y tratar dicho trastorno, adicional al progreso social que debe ser alcanzado al lograr un crecimiento en la reflexión general de las personas que padezcan o no este trastorno.

3. Justificación

No lograr descansar mediante el sueño ameno es un problema de salud pública que afecta a muchas personas al rededor del mundo, estimando que uno de cada 10 adultos padece de sueño insuficiente presentando consecuencias graves para la salud física y mental (Díaz et al., 2011). Dicha problemática es relevante en el contexto social actual, donde vemos un ritmo acrecentado en nuestras vidas ocasionado por el continuo desarrollo tecnológico y el crecimiento desmedido de la necesidad del ser humano por obtener resultados, en su diario vivir, de manera casi inmediata.

Con los años se ha desarrollado evidencia que habla de los efectos negativos producidos por no dormir adecuadamente, fortaleciendo el conocimiento sobre las causas de esta problemática; pero aún existe un vacío significativo sobre los efectos del no dormir adecuadamente, sus diferentes motivos y las posibles intervenciones efectivas para prevenirlo y tratarlo, por lo que la necesidad de profundizar y explorar estudios que aporten soluciones para abordar el problema derivado de la privación del sueño de diferentes causas personales, profesionales y sociales, se hace imperioso.

Los estudios realizados que engloban el problema del descanso deficiente en las personas se han enfocado en los efectos generales en la salud física y mental, por lo que se debe abordar la necesidad de aumentar los estudios que fortalezcan el por qué el sueño insuficiente afecta las habilidades cognitivas y emocionales, adicional, a la exploración del impacto que esto produce en diferentes ámbitos de la vida de las personas como su rendimiento académico, laboral o social.

Por lo anterior, los objetivos planteados en este documento contribuirían al entendimiento de las correlaciones existente entre las señales cerebrales EEG y las señales dérmicas EDA derivadas de la privación del sueño y las alteraciones cognitivas que esto conlleva, al proporcionar una mirada, basada en el análisis de datos y uso de herramientas de la inteligencia artificial, de los efectos del sueño insuficiente en las habilidades cognitivas y emocionales de las personas. Las conclusiones que se deriven del estudio irán en la dirección de ayudar a comprender un poco mejor el ¿por qué? de los efectos que se derivan de la privación del sueño en las personas.

En busca de fundamentar aún más la necesidad de estudiar sobre los efectos de la privación del sueño en las personas, se hace hincapié en que los resultados de este estudio probablemente pueden tener importantes implicaciones prácticas en las áreas de la salud pública, la educación y el trabajo en general. Como ejemplo, la información obtenida sobre las correlaciones de los efectos producidos por la privación del sueño para su análisis en función de algoritmos de aprendizaje automático y sus consecuencias en las capacidades cognitivas de las personas, puede usarse para diseñar programas educativos sobre la importancia del sueño, dirigidos a diferentes grupos poblacionales, como universitarios, trabajadores y adultos mayores.

Al abarcar y obtener respuestas a la problemática planteada, se buscará, mediante el estudio y análisis, beneficiar principalmente a las personas que no obtienen un descanso óptimo y producto de ello, fatiga mental o estrés, así como a sus familias y a la sociedad, ya que dichos resultados proporcionarán información valiosa para ayudar a las personas a mejorar sus hábitos de descanso y prevenir o tratar problemas asociados al sueño insuficiente.

Para alcanzar los objetivos planteados, se tiene la experiencia tecnológica adquirida a través del proceso académico realizado durante el estudio del pregrado de licenciatura en

electrónica, adicional al conocimiento y experticia en análisis de datos cuantitativos y cualitativos, búsqueda de información en función de los datos y la toma de decisiones basada en hechos, sumado a la motivación de alcanzar los objetivos del estudio propuesto de encontrar correlaciones significativas en los datos que ayuden a mejorar la vida de las personas con trastornos asociados a la privación del sueño.

El conjunto de datos que se usará para cumplir con los objetivos propuestos es producto de una investigación previa realizada en la universidad de Connecticut, donde se puso bajo observación a 10 individuos (entre los 25 años a los 35 años) durante un periodo de 24 horas, a los cuales se les conectó 9 electrodos sobre el cuero cabelludo (3 electrodos en la parte frontal, 2 electrodos e la parte temporal, 1 electrodo en la parte parietal y 3 electrodos en la parte posterior de la cabeza), cada uno de ellos captando 5 diferentes ondas cerebrales (Delta, Teta, Alfa, Beta y Gamma) y un electrodo sobre la piel para tomar las mediciones de las señales dérmicas (señal tónica y señal fásica). Durante las 24 horas los individuos no se les permitió dormir en ningún momento y cada 2 horas tenían que desarrollar diferentes pruebas cognitivas, momento en el cual se recolectaban los datos que alimentaba constantemente el conjunto de datos dentro del periodo de tiempo que duró el experimento.

El proceso de trabajo de grado estará bajo la supervisión del docente David Martínez Vásquez, profesor ocasional del departamento de tecnología de la Universidad Pedagógica Nacional, quien tiene la experiencia y los conocimientos idóneas para asesorar el caso de estudio presentado. Las reuniones con el docente se dieron de manera regular en pro de guiar y garantizar que el caso de estudio se mantuviera dentro de los objetivos propuestos y conservar la disciplina que se ameritó.

4. Objetivos

4.1. Objetivo general

Desarrollar un modelo predictivo basado en técnicas de aprendizaje de máquina, para la identificación de niveles de estrés o fatiga mental en función de las señales EEG y señales EDA, bajo el desarrollo de actividades cognitivas.

4.2. Objetivos específicos

- 4.2.1.** Identificar parámetros de correlación entre las señales EDA y EEG que sirvan como características para la predicción de patrones de fatiga o estrés bajo el desarrollo de actividades cognitivas.
- 4.2.2.** Determinar algoritmos de aprendizaje de máquina que se adapten a las señales EDA y EEG que se van a manejar en el proyecto para la identificación de niveles de estrés o fatiga.
- 4.2.3.** Crear un modelo de aprendizaje de máquina de clasificación acorde con las características y las señales utilizadas.
- 4.2.4.** Evaluar el desempeño del modelo a través de métricas de evaluación destinadas para modelos de aprendizaje automático de clasificación.

5. Antecedentes

5.1. Revisión literaria

Dentro de la revisión literaria, se escogieron 6 artículos relevantes en temas como señales EEG y privación del sueño. Estos artículos se obtuvieron de bases de datos académicas como Behavioral Sciences, Scopus, Web of Science y Google Scholar, escritos por autores con cierta experticia en las áreas que se concentran en el caso de estudio de este documento.

Uno de los artículos es parte fundamental de este estudio, ya que es la base del análisis realizado, que lleva como título: Martínez Vásquez et al. (2023) “*Mutual Information between EDA and EEG in Multiple Cognitive Tasks and Sleep Deprivation Conditions*”, que describe el experimento donde se recopilaron los datos de las señales EEG y EDA usadas como base de datos principal para el desarrollo del presente estudio. En él se propuso explorar la información mutua entre la Actividad Electrodermica (EDA) y el Electroencefalograma (EEG) en condiciones de privación de sueño y durante la ejecución de tareas cognitivas que demandaban un gran volumen de capacidad motriz. Diez participantes fueron sometidos a un riguroso protocolo de 24 horas, realizando cuatro tareas cognitivas distintas (EAT, N-Back, Ship Search y PVT) cada dos horas.

5.2. Investigaciones previas sobre el tema

Los artículos que fueron objeto de revisión abordan diversas aplicaciones como:

- Reconocimiento de patrones de imágenes motoras (MI) a partir de señales de EEG: El estudio de Rensong Liu, Zhiwen Zhang, Feng Duan, Xin Zhou, y Zixuan Meng. (2018) propone un sistema para clasificar estados de MI usando señales de

EEG y el algoritmo de aprendizaje automático KNN-SVM, alcanzando una precisión alta para asignar a personas a recibir entrenamiento MI sistemático.

- Evaluación del trastorno del control de impulsos en pacientes con enfermedad de Parkinson: Yuan-Pin Lin, Hsing-Yi Liang, Yueh-Sheng Chen, Cheng-Hsien Lu, Yih-Ru Wu, Yung-Yee Chang⁴ and Wei-Che (2019) mediante su artículo dan a conocer un estudio de viabilidad que utiliza un auricular EEG de bajo costo en búsqueda de evaluar el trastorno del control de impulsos en pacientes diagnosticados con Parkinson, llegando a conclusiones prometedoras para el diagnóstico y seguimiento de esta condición.
- Evaluación de la atención del conductor mediante medidas fisiológicas: Taraneh Aminosharieh Najafi, Antonio Affanni, Roberto Rinaldo and Pamela Zontone. (2019) plantean un sistema que evalúa el cuidado de los conductores en función de señales EEG, ECG y EDA, en pro de diferenciar la forma en que maneja una persona normal y la forma de conducción autónoma de vehículos que cuentan con esta característica, buscando implicaciones para la seguridad vial y el desarrollo de vehículos autónomos.
- Asociación entre el desempeño de la atención sostenida durante la privación del sueño y la inestabilidad en el comportamiento y las medidas fisiológicas: Eric Chern-Pin Chua; Sing-Chen Yeo; Ivan Tian-Guang Lee; Luuan-Chin Tan; Pauline Lau; Shiwei Cai. (2016) encuentran que las medidas de referencia de la variabilidad cognitiva y fisiológica pueden usarse para predecir la vulnerabilidad individual de las personas al ser sujetas de la privación del sueño, esto en función

de determinar implicaciones para la selección y el manejo del personal que deben llevar a cabo funciones laborales que son susceptibles al sueño.

- Diez minutos de α -tACS e iluminación ambiental modulan de forma independiente la potencia α del EEG: Heiko i. Esteche, Tania M. Pollok, Daniel Struber, Fabian Sobotka y Christoph S. Herrmann (2015) investigan los efectos de la tACS (transcranial alternating current stimulation) y la iluminación ambiental en la modulación de las oscilaciones de las ondas cerebrales alfa de las señales EEG, encontrando gran importancia el controlar la luz ambiental al estudiar los efectos de la estimulación cerebral.

6. Marco teórico

6.1. Señales cerebrales EEG

6.1.1. Electroencefalografía (EEG)

La electroencefalografía (EEG) es un sistema no invasivo utilizado para registrar la actividad eléctrica en el cerebro a través de electrodos colocados sobre la superficie de la cabeza.

Las señales EEG miden las variaciones del potencial eléctrico generadas por la actividad neuronal, ofreciendo información sobre los estados funcionales del cerebro y de esta manera, permitiendo que se pueden analizar distintos patrones de actividad cerebral relacionados con procesos cognitivos relacionados con estímulos externos.

Estas señales miden las variaciones del potencial eléctrico generadas por la actividad neuronal, ofreciendo información sobre los estados funcionales del cerebro y, de esta manera, permitiendo el análisis de distintos patrones de actividad cerebral relacionados con procesos cognitivos y estímulos externos. Dicha actividad se relaciona con la estructura del cerebro humano, el cual actúa como el centro biológico del sistema nervioso y es capaz de adaptarse de acuerdo con los estímulos que recibe (Irisarri & Villegas, 2021).

6.1.2. Componentes de la señal EEG

- **Amplitud:** La amplitud de una onda EEG hace referencia a la magnitud o voltaje de la variación eléctrica, que usualmente se cuantifica en microvoltios (μV), y representa la diferencia de potencial entre dos puntos de registro en un intervalo de tiempo específico, lo que permite obtener el grado de actividad neuronal sincrónica. La amplitud de las señales EEG es relativamente pequeña, usualmente

en el rango de 10 μV a 100 μV en adultos sanos en estado de alerta (persona despierta y que está consciente de su entorno).

- **Frecuencia:** La frecuencia de una señal EEG expresa el número de ciclos completos que ocurren por unidad de tiempo (usualmente en segundos), medida en Hertz (Hz). El espectro de frecuencias de la señal EEG es amplio y de la cual se pueden obtener como resultado distintas bandas de frecuencia, que se mencionan a continuación: delta, theta, alfa, beta y gamma, cada una asociada con diferentes estados de procesos cognitivos y funciones cerebrales. El análisis de la frecuencia es una de las bases del procesamiento de señales EEG, ya que este permite inferir el estado funcional del cerebro.
- **Fase:** La fase de una señal EEG da una descripción de la posición en un ciclo de la oscilación específico, expresa en grados o radianes, y resulta siendo de suma importancia para entender las relaciones, a lo largo del tiempo, entre diferentes componentes de frecuencia dentro de una misma señal o entre señales registradas en distintas localizaciones de la zona superior de la cabeza.

Estos tres componentes cumplen un papel que destaca en la interpretación de la actividad cerebral, tomando factores que van desde estados de alerta hasta análisis neuronales.

6.2. Bandas de frecuencia de la señal EEG

La actividad eléctrica del cerebro que es registrada mediante el sistema de electroencefalografía (EEG) puede y debe descomponerse en diferentes bandas de frecuencia, cada una asociada con estados cerebrales y procesos cognitivos específicos.

Según Başar (2016) citando a Başar (2013), las señales EEG se pueden definir como:

“El EEG consiste en la actividad de un conjunto de generadores que producen actividad rítmica en varios rangos de frecuencia. Estos osciladores suelen estar activos de forma aleatoria. Sin embargo, mediante la aplicación de estimulación sensorial, estos generadores se acoplan y actúan juntos de forma coherente. Esta sincronización y mejora de la actividad del EEG da lugar a ritmos ‘evocados’ o ‘inducidos’. Los potenciales evocados, que representan conjuntos de respuestas de la población neuronal, se consideraban el resultado de la transición de un estado desordenado a uno ordenado. El ERP compuesto manifiesta una superposición de oscilaciones evocadas en las frecuencias del EEG, que van de delta a gamma (‘frecuencias naturales del cerebro’ como delta: 0,5–3,5 Hz, theta: 3,5–7 Hz, alfa: 8–13 Hz, beta 15–28 Hz y gamma: 30–70 Hz).”.

6.2.1. Banda de frecuencia delta (δ)

La banda de frecuencia delta trabaja en el rango de 0.5 Hz a 4 Hz y se caracteriza por ondas de gran amplitud a baja frecuencia. Su actividad tiene relevancia en el sueño profundo, según Verdú Ferrer (2021) *“en la fase 2 y las ondas Delta (igual o menos de 3,5 Hz), características de las fases de sueño profundo”*, asociada a la memoria o puede mostrarse en estados de relajación y procesos de recuperación fisiológica.

6.2.2. Banda de frecuencia theta (θ)

La banda theta tienen un rango de frecuencia de 4 Hz a 8 Hz y son observadas habitualmente en estados de somnolencia y relajación profunda, teniendo la actividad de la banda theta predominante en estados de meditación, facilitando la atención y la disminución de la actividad cortical orientada a estímulos externos.

6.2.3. Banda de frecuencia alfa (α)

La banda alfa abarca el rango de frecuencias de 8 Hz a 12 Hz y se asocia con estados de relajación cuando la persona está despierta. Según Cardona y Segovia (2014), *“El estado de Alfa se da en los momentos de despreocupación, de meditación, donde el cuerpo no ve una necesidad de estrés”*, observándose con mayor presencia en sujetos con los ojos cerrados y en momentos de atención interna (interés en procesos mentales y sensaciones internas del cuerpo). Esto lleva a que la actividad alfa presente un comportamiento que tiende a incrementarse cuando la persona entra en un estado de calma y a disminuir ante estímulos que demandan procesamiento activo.

La modulación de la banda alfa también puede verse influenciada por el nivel de concentración y el tipo de tarea cognitiva realizada. En estudios sobre la asimetría alfa frontal (FAA), se ha encontrado que diferencias en la actividad alfa entre los hemisferios están vinculadas con la regulación emocional y la predisposición a estados afectivos positivos o negativos.

6.2.4. Banda de frecuencia beta (β)

Las ondas beta tienen un rango de operación entre los 12 Hz a 30 Hz y están relacionadas con procesos cognitivos activos, como la concentración, la resolución de problemas y la toma de decisiones. Esta banda se destaca en momentos de alerta y alto nivel de procesamiento mental.

La actividad beta se subdivide en beta baja (con frecuencias entre 12 Hz a 15 Hz), beta media (15 Hz - 20 Hz) y beta alta (20 Hz - 30 Hz), cada una con funciones específicas dentro del espectro de activación cerebral, lo que ayuda determinar que un incremento excesivo de actividad beta puede estar asociado con estados de ansiedad o excitación alta cerebral, mientras que una disminución puede relacionarse con trastornos de atención.

6.2.5. Banda de frecuencia gamma (γ)

La banda de frecuencia gamma trabaja en rangos superiores a los 30 Hz, generalmente entre 30 y 100 Hz, y cuya banda de frecuencia ha sido vinculada con procesos cognitivos de alto nivel, como la integración de información y la conciencia, como lo menciona como lo menciona Niklitschek, Pino y Aboitiz (2011) *“La sincronización neuronal y las oscilaciones de alta frecuencia (rango de frecuencia gamma) tendrían un papel crucial en el procesamiento de la información y la integración de funciones cerebrales. Distintas anomalías relacionadas con oscilaciones de alta frecuencia se han encontrado en pacientes”*

6.3. Densidad espectral de potencia de las bandas de frecuencia

La densidad espectral de potencia (PSD) es una medida utilizada en el análisis de señales EEG para encontrar la distribución de la energía en distintas frecuencias presentes en dicha señal. La densidad mencionada, permite evaluar la intensidad relativa de las oscilaciones cerebrales y su relación con estados cognitivos y emocionales.

La PSD describe cómo la energía de una señal EEG se distribuye a lo largo de su espectro de frecuencias, como lo menciona Esqueda y Reyes (2017) *"permite encontrar la Densidad Espectral de Potencia, es decir, cómo se distribuye la potencia de la señal EEG en función de la frecuencia para cada electrodo"*, permitiendo un análisis de la variación eléctrica del cerebro en función de la frecuencia.

Matemáticamente, la PSD se obtiene a partir de la transformación de la señal EEG desde el dominio del tiempo al dominio de la frecuencia mediante técnicas de análisis espectral. El cálculo de la PSD se basa en la aplicación de la Transformada de Fourier, o en su defecto, el uso de la Transformada de Fourier Rápida, pasando la señal EEG, originalmente en el dominio del

tiempo, al dominio de las frecuencias para obtener la información de la distribución de la potencia partiendo de su frecuencia. La expresión matemática general de la PSD mediante la transformada de Fourier viene dada por:

$$P_x(f) = \lim_{T \rightarrow \infty} \frac{1}{T} * E\{|G_T(f)|^2\}$$

Donde $P_x(f)$ corresponde a la estimación de la densidad de potencia de una señal x en función de la frecuencia f , $E\{\}$ es el valor esperado o la esperanza matemática, $G_T(f)$ representa la transformada de Fourier de la señal EEG, $|G_T(f)|^2$ esta dado por el cuadrado de la magnitud de $G_T(f)$, ya que esta, por lo general, da como resultado un número complejo.

En el contexto de señales EEG, la PSD es útil para identificar patrones de actividad cerebral, dividir el espectro de frecuencias en diferentes bandas de operación y extraer características relevantes para el análisis de estados neurológicos, como el estrés o la privación del sueño.

El análisis de la PSD permite determinar la importancia de algunas frecuencias en la actividad neuronal, es por ello, que la variabilidad de la PSD en distintas bandas de frecuencia se correlaciona con los niveles de excitación cortical y procesos cognitivos específicos, como, por ejemplo:

- PSD en Banda Delta (0.5 - 4 Hz): Un aumento en la potencia delta suele estar asociado con estados de sueño profundo y relajación extrema.
- PSD en Banda Theta (4 - 8 Hz): La actividad theta trabaja con el procesamiento de memoria, en la consolidación de la información.

- PSD en Banda Alfa (8 - 12 Hz): Un incremento en la densidad de potencia alfa se relaciona con estados de relajación y atención interna.
- PSD en Banda Beta (12 - 30 Hz): Altos valores de PSD en beta están vinculados con concentración, procesamiento cognitivo y estados de alerta.
- PSD en Banda Gamma (30 - 100 Hz): La actividad gamma está asociada con integración de información, atención y procesos cognitivos de alto nivel.

El análisis de la PSD se usa en la evaluación del aporte de factores externos, como la privación del sueño, el estrés y el deterioro cognitivo, sobre la actividad eléctrica cerebral.

6.4. simetría alfa frontal (FAA - Frontal Asymmetric Alpha)

La Asimetría Alfa Frontal (FAA, por sus siglas en inglés) es una de las métricas usadas en el análisis de señales EEG para explorar la diferencia en la actividad de la banda de frecuencia alfa (8 Hz -12 Hz) teniendo en cuenta las regiones frontales cerebrales del hemisferio izquierdo y derecho, cuya diferencia se ha relacionado con la variación de estados emocionales, la regulación afectiva y predisposición a respuestas motivacionales.

El cálculo de la FAA se realiza a partir de la densidad espectral de potencia (PSD) de las señales EEG en electrodos específicos de la región frontal, comúnmente F7 (hemisferio izquierdo) y F8 (hemisferio derecho), siguiendo el sistema internacional 10-20 de colocación de electrodos (estandarización de la ubicación de los electrodos sobre la superficie de la cabeza). La fórmula general para la estimación de FAA es:

$$FAA = \log(PSD_{F8}) - \log(PSD_{F7})$$

Donde PSD_{F8} y PSD_{F7} representan la densidad espectral de potencia en los electrodos ubicados en la región frontal derecha (F8) e izquierda (F7), respectivamente.

El uso del logaritmo natural cumple la función de normalizar la distribución de los valores de potencia Alfa, que a menudo no es una distribución gaussiana, y a estabilizar la varianza, por lo que a una mayor presencia de ondas alfa en un hemisferio sugiere menor excitación neuronal en dicha región. De esta manera, un valor positivo de FAA indica mayor actividad alfa en el hemisferio derecho (menor excitación), mientras que un valor negativo sugiere mayor excitación en el hemisferio izquierdo. Según la Facultad de Medicina de la UNAM (2019), en sujetos normales se presenta una asimetría del ritmo alfa, con una amplitud, por lo general, mayor en el hemisferio derecho, lo que se ha asociado con estados de relajación y menor activación cortical.

6.5. Señales fisiológicas de la actividad electrodérmica (EDA)

La señal (EDA) es una medida dérmica (de la piel) que evalúa las variaciones en la conductancia eléctrica de la piel ayudando a determinar la activación del sistema nervioso autónomo, principalmente la actividad del sistema simpático. Estas variaciones ocurren debido a la excitación de las glándulas sudoríparas, cuya respuesta está controlada por estados emocionales, como el estrés, y otros factores emocionales y fisiológicos.

El funcionamiento fisiológico de la señal EDA se fundamenta en la secreción de sudor sobre la piel, lo que altera su conductividad, esto se logra al observar cuando se produce una activación simpática en respuesta a un estímulo emocional o cognitivo, dando como resultado, que las glándulas sudoríparas aumentan la producción del sudor, generando un cambio en la resistencia eléctrica de la piel.

6.5.1. Componentes de la señal EDA

Las dos componentes principales de la señal EDA son:

- Señal tónica (nivel basal): Representa la actividad basal (estado de una variable cuando su comportamiento no depende de estímulos externos) de la conductancia de la piel, reflejando el nivel general de activación del sistema nervioso autónomo. La señal tónica varía lentamente a lo largo del tiempo y está atada a factores como el estado emocional continuo, la temperatura ambiental y la hidratación de la piel.
- Señal fásica (SCRs - Skin Conductance Responses): Variaciones rápidas en la conductancia que ocurren en respuesta a estímulos externos, como cambios emocionales dinámicos o eventos que pueden llegar a producir estrés en una persona, como hace alusión Delgado (2021), *“El miedo es una respuesta fásica y específica provocada por amenazas inminentes, reales y predecibles”*. Estas respuestas se presentan como picos transitorios en la señal EDA y tienen una duración relativamente corta dentro de un rango de 1 a 5 segundos después de la presencia del estímulo.

La diferenciación entre estos componentes es importante para interpretar de una manera adecuada la señal EDA en estudios como lo es el análisis del estrés.

6.5.2. Métricas de la señal EDA utilizadas

Para el análisis cuantitativo de la señal EDA, se presentan métricas que permiten describir su comportamiento y correlacionarla con estados fisiológicos o emocionales. Entre las métricas más sobresalientes, se pueden encontrar:

- Promedio y mediana: Valores de tendencia central de la señal, utilizados para evaluar el comportamiento cuantitativo alrededor de un punto medio de los datos en la señal electrodérmica.
- Desviación estándar: Medida estadística de dispersión que mide la variabilidad de la señal dentro de un período determinado.
- Número de picos SCRs: Representa el número de respuestas rápidas de conductancia de la piel dentro de un intervalo de tiempo.

El análisis sobre estas métricas permite evaluar la posible influencia de la privación del sueño sobre el estrés y la fatiga cognitiva. Según Rodríguez (2009) *“en el córtex frontal medial superior relacionada con los estados de sueño, vigilancia, alerta..., atención fásica en definitiva, en estrecha interacción con lo que Luria denominó primera unidad funcional”*.

6.6. Base estadística para el análisis de señales EEG y EDA

El análisis de señales fisiológicas y cerebrales necesita la aplicación de herramientas matemáticas, especialmente en la disciplina de la estadística, que permitan obtener información importante sobre comportamiento y relación entre ellas, destacando los métodos de las estadísticas descriptivas, análisis diagnóstico por medio de la correlación y las distribuciones de probabilidad, cada una con un papel sobresaliente en la interpretación de datos provenientes de las señales EEG y EDA.

6.6.1. Estadística descriptiva

La estadística descriptiva permite caracterizar cuantitativamente la información almacenada en las señales fisiológicas mediante medidas de tendencia central y dispersión. Este

tipo de métricas son esenciales para analizar la variabilidad de las señales y la distribución de los valores en un conjunto de datos.

- Media (\bar{x}): Es el valor promedio de una agrupación de observaciones y se calcula como:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

Donde x_i representa cada muestra de la señal y n es el número total de muestras.

Con las señales EEG y EDA, la media permite evaluar tendencias generales en la amplitud o conductancia de la piel.

- Mediana (\hat{x}): Es el valor central de un conjunto de datos, posterior al ordenamiento de los mismo. Se usa cuando la distribución presenta valores extremos que afectan la media, proporcionando una representación más robusta de la tendencia.
- Desviación estándar (σ): Permite obtener información sobre la dispersión de los datos respecto a la media y se define como:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$

En el análisis de señales, la desviación estándar permite medir la variabilidad de la actividad cerebral o fisiológica en diferentes estados cognitivos.

6.6.2. Coeficiente de correlación de Spearman

La correlación estadística mide la relación entre dos variables numéricas para lograr determinar si existe un patrón de asociación entre dichas variables, dependiendo si la relación es

lineal o no lineal. El coeficiente de correlación de Spearman (ρ) es de uso imprescindible cuando la relación entre las variables no es estrictamente lineal, calculándose mediante la siguiente fórmula:

$$\rho = 1 - \frac{6 * \sum d_i^2}{n(n^2 - 1)}$$

donde d_i representa la diferencia entre los rangos de las observaciones y n es el número total de datos.

6.6.3. Distribuciones de probabilidad

Las distribuciones de probabilidad permiten modelar el comportamiento de variables aleatorias, ayudando a la interpretación estadística a lo largo de los datos y teniendo como base, algunas de las distribuciones más conocidas son:

- Distribución Gaussiana (Normal):

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\bar{x})^2}{2\sigma^2}}$$

$f(x)$ es la función de densidad de la distribución normal (Gaussian) utilizada para representar la variabilidad de señales cuando los valores tienden a agruparse alrededor de un punto central, formando una forma de campana (campana de Gauss).

- Distribución Exponencial:

$$f(x) = \lambda e^{-\lambda x}$$

Donde $\lambda > 0$ es el parámetro de tasa (rate), y x debe ser mayor o igual a 0.

Es útil en el modelado de eventos como la aparición de SCRs en señales EDA, que suelen seguir una distribución exponencial en términos de duración e intensidad de los picos.

6.7. Aprendizaje automático supervisado

El aprendizaje automático hace parte del robusto conjunto tecnológico de la inteligencia artificial, que centra su objetivo en darle a las máquinas la habilidad de aprender de los datos, técnica que es utilizada para construir modelos, tanto de clasificación como de regresión, entre otros, que permiten asignar etiquetas a observaciones con base en patrones extraídos de datos previamente etiquetados. Estos modelos tienen una de sus aplicaciones en el análisis de señales fisiológicas para evaluar estados emocionales, cognitivos y detectar condiciones como el estrés dado a raíz de la privación del sueño, objetivo principal del estudio abordado, como se menciona por Schaab et al. (2024) *“El creciente uso del aprendizaje automático en evaluaciones psicológicas se ha observado en diferentes frentes. Por ejemplo, se ha utilizado para la evaluación de variables psicopatológicas, como la depresión, la ansiedad y estrés”*.

6.7.1. Aprendizaje automático supervisado por clasificación

El aprendizaje automático supervisado por clasificación consiste en el entrenamiento de un modelo utilizando un conjunto de datos donde cada muestra o registro tiene una etiqueta conocida y especificada dentro del conjunto de datos. El objetivo del algoritmo es aprender, con base en una función, que, al recibir datos nuevos, permita predecir la clase (valores únicos discretos de la etiqueta) a la que pertenece cada observación nueva.

Matemáticamente, un problema de clasificación puede definirse como, encontrar una función $f(x)$ que mapea un conjunto de características x hacia una clase de la etiqueta y . Dado

un conjunto de datos de entrenamiento D , con muestras $(x_i$ y $y_i)$ el modelo aprende una representación de la relación entre x y y con base en funciones de optimización y evaluación de desempeño.

El aprendizaje supervisado en clasificación se divide principalmente en:

- Clasificación binaria, donde la variable objetivo (la etiqueta) tiene dos clases (categorías), por ejemplo: presencia de estrés vs. ausencia de estrés).
- Clasificación multiclase, donde se manejan más de dos clases (categorías), como, por ejemplo: niveles de activación neuronal segmentados en diferentes bandas de frecuencia.

6.7.2. Balance de clases: Undersampling

En problemas de modelo de clasificación, los conjuntos de datos pueden presentar desbalance de clases, es decir, que una clase tiene mayor cantidad de muestras que la otra. Este problema afecta el rendimiento del modelo al inducir un sesgo de clases en dirección de la clase dominante, disminuyendo la capacidad de generalización óptima del algoritmo.

El undersampling es una técnica utilizada para abordar el desbalance de clases al reducir el número de muestras de la clase mayoritaria. Esto permite que el modelo tenga una representación más equitativa de las clases y mejore su capacidad de generalización.

6.7.3. Regresión logística

La Regresión Logística es uno de los algoritmos de aprendizaje automático supervisado más usados en problemas de clasificación binaria, donde su objetivo aborda la predicción de la probabilidad de que una observación dada pertenezca a una determinada clase (binaria) mediante una función logística.

Matemáticamente, la regresión logística hace uso de la siguiente ecuación:

$$P(y = 1|x) = \frac{1}{1 + e^{-(\beta_0 + \sum_{i=1}^n \beta_1 x_i)}}$$

donde:

- $P(y = 1|x)$ representa la probabilidad de pertenecer a la clase positiva.
- β_0 es el término de sesgo.
- β_1 son los coeficientes asociados a cada característica x_i .

La función logística da como resultado un valor en el rango entre 0 y 1, permitiendo interpretaciones de probabilidad.

6.7.4. Máquinas de vectores de soporte (Support Vector Machines)

El algoritmo de máquinas de vectores de soporte (SVM) es un algoritmo de aprendizaje automático supervisado utilizado en problemas de clasificación y regresión, cuyo objetivo es encontrar un hiperplano óptimo que separe cada una de las clases del conjunto de datos de manera que la distancia entre los puntos más cercanos de cada clase y el hiperplano sea la máxima posible.

En términos matemáticos, dado un conjunto de datos de entrenamiento $D = \{(x_i, y_i)\}_{i=1}^n$, donde x_i representa las características y y_i la clase respectiva de cada registro (generalmente $y \in \{-1, 1\}$ en clasificación binaria), el SVM busca una frontera de decisión teniendo como punto de partida la siguiente ecuación del hiperplano:

$$w^T x + b = 0$$

donde:

- w es el vector de pesos que define la orientación del hiperplano.
- x representa la entrada de características.
- b es el término de sesgo que ajusta la posición del hiperplano.

El objetivo del SVM es maximizar el margen entre las clases, objetivo que se logra resolviendo un problema de optimización que tiene en cuenta restricciones de clasificación mediante programación cuadrática.

6.7.4.1. Kernels en SVM

Los kernels en SVM permiten extender su aplicación a problemas donde las clases no son linealmente separables, transformando los datos hacia espacios de mayor dimensión donde sí es posible definir una separación óptima.

El kernel más usado es el denominado Kernel de Base Radial (RBF - Radial Basis Function), el cual proyecta los datos hacia un espacio de características no lineal teniendo como base la siguiente función:

$$K(x_i, x_j) = e^{(-\gamma \|x_i - x_j\|^2)}$$

donde γ es el parámetro que manipula la influencia de los puntos cercanos y su comportamiento trabaja en función de si se tiene un valor alto de γ hace que el modelo se enfoque en patrones más detallados, mientras que un valor bajo permite aumentar la generalización de los datos.

6.7.4.2. Funcionamiento del SVM

El proceso de clasificación mediante SVM se da bajo tres pasos básicamente:

- Transformación de los datos: Si los datos no son linealmente separables, se debe aplicar un kernel (como el mencionado RBF) para proyectarlos a un espacio de mayor dimensión donde sí se pueden ser separados mediante la implementación del hiperplano.
- Optimización del margen: El algoritmo busca el hiperplano que maximiza la separación entre clases, minimizando el error de la clasificación.
- Clasificación de nuevas muestras: Al finalizar la fase de entrenamiento del modelo, se asignan etiquetas a nuevas observaciones según su posición con respecto al hiperplano de separación.

6.7.5. K-Vecinos más cercanos (K-Nearest Neighbors)

El algoritmo de aprendizaje automático supervisado por clasificación K-Vecinos Más Cercanos (KNN) asigna una etiqueta a cada observación nueva, esto en función de la similitud con su número de K vecinos más cercanos dentro del espacio de características (features). La clasificación se realiza considerando la mayoría de los votos entre los vecinos más próximos a la muestra analizada.

Matemáticamente, el criterio de similitud en KNN se establece mediante la distancia euclidiana entre un nuevo dato x y sus vecinos x_i , definida como:

$$d(x, x_i) = \sqrt{\sum_{j=1}^n (x_j - x_{ji})^2}$$

donde x_j y x_{ji} representan las coordenadas de los puntos dentro del espacio de las características.

El algoritmo KNN parte de tres pasos para su funcionamiento:

- Primero se debe establecer un valor para k , el cual hace referencia a el número de vecinos cercanos a considerar.
- Segundo, se debe calcular la distancia existente entre la muestra y todos los puntos en el conjunto de datos.
- Tercero, se seleccionan los k vecinos más cercanos y se determina la clase que presenta una frecuencia mayor entre ellos.

6.7.6. Árboles de decisión

Los árboles de decisión (decision tree) son algoritmos de clasificación que dividen los datos en regiones utilizando criterios de decisión jerárquicos. Su estructura está conformada por nodos internos, ramas y hojas, donde cada nodo representa una pregunta sobre una característica y cada hoja corresponde a una categoría asignada.

El criterio de división se basa en medidas de impureza, como la entropía o el índice Gini, que determinan la mejor separación entre las clases. La ecuación del índice Gini se define como:

$$G = 1 - \sum_{i=1}^c p_i^2$$

donde p_i es la proporción de elementos de la clase i dentro de un nodo y c es el número total de clases.

El algoritmo de árboles de decisión trabaja de manera tal, que en primer lugar selecciona la mejor característica para dividir los datos usando un criterio de impureza, luego crea nodos de decisión hasta alcanzar una condición en la cual se detiene, buscando evitar el sobreajuste (overfitting) y al final clasifica nuevas muestras recorriendo el árbol desde la raíz hasta una hoja.

6.7.7. Bosques aleatorios (Random Forest)

Random Forest está determinado como una extensión del algoritmo de árboles de decisión, en el cual se itera sobre varios algoritmos de árboles y se agrupan sus predicciones individuales para mejorar la precisión del modelo del algoritmo de bosque aleatorio. Este algoritmo se basa en el principio de bagging (Bootstrap Aggregating), por medio del cual se entrenan varios árboles de decisión sobre diferentes subconjuntos del conjunto de datos para finalmente promediar cada una de sus decisiones.

Cada uno de los árboles se entrena utilizando una muestra aleatoria del conjunto de datos, al igual que el proceso de selección de un subconjunto de características en cada división. Este proceso logra reducir la correlación entre los árboles en cuestión logrando una mejora sobre la capacidad de generalización del modelo Random Forest.

Se logra describir el modo en que opera el algoritmo de Random Forest planteado los siguientes pasos:

- Generar múltiples árboles de decisión de manera estadística con muestras aleatorias sobre el conjunto de datos.
- Clasificación de una nueva muestra de cada árbol y obtener la predicción de cada uno de ellos.

- Calcular la importancia de cada característica, ayudando al análisis en factores importantes de la clasificación.

6.8. Aprendizaje automático no supervisado

El aprendizaje automático no supervisado es una técnica de análisis y entrenamiento de conjunto de datos, donde el modelo no cuenta con etiquetas predefinidas en su contenido y no tiene una guía fija con el cual ser entrenado, sino que, por el contrario, al momento de iniciar el proceso de prueba y entrenamiento del modelo, él mismo se encarga de buscar patrones y estructurar en el conjunto de datos consiguiendo agrupar los datos por clústeres. Este enfoque de aprendizaje automático no supervisado es de gran utilidad para fijar los datos en grupos homogéneos sin la necesidad de información previa sobre sus posibles categorías o clases, lo que permite identificar relaciones difíciles de observar y estructuras ocultas en la información.

6.8.1. Clustering con K-Means

K-Means es uno de los algoritmos de agrupamiento más utilizados en aprendizaje no supervisado, el cual establece el objetivo de dividir un conjunto de datos en k grupos o clusters, logrando minimizar la distancia entre cada una de las observaciones y calculando el centroide de cada grupo al que pertenecen (clase).

6.8.2. Funcionamiento del algoritmo K-Means

El proceso de agrupamiento mediante K-Means es descrito por una serie de pasos mencionados a continuación:

- Elegir un número k de clusters que se desean formar.
- Inicializar aleatoriamente k centroides dentro del espacio de datos.

- Asignar cada observación al clúster cuyo centroide se encuentre más cercano, utilizando la distancia euclidiana:

$$d(x, \mu_k) = \sqrt{\sum_{i=1}^n (x_i - \mu_{ki})^2}$$

Donde x_i representa una muestra de datos y μ_k el centroide del clúster k .

- Calcular de nuevo los centroides como la media de los puntos en cada clúster.
- Repetir los pasos de asignar cada observación al clúster y de calcular de nuevo los centroides, hasta que los centroides dejan de moverse o se alcanza un criterio de convergencia.

6.8.3. Método del codo

El Método del Codo se usa para determinar el número óptimo de clústeres k en un problema diseñado para el agrupamiento, que trabaja en la evaluación de la inercia intra-cluster, la cual mide la variabilidad dentro de cada grupo y se define como:

$$W(K) = \sum_{K=1}^K \sum_{x_i \in C_k} ||x_i - \mu_k||^2$$

Donde $W(K)$ representa la suma de las distancias cuadradas entre las observaciones y sus centroides para un número dado de clústeres k .

Para encontrar el número óptimo de clúster k , se ejecuta el algoritmo K-Means para varios valores de k y se calcula la inercia intra-cluster, luego se grafica $W(K)$ en función de k , para finalmente identificar el punto donde la curva comienza a estabilizarse, formando la forma de "codo", punto que representa el número óptimo de clústeres.

6.9. Métricas de evaluación para algoritmos de clasificación

La evaluación de modelos de clasificación es un paso de gran importancia para medir el rendimiento y efectividad del modelo para la creación de etiquetas a nuevas observaciones, lo que se denomina, generalización del modelo. Para ello, se implementan diversas métricas que permiten analizar la precisión, sensibilidad y balance entre estos valores, permitiendo que el modelo sea robusto y confiable en distintos escenarios.

6.9.1. Exactitud (Accuracy)

La exactitud es una métrica que mide el porcentaje de predicciones correctas realizadas por un modelo de clasificación sobre el total de observaciones analizadas. Se define matemáticamente como:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

donde:

- *TP* (True Positives) son las instancias correctamente clasificadas como positivas.
- *TN* (True Negatives) son las instancias correctamente clasificadas como negativas.
- *FP* (False Positives) son las instancias clasificadas erróneamente como positivas.
- *FN* (False Negatives) son las instancias clasificadas erróneamente como negativas.

La exactitud es útil cuando las clases están balanceadas, pero en situaciones de presentar un desbalance de clases muy pronunciado, puede llegar a no ser válida su medición, ya que un

modelo puede tener alta exactitud simplemente clasificando todas las observaciones como pertenecientes a la clase mayoritaria.

6.9.2. Precisión (Precision)

La precisión mide cuántas de las instancias clasificadas como positivas en realidad pertenecen a la clase positiva y se define como con la fórmula:

$$Precision = \frac{TP}{TP + FP}$$

La precisión es relevante bajo contextos en los cuales es importante minimizar los falsos positivos, como es el caso de la detección de enfermedades, donde un diagnóstico incorrecto podría incurrir en la generación de tratamientos incorrectos.

6.9.3. Recall (Sensibilidad)

El recall (sensibilidad) indica la proporción de instancias positivas correctamente identificadas por el modelo entrenado, es decir, mide cuántos de los casos positivos reales fueron recuperados. Se expresa como:

$$Recall = \frac{TP}{TP + FN}$$

El recall es necesario en aplicaciones donde se busca de manera imperativa minimizar los falsos negativos, como en sistemas de seguridad o detección de fraudes, donde perder una instancia positiva podría representar un riesgo significativo.

6.9.4. Puntuación F1 (F1-Score)

La puntuación F1 (F1-Score) es una métrica que combina tanto la precisión como el recall, proporcionando un equilibrio entre ambas. Su cálculo se establece como la media de estas dos métricas:

$$F1 = 2 \frac{\textit{Precisión} * \textit{Recall}}{\textit{Precisión} + \textit{Recall}}$$

El F1-Score es útil cuando existe un desbalance de clases, puesto que evalúa la capacidad del modelo para clasificar correctamente la clase minoritaria sin favorecer excesivamente la precisión o la sensibilidad.

6.9.5. Curva ROC (Receiver Operating Characteristic)

La Curva ROC (Receiver Operating Characteristic) es una herramienta gráfica utilizada en la evaluación de modelos de aprendizaje automático supervisado de clasificación binaria. Su objetivo es analizar el rendimiento del modelo entrenado en la separación de clases mediante la visualización de la relación entre la tasa de verdaderos positivos (TPR) y la tasa de falsos positivos (FPR) en distintos umbrales de clasificación.

6.9.5.1. Construcción de la Curva ROC

La curva ROC se obtiene siguiendo los siguientes pasos:

- Variar el umbral de decisión del modelo en diferentes puntos, registrando las tasas de verdaderos positivos (TPR) y falsos positivos (FPR).
- Graficar los valores de TPR en el eje y y FPR en el eje x , formando la curva ROC.

Matemáticamente, las tasas TPR y FPR se definen como:

$$TPR = \frac{TP}{TP + FN} \quad (\text{True Positive Rate})$$

$$FPR = \frac{FP}{FP + TN} \quad (\text{False Positive Rate})$$

La interpretación de la Curva ROC permite evaluar cómo es la variabilidad de la capacidad de discriminación del modelo en función del umbral de clasificación. Cuanto más se acerque la curva al vértice superior izquierdo de la gráfica ($TPR = 1$, $FPR = 0$), mejor será el desempeño del modelo.

6.9.6. Área Bajo la Curva ROC (AUC)

El Área Bajo la Curva (AUC - Area Under the Curve) es un indicador que resume el rendimiento del modelo en la tarea de clasificación. Su valor representa la probabilidad de que el modelo asigne una puntuación más alta a una instancia positiva que a una negativa, reflejando la calidad de la separación entre clases. La interpretación del valor de AUC se detalla a continuación:

- $AUC \approx 1$: El modelo tiene una separación perfecta entre clases, lo que indica un excelente rendimiento.
- $AUC \approx 0.5$: El modelo no tiene capacidad predictiva y su desempeño no es mayor que el azar.
- $AUC < 0.5$: El modelo está clasificando las clases de manera incorrecta, lo que refleja una configuración deficiente del algoritmo el momento de ser entrenado

6.9.7. Matriz de confusión

La Matriz de Confusión es una tabla que permite evaluar el rendimiento de un modelo de clasificación, mostrando el número de predicciones correctas e incorrectas en cada clase, para

ello, es importante analizar los tipos de errores del modelo y llegar a conclusiones que ayuden a mejorar el rendimiento de dicho modelo.

Table 1 Organización de los datos que se muestran por medio de una matriz de confusión

Clase Real \ Predicción	Positiva	Negativa
Positiva (Verdaderos Positivos, TP)	TP	FN
Negativa (Falsos Positivos, FP)	FP	TN

- TP (True Positives): Casos correctamente clasificados como positivos.
- TN (True Negatives): Casos correctamente clasificados como negativos.
- FP (False Positives): Casos incorrectamente clasificados como positivos (error tipo I).
- FN (False Negatives): Casos incorrectamente clasificados como negativos (error tipo II).

6.9.8. Validación cruzada (Cross-Validation)

La validación cruzada (Cross-Validation) es un método utilizado en el entrenamiento y evaluación de modelos de aprendizaje automático para estimar la capacidad del modelo de generalizar. El objetivo de la validación cruzada es evitar problemas de sobreajuste (overfitting), buscando que el modelo no se adapte estricta y únicamente a los datos de entrenamiento, sino que tenga un desempeño robusto en datos nuevos.

El procedimiento consiste en dividir el conjunto de datos en múltiples subconjuntos de entrenamiento y prueba, permitiendo evaluar el rendimiento del modelo en diferentes particiones

del mismo conjunto de datos. Esto garantiza una estimación más confiable del error de predicción y mejora la estabilidad del modelo.

6.9.8.1. Métodos de Validación Cruzada

Existen varios enfoques de validación cruzada, entre los que se encuentran la Validación Hold-Out, K-Fold Cross-Validation y Leave-One-Out Cross-Validation (LOO-CV), los cuales se explican a continuación:

- Validación Hold-Out: Se divide el conjunto de datos en dos partes, una para entrenamiento y otra para prueba.
- K-Fold Cross-Validation: Enfoque de uso común que divide el conjunto en subconjuntos llamados “ k ” para luego entrenar el modelo k veces, cada vez utilizando un subconjunto diferente como prueba y el resto para entrenamiento.
- Leave-One-Out Cross-Validation (LOO-CV): Se usa cada muestra individualmente como conjunto de prueba, dejando todas las demás para entrenamiento, útil en conjuntos de datos pequeños.

7. Metodología

7.1. Tipo de investigación y diseño del estudio

El presente trabajo de grado maneja un enfoque de investigación cuantitativo fundamentado en el análisis sobre un conjunto de datos que son producto del registro de las señales cerebrales electroencefalográficas (EEG) y señales de la actividad electrodérmica (EDA) en el experimento denominado “Sleep deprivation”. Este enfoque investigativo permite efectuar un proceso cuantificable sobre las señales fisiológicas y cerebrales, así como la aplicación de algoritmos de aprendizaje automático para la identificación de patrones en los datos y la subyacente construcción de modelos predictivos.

Por otra parte, el diseño de estudio se define como un diseño descriptivo-correlacional con elementos de clasificación. En primera instancia, se llevó a cabo una etapa descriptiva para obtener la caracterización de las señales EEG (a través del filtrado para obtener sus bandas de frecuencia y el cálculo de la asimetría alfa frontal) y EDA (apoyado en sus componentes tónica y fásica) en la muestra de los participantes. Luego, se abordó la exploración de las posibles correlaciones existentes entre las señales fisiológicas y cerebrales para finalmente llegar al desarrollo de un modelo predictivo de aprendizaje automático para evaluar el estrés o deterioro cognitivo debido a la privación del sueño, abordando un problema de clasificación binaria que busca discriminar entre los posibles estados fisiológicos asociados a “estrés” y “no estrés” inferidos a partir de la técnica de clustering K-means.

La elección de este diseño metodológico se justifica en función de los objetivos planteados para la investigación, lo que lleva a una fase descriptiva que es imperativa para entender las características de las señales fisiológicas y cerebrales en la muestra estudiada. El componente correlacional ayuda a identificar posibles relaciones entre las variables, permitiendo

obtener información determinante sobre la interrelación entre la actividad cerebral y el sistema nervioso autónomo. A su vez, agregar elementos de clasificación , mediante el uso de algoritmos de aprendizaje automático, complementa en buena medida el objetivo de desarrollar un modelo que permita identificar patrones complejos en los datos fisiológicos y cerebrales. En conjunto, este diseño integral busca proporcionar una comprensión detallada de las señales fisiológicas y cerebrales junto a su potencial para la clasificación de estados relevantes.

7.2. Conjunto de datos inicial

Para el desarrollo del presente trabajo de investigación cuantitativa, el conjunto de datos existente que se tomó como base para llevar a cabo el estudio, fue producto de un experimento denominado “Sleep Deprivation” descrito por Martínez Vásquez et al. (2023), en el cual, 11 sujetos durante 24 horas se mantuvieron despiertos y realizando 15 diferentes actividades en 12 momentos (12 trials – 1 trial cada 2 horas) a lo largo del experimento (24 horas); estas actividades, denominadas eventos, tuvieron como objetivo, censar el desarrollo o deterioro del funcionamiento cognitivo y emocional de los sujetos a medida que permanecían bajo el desarrollo del experimento. Dicho esto, y por la complejidad dimensional del conjunto de datos, el presente trabajo centró su análisis en uno de los quince eventos disponibles en el conjunto de datos, denominado: Tarea de Consciencia de Error (*Error Awareness Task - EAT*).

7.1.1. EAT (*Error Awareness Task*)

EAT fue utilizada para explorar el efecto de la privación de sueño sobre el desempeño motriz y cognitivo de los sujetos. En este evento los sujetos desarrollaban, por medio de un computador, la presentación secuencial de palabras que describían un tono de color y su fuente era similar a la descrita por la palabra y cada palabra se mostraba durante 900 ms seguida de un intervalo entre estímulos de 600 ms. Cada Sujeto debía responder mediante presionando el botón

acorde a cada intervalo: "Enter" y retener la respuesta en los ensayos de "No enter", los cuales se activaban bajo en función de dos condiciones específicas: "Enter" cuando la misma palabra aparecía en dos ensayos consecutivos, o cuando la palabra y su color no coincidían, y "No enter", la palabra y el color de la palabra no coincidían.

7.3. Participantes

El estudio utilizó un conjunto de datos previo correspondiente al experimento denominado "Sleep Deprivation" el cual incluía originalmente los registros cerebrales y fisiológicos de once sujetos. En la búsqueda de cubrir los objetivos de la actual investigación, el análisis se centró inicialmente en los datos de nueve sujetos (identificados como 1, 4, 5, 6, 7, 8, 9, 10, 11), cuyos registros completos de señales electroencefalográficas (EEG) y de actividad electrodérmica (EDA) fueron procesados.

El proceso de selección de la muestra para el análisis final fue iterativo basado en la calidad y modelado de los datos, en el cual, en su primera fase de depuración, se descartaron cuatro de los nueve sujetos, concretamente, tres de los cuatro sujetos descartados fueron el 5, 8 y 10, excluidos en función de diversos análisis, como la detección de valores atípicos y una alta desviación estándar en la característica "EDA_Tonic_AVG" (promedio de la señal tónica EDA), indicando un ruido elevado en sus respectivos registros electrodérmicos, y en la misma dirección, el sujeto 11 fue descartado luego de observarse valores atípicos y una elevada desviación estándar en la característica "alpha_AVG" (promedio de la actividad cerebral en la banda de frecuencia alfa), lo que, en su momento, sugería particularidades que podían llegar a distorsionar el análisis grupal. Esta primera etapa de exploración y selección dio como resultado la depuración de los datos y dando como consecuencia, un conjunto de datos correspondiente a 5 sujetos (1, 4, 6, 7 y 9).

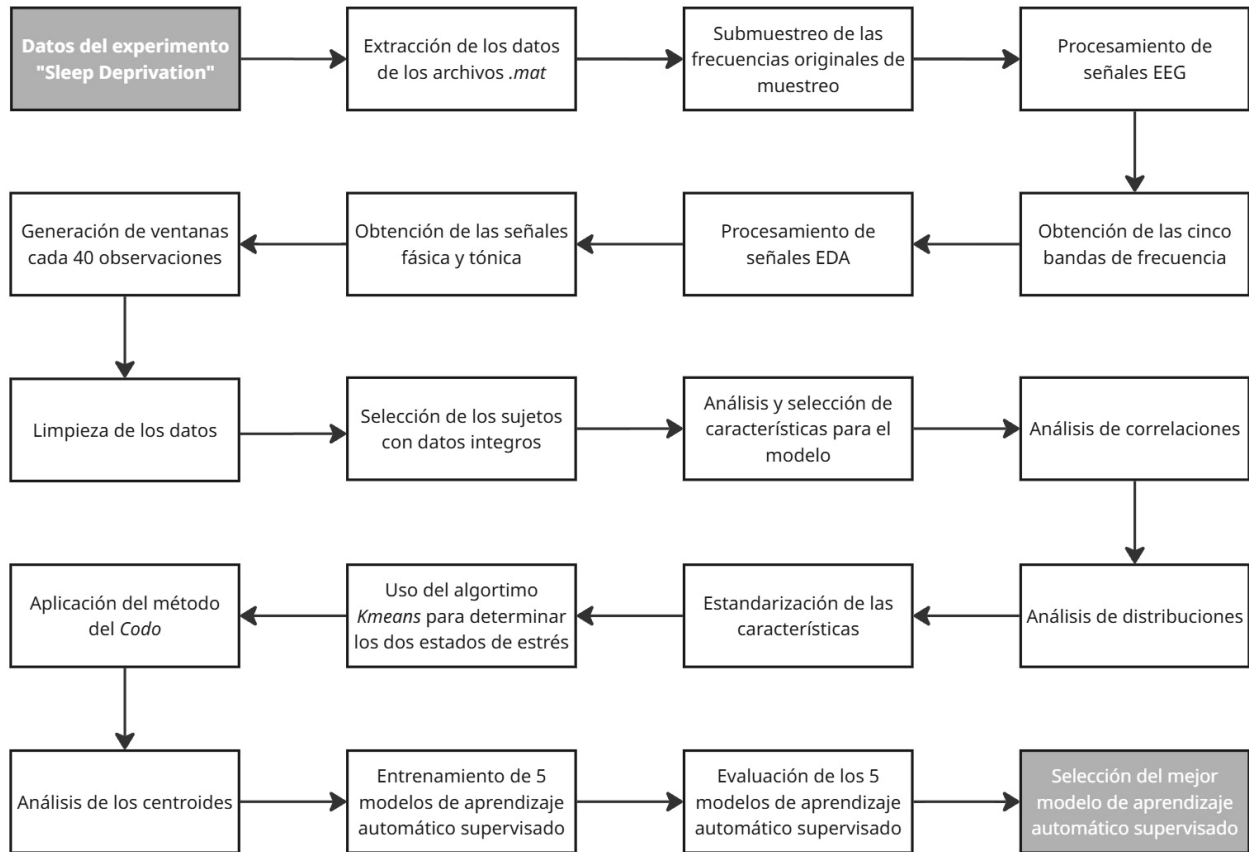
Posteriormente, para el desarrollo y evaluación del modelo predictivo como producto final, se realizó una segunda selección a partir de estos cinco sujetos y se logró optimizar el conjunto de datos, conformándolo finalmente por los sujetos 1, 6 y 7. Esta decisión se fundamentó en los resultados del modelo individual (para cada sujeto por separado), en el cual, estos tres sujetos mostraron un balance de clases adecuado entre los estados fisiológicos inferidos (“estrés” y “no estrés”) junto con un rendimiento de clasificación altos y consistente. En contraste, el sujeto 4 mostró indicios de sobreajuste en su modelado individual, mientras que el sujeto 9 presentó un desbalance considerable de sus clases que podrían desencadenar en un sesgo en el entrenamiento del modelo general.

Con los parámetros mencionado anteriormente, el análisis y modelo predictivo se llevó a cabo con los datos de los tres sujetos (1, 6 y 7), donde para cada uno de ellos, se realizó el análisis con todos y cada uno de los doce trials (periodos de evaluación durante el experimento Sleep Deprivation) disponibles en el conjunto de datos, usando un segmento específico, correspondiente a 48,000 muestras dentro de cada trial, para cada sujeto, en la extracción de las características.

7.4. Recolección de los datos

En la Figura 1 se muestra la descripción general de la metodología que estructuró el desarrollo del presente estudio. A través del diagrama, se ilustran las fases importantes del proceso, desde del preprocesamiento de los datos de las señales fisiológicas y cerebrales, hasta la implementación de técnicas de aprendizaje automático para la clasificación de los estados de estrés, buscando una comprensión clara y plausible de cada etapa, destacando la interconexión entre los distintos componentes metodológicos.

Figura 1. Descripción general de la metodología llevada a cabo en el proceso de desarrollo del trabajo de grado



7.4.1. Procedimiento

El procesamiento de las señales fisiológicas y cerebrales para lograr la conformación del conjunto de datos, el cual serviría como punto de partida para el análisis de dichos datos, se llevó a cabo mediante una secuencia de pasos ordenados, ejecutados en el entorno de programación de Python llamado Jupyter-Notebook, y el uso de sus librerías especializadas para tal fin analítico. A continuación, se enumeran estos pasos secuenciales:

- Extracción de los datos:** Los datos en crudo, de las señales EEG y EDA de los nueve sujetos fueron extraídos de sus respectivos archivos con extensión *.mat*. Esta extracción se logró mediante la librería *scipy.io* de Python, organizando la información por sujeto y por cada uno de los doce trials del experimento.

- **Submuestreo de las frecuencias originales de muestreo:** Las señales de actividad electrodérmica (EDA) tiene originalmente una frecuencia de muestreo de 400 Hz, mientras que las señales electroencefalográficas (EEG) tiene su frecuencia de muestreo a 200 Hz, lo que llevo a realizar un submuestreo en las señales EDA a 200 HZ. Dicho proceso se alcanzó seleccionando una de cada dos muestras consecutivas de la señal original y así obtener la frecuencia de muestreo de las señales EDA bajo la misma frecuencia muestral de las señales EEG, permitiendo un análisis temporal acorde a las diferentes características del conjunto de datos.
- **Estructura inicial de los datos:** Luego de ser extraídas y de un submuestreo en la señal electrodérmica (EDA), las dos señales se cargaron en estructuras de datos tipo DataFrame, estructura propia de la librería Pandas de Python, facilitando la manipulación y acceso a los datos de cada uno de los sujetos, sus respectivos trials y evento específico para las fases subsiguientes.
- **Procesamiento de señales EEG:** Para el análisis de la actividad electroencefalográficas, se seleccionó el canal frontal Fp2 como fuente principal para la extracción de las características en las 5 bandas de frecuencia, logrando de esta manera, el proceso de filtrado digital FIR (Finite Impulse Response), implementado con la función remez de la librería scipy.signal de Python. Este filtrado permitido descomponer la señal en sus 5 bandas de frecuencia: delta (0.5 Hz – 4 Hz), theta (4 Hz – 8 Hz), alfa (8 Hz- 13 Hz), theta (13 Hz – 30 Hz) y gamma(>30 Hz).

- **Procesamiento de señales EDA:** Las señales EDA de cada sujeto y sus respectivos trilas, luego de la etapa de submuestreo a 200 Hz, fueron procesadas utilizando la librería Neurokit2. Esta Librería de Python permitió la descomposición de la señal electrotérmica en sus componentes principales: la señal tónica, que proporciona la información relacionada con el nivel de conductancia basal de la piel (Skin Conductance Level - SCL), y la señal fásica, señal que captura las respuestas transitorias de la conductancia de la piel (Skin Conductance Responses - SCRs).
- **Segmentación y extracción de las características estadísticas:** Las series temporales de las cinco bandas de frecuencia de la señal EEG (obtenidas del canal frontal Fp2) y de las componentes tónica y fásica de la señal EDA fueron segmentadas en ventanas consecutivas. Cada ventana tuvo una longitud de 40 registros equivalente a 200 milisegundos de la señal EDA, partiendo del hecho de que la frecuencia de muestreo está establecida a 200 Hz, y teniendo en cuenta que cada trial está compuesto por 48000 registros muestrales, el proceso de generación de las ventanas dio como resultado 1200 ventanas por cada uno de los doce trilas. Para cada una de estas ventanas se calcularon tres características estadísticas: la media, la mediana y desviación estándar.
- **Cálculo de la densidad espectral de potencia y asimetría alfa frontal:** Al diseño de la segmentación por ventanas se agregó el cálculo de la Densidad Espectral de Potencia (PDS) para cada una de las 5 bandas de frecuencia extraídas del canal Fp2, usando el método de la transformada rápida de Fourier (FFT) para estimar la potencia media en cada banda. Asimismo, se calculó la Asimetría Alfa

Frontal (FAA), el cual se obtuvo a partir de la actividad de la banda de frecuencia Alfa de los canales frontales F7 y F8 (que fueron filtrados previamente), mediante la fórmula:

$$FAA = \text{Log}(\text{Potencia Alfa F8}) - \text{Log}(\text{Potencia Alfa F7})$$

calculada para segmento o ventana.

- **Almacenamiento del conjunto de características:** Las características extraídas por ventana (estadísticas de las bandas de frecuencia de la señal EEG, las componentes tónica y fásica de la señal EDA, PDS y FAA) para los nueve sujetos con sus respectivos doce trials fueron agrupados y almacenados en un archivo plano .csv de forma individual, por sujeto, para posteriormente usar estos archivos planos en el diseño y creación del DataFrame de Pandas que serviría como punto base para la fase de limpieza, análisis diagnóstico y modelado predictivo.

7.4. Análisis de los datos

Luego de estar consolidadas las características extraídas de las señales EEG y EDA, se inició la fase de análisis de los datos que incluyó el preprocesamiento de los mismo y la preparación para el modelo predictivo final.

7.5.1. Preprocesamiento

7.5.1.1. Empalme del conjunto de datos

El primer paso del preprocesamiento estableció el concatenar los DataFrames individuales (correspondientes a cada sujeto y trial) en un único DataFrame general, que en un inicio estuvo estructurado por los registros (ventanas) de los nueve sujetos procesados, dando como resultado una estructura de datos bidimensional de 129600 ventanas caracterizadas por 31 columnas de variables fisiológicas, cerebrales y espectrales calculadas.

7.5.1.2. Verificación de la calidad de los datos

Se realizó una exploración a cabalidad del DataFrame general para asegurar su integridad y consistencia en los datos almacenados en ella, dicha exploración dio como resultado la ausencia de valores faltantes o nulos, en todas las columnas, adicional, a la confirmación de la asignación de tipos de datos a cada característica acorde a la naturaleza de los datos en cada una de ellas evitando realizar transformaciones adicionales.

7.5.1.3. Detección de valores duplicados

El procedimiento para identificar y eliminar registros duplicados proporcionó la información necesaria para establecer que no existían registros duplicados y continuar con la intención de lograr un conjunto de datos integro y consistente.

7.5.1.4. Identificación y eliminación de sujetos con datos atípicos

Para llevar a cabo un análisis de los datos y posterior modelado de estos robusto, se implementó un procedimiento para identificar y excluir a los sujetos que presentaban características atípicas acentuadas, basado en la observación de la dispersión de los datos con base en la media aritmética calculada, observación realizada por medio de la desviación estándar (STD) buscando valores fuera de lo esperado, logrando así determinar que los sujetos 5, 8 y 10 tendían a poseer una alta variabilidad en la característica EDA_Tonic_STD (promedio del nivel tónico de la actividad electrodérmica) mientras que el sujeto 11 mostró un comportamiento similar en la característica alpha_AVG (promedio de la actividad en la banda de frecuencia Alpha de la señal EEG) resultados que ayudaron a excluir a los sujetos 5, 8, 10 y 11 del conjunto de datos general. Luego de determinar la eliminación de los registros respectivos de dichos sujetos, se llegó a un conjunto de datos dispuesto en el DataFrame general con la permanencia de los

sujetos 1, 4, 6, 7 y 9, y un total de registros igual a 72,000 (5 sujetos con sus 12 trials respectivos y 1200 ventanas para cada trial) y manteniendo por el momento las 31 columnas.

7.5.1.5. Selección de características para el análisis exploratorio y correlacional

Para el análisis exploratorio y análisis de correlaciones, el proceso se centró en la selección de subconjuntos sobre las 31 características a partir de su relevancia teórica en el contexto del estrés y la actividad cognitiva. Esta incluyó principalmente las métricas derivadas de la actividad electrodérmica (EDA), la actividad cerebral de la banda de frecuencia alfa de la señal EEG y el índice de asimetría alfa frontal FAA partiendo de la asociación de la alfa y FAA con estados de relajación, alerta y estrés.

7.5.1.6. Análisis de correlaciones

Se calculó la matriz de correlaciones en función del coeficiente de correlación de Spearman, buscando describir de manera óptima las posibles relaciones no lineales, usando las siguientes características: EDA_Phasic_AVG, EDA_Phasic_STD, EDA_Tonic_AVG, EDA_Tonic_STD, FAA, alpha_AVG y alpha_STD, obteniendo una exploración de las interrelaciones lineales y no lineales entre estas características, encontrando al final de este proceso, correlaciones positivas en términos de un magnitud baja, entre el índice FAA y las métricas de variabilidad de la señal EDA (EDA_Phasic_STD y EDA_Tonic_STD).

Para realizar el cálculo de correlación, se usó el coeficiente de Spearman (ρ) dado que las señales fisiológicas medidas (EEG y la EDA) pueden no cumplir con los supuestos de normalidad necesarios para las relaciones lineales, es ahí donde el coeficiente ρ toma relevancia ya que esta métrica basa su comportamiento con base rangos en lugar de valores absolutos como

lo realiza el coeficiente de correlación lineal Pearson, llegando a concluir que el coeficiente de Spearman es determinante para encontrar si las variables se mueven en la misma dirección sin importar la presencia o no de comportamientos netamente lineales.

7.5.1.7. Análisis de distribuciones

Se inspeccionó las distribuciones de probabilidad de las características clave (EDA_Phasic_STD, EDA_Tonic_AVG, FAA, alpha_AVG) encontrando que la característica EDA_Tonica_AVG y FAA se aproximaban a una distribución Gaussiana, como se observa en la Figura 2 y Figura 3 respectivamente, mientras que, la característica EDA_Phasic_STD mostraba una distribución de tipo exponencial como se destaca en la Figura 1.

Figura 2. Distribución exponencial de la característica EDA_Phasic_STD

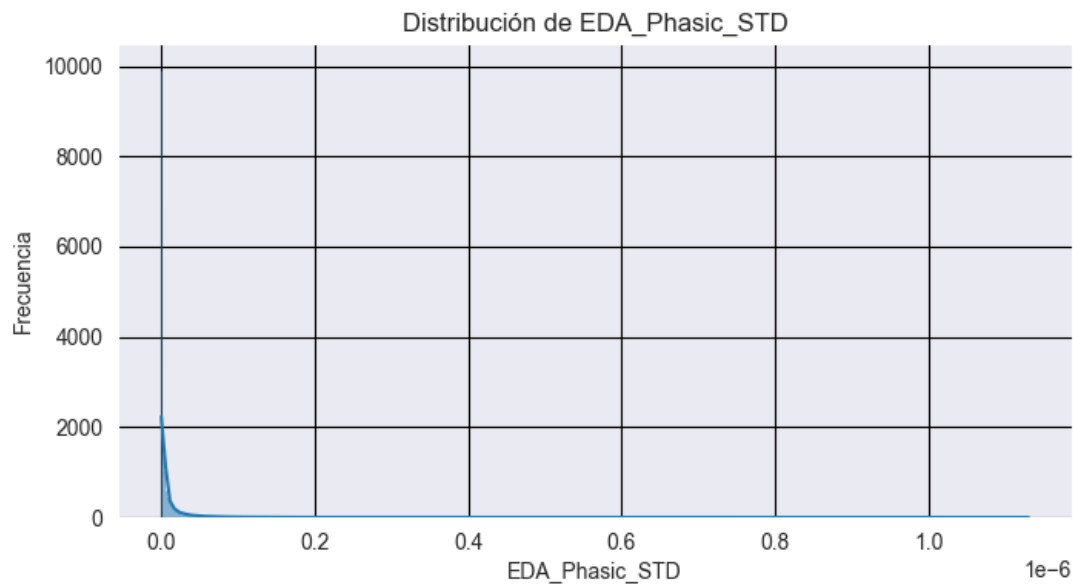


Figura 3. Distribución gaussiana de la característica EDA_Tonic_AVG

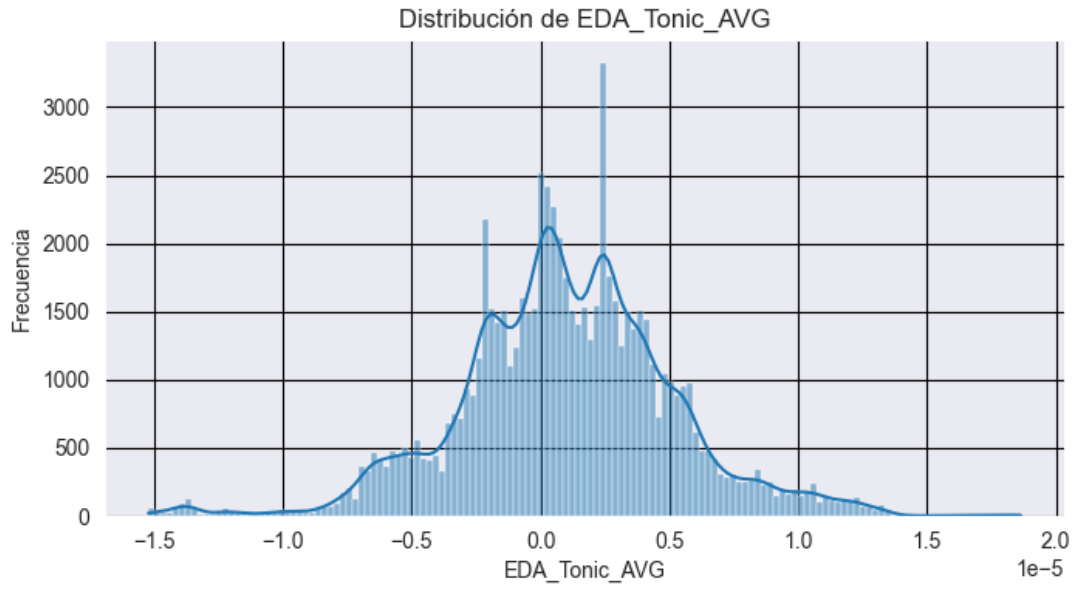
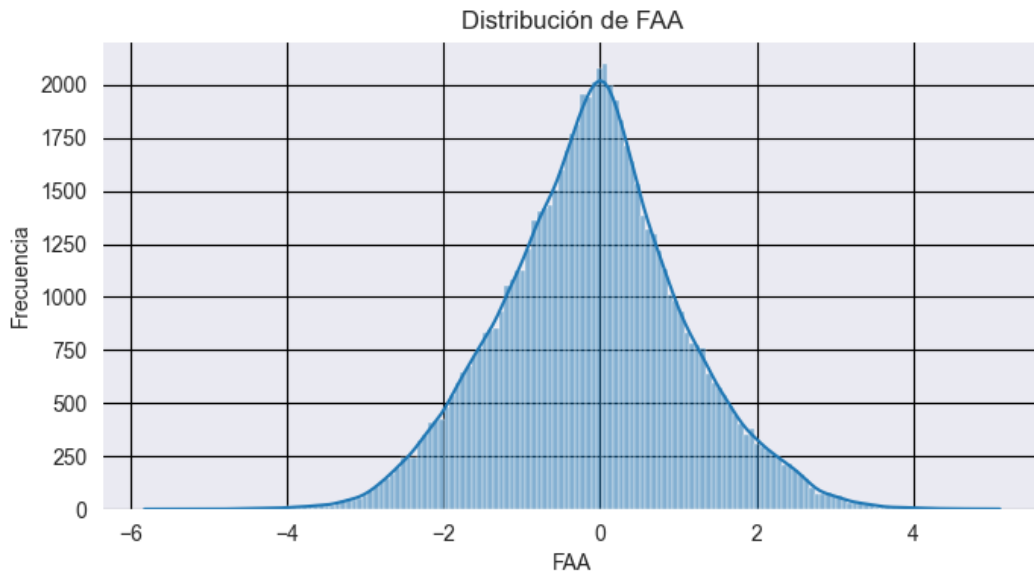


Figura 4. Distribución gaussiana de la característica FAA



7.5.2. Modelado de los datos para el aprendizaje automático (fase inicial de etiquetado y evaluación individual)

7.5.2.1. Definición de la tarea y selección de características para el agrupamiento por el método de clústeres

El objetivo del modelado de los datos fue desarrollar un sistema de clasificación binaria cuya función principal fuera determinar posibles estados fisiológicos asociados a “estrés” y “no estrés” como etiquetas para el proceso de análisis predictivo. Dado que originalmente no se tenía disposición de etiquetas predefinidas para estos estados, se aplicó el método de algoritmo de aprendizaje automático no supervisado para optimizar el diseño de las etiquetas en mención, proceso que se logró seleccionando cuatro características clave y alcanzando el objetivo por medio del algoritmo denominado K-means, logrando el planteamiento de estados fisiológicos discriminados entre “estrés” y “no estrés”. Las características usadas para este proceso fueron: EDA_Phasic_STD (variabilidad de la respuesta fásica de EDA), EDA_Tonic_AVG (nivel promedio de la actividad tónica de EDA), FAA (Asimetría Alfa Frontal) y alpha_AVG (promedio de la actividad en la banda Alfa).

7.5.2.2. Estandarización de características

Previo al proceso de clustering y al entrenamiento de los modelos en el análisis predictivo, las características seleccionadas (EDA_Phasic_STD, EDA_Tonic_AVG, FAA, alpha_AVG) para cada uno de los 5 sujetos fueron estandarizadas mediante la aplicación del método de StandarScaler de la librería scikit-learn de Python, cuyo proceso transformó los datos, en las columnas seleccionadas, para que tuvieran una media (o promedio) de 0 y una desviación estándar de 1, buscando asegurar que todas las características contribuyeran de forma equitativa al análisis, independientemente de sus magnitudes originales.

7.5.2.3. Generación de etiquetas mediante clústeres de K-Means

Por medio del algoritmo de aprendizaje automático no supervisado por agrupamiento (clustering) K-Means se realizó la estimación, de manera individual, sobre los cinco sujetos (1, 4, 6, 7 y 9) de las etiquetas que describen de forma binaria la presencia o no de estrés en señales fisiológicas configurando el algoritmo con dos clústeres ($k=2$) y la hipótesis de que estos dos conglomerados serían la representación de los dos estados de interés: “No estrés” (clúster 0) y “Estrés” (clúster 1). La posterior asignación a cada ventana de datos a uno de estos dos clústeres generó la variable objetivo para el entrenamiento de modelos de aprendizaje automático supervisado subsiguientes.

7.5.2.4. Asignación de Etiquetas a los Clústeres K-Means

La asignación de las etiquetas "No estrés" y "Estrés" a los dos clústeres generados por el algoritmo K-Means se basa en el perfil fisiológico de cada una de las dos agrupaciones, que es coherente con la respuesta humana al estrés. Dado que el algoritmo de K-Means es un modelo de aprendizaje automático no supervisado que agrupa datos por similitud, la interpretación de estos clústeres se realiza analizando los valores promedio de sus características luego de su estandarización. Al observar los valores centrales para EDA_Phasic_STD, EDA_Tonic_AVG, FAA y alpha_AVG dentro de cada uno de los dos clústeres, fue posible determinar dos estados fisiológicos opuestos como se detalla en la Tabla 1; el Clúster 0 se caracteriza por tener valores bajos o cercanos a la media en las características luego de ser estandarizadas, dicho de una manera plausible, los valores de la característica EDA_Phasic_STD (-0.1978) y EDA_Tonic_AVG (-0.4962) se sitúan por debajo de su promedio estandarizado, recordando que dicho promedio es 0. Estos datos sugieren una menor activación del sistema nervioso simpático, lo que se correlaciona con un estado de relajación. Según Martínez et al. (2020), la Actividad

Electrodermal (AED), compuesta por sus componentes tónica y fásica, se relaciona directamente con la activación del sistema sudomotor, razón por la cual, la AED es considerada un marcador fiable de la activación simpática. En su estudio, aunque se centra en el estudio de la depresión, se observa que los sujetos control (eutímicos y sanos) exhiben respuestas electrodérmicas más pronunciadas ante estímulos estresores en comparación con pacientes deprimidos (Martínez et al., 2020, p. 258). De igual manera, dentro del clúster 0, La asimetría alfa frontal (FAA) con un valor de -0.3260 y un α_AVG cercano a la media (0.0013) complementan este perfil. La FAA tiende a vincularse a menor carga emocional/cognitiva o a emociones de valencia positiva, en contraste con patrones de estrés (Corona, 2023, p. 16, citando a Cheung et al., 2019), llegando a inferir que el Clúster 0 se interpreta como el estado de "No Estrés".

Tabla 1. Centros de los Clústeres K-Means y su Interpretación Fisiológica

Característica	Clúster 0 (No Estrés)	Clúster 1 (Estrés)	Descripción
EDA_Phasic_STD	-0.1978	0.4641	Variabilidad en la respuesta fisiológica. Un valor menor indica menor reactividad simpática ante estímulos, mientras que un valor mayor sugiere una respuesta más pronunciada
EDA_Tonic_AVG	-0.4962	1.1643	Un valor menor se asocia a un estado más relajado, mientras que un valor mayor indica un incremento general en la excitación del sistema nervioso.
FAA	-0.326	0.765	Un valor menor se logra vincular a menor carga emocional/cognitiva o emociones positivas, mientras que un valor mayor sugiere un mayor procesamiento, carga o emociones negativas (retirada), dependiendo del contexto.
alpha_AVG	0.0013	-0.0031	Un valor cercano a la media (estandarizada) puede estar presente tanto en estados de relajación/alerta moderada como en momentos de activación o procesamiento mental, por lo que la interpretación es más minuciosa cuando se

			considera a la par con las otras características.
	Centroides		

Nota Los valores de los centros de los clústeres son adimensionales, resultado de la estandarización de las características fisiológicas y cerebrales. Representan el promedio del perfil de actividad para cada clúster, facilitando su interpretación como estados de "No Estrés" y "Estrés".

Por otro lado, el clúster 1 presenta valores predominantemente altos y superiores a la media en sus características estandarizadas, dando como resultado, los siguientes valores de las características EDA_Phasic_STD (0.4641) y EDA_Tonic_AVG (1.1643) que expresan una mayor activación simpática. Adicionalmente, el valor más alto en FAA (0.765) sugiere un mayor procesamiento emocional o una activación cerebral característica de situaciones que entablan emociones de alerta. Bajo un estudio literario, se encontró que un aumento en el valor de la asimetría en la banda alfa en la corteza prefrontal, con dominancia del hemisferio derecho, se asocia con el estrés elevado (Martínez Pelayo et al., 2024, p. 302), mencionando que aunque la característica alpha_AVG (-0.0031) es cercana a la media, su comportamiento en conjunto con las otras características es coherente con un estado de alerta y procesamiento activo, donde la banda alfa puede no ser dominante ante una sobreestimulación mental (Martínez Pelayo et al., 2024, p. 302). Bajo esta argumentación, el clúster 1 se etiquetó como el estado de "Estrés", encontrando una diferenciación clave entre estos estados por parte del algoritmo K-Means y llegando a su utilidad para clasificar los datos en las categorías de interés del presente estudio.

7.5.2.5. Modelos de clasificación y evaluación individual preliminar

Luego de ser generadas las etiquetas bajo el criterio de "Estrés" y "No estrés" para el conjunto de datos y la estandarización previa de las características, se inició con el proceso de entrenamiento y evaluación de cinco algoritmos de aprendizaje automático por clasificación de manera individual, es decir, para cada uno de los cinco sujetos por aparte. Para esta fase

evaluativa de los algoritmos de manera individual, los cinco algoritmos considerados fueron: Regresión Logística, Maquinas de Vectores de Soporte (SVM), KNN (K vecinos más cercanos), Árboles de Decisión (Decision Tree) y Bosques aleatorios (Random Forest), y las variables usadas para el análisis predictivo fueron: EDA_Phasic_STD y EDA_Tonic_AVG, es decir, las dos primeras características del conjunto utilizado para el proceso de clustering, ya estandarizadas, mientras que la variable objetivo fue la columna denominada “estrés” cuya columna almacenó el resultado generado por el algoritmo K-Means.

7.5.2.6. Evaluación de modelos predictivos por sujeto y selección de la muestra final

En la fase de evaluación individual de los cinco modelos predictivos (Logistic Regression, SVM, KNN, Decision Tree y Random Forest) para cada uno de los cinco sujetos (1, 4, 6, 7 y 9) se empleó la estrategia denominada validación cruzada (cross validation en inglés) estratificada con 3 divisiones (3 splits) sobre las dos características seleccionadas hasta este punto: EDA_Phasic_STD y EDA_Tonic_AVG (estandarizadas), y la variable binaria objetivo etiquetada como “estrés” obtenida a través de los clústeres del algoritmo de K-Means para cada sujeto. Los resultados de esta evaluación, observados en la tabla 3, mostraron la variación del rendimiento y balance de las clases entre cada uno de los sujetos, específicamente, en los sujetos 1, 6 y 7, que evidenciaron un rendimiento alto y constante en cada uno de los splits (variación estándar del rendimiento cercana a 0 entre los tres splits), obteniendo una precisión y exactitud alrededor del 0.9 en cada uno de los cinco algoritmos y un idóneo balance de clases y relativamente adecuado durante el entrenamientos de cada uno de los cinco algoritmos. En contraste, el sujeto 4, a pesar de obtener un rendimiento muy alto (presión y exactitud superiores al 0.99), se perfiló para ser excluido, partiendo del hecho de que este tipo de rendimientos tan

altos son indicios fuertes de posible sobreajuste (overfitting), lo que desencadena en la limitación del modelo predictivo para generalizar adecuadamente, ajustándose casi de manera perfecta a los datos con los que ha sido entrenado dicho modelo y dando resultados completamente inesperados al momento de usar datos nuevos sobre el modelo entrenado. Por otra parte, el sujeto 9 presentó un desbalance de clases notorio, este desbalance puede provocar en modelos predictivos de clasificación binaria, un trabajo deficiente, al no ser entrenado con datos suficientes y equilibrados entre ambas clases (“Estrés” y “No estrés”). Con base en estas observaciones y llevando el objetivo de construir un modelo predictivo robusto que generalice eficazmente, se seleccionaron los sujetos 1, 6 y 7 para conformar el conjunto de datos filtrado que se usó posteriormente en la fase de entrenamiento y evaluación del modelo predictivo final.

7.5.2.7. Entrenamiento y evaluación del conjunto de datos final

En la fase final del trabajo, se procedió a consolidar los datos estandarizados de las características EDA_Phasic_STD, EDA_Tonic_AVG, FAA y alpha_AVG de los sujetos: 1, 6 y 7, y de esta manera, iniciar la iteración del proceso descrito con anterioridad, donde a este conjunto de datos consolidado, se le aplicó el método de agrupación por medio del algoritmo de aprendizaje automático no supervisado K-Means con dos clústeres para generar nuevamente la variable binaria objetivo que representa de manera adecuada a los tres sujetos seleccionados como un solo conjunto. A continuación, se entrenaron y evaluaron los 5 algoritmos de aprendizaje automático supervisado de clasificación, con las características predictoras como variables independientes (EDA_Phasic_STD y EDA_Tonic_AVG) y la variable binaria objetivo como la etiqueta (estrés). La evaluación se realizó mediante la validación cruzada estratificada con 3 splits obteniendo, en su rendimiento, valores promedio apropiados de su precisión y exactitud, superiores y muy cercanos a 0.9.

7.5.2.8. Selección del algoritmo entrenado con mejor rendimiento

Al comparar el rendimiento de los cinco algoritmos sobre el conjunto de datos consolidado, el algoritmo de aprendizaje automático de clasificación SVM (Support Vector Machines), configurado con los parámetros: kernel de base radial (RBF), $C=1.0$ y $\text{gamma}='scale|'$, demostró ser el de mejor desempeño general, presentando una alta precisión y estabilidad en las mediciones de precisión y exactitud luego de la validación cruzada.

7.5.2.9. Evaluación integral del modelo predictivo SVM

Para la evaluación rigurosa sobre el modelo predictor seleccionado SVM, se ejecutó una validación cruzada estratificada con cinco splits sobre el conjunto de datos consolidado de los tres sujetos (1, 6 y 7) usando EDA_Phasic_STD y EDA_Tonic_AVG como variables predictoras y las etiquetas binarias de "estrés" generada por el algoritmo K-Means sobre este mismo conjunto, obtenido las siguientes métricas de rendimiento:

- Accuracy (Exactitud) = 0.9037
- Precision (Precisión para la clase 1 ("Estrés")): 0.8960
- Recall (Sensibilidad para la clase 1 ("Estrés")): 0.8877
- F1-Score: 0.8919
- AUC (Área bajo la curva ROC) = 0.9563; demuestra una capacidad superlativa para discriminar entre las clases "Estrés (1)" y "No estrés (0)"

Matriz de confusión: 21,889 verdaderos negativos (True Negatives TN), 2169 falsos negativos (False Negatives FN), 1990 falsos positivos (False Positives FP) y 17152 verdaderos positivos (True Positives TP), indicadores de un buen número de TP y TN; indicadores que permiten analizar los tipos de errores de la clasificación del modelo predictivo.

7.5.2.10. Confirmación del número de clústeres por medio del método del codo

La elección de dos clústeres al momento de aplicar el algoritmo de aprendizaje automático no supervisado K-Means, utilizado para la generación de la etiqueta binaria: “Estrés” y “No estrés”, sobre el conjunto de datos consolidado de los sujetos 1, 6 y 7 se respaldó por medio del método del codo, calculando la inercia en un rango de 10 clústeres ($k=1, k=2, \dots, k=10$) sobre las cuatro características estandarizadas (EDA_Phasic_STD, EDA_Tonic_AVG, FAA, alpha_AVG). La gráfica de inercia versus el número de clústeres, de la Figura 6, muestra un punto de inflexión que resalta (codo) en $k=2$ (dos clústeres), sugiriendo que dos clústeres son una agrupación natural y adecuada para el conjunto de datos.

7.5.2.11. Almacenamiento del modelo predictivo final y el escalador

En la parte final del proceso de entrenamiento y evaluación del algoritmo supervisado por clasificación SVM sobre el conjunto de datos consolidado, el producto final del entrenamiento y el escalador obtenido al aplicar el método StandardScaler de la librería de scikit-learn, fueron serializados y guardados en archivos con extensión .joblib para una posible reutilización o despliegue, como servicio, en el futuro.

7.5.3. Software utilizado

El procesamiento, análisis de datos y modelos de algoritmos de aprendizaje automático supervisado por clasificación descritos en el presente estudio, se llevaron a cabo usando el lenguaje de programación Python (versión 3.12) empleando varias librerías destinadas de dicho lenguaje para abordar estos enfoques tecnológicos, entre las que se deben mencionar:

- Pandas: Manipulación y análisis de estructuras de datos bidimensionales (DataFrames).

- Numpy: Operaciones numéricas eficientes y manejo de arreglos multidimensionales.
- SciPy: Funciones científicas y técnicas, incluyendo `scipy.io` para la carga de archivos `.mat` y `scipy.signal` para el diseño de filtros FIR.
- Neurokit2: Procesamiento avanzado de señales fisiológicas, específicamente para señales EDA y sus componente tónica y fásica.
- Scikit-Learn: Implementación de algoritmos de aprendizaje automático (Regresión Logística, SVM, KNN, Árboles de Decisión, Random Forest, K-Means), métricas de evaluación (accuracy, precisión, recall, F1-score, AUC, matriz de confusión), técnicas de validación cruzada (StratifiedKFold, `cross_val_score`, `cross_val_predict`) y preprocesamiento de datos (StandardScaler).
- Matplotlib y Seaborn: Generación de visualizaciones no dinámicas, como histogramas, mapas de calor de correlaciones, matrices de confusión y graficas del método del codo.
- Joblib: Serialización y almacenamiento de los modelos de aprendizaje automático entrenados y los objetos de preprocesamiento.

El entorno de desarrollo interactivo Jupyter-Notebook se usó para la ejecución y documentación del código, los análisis descriptivos, diagnósticos y predictivos, y el diseño de graficas.

8. Resultados y análisis

En esta sección se presentan los hallazgos obtenidos a partir de la aplicación de la metodología descrita anteriormente y se iniciará con la caracterización del conjunto de datos luego de las fases de procesamiento de los datos, seguido del análisis de correlaciones entre variables fisiológicas de mayor relevancia y, finalmente, se profundizará en los detalles de los resultados del desarrollo y evaluación del modelo de aprendizaje automático para la clasificación de los estados de estrés.

8.1. Estadística descriptiva de los datos procesados

Tras la fase de preprocesamientos de los datos y la subsecuente depuración del conjunto de datos, que fue el resultado de una muestra final consolidada por los registros de 5 sujetos (1, 4, 6, 7 y 9), se realizó un análisis descriptivo, centrado en cuatro variables seleccionadas por su relevancia con el estrés y actividad cognitiva: la desviación estándar de la actividad electrodérmica fásica (EDA_Phasic_STD), el promedio de la actividad electrodérmica tónica (EDA_Tonic_AVG), el índice de Asimetría Alfa Frontal (FAA) y el promedio de la actividad en la banda Alfa del EEG (alpha_AVG).

El propósito de este análisis es interpretar la tendencia central, dispersión y rangos de operación de estas variables dentro del conjunto de datos limpio (después del preprocesamiento), el cual está conformado por 72,000 registros (ventanas) obtenidos de los 12 trials, con 1200 registros cada uno, de los 5 sujetos. Es fundamental destacar que estas estadísticas reflejan el comportamiento de las características antes de su estandarización o transformaciones utilizadas en las fases consecuentes al modelo predictivo. La Tabla 2 resume las principales características descriptivas para las cuatro variables mencionadas, ofreciendo una visión cuantitativa de las magnitudes y variabilidad típica de las respuestas fisiológicas y cerebrales observadas en la

muestra de sujetos seleccionados, observando una variabilidad considerable en algunas de estas métricas, particularmente en α_AVG , como indican sus desviaciones estándar y el amplio rango entre sus valores mínimo y máximo.

Tabla 2. Estadísticas Descriptivas de las Variables Fisiológicas y Cerebrales Clave en el Conjunto de Datos Depurado (N=72,000 segmentos)

Variable	Media	Desviación estándar	Mediana	Mínimo	Máximo
EDA_Phasic_STD	9.79×10^{-9}	2.4×10^{-8}	1.92×10^{-9}	2.08×10^{-12}	1.13×10^{-6}
EDA_Tonic_AVG	1.01×10^{-6}	4.19×10^{-6}	9.17×10^{-7}	-1.52×10^{-5}	1.86×10^{-5}
FAA	-0.107	1.162	-0.09	-5.828	5.111
alpha_AVG	0.24	40.289	-0.095	-935.149	558.68

Nota Los valores de Media, Desviación Estándar, Mediana, Mínimo y Máximo para EDA_Phasic_STD y EDA_Tonic_AVG están expresados en las unidades originales de la señal EDA procesada; FAA es un índice logarítmico adimensional; α_AVG está en unidades de amplitud de la señal EEG

8.2. Correlaciones entre las variables

Para llevar a cabo la exploración de las interrelaciones entre las distintas características fisiológicas y cerebrales extraídas del conjunto de datos preprocesado (72,000 registros), se realizó un análisis de correlaciones no paramétrico, especialmente, se calculó el coeficiente de correlación de Spearman (ρ) de un subconjunto de variables importantes que incluyen métricas de la señal EDA, la banda de frecuencia alfa de la señal EEG y el índice de asimetría alfa frontal (FAA), mostrando dichas correlaciones en la Tabla 3, logrando analizar que la matriz de correlaciones muestra que la mayoría de interrelaciones entre las variables seleccionadas son de magnitud baja. No obstante, como se esperaba luego, de la exploración sobre los datos enfocados a la FAA y las métricas de la actividad electrodérmica, se encontró una correlación positiva baja entre FAA y la desviación estándar de la componente fásica de la señal EDA (EDA_Phasic_STD, $\rho=0.17$), así como la FAA y la desviación estándar de la componente tónica de la señal EDA (EDA_Tonic_STD, $\rho=0.17$).

Tabla 3. Matriz de Correlación de Spearman (ρ) entre Variables Fisiológicas y Cerebrales Seleccionadas

Variable	EDA Phasic AVG	EDA Phasic STD	EDA Tonic AVG	EDA Tonic STD	FAA	Alpha AVG	Alpha STD
EDA Phasic AVG	1	-0.012133	-0.009137	-0.07800	-0.02615	0.010063	0.00573
EDA Phasic STD	-0.01213	1	0.168165	0.53706	0.16646	-0.02387	-0.0603
EDA Tonic AVG	-0.00913	0.168165	1	0.112903	-0.00320	-0.00617	0.0661
EDA Tonic STD	-0.07800	0.53706	0.112903	1	0.16967	0.00149	-0.1277
FAA	-0.02615	0.166466	-0.003205	0.169679	1	0.00186	-0.1850
Alpha AVG	0.010063	-0.023871	-0.00617	0.001493	0.00186	1	0.0119
Alpha STD	0.00573	-0.060367	0.066154	-0.12778	-0.18503	0.01198	1

Nota: Valores de correlación de Spearman (ρ). $N=72,000$ segmentos.

Estas correlaciones, a pesar de que presentan una magnitud baja y considerada como correlaciones positivas débiles, siguieren una posible vinculación entre los patrones de asimetría en la actividad cortical frontal y la variabilidad del sistema nervioso simpático. La FAA es un índice, que, por lo regular, está asociado con la regulación emocional de las personas y sus niveles motivacionales; valores más altos en la FAA (mayor potencia alfa relativa en el hemisferio derecho y/o menor potencia alfa relativa en el hemisferio izquierdo) se conectan, en algunos contextos, con estados emocionales positivos. Por otro lado, una variabilidad alta en la señal EDA (en sus componente tónica y fásica), pueden representar una mayor fluctuación o reactividad en la excitación simpática, mencionado por Pelayo et al. (2024):

“Pelayo, M. M., Pelayo, E. V., Medina, S. D., & Coutiño, A. B. M. (2024). El registro electroencefalográfico y el cortisol salival en el estudio del estrés: una revisión sistemática. Psicología y salud, 34(2), 301-315.”

Bajo el método del estrés inducido por la privación del sueño, la relación positiva observada entre el índice FAA y las componentes de la señal EDA, puede indicar patrones de asimetría cerebral asociados a estados emocionales, varían con mayor inestabilidad en la respuesta electrodérmica. Por ejemplo, un incremento en el índice de la FAA se relaciona con un estado de mayor alerta o esfuerzo cognitivo, respuesta que puede ir acompañada de una variabilidad alta en sistema simpático. Estos hallazgos sugieren una interrelación perspicaz que puede ser explorada a fondo en futuras investigaciones, con la inclusión de otras señales fisiológicas y cerebrales, y bajo otros contextos.

El análisis de correlaciones finaliza con magnitudes cercanas a cero, indicando independencia entre las variables bajo el estudio correlacional.

8.3. Resultados del Modelado de Aprendizaje Automático

Luego de finalizar el preprocesamiento de los datos y el diseño de las etiquetas binarias de "Estrés" y "No estrés" mediante el agrupamiento por clustering del algoritmo de aprendizaje automático no supervisado K-Means, se evaluó el rendimiento de los cinco algoritmos de aprendizaje automático supervisado por clasificación para lograr la identificación de patrones asociados a la privación del sueño. El análisis se realizó en dos etapas primordiales: primero, entrenando y evaluando los modelos predictivos para cada sujeto de manera individual y, segundo, entrenando y evaluando los modelos sobre un conjunto de datos consolidado de los sujetos que presentaron un comportamiento acertado a través de las diferentes fases de limpieza y modelado de datos para el análisis predictivo.

8.3.1. Rendimiento de los Modelos por Sujeto

Inicialmente, se evaluó el desempeño de cinco algoritmos de clasificación (Regresión Logística - LG, Máquinas de Vectores de Soporte - SVC, K-Vecinos Más Cercanos - KNN, Árbol de Decisión - DT, y Bosque Aleatorio - RF) para cada uno de los cinco sujetos seleccionados tras la fase de limpieza de datos (sujetos 1, 4, 6, 7 y 9). Para esta evaluación individual, se utilizaron las características estandarizadas EDA_Phasic_STD y EDA_Tonic_AVG como predictoras, y la etiqueta "estrés" (0 o 1) generada por K-Means para cada sujeto respectivo. El rendimiento se midió acorde al promedio de la exactitud (accuracy). La Tabla 4 resume los porcentajes de pertenencia a cada cluster (indicativos del balance de clases para la variable "estrés") y los puntajes del rendimiento de la exactitud para cada algoritmo y sujeto.

Tabla 4. Rendimiento de los Modelos de Clasificación por Sujeto Individual (Accuracy Media de Validación Cruzada con 3 Splits)

Sujeto	Muestras	Cluster 0 (%)	Cluster 1 (%)	Score LG	Score SVC	Score KNN	Score DT	Score RF
1	14,400	59.4	40.6	0.908	0.9017	0.9051	0.8938	0.9147
4	14,400	20.6	79.4	0.997	0.9961	0.9956	0.9948	0.9958
6	14,400	50.4	49.6	0.8135	0.813	0.8138	0.7868	0.8134
7	14,400	64.6	35.4	0.9276	0.9281	0.9208	0.8929	0.9203
9	14,400	70	30	0.9022	0.9011	0.892	0.867	0.8944

Nota: Los scores representan la exactitud media de la validación cruzada. Cluster 0 y Cluster 1 representan el porcentaje de las etiquetas inferidas de "no estrés" y "estrés", respectivamente. LG (Logistic Regression) - SVC (Support Vector Classifier) - KNN (K-Nearest Neighbors) - DT (Decision Tree) - RF (Random Forest)

El análisis de la Tabla 4 revela diferencias notables tanto en el balance de clases generado por K-Means como en el rendimiento de los algoritmos entre los sujetos. Los sujetos 1 y 7 mostraron un buen rendimiento predictivo, con scores de exactitud consistentes y altos (superiores a 0.90 para la mayoría de los algoritmos) y un balance de clases relativamente

balanceado. El sujeto 6 presentó el balance de clases más equitativo (aproximadamente 50%/50%), aunque con scores de exactitud ligeramente inferiores (alrededor de 0.81).

Por otro lado, el sujeto 4 mostró scores de exactitud considerablemente altos (superiores a 0.99) acompañados de un desbalance de clases notorio (Cluster 0: 20.6%, Cluster 1: 79.4%). Este rendimiento casi perfecto, junto con el desbalance de las clases, sugirió la posibilidad de que los clusters generados para este sujeto fueran linealmente muy separables o que el modelo presentó sobreajuste sobre las características del conjunto de datos, lo que podría comprometer su capacidad de generalización. El sujeto 9, aunque con scores de exactitud también elevados (alrededor de 0.90), presentó el mayor desbalance de clases (Cluster 0: 70.0%, Cluster 1: 30.0%), lo cual puede influir en la fiabilidad y generalización del modelo entrenado con sus datos.

Considerando estos factores – la necesidad de un rendimiento robusto, un balance de clases adecuado para evitar sesgos, y la prevención del sobreajuste – se tomó la decisión de seleccionar a los sujetos 1, 6 y 7 para la siguiente fase de entrenamiento. Estos sujetos, en conjunto, ofrecieron una consolidación de un alto rendimiento individual (sujetos 1 y 7) y un buen balance de clases (sujeto 6), lo que se consideró óptimo para desarrollar un modelo predictivo generalizable.

8.3.2. Rendimiento de los Modelos con el Conjunto de Datos consolidado (Sujetos 1, 6 y 7)

Para desarrollar un modelo predictivo general, teniendo en cuenta a los sujetos 1, 6 y 7 como un solo conjunto, se consolidaron los datos de las características estandarizadas (EDA_Phasic_STD, EDA_Tonic_AVG, FAA y alpha_AVG) de los tres sujetos. Sobre este conjunto de datos agregado (43,200 registros en total), se aplicó de nuevo el algoritmo K-Means

(k=2) para generar una única variable objetivo "estrés". Posteriormente, se entrenaron los cinco algoritmos de clasificación utilizando las características predictoras EDA_Phasic_STD y EDA_Tonic_AVG (estandarizadas a partir del conjunto consolidado) y la nueva etiqueta binaria "Estrés" y "No estrés". La evaluación se realizó mediante validación cruzada estratificada con 3 splits dando como resultados, incluyendo los scores de cada split, la media de la exactitud y la desviación estándar que se presentan en la Tabla 5.

Tabla 5. Rendimiento de los Modelos de Clasificación con Datos Combinados de Sujetos 1, 6 y 7 (Accuracy de Validación Cruzada con 3 Splits)

Algoritmo	Score Split 1	Score Split 2	Score Split 3	Accuracy Media	Desv. Estándar
Regresión Logística	0.9026	0.9028	0.9051	0.9035	0.0011
Máquinas de Vectores de Soporte	0.9033	0.9031	0.9052	0.9038	0.001
K-Vecinos Cercanos	0.8915	0.8946	0.8919	0.8927	0.0014
Árbol de Decisión	0.8674	0.8667	0.8635	0.8659	0.0017
Bosque Aleatorio	0.8917	0.8932	0.8952	0.8934	0.0015

Al analizar el rendimiento sobre el conjunto de datos empalmados (Tabla 5), se observa que los algoritmos de Regresión Logística, SVM y Bosque Aleatorio mantuvieron un desempeño robusto, con exactitudes medias superiores a 0.89. El algoritmo KNN obtuvo un resultado ligeramente inferior, mientras que el Árbol de Decisión mostró la exactitud más baja. De entre todos los modelos evaluados, el algoritmo de **Máquinas de Vectores de Soporte (SVC)** destacó por alcanzar la exactitud media más alta (0.9038), con una baja desviación estándar entre los splits, lo que sugiere una buena estabilidad y capacidad de generalización. Este rendimiento superior lo presentó como el modelo predictivo principal para una evaluación más exhaustiva.

8.3.3. Evaluación Detallada del Modelo predictivo SVM

Tras identificar el modelo de Máquinas de Vectores de Soporte (SVM) como el de mayor rendimiento promedio en la clasificación de los estados de "estrés" y "no estrés" sobre el conjunto de datos consolidado de los tres sujetos seleccionados (1, 6 y 7), se procedió a una evaluación más exhaustiva sobre su desempeño, utilizando una validación cruzada estratificada con 5 divisiones (splits). Las características predictoras continuaron siendo EDA_Phasic_STD y EDA_Tonic_AVG (estandarizadas a partir del conjunto combinado de los tres sujetos), y la variable objetivo fue la etiqueta "estrés" generada por K-Means sobre este mismo conjunto.

Los scores de exactitud (accuracy) obtenidos en cada una de las 5 divisiones de la validación cruzada para el modelo SVM fueron: 0.9003, 0.9051, 0.9045, 0.9032 y 0.9054. Esto resultó en una **exactitud media de 0.9037**, con una **desviación estándar de 0.0018**. La baja desviación estándar entre los splits sugiere una importante estabilidad y consistencia en el rendimiento del modelo SVM.

Para profundizar en la capacidad predictiva del modelo, se calcularon métricas de evaluación adicionales utilizando las predicciones obtenidas a través de la validación cruzada (cross_val_predict). Los resultados se presentan a continuación:

- **Exactitud (Accuracy):** 0.9037. Este valor indica que el modelo SVM clasificó correctamente aproximadamente el 90.37% del total de los segmentos (ventanas temporales) de los tres sujetos combinados.
- **Precisión (para la clase "estrés"):** 0.8960. De todos los segmentos que el modelo identificó como pertenecientes al estado de "estrés", el 89.60% fueron clasificados correctamente (es decir, eran verdaderamente segmentos de "estrés" según la etiqueta

generada por K-Means). Una alta precisión es relevante para minimizar falsas alarmas de estrés.

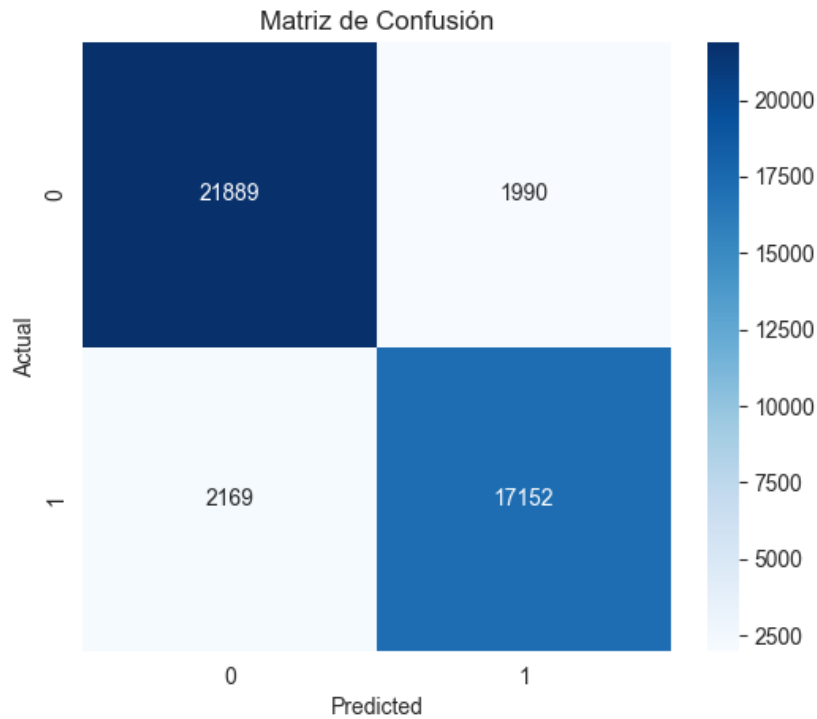
- **Recall (Sensibilidad, para la clase "estrés"):** 0.8877. El modelo fue capaz de identificar correctamente el 88.77% de todos los segmentos que realmente pertenecían al estado de "estrés". Un recall elevado es crucial si el objetivo es no pasar por alto la mayoría de los episodios de estrés.
- **Puntuación F1 (F1-Score, para la clase "estrés"):** 0.8919. Esta métrica, que representa la media armónica de la precisión y el recall, ofrece un balance entre ambas. Un valor de 0.8919 indica un buen equilibrio en la capacidad del modelo tanto para identificar correctamente los casos de "estrés" como para evitar clasificarlos incorrectamente.
- **Área Bajo la Curva ROC (AUC):** 0.9563. Este valor, cercano a 1, sugiere una excelente capacidad del modelo para discriminar entre los segmentos pertenecientes a la clase "estrés" y aquellos de la clase "no estrés", independientemente del umbral de clasificación específico que se elija.

Para un análisis más detallado de los tipos de errores cometidos por el modelo SVM, se generó la matriz de confusión, la cual se presenta esquemáticamente a continuación y se visualiza en la Figura 4.

- **Verdaderos Negativos (TN):** 21,889 (segmentos de "no estrés" correctamente clasificados).
- **Falsos Positivos (FP):** 1,990 (segmentos de "no estrés" incorrectamente clasificados como "estrés" - Error Tipo I).

- **Falsos Negativos (FN):** 2,169 (segmentos de "estrés" incorrectamente clasificados como "no estrés" - Error Tipo II).
- **Verdaderos Positivos (TP):** 17,152 (segmentos de "estrés" correctamente clasificados).

Figura 5. Matriz de confusión del modelo SVM




La matriz de confusión (Figura 4) muestra que el modelo tiene un alto número de clasificaciones correctas tanto para la clase "no estrés" como para la clase "estrés", sin embargo, se observa un número comparable de falsos positivos y falsos negativos, lo que indica que el modelo presenta un balance en el tipo de error cometido, con la ventaja de no mostrar un sesgo pronunciado hacia la sobreestimación o subestimación de una de las dos clases en particular.

Finalmente, la capacidad de discriminar entre las dos clases de la variable binaria objetivo del modelo SVM se visualizó mediante la curva Característica Operativa del Receptor (ROC), presentada en la Figura 5, describiendo una curva que se eleva marcadamente hacia la

esquina superior izquierda del gráfico, y el valor de la métrica AUC de 0.9563 cuantifica esta acertada habilidad del modelo para distinguir entre las dos clases en todo el espectro de umbrales de decisión. Este alto valor de AUC refuerza la conclusión de que el modelo SVM desarrollado tiene una capacidad robusta para la tarea de clasificación propuesta en el presente estudio.

Figura 6. Curva ROC del modelo SVM



8.4. Análisis del Clustering con K-Means para la Generación de Etiquetas

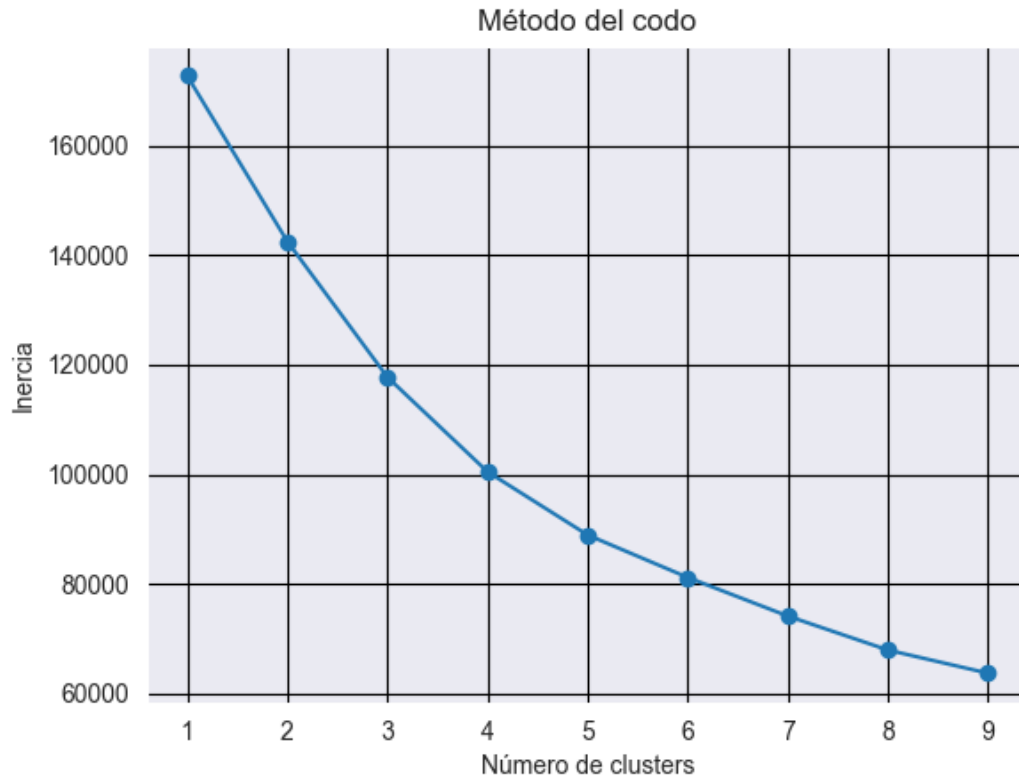
Como se describió en la Metodología, la variable objetivo "estrés" (con dos clases: 0 para "no estrés" y 1 para "estrés") para el entrenamiento de los modelos de clasificación supervisada fue generada mediante el algoritmo de agrupamiento no supervisado K-Means. Esta técnica se aplicó al conjunto de datos consolidado y estandarizado de los tres sujetos seleccionados (1, 6 y 7), utilizando las cuatro características consideradas relevantes para la distinción de estados fisiológicos: EDA_Phasic_STD, EDA_Tonic_AVG, FAA y alpha_AVG, posterior al proceso que

determinó y confirmó que el número óptimo de clústeres (k) para cumplir con el objetivo era $k=2$.

Para justificar la elección de $k=2$ (dos clústeres), se empleó el método del codo (Elbow Method), el cual evalúa la varianza explicada como una función del número de clústeres, calculando la inercia (suma de los cuadrados de las distancias de cada punto a su centroide más cercano, conocida como Within-Cluster sum of Squares - WCSS) para un rango de valores de k . La Figura 6 muestra la gráfica de la inercia en función del número de clusters (k) probados, desde $k=1$ hasta $k=9$.

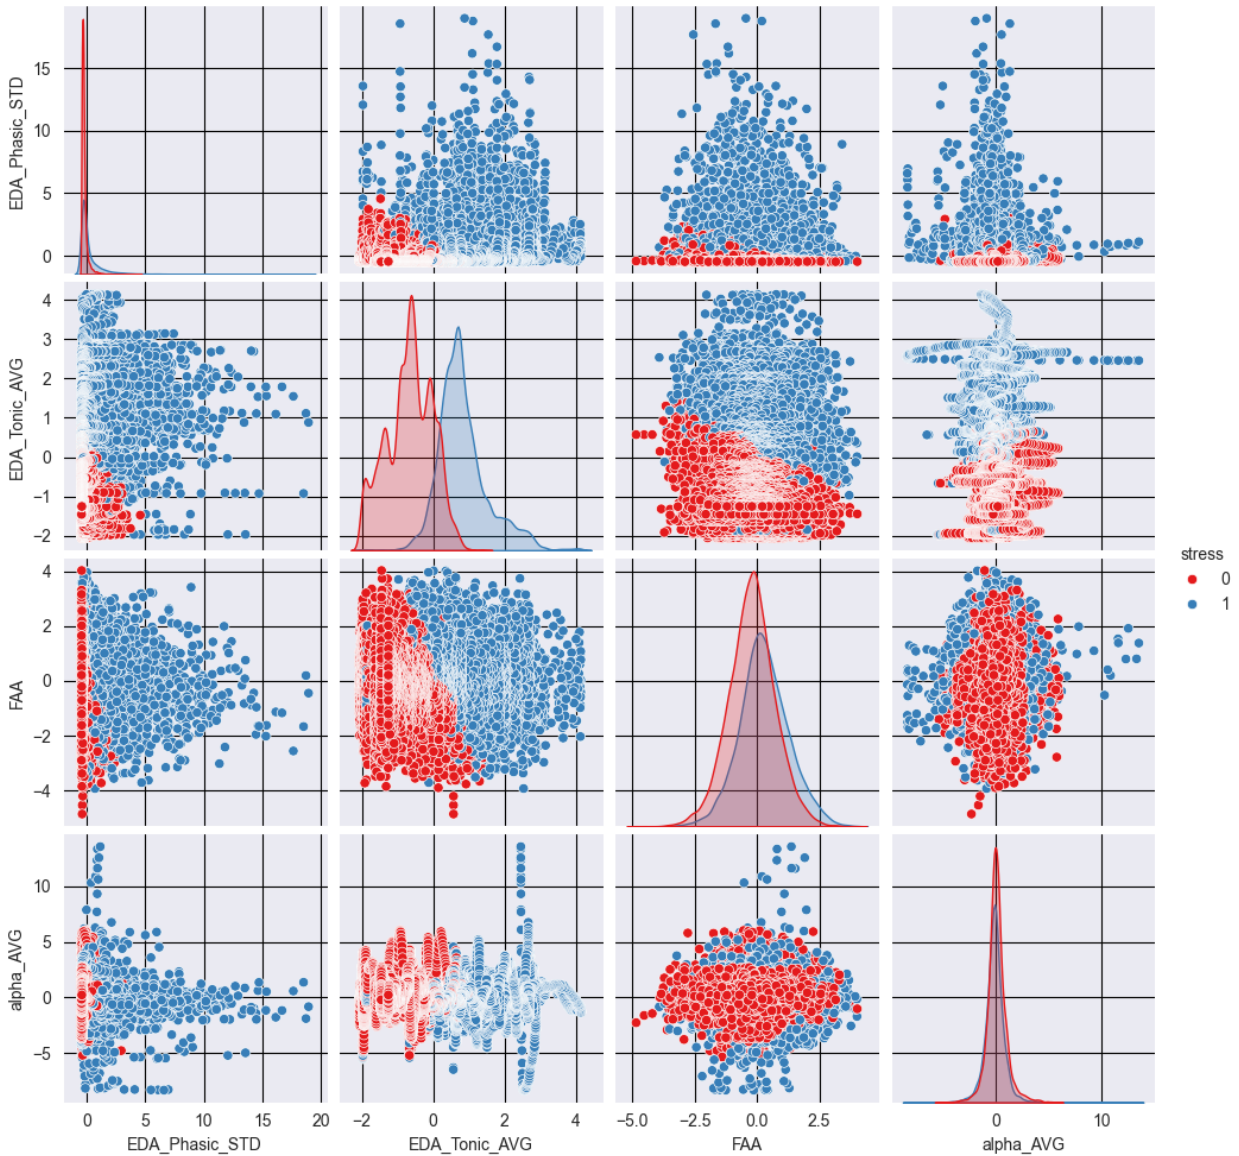
Como se observa en la Figura 6, la inercia disminuye a medida que aumenta el número de clusters. El "codo" o punto de inflexión en la curva, donde la adición de un nuevo cluster ya no proporciona una reducción sobresaliente en la inercia, se identificó visualmente en $k=2$. Para $k=1$, la inercia fue de 172,800.0; para $k=2$, descendió a 142,553.98; y para $k=3$, fue de 117,752.80, calculando la reducción en la inercia, al pasar de $k=1$ a $k=2$, se encontró que fue de aproximadamente 30,246 unidades, mientras que al pasar de $k=2$ a $k=3$ fue de 24,801 unidades. Aunque la disminución continúa, la tasa de reducción es notablemente menor después de $k=2$. Esta observación, junto con la hipótesis que subyace del estudio de identificar dos estados principales (estrés vs. no estrés), respaldó la selección de dos clusters como la estructura de agrupación más apropiada para los datos.

Figura 7. Gráfica del método del codo para 10 clústeres



Adicionalmente, para visualizar la separación y las características de estos dos clusters inferidos, se generó un gráfico de pares (pairplot) utilizando las mismas cuatro características empleadas en el proceso de clustering. La Figura 7 presenta las distribuciones de cada variable para los dos clusters y los diagramas de dispersión para cada par de variables, coloreados según la asignación al cluster 0 ("no estrés") o al cluster 1 ("estrés").

Figura 8. Diferenciación entre clústeres



El análisis visual del gráfico de pares (Figura 7) sugiere que, aunque existe cierto solapamiento entre los dos clusters en algunas de las perspectivas de la gráfica, hay tendencias de separación fácilmente observables. Esta visualización complementa el análisis del método del codo, proporcionando una perspectiva cualitativa sobre la estructura de los datos agrupados que se utilizaron como base para las etiquetas en el modelado supervisado.

9. Conclusiones

A través del presente trabajo de grado se propuso como objetivo principal el desarrollo de un modelo predictivo basado en técnicas de aprendizaje de máquina para lograr la identificación de la presencia de estrés o fatiga mental producido por factores externo como la privación del sueño, a partir del análisis en conjunto de señales electroencefalográficas (EEG) y de actividad electrodérmica (EDA). A continuación, se da a conocer las conclusiones resultado de abordar el cumplimiento de los objetivos específicos y del objetivo general.

Se logró, mediante el análisis de correlación de Spearman, una interrelación positiva, aunque de baja magnitud, entre las características: Asimetría Alfa Frontal (FAA) y la variabilidad de la señal EDA (específicamente, EDA_Phasic_STD y EDA_Tonic_STD). Esta interrelación contribuye al poder entender las interacciones entre la actividad cerebral en su zona frontal y la respuesta simpática (en la piel). Además, la fase exploratoria permitió caracterizar las principales métricas de las señales EEG y EDA, de las cuales se lograron seleccionar las características EDA (EDA_Phasic_STD y EDA_Tonic_AVG) que permitieron impulsar el desarrollo del modelo de predicción desarrollado.

Para determinar los algoritmos de aprendizaje de máquina adecuados para las señales EDA y EEG y la identificación de niveles de estrés o fatiga, se realizó una comparativa entre cinco algoritmos de clasificación: Regresión Logística, Máquinas de Vectores de Soporte (SVM), K-Vecinos Más Cercanos (KNN), Árboles de Decisión y Bosques Aleatorios. El análisis del rendimiento de cada conjunto de datos consolidado de los tres sujetos, utilizando etiquetas de "estrés" y "no estrés" generadas a través de aprendizaje automático no supervisado con el modelo clustering K-Means, permitió identificar al algoritmo de Máquinas de Vectores de Soporte

(SVM) con el mejor desempeño general, mostrando un buen rendimiento y generalización sobre el conjunto de datos modelado.

Al momento de desarrollar el modelo de aprendizaje de máquina de clasificación, se configuró de manera apropiada el modelo de SVM. Dicho modelo fue entrenado utilizando las características EDA_Phasic_STD y EDA_Tonic_AVG (posterior a su estandarización) como variables predictoras en búsqueda de clasificar, y generalizar adecuadamente la señal EDA, en dos clases ("estrés" o "no estrés") obtenidas luego de un análisis de clustering K-Means, alcanzado un rendimiento en dicho modelo, superior y cercano 0.9, logrando el modelado del algoritmo de SVM acertado.

Finalmente, al evaluar el desempeño del modelo de SVM a través de métricas de evaluación para algoritmos de clasificación, configurado con una validación cruzada establecida con estratificada con 5 divisiones, se llegó a un rendimiento con los siguientes resultados derivados de las métricas: una exactitud media de 0.9037, una precisión (para la clase "estrés") de 0.8960, un recall (sensibilidad para la clase "estrés") de 0.8877, una puntuación F1 (para la clase "estrés") de 0.8919 y un Área Bajo la Curva ROC (AUC) de 0.9563. Estos valores indican una buena y sobresaliente capacidad del modelo para generalizar entre las dos clases establecidas.

Considerando el cumplimiento adecuado a los objetivos específicos planteados, se llega a la conclusión de que el objetivo general de presente trabajo de grado fue alcanzado con notoriedad. Se desarrolló un modelo predictivo, basado en el algoritmo de SVM, capaz de identificar con buena precisión, categorías para identificar el "estrés", utilizando características obtenidas de la señal EDA, trabajando bajo un contexto de privación de sueño y desarrollo de actividades cognitivas.

Como recomendaciones para trabajos futuros, se sugiere validar el modelo y los hallazgos en una muestra de participantes nueva y diversa e incorporar medidas de referencia para el estrés, como son las evaluaciones conductuales o señales cardiovasculares. Una opción importante es el explorar abarcar un mayor número de canales cerebrales de la señal EEG para alcanzar una investigación, sobre el modelo, en diferentes tareas cognitivas, así como explorar su capacidad para implementaciones en tiempo real con datos totalmente nuevos.

10. Bibliografía

Martínez Vásquez, D. A., Posada-Quintero, H. F., & Rivera Pinzón, D. M. (2023). Mutual information between EDA and EEG in multiple cognitive tasks and sleep deprivation conditions. *Behavioral Sciences*, *13*(9), 707.

Pérez Ortega, P., Duarte Arias, D., & Rojas Valverde, D. (2022). Alteraciones y monitorización del sueño en personas que atienden situaciones de emergencia: una revisión narrativa. *RPCAFD*, *9*(3), 1-12.

Díaz, R., & Ruano, M. I. (2011). Prevalencia y persistencia del insomnio crónico estudio SUECA II. *Acta Médica Colombiana*, *36*(3), 119-124.

Aminosharieh Najafi, T., Affanni, A., Rinaldo, R., & Zontone, P. (2023). Driver attention assessment using physiological measures from EEG, ECG, and EDA signals. *Sensors*, *23*(4), 2039.

Liu, R., Zhang, Z., Duan, F., Zhou, X., & Meng, Z. (2017). Identification of anisomeric motor imagery EEG signals based on complex algorithms. *Computational intelligence and neuroscience*, *2017*(1), 2727856.

Lin, Y. P., Liang, H. Y., Chen, Y. S., Lu, C. H., Wu, Y. R., Chang, Y. Y., & Lin, W. C. (2021). Objective assessment of impulse control disorder in patients with Parkinson's disease using a low-cost LEGO-like EEG headset: a feasibility study. *Journal of NeuroEngineering and Rehabilitation*, *18*, 1-12.

Chua, E. C. P., Yeo, S. C., Lee, I. T. G., Tan, L. C., Lau, P., Cai, S., ... & Gooley, J. J. (2014). Sustained attention performance during sleep deprivation associates with instability in behavior and physiologic measures at baseline. *Sleep*, *37*(1), 27-39.

Stecher, H. I., Pollok, T. M., Strüber, D., Sobotka, F., & Herrmann, C. S. (2017). Ten minutes of α -tACS and ambient illumination independently modulate EEG α -power. *Frontiers in human neuroscience*, *11*, 257.

Vega, N. I., & Villegas-Paredes, G. (2021). Aportaciones de la neurociencia cognitiva y el enfoque multisensorial a la adquisición de segundas lenguas en la etapa escolar. *MarcoELE. Revista de Didáctica Español Lengua Extranjera*, (32), 1-20.

Başar, E., & Düzgün, A. (2016). The CLAIR model: Extension of Brodmann areas based on brain oscillations and connectivity. *International Journal of Psychophysiology*, *103*, 185-198.

Niklitschek, S., Pino, P., & Aboitiz, F. (2011). Sincronía neuronal y esquizofrenia: luces y sombras. *Revista chilena de neuro-psiquiatría*, *49*(4), 372-380.

Verdú Ferrer, A. (2021). *Efectos de la estimulación acústica en las oscilaciones lentas durante el sueño y sus repercusiones en la consolidación de la memoria* (Bachelor's thesis).

Cardona, J. S. C., & Segovia, N. F. (2014). Eficacia al alternar las ondas cerebrales. *Montaje y producción*, 2026.

ESQUEDA-ELIZONDO, J. J., ROA-RICO, D. O., PINTO-RAMOS, M. A., & REYES-MARTÍNEZ, R. A. (2017). Determinación de actividad electroencefalográfica en personas escuchando música mediante transformada wavelet y análisis espectral. *Revista de Tecnología*, *4*(13), 49-59.

UNAM. Fisiología de la actividad eléctrica del cerebro: electroencefalografía. *Facultad de Medicina, Universidad Nacional Autónoma de México*, 2019.

Delgado Tejada, H. S. (2021). Base de datos con señales fisiológicas para la determinación del nivel de ansiedad.

Rodríguez Santos, F. (2009). Educación y neurociencia. *Educational Psychology*, 15(1), 27-38.

Schaab, B. L., Calvetti, P. Ü., Hoffmann, S., Diaz, G. B., Rech, M., Cazella, S. C., ... & Reppold, C. T. (2024). ¿Cuál es el rendimiento de los modelos de aprendizaje automático para detectar la depresión, la ansiedad y el estrés entre los estudiantes universitarios? Una revisión sistemática. *Cadernos de Saúde Pública*, 40, e00029323.

Pelayo, M. M., Pelayo, E. V., Medina, S. D., & Coutiño, A. B. M. (2024). El registro electroencefalográfico y el cortisol salival en el estudio del estrés: una revisión sistemática. *Psicología y salud*, 34(2), 301-315.

DE EXAMEN, J. U. R. A. D. O. (2023). *BRENDA DENISSE CORONA MÁRQUEZ* (Doctoral dissertation, UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO).

Cámara, C., Aguiló, J., García, E., Haro, J. M., & Bailón, R. Análisis de la respuesta electrodermal para la identificación de pacientes con depresión.