



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Industrial

Análisis de las respuestas fisiológicas ante estímulos
auditivos con distinta carga emocional

Trabajo Fin de Grado

Grado en Ingeniería Biomédica

AUTOR/A: Chacón Domingo, Alejandro

Tutor/a: Lloréns Rodríguez, Roberto

Cotutor/a externo: Goizueta Berheide, Sandra

CURSO ACADÉMICO: 2023/2024

AGRADECIMIENTOS

A mi madre, mi hermano, mi hermana y mi padre, por apoyarme siempre en todo lo que hago y confiar en mí en todo momento.

A mi abuelo, mi abuela y mi tía, por lo feliz y orgullosos que sé que están y por todo el cariño que me han dado siempre.

A Lucía, por escucharme y animarme siempre que lo necesitaba y por haber hecho de estos años los más bonitos hasta ahora.

A mis amigos, con los que he tenido la suerte de coincidir y haber formado una segunda familia.

A mis tutores, por el tiempo y dedicación empleados en mí y por todo lo que he aprendido.

RESUMEN

El reconocimiento de emociones utilizando señales fisiológicas ha captado una atención creciente en los últimos años debido a sus aplicaciones potenciales en diferentes campos como la salud, aprovechando las ventajas que proporciona el registro continuo de respuestas fisiológicas controladas por el sistema nervioso. La conductividad eléctrica de la piel (GSR, por sus siglas en inglés *Galvanic Skin Response*), generada por la actividad de las glándulas sudoríparas, y la señal de respiración (RSP) se han posicionado como unas de las mediciones controladas por el sistema nervioso autónomo que proporcionan más información de los estados afectivos de los humanos. Este estudio analiza los datos de GSR y RSP obtenidos de una muestra de 45 participantes bajo un paradigma de inducción de emociones, en el que se presentan estímulos sonoros positivos, negativos y eróticos para tratar de desencadenar respuestas emocionales. En este sentido, se realizó un análisis estadístico multivariante en el que se evaluó la diferencia entre las características de las señales para las distintas parejas de estímulos (positivos, negativos y eróticos) y para los niveles alto y bajo de las dimensiones emocionales puntuadas por los participantes mediante la escala de autoevaluación de emociones *Self-Assessment Manikin* (SAM) para cada uno de los tres estímulos (valencia, dominancia y excitación). Se obtuvieron características capaces de diferenciar entre los distintos tipos de estímulos para las dos señales y otras que pudieron distinguir excitación y dominancia. Seguidamente, se entrenaron modelos de aprendizaje automático dependientes del sujeto utilizando Máquinas de Vectores de Soporte, capaces de diferenciar entre los pares de clases mencionados utilizando las características de GSR y RSP, tanto por separado como en conjunto. El modelo entrenado con la combinación de ambas señales fue el que proporcionó mejores métricas, obteniendo precisiones superiores al 85% tanto para la diferenciación de estímulos, como para la distinción de dimensiones emocionales.

Palabras clave: reconocimiento de emociones, GSR, RSP, estímulos auditivos, análisis estadístico, clasificación, aprendizaje automático.

RESUM

El reconeixement d'emocions utilitzant senyals fisiològiques ha captat una atenció creixent en els últims anys a causa de les seues aplicacions potencials en diferents camps com la salut, aprofitant els avantatges que proporciona el registre continu de respostes fisiològiques controlades pel sistema nerviós. La conductivitat elèctrica de la pell (GSR, per les seues sigles en anglès *Galvanic Skin Response*), generada per l'activitat de les glàndules sudorípares, i la senyal de respiració (RSP) s'han posicionat com unes de les mesures controlades pel sistema nerviós autònom que proporcionen més informació dels estats afectius dels humans. Aquest estudi analitza les dades de GSR i RSP obtingudes d'una mostra de 45 participants davant d'un paradigma d'inducció d'emocions, en el qual es presenten estímuls sonors positius, negatius i eròtics per tractar de desencadenar respostes emocionals. En aquest sentit, es va realitzar una anàlisi estadística multivariant en la qual es va avaluar la diferència entre les característiques dels senyals per a les diferents parelles d'estímuls (positius, negatius i eròtics) i per als nivells alt i baix de les dimensions emocionals puntuades pels participants mitjançant l'escala d'autoevaluació d'emocions *Self-Assessment Manikin* (SAM) per a cadascun dels tres estímuls (valència, dominància i excitació). Es van obtenir característiques capaces de diferenciar entre els diferents tipus d'estímuls per a les dues senyals i altres que van poder distingir excitació i dominància. Seguidament, es van entrenar models d'aprenentatge automàtic dependents del subjecte utilitzant Màquines de Vectors de Suport, capaços de diferenciar entre els parells de classes mencionats utilitzant les característiques de GSR i RSP, tant per separat com en conjunt. El model entrenat amb la combinació d'ambdues senyals va ser el que va proporcionar millors mètriques, obtenint precisions superiors al 85% tant per a la diferenciació d'estímuls, com per a la distinció de dimensions emocionals.

Paraules clau: reconeixement d'emocions, GSR, RSP, estímuls auditius, anàlisi estadístic, classificació, aprenentatge automàtic.

ABSTRACT

Emotion recognition using physiological signals has garnered increasing attention in recent years due to its potential applications in various fields such as health, leveraging the advantages provided by continuous monitoring of physiological responses controlled by the nervous system. Skin conductance (GSR, for its acronym in English, Galvanic Skin Response), generated by activity in the sweat glands, and respiratory signal (RSP) have emerged as measurements controlled by the autonomic nervous system that provide more information about human emotional states. This study analyses GSR and RSP data obtained from a sample of 45 participants under an emotion induction paradigm, where positive, negative, and erotic sound stimuli are presented to trigger emotional responses. In this regard, a multivariate statistical analysis was conducted to assess the difference between signal characteristics for different pairs of stimuli (positive, negative, and erotic) and for high and low levels of emotional dimensions scored by participants using the Self-Assessment Manikin (SAM) scale for each of the three stimuli (valence, dominance, and arousal). Features capable of distinguishing between different types of stimuli for both signals were obtained, as well as others that could differentiate arousal and dominance. Subsequently, subject-dependent machine learning models were trained using Support Vector Machines, capable of distinguishing between the mentioned pairs of classes using GSR and RSP features, both separately and together. The model trained with the combination of both signals provided the best metrics, achieving accuracies exceeding 85% for both stimulus differentiation and emotional dimension distinction.

Keywords: emotion recognition, GSR, RSP, auditory stimuli, statistical analysis, classification, machine learning.

ÍNDICE

DOCUMENTOS CONTENIDOS EN EL TFG

- Memoria
- Presupuesto
- Anexos

ÍNDICE DE LA MEMORIA

1.	INTRODUCCIÓN	2
1.1.	EMOCIONES	2
1.1.1.	Definición y función de las emociones	2
1.1.2.	Clasificación de emociones y modelos cognitivos	3
1.1.3.	Anatomía de la emoción	7
1.2.	COMPUTACIÓN AFECTIVA	8
1.2.1.	Expresión de emociones.....	9
1.2.1.1.	<i>Nivel exosomático</i>	10
1.2.1.2.	<i>Nivel endosomático</i>	11
1.2.2.	Autoevaluación de emociones.....	20
1.2.3.	Inducción de emociones.....	21
1.2.3.1.	<i>Métodos de inducción de emociones</i>	22
1.2.3.2.	<i>Bases de datos para la inducción de emociones</i>	23
1.2.4.	Reconocimiento de emociones en señales fisiológicas.....	25
1.3.	HIPÓTESIS Y OBJETIVOS	27
1.3.1.	Hipótesis general.....	27
1.3.2.	Objetivos	27
2.	MATERIALES Y MÉTODOS.....	28
2.1.	PARTICIPANTES DEL ESTUDIO.....	28
2.2.	INSTRUMENTACIÓN	28
2.2.1.	Estímulos	28
2.2.2.	Registro	29
2.2.3.	Hardware y software.....	31
2.3.	PROCEDIMIENTO.....	32
2.4.	ANÁLISIS DE DATOS	33

2.4.1.	Procesado de señal y extracción de características	33
2.4.1.1.	<i>Respuesta galvánica de la piel</i>	34
2.4.1.2.	<i>Señal de respiración</i>	38
2.4.2.	Análisis estadístico	42
2.4.3.	Modelos de aprendizaje automático.....	44
3.	RESULTADOS.....	49
3.1.	VALIDACIÓN DE LOS ESTÍMULOS EMPLEADOS MEDIANTE LA ESCALA SAM	49
3.2.	DIFERENCIAS ESTADÍSTICAS ENTRE CLASES DE ESTÍMULOS Y NIVELES DE DIMENSIONES DEL SAM PARA LAS SEÑALES DE GSR Y RSP.....	51
3.3.	MODELOS DE RECONOCIMIENTO DE EMOCIONES UTILIZANDO LAS SEÑALES FISIOLÓGICAS DE GSR Y RSP	53
4.	DISCUSIÓN	56
4.1.	ESTÍMULOS EMPLEADOS PARA EL RECONOCIMIENTO DE EMOCIONES	56
4.2.	DIFERENCIAS EN LAS SEÑALES DE GSR Y RSP ANTE DIFERENTES ESTÍMULOS Y NIVELES DE DIMENSIÓN EMOCIONALES	57
4.2.1.	<i>Respuesta galvánica de la piel</i>	57
4.2.2.	<i>Señal de respiración</i>	59
4.3.	USO COMBINADO DE LAS SEÑALES DE GSR Y RSP EN MODELOS DE APRENDIZAJE AUTOMÁTICO PARA EL RECONOCIMIENTO DE EMOCIONES Y NIVELES DE DIMENSIÓN EMOCIONALES	60
5.	CONCLUSIONES.....	63
6.	REFERENCIAS.....	64

ÍNDICE DE FIGURAS

Ilustración 1. Rueda de Plutchik. Recogida de (Shu et al., 2018)	4
Ilustración 2. Modelo de emoción bidimensional valencia-excitación. Recogida de (Ayata et al., 2017)	5
Ilustración 3. Modelo de emoción valencia-excitación-dominancia. Recogida de (Shu et al., 2018).....	6
Ilustración 4. Funciones reguladas por el sistema nervioso simpático y parasimpático. Recogida de (Lifeder, 2022).....	8
Ilustración 5. Forma de onda típica de señal GSR. Recogida de (Kipli et al., 2022).....	15
Ilustración 6. Artefactos de GSR generados por el entorno. A) Artefacto de movimiento generado por la mala adhesión de los electrodos a la piel. B) Artefacto de alta frecuencia. C) Artefacto transitorio rápido. Recogidas de (Tobii, 2023).....	16
Ilustración 7. Forma de onda típica de la señal de RSP. Recogida de (MindWare Technologies Ltd., 2017).....	19
Ilustración 8. Escala SAM para las tres dimensiones de emoción: valencia, excitación y dominancia. Adaptada de (Lima et al., 2024).....	21
Ilustración 9. Proceso para el reconocimiento de emociones utilizando modelos de aprendizaje automático para señales fisiológicas. Adaptada de (Shu et al., 2018).	26
Ilustración 10. Dispositivo NIRxWINGS. Para este estudio solo aplican 2, 3, 8 y 9. Recogida de (NIRx, 2021).....	31
Ilustración 11. Esquema del protocolo experimental.....	33
Ilustración 12. Esquema del análisis seguido para las señales de GSR y RSP.....	34
Ilustración 13. Distorsiones de la señal GSR. A) Señal con pérdida de datos. B) Señal con ruido.....	34
Ilustración 14. Procesado de artefactos. A) Artefacto de movimiento. B) Artefacto de movimiento interpolado	35
Ilustración 15. Pérdida de datos en la señal RSP.....	38
Ilustración 16. Distribución de puntuaciones en la escala SAM y división entre valores altos y bajos de cada dimensión.	42
Ilustración 17. Validación LOO modificada para solucionar el problema de solapamiento al 50%.....	45
Ilustración 18. Funcionamiento del algoritmo SVM. Adaptada de (MATLAB).	46
Ilustración 19. Distribuciones de puntuaciones de las dimensiones del SAM en función de los bloques de estímulos.....	50
Ilustración 20. Distribuciones de la precisión obtenida de los clasificadores de estímulos emocionales con los datos reales (verde) y las etiquetas permutadas (azul) empleando las señales de GSR y RSP combinadas.....	54
Ilustración 21. Distribuciones de la precisión obtenida de los clasificadores de niveles de dimensiones emocionales con los datos reales (verde) y las etiquetas permutadas (azul) empleando las señales de GSR y RSP combinadas.....	55

ÍNDICE DE TABLAS

Tabla 1. Bases de datos más utilizadas para diferentes tipos de estímulos.....	25
Tabla 2. Características del sistema de registro NIRxWINGS (NIRx, 2021).....	29
Tabla 3. Especificaciones técnicas de los auriculares JBL Tune 510BT (Harman International Industries)	31
Tabla 4. Características extraídas de la señal GSR.....	36
Tabla 5. Características extraídas de la señal RSP.....	40
Tabla 6. Medias y desviaciones estándar obtenidas de la escala SAM rellena por los participantes del estudio	50
Tabla 7. Medias, desviaciones estándar y significancia de la comparación de las características de GSR con diferencia significativa para los distintos estímulos.....	51
Tabla 8. Medias, desviaciones estándar y significancia de la comparación de las características de GSR con diferencia significativa para las distintas dimensiones.....	52
Tabla 9. Medias, desviaciones estándar y significancia de la comparación de las características de RSP con diferencia significativa para los distintos estímulos.....	52
Tabla 10. Medias, desviaciones estándar y significancia de la comparación de las características de RSP con diferencia significativa para las distintas dimensiones.....	53
Tabla 11. Medias y desviaciones estándar de la precisión de los modelos SVM obtenidos para cada señal y combinación de estímulos y niveles de dimensión.....	53

ÍNDICE DEL PRESUPUESTO

1. INTRODUCCIÓN	72
2. CUADRO DE MANO DE OBRA.....	72
3. CUADRO DE MAQUINARIA.....	72
4. CUADRO DE PRESUPUESTOS PARCIALES.....	73
5. CUADRO DE PRECIOS DESCOMPUESTOS.....	74
6. PRESUPUESTO TOTAL.....	75

ÍNDICE DE ANEXOS

1. ESTADÍSTICOS PARA LAS CARÁCTERÍSTICAS EXTRAÍDAS Y NIVEL DE SIGNIFICANCIA	77
2. MÉTRICAS PARA LOS CLASIFICADORES DE EMOCIONES UTILIZADOS PARA LA COMPARACIÓN INICIAL	85
3. MÉTRICAS PARA LOS CLASIFICADORES FINALES REPORTADOS EN EL TRABAJO	135
4. PRUEBAS DE PERMUTACIÓN PARA LOS MODELOS SVM REPORTADOS EN EL TRABAJO	138

LISTADO DE ABREVIATURAS

GSR	Respuesta Galvánica de la Piel
RSP	Señal de respiración
ECG	Electrocardiograma
SCR	Respuesta de Conductancia de la Piel
SCL	Nivel de Conductancia de la Piel
DWT	Transformada Wavelet Discreta
RSA	Arritmia Sinusal Respiratoria
SAM	<i>Self-Assessment Manikin</i>
IADS	<i>International Affective Digitized Sounds</i>
IADS-E	<i>International Affective Digitized Sounds Expanded</i>
IAPS	<i>International Affective Picture System</i>
ANEW	<i>Affective Norms for English Words</i>
SVM	Máquinas de Vectores de Soporte
KNN	K-Vecinos más cercanos
RF	Bosques aleatorios
LOO	<i>Leave One Out</i>
MAD	Desviación Absoluta Mediana

MEMORIA

1. INTRODUCCIÓN

1.1. EMOCIONES

1.1.1. Definición y función de las emociones

Las emociones se definen como estados psicológicos y fisiológicos experimentados por los humanos que suelen ir acompañados de cambios físicos y funcionales como respuesta a un estímulo (Canento et al., 2011; Shu et al., 2018). Estos involucran varios aspectos coordinados y diferentes que incluyen un sentimiento subjetivo, una manifestación motora y una reacción fisiológica (Jang et al., 2015). De esta forma, el término emoción hace referencia a la respuesta fisiológica y motora, mientras que el sentimiento alude a la interpretación cognitiva de esa respuesta.

La emoción se considera una noción compleja que abarca dos elementos principales (Ali et al., 2018):

- Experiencia subjetiva: aunque las emociones se encuentren categorizadas, cada persona tiene una forma concreta y diferente de experimentarlas que vienen influenciadas por diversos factores como la cultura, las experiencias pasadas, el contexto o las relaciones intrapersonales.
- Expresión: en la mayoría de las ocasiones las emociones se expresan mediante comportamientos evidentes y no verbales que reflejan el estado afectivo. Estas se pueden expresar por el tono de la voz, gestos, miradas, sonidos, etc.

Cabe destacar que muchos autores apuntan a que las emociones son unos estados que no se pueden expresar con una simple definición, pues estas están influenciadas por la experiencia subjetiva y se encuentran estrechamente relacionadas tanto a nivel intrapersonal como entre las personas que las experimentan (Valenza et al., 2012). No obstante, existen elementos fundamentales de las emociones que son universales y tienen bases biológicas (Pinto et al., 2019).

Estos estados afectivos cumplen una función fundamental en la vida humana. Así, se ha demostrado que las emociones positivas suponen mejoras a nivel laboral y de salud; al mismo tiempo que aquellas de carácter negativo inducen a problemas psicológicos y de salud (Shu et al., 2018). Dejando a un lado el bienestar personal, las emociones también juegan un papel muy importante en la supervivencia, ya que permiten que el individuo tenga la capacidad de afrontar los problemas que se le presentan de la mejor forma posible (Jang et al., 2015). Emociones positivas conducirán a sentimientos optimistas y a una mejora de las capacidades cognitivas, emociones de tristeza llevarán a la evaluación de las circunstancias y a una posible mejora de las relaciones sociales, o emociones negativas acarrearán sentimientos pesimistas que aumentarán el pensamiento analítico (Jang et al., 2015).

Una corriente popular considera que las emociones son perjudiciales para el pensamiento racional; pero notablemente menos conocido es que diferentes investigaciones en los campos de la cognición, la psicología y la neurociencia proponen, de forma totalmente contraria, que las emociones influyen de forma positiva en la razón y la inteligencia (Picard, 2001).

La comunicación entre los humanos puede efectuarse de forma verbal, mediante la voz, el lenguaje o los sonidos; o de manera no verbal, con acciones motoras, signos o expresiones faciales. Esta última resulta esencial para la interpretación del contenido en un acto de comunicación (Verma & Tiwary, 2014). Tanto en la verbal como en la no verbal, las emociones desempeñan una labor central, puesto que, en función del estado afectivo del individuo en el momento de la comunicación, la transmisión del mensaje será de una forma u otra y, por tanto, la comprensión contextual por parte de otros individuos vendrá influenciada por la emoción del comunicador (K. H. Kim et al., 2004; Takahashi et al., 2012).

La forma en la que los humanos regulan sus emociones se considera un factor clave para la adaptación a nuevas rutinas diarias o la conservación de los vínculos sociales. En salud mental y psicoterapia se convierte en uno de los puntos de estudio más relevante por asociarse a diferentes enfermedades como trastornos de la conducta alimentaria, depresión, ansiedad o hipocondría (Lima et al., 2024).

1.1.2. Clasificación de emociones y modelos cognitivos

El reconocimiento de emociones precisa no solo de la definición general de emoción, sino de la descripción de cada una de las emociones que puede experimentar un individuo. La primera definición que se realizó de las emociones fue llevada a cabo por el psicólogo estadounidense Paul Ekman en 1970 (Wang et al., 2022). Sin embargo, a pesar de que los psicólogos se esfuerzan por categorizar las emociones de diversas maneras, dentro de los campos interdisciplinarios de la filosofía, neurociencia e informática, nunca se ha reconocido una definición precisa; por lo que no hay modelos de emociones que sean universalmente aceptados y reconocidos (Shu et al., 2018; Wang et al., 2022). Aun así, dos modelos se han establecido como la base de la investigación actual: el modelo emocional discreto y el modelo emocional continuo (Ali et al., 2018; Lima et al., 2024; Pinto et al., 2019; Shu et al., 2018; Wang et al., 2022).

a) Modelo emocional discreto

El modelo emocional discreto o modelo emocional categórico establece las emociones en categorías limitadas. Dentro de este los más ampliamente utilizados son el modelo de las seis emociones básicas de Ekman y el modelo de la rueda de Plutchik (Verma & Tiwary, 2014; Wang et al., 2022).

El modelo de las emociones básicas de Ekman se basa en la afirmación de que las emociones son universales y comunes a diferentes culturas. Esto permite que personas de lugares totalmente diferentes sean capaces de reconocer expresiones (Lima et al., 2024). Basándose en esta capacidad de las personas de identificar expresiones faciales, Ekman identificó seis emociones básicas: felicidad, tristeza, miedo, ira, disgusto y sorpresa (Shu et al., 2018; Valenza et al., 2012). Estas seis emociones básicas se identificaron conforme a cuatro criterios centrales (Shu et al., 2018):

1. Las emociones humanas provienen del instinto humano.
2. Personas diferentes deben producir la misma emoción básica como respuesta a la misma situación.
3. Los individuos expresan las mismas emociones básicas utilizando los mismos términos y conceptos.

4. El patrón de expresión de las emociones básicas debe ser idéntico para todas las personas.

Las emociones que no se acoplaron a estos cuatro criterios se consideraron producto de la combinación de emociones básicas (Shu et al., 2018), por ejemplo, el desprecio sería la combinación de la ira y el disgusto. Sin embargo, cabe destacar que este modelo puede no ser suficiente para definir emociones intermedias o mixtas, ya que muchas de ellas no se pueden reducir a simples combinaciones de otras emociones (Valenza et al., 2012). Asimismo, el supuesto de la universalidad de las emociones básicas entre diferentes culturas tampoco se considera del todo cierto, pues diferentes sociedades poseen formas de interpretación distintas de las emociones básicas (Wang et al., 2022).

Por otra parte, el modelo de la rueda de Plutchik se creó en 1982 e incluyó ocho emociones básicas: alegría, confianza, miedo, sorpresa, tristeza, disgusto, ira y anticipación (Verma & Tiwary, 2014). Dicho modelo, mostrado en la Ilustración 1, establece las emociones discretas según su intensidad, de tal forma que las emociones más fuertes ocupan el centro de la rueda, mientras que las más débiles se encuentran en los extremos (Lima et al., 2024; Wang et al., 2022). Todas estas emociones se pueden clasificar, de forma general, en tres polaridades que se pueden utilizar para el análisis los estados afectivos: positiva, negativa y neutra (Wang et al., 2022). Además, en este modelo las emociones que se encuentran en posiciones contrarias son opuestas (Lima et al., 2024): alegría versus tristeza, miedo versus ira, anticipación versus sorpresa, etc.




Ilustración 1. Rueda de Plutchik. Recogida de (Shu et al., 2018)

En general, los modelos de emociones discretas emplean descripciones verbales de las emociones en lugar de análisis cuantitativos, lo que supone limitaciones a la hora de analizar emociones más complicadas (Shu et al., 2018). Para solucionar los problemas que introducían los modelos discretos surgieron los modelos continuos.

b) Modelo emocional continuo o dimensional

A medida que la investigación avanzaba, los psicólogos se percataron de que existía cierta relación entre emociones distintas, como el agrado y el placer. Además, percibieron que dentro de la misma emoción las personas podían experimentar diferentes grados de intensidad: un individuo puede estar muy triste o un poco triste (Shu et al., 2018). Para introducir estas observaciones se propusieron los modelos dimensionales, por los que se crean espacios continuos con diferentes dimensiones donde cada una de ellas representa una característica fundamental compartida entre todas las emociones (Valenza et al., 2012).

Rusell introdujo en 1980 el modelo circunplejo de emoción mostrado en la Ilustración 2, en el que se define un modelo espacial bidimensional continuo con el eje vertical representado por la excitación y el eje horizontal por la valencia (Wang et al., 2022). La valencia simboliza el agrado y varía de negativo a positivo, mientras que la excitación representa la actividad corporal y el estado de alerta mental, variando de bajo a alto (Pinto et al., 2019). Estos ejes definen cuatro cuadrantes: el primero de ellos, valencia positiva y excitación alta, representa emociones felices; el segundo, valencia negativa y excitación alta, refleja emociones de ira; el tercero, valencia negativa y excitación baja, está asociado con emociones tristes; y el cuarto, valencia positiva y excitación baja, muestra emociones tranquilas (Wang et al., 2022). Así, con este modelo las emociones pueden representarse por niveles de valencia y excitación (Lima et al., 2024; Pinto et al., 2019).

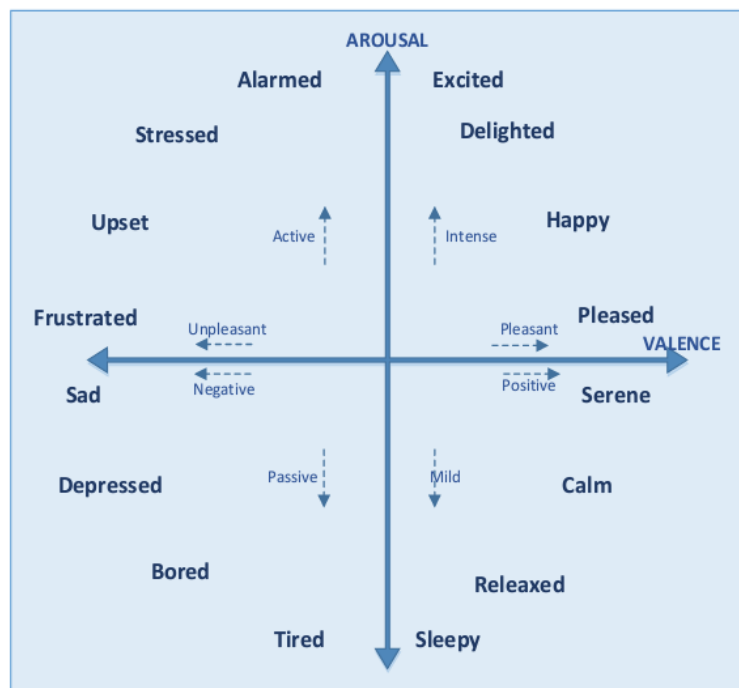


Ilustración 2. Modelo de emoción bidimensional valencia-activación. Recogida de (Ayata et al., 2017)

Rusell y Mehrabian notaron que con este modelo bidimensional era fácil identificar emociones positivas y negativas, pero existían emociones muy parecidas entre sí que el modelo era incapaz de diferenciar. La solución que propusieron fue introducir una nueva dimensión a la que denominaron dominancia, representadas en la Ilustración 3, que simboliza la habilidad del ser humano para gestionar una emoción específica (Lima et al., 2024; Shu et al., 2018; Wang et al., 2022). De esta forma, la ira y el miedo son emociones muy próximas que están dentro del segundo cuadrante, por lo que con el modelo valencia-

excitación no se pueden reconocer como diferentes. Al añadir la tercera dimensión, estas dos emociones se identifican de forma sencilla, pues la ira tiene una dominancia elevada y el miedo una dominancia baja.




Ilustración 3. Modelo de emoción valencia-excitación-dominancia. Recogida de (Shu et al., 2018)

Se pueden encontrar otros modelos dimensionales que incluyen dimensiones adicionales como la potencia, pero estos no están tan aceptados como los anteriores (Verma & Tiwary, 2014).

c) Otros modelos

Existen otros modelos distintos a los discretos y los dimensionales que también han sido aplicados en algunas investigaciones. Sin embargo, estos no están tan extendidos y aceptados. Algunos de los que más destacan son:

- Modelo de tasación: se basa en la idea de que las emociones se generan por la evaluación del contexto pasado, actual o imaginado sobre el entorno y sobre uno mismo. En otras palabras, las emociones están influenciadas, fundamentalmente, por la importancia que un individuo les otorga a unas cosas o a otras (Valenza et al., 2012). Un ejemplo sería la frustración, que se genera cuando una persona no consigue lograr una meta.
- Modelo dinámico: considera a las emociones como procesos activos y cambiantes. Este modelo aplica un punto de vista evolutivo, por el que contempla que las emociones han evolucionado para ayudar a los humanos a responder de forma adaptada a su entorno. Además, establece que las emociones no son emociones incontrolables y que, por tanto, las personas pueden aprender a manejar y modificar sus conductas emocionales.

1.1.3. Anatomía de la emoción

Las teorías sobre la localización de las emociones en el cerebro han ido alternando a lo largo de los años entre un enfoque en regiones, por el que se pensaba que existían zonas concretas del cerebro como el hipotálamo, el tálamo anterior, el hipocampo o la amígdala que estaban involucradas en la generación de las emociones; y un enfoque en circuitos, en el que las emociones tenían su origen en circuitos neuronales concretos como el sistema límbico o el circuito de recompensa (Pessoa, 2017).

Las respuestas del sistema nervioso autónomo se consideran altamente relevantes ante la experimentación de una emoción. El sistema nervioso se encuentra dividido entre el sistema nervioso central y el sistema nervioso periférico. Este último, a su vez, se divide entre el sistema nervioso somático y el sistema nervioso autónomo. El autónomo es el encargado de controlar el músculo cardíaco, las glándulas exocrinas y el músculo liso y se han identificado tres componentes básicos (Haag et al., 2004; Porges, 1997):

- Sistema aferente visceral: está compuesto por fibras nerviosas aferentes que se encargan de transmitir la información desde órganos internos hasta el sistema nervioso central. Por ejemplo, las vías nerviosas que transmiten la sensación de hambre también pueden generar náuseas cuando el individuo se encuentra en un estado de malestar emocional.
- Sistema nervioso simpático: este sistema, junto con la actividad suprarrenal, se activa para la movilización del sujeto en momentos de lucha o huida. Cuando esto ocurre se produce un incremento del volumen de sangre bombeado por el corazón y una disminución de las demandas metabólicas del aparato digestivo. Emociones como el miedo, la ira o la ansiedad pueden activar este sistema para intentar huir de la situación que los está provocando.
- Sistema nervioso parasimpático: se encarga de llevar al organismo a un estado de conservación energética promoviendo el reposo y la digestión. Emociones como la alegría pueden activar este sistema.

Como se ha podido observar, los sistemas nerviosos simpático y parasimpático suelen actuar de forma opuesta, pero es el equilibrio entre ambos el que permite mantener la homeostasis interna cuando las situaciones externas cambian (Haag et al., 2004). En la Ilustración 4 se puede observar algunas de las diferentes funciones llevadas a cabo por las dos ramas del sistema nervioso autónomo y la contraposición de funciones, como la contracción de las pupilas gestionada por el sistema nervioso parasimpático y la dilatación de estas por el sistema nervioso simpático. Algunas emociones tienen la capacidad de alterar el equilibrio entre ambos sistemas, produciendo reacciones fisiológicas como una aceleración del pulso, una respiración rápida y superficial, sudoración de las manos, contracción y rigidez muscular o sequedad bucal (Haag et al., 2004; K. H. Kim et al., 2004).




Ilustración 4. Funciones reguladas por el sistema nervioso simpático y parasimpático. Recogida de (Lifeder, 2022)

Los enfoques en regiones y en circuitos están siendo relegados en los últimos años por una visión más abierta en la que se hipotetiza que las emociones son el resultado de complejas interacciones cortical-subcorticales basadas en redes a gran escala y las interacciones entre estas (Pessoa, 2017). En otras palabras, las emociones no serían el resultado de actividades neuronales en ciertas estructuras o circuitos anatómicos, si no que se originarían como un conjunto de procesos neuronales a todos los niveles del cerebro que están en continuo cambio e influenciados por el contexto.

Esta nueva visión lleva a la idea de que no se puede estudiar una emoción de forma completa analizando, únicamente, la activación neuronal, las expresiones faciales o las alteraciones producidas por el sistema nervioso autónomo (Barrett, 2017). Sin embargo, el estudio de estos aspectos puede ofrecer una buena aproximación de la emoción que está experimentando el individuo.

1.2. COMPUTACIÓN AFECTIVA

El avance exponencial de la tecnología ha provocado que esta se incorpore a numerosos ámbitos de la sociedad, suponiendo una relación cada vez más estrecha entre los ordenadores y el ser humano. Habitualmente se piensa en los ordenadores como instrumentos de razonamiento y lógica, por lo que las emociones se han caracterizado por ser uno de los ámbitos menos investigados en la interacción hombre-computadora por su aparente naturaleza irracional e ilógica. A pesar de este pensamiento generalizado, la integración de emociones en los sistemas informáticos está cada vez más presente (Haag et al., 2004).

Se ha demostrado que las personas interactúan con los ordenadores de la misma forma que lo hacen con las personas y existen muchos estudios que avalan los beneficios introducidos de aplicar habilidades sociales a estos sistemas (Egger et al., 2019). Estos hechos demuestran la necesidad de incorporar a la interacción un factor tan importante como la emoción. Ekman ya resaltó la importancia de la interpretación de las emociones: “Si B percibe la expresión facial de la emoción de A, el comportamiento de B hacia A puede cambiar, y el hecho de que A se dé cuenta de esto puede influir o determinar la experiencia de emoción de A” (Egger et al., 2019)

El término computación afectiva fue propuesto en 1997 por la estadounidense Rosalind Picard (Wang et al., 2022). Este hace referencia a la informática que se vincula o afecta a las emociones y se centra en comprender los mecanismos psicofisiológicos por los que las personas reconocen las emociones (Lima et al., 2024). Su objetivo central es desarrollar ordenadores que sean capaces de reconocer, interpretar, procesar y simular las emociones humanas.

La computación afectiva se compone de dos partes bien diferenciadas: el reconocimiento de las emociones y el análisis de los sentimientos. El reconocimiento de emociones se centra en averiguar cuál es la emoción que está experimentando una persona en cada momento mediante señales visuales, auditivas y fisiológicas, principalmente (se suelen utilizar modelos discretos o dimensionales); mientras que el análisis de sentimientos se centra en evaluar el contenido textual para extraer opiniones y actitudes sobre diferentes temas y clasificarlas, generalmente, en positivas, negativas o neutras (Wang et al., 2022). Aunque son áreas distintas pueden superponerse, por ejemplo, una persona que escribe una reseña positiva probablemente se encuentre en un buen estado emocional.

En este sentido, se profundizará más en el reconocimiento de emociones por ser el aspecto tratado y estudiado en el trabajo.

Las aplicaciones de la computación afectiva en salud son enormemente variadas: en sistemas de telemedicina el conocimiento de la emoción del paciente podría ofrecer al médico herramientas potentes para detectar miedo, ansiedad o estrés y con ello poder ajustar la comunicación para fomentar la tranquilidad del individuo; el conocimiento de las emociones de pacientes que están en un periodo de rehabilitación física o mental puede ayudar a adaptar el nivel de la terapia para impulsar la motivación y el compromiso de los pacientes; los dispositivos portátiles capaces de detectar parámetros fisiológicos, como la frecuencia cardíaca, pueden tener sistemas que detecten estados emocionales como el estrés o la ansiedad y avisen al médico o a familiares; etc (Ayata et al., 2017; Pinto et al., 2019). Otra aplicación considerablemente útil podría ser el uso del reconocimiento de emociones por parte de sistemas informáticos en pacientes que poseen un daño cerebral adquirido y que se encuentran en estados alterados de la conciencia. Esto podría proporcionar un método alternativo de diagnóstico para este tipo de personas, sin necesidad de precisar la medición de la actividad cerebral por el elevado coste y acceso limitado que supone (Barrett, 2017).

1.2.1. Expresión de emociones

Las emociones pueden manifestarse de diferentes formas y, por tanto, ser reconocidas mediante métodos variados. Su expresión puede suceder a dos niveles distintos: el nivel exosomático, por el que se expresan las emociones a través de signos físicos y visibles en el cuerpo del individuo, y el nivel endosomático, refiriéndose a respuestas psicofisiológicas que ocurren dentro del cuerpo y son reguladas a través del sistema nervioso autónomo (Pinto et al., 2019).

El reconocimiento de emociones utiliza las diferentes expresiones de los estados afectivos en el cuerpo humano para identificar y clasificar los diferentes estados emocionales (Haag et al., 2004). De la misma forma que la expresión de las emociones mediante diferentes canales puede ser una ventaja para identificar diferentes vías de

estudio, también puede introducir complicaciones relacionadas con la integración y sincronización de los datos, el incremento del costo o la variabilidad individual. El objetivo principal del reconocimiento de emociones ha sido la independencia entre diferentes sujetos, pero este es un esfuerzo investigador que demanda un estudio a largo plazo por la amplia variabilidad interpersonal en la expresión de estas (Takahashi et al., 2012).

1.2.1.1. Nivel exosomático

Las emociones se expresan a través de todas las formas en que las personas se relacionan y se comunican entre sí. Estas expresiones suelen ser, fundamentalmente, no verbales, ya que a menudo suelen ser reacciones automáticas del cuerpo ante situaciones externas o pensamientos (Verma & Tiwary, 2014). Entre ellas, destacan (Egger et al., 2019):

- Expresiones faciales: movimientos del rostro que suelen estar asociados a diferentes tipos de emociones como muecas, levantamiento de cejas, ceños fruncidos o sonrisas.
- Gestos: movimientos y posturas corporales por las que se comunican emociones. Incluye cualquier tipo de lenguaje corporal, como levantamiento de hombros, cruzamiento de brazos o movimientos de manos.
- Discurso: engloba aspectos del habla como el lenguaje, el tono de voz, el ritmo o la velocidad del habla.
- Postura corporal: cómo una persona mueve o sostiene su postura puede revelar ciertas emociones. Por ejemplo, una persona con una postura más erguida puede indicar cierta confianza en sí mismo, mientras que un individuo con una postura más caída puede revelar cierta tristeza o inseguridad.
- Mirada: la forma en que las personas utilizan el contacto visual revela ciertos estados emocionales como la vergüenza, cuando se evita el contacto, o la confianza, en los momentos que hay un mayor mantenimiento de la mirada.

En una investigación se descubrió que la expresión de las emociones humanas a nivel físico venía representada, principalmente, por un 55% de las expresiones faciales, un 38% de la voz y un 7% del lenguaje (Wang et al., 2022). Por ello, la mayoría de los estudios a nivel exosomático se han centrado en identificar expresiones faciales y analizar las señales del habla (K. H. Kim et al., 2004; Wang et al., 2022). En 2003 Ekman escribió un libro llamado “Desenmascarar el rostro” en el que se llevaba a cabo una descripción exhaustiva del cambio de las expresiones faciales en función de las emociones experimentadas por las personas, estudiando factores como el ángulo de los labios o las arrugas que se forman en la frente ante ciertos estímulos (Egger et al., 2019). Desde entonces se han ido mejorando las técnicas de reconocimiento mediante cámaras y sistemas informáticos capaces de reconocer estos parámetros (Egger et al., 2019).

Sin embargo, el estudio exosomático de las emociones introduce diversas limitaciones que es necesario tener en cuenta. Así, en el estudio del reconocimiento de emociones mediante expresiones faciales, el nivel de iluminación bajo y el movimiento del individuo suponen importantes factores limitantes, ya que pueden afectar de forma significativa a la precisión y confiabilidad de los resultados obtenidos (Haag et al., 2004). En cuanto al discurso, existen problemas para aislar el ruido de fondo cuando los individuos se encuentran realizando otras tareas como la escucha de música o el visionado de películas,

pues la identificación de emociones requiere de un claro entendimiento de todos los componentes del habla del emisor (Haag et al., 2004).

Por otra parte, la detección de las expresiones exosomáticas está fuertemente influenciada por la cultura, la edad y el género del individuo (Egger et al., 2019). De esta forma, hay culturas en las que no está bien visto expresar emociones como el dolor o la ira, por lo que tienden a sustituir estas emociones por una sonrisa falsa; o, de la misma forma, en algunas culturas orientales se tiende a expresiones faciales en público más neutras que las culturas occidentales (Khoury Karayanni, 2017). En cuanto a la edad, los niños tienden a mostrar sus emociones de forma más exagerada que los adultos y las jergas y gestos varían considerablemente entre distintas generaciones (Grossard et al., 2018). Algunos estudios demuestran una mayor dificultad para el reconocimiento de emociones mediante expresiones fáciles en hombres que en mujeres (Khoury Karayanni, 2017) y otros apuntan a la mayor precisión que supone emplear diferentes modelos para cada género (Shaqra et al., 2019).

Una posible solución para mejorar la precisión de los modelos de reconocimiento de emociones de forma exosomática podría ser el empleo de sistemas multimodales, es decir, metodologías en las que se obtiene información conjunta de múltiples canales como el visual, auditivo y textual. De esta forma, el hecho de disponer información de diferentes vías por las que el cuerpo humano expresa las emociones de forma exosomática permite una mayor precisión en el momento de reconocerlas y diferenciarlas (Verma & Tiwary, 2014; Wang et al., 2022).

1.2.1.2. Nivel endosomático

Diversas investigaciones sobre las emociones sugieren que los estímulos afectivos pueden desencadenar reacciones automáticas del sistema nervioso autónomo (Greco et al., 2017; Haag et al., 2004; Porges, 1997). Dichas reacciones son las que se emplean para obtener patrones que ayuden a diferenciar unas emociones de otras; para ello, se monitorizan y se miden a través de las señales biológicas (Haag et al., 2004; K. H. Kim et al., 2004).

La utilización de señales fisiológicas para identificar las emociones dispone de tres ventajas fundamentales.

La primera de ellas radica en el tamaño del equipo de medida. Los últimos años han venido marcados por una tendencia a la miniaturización de los dispositivos, llegando a sensores de tamaños nanométricos (Fu et al., 2023). En el campo de las bioseñales la investigación se ha enfocado en el desarrollo de dispositivos *wearables* llegando a sistemas de electromiografía basados en un brazalete que se coloca sobre el brazo, dispositivos de registro de electrocardiogramas (ECG) conformados por un único parche que permite un registro de hasta 14 días sin comprometer la vida del paciente, o diademas capaces de realizar un registro de electroencefalografía de alta calidad de unos cuantos canales (Athavale & Krishnan, 2017). Estos métodos para obtener datos con los que reconocer emociones se consideran más discretos y menos intrusivos que los métodos exosomáticos, en los que se precisan de cámaras delante de la cara del individuo, métodos de tracking de la mirada muy cerca del ojo, o micrófonos para el habla que el usuario considera intrusivo por estar grabando constantemente sus conversaciones (Canento et al., 2011; Egger et al., 2019; Haag et al., 2004). Asimismo, esta miniaturización de los sensores se irá desarrollando

con los años, alcanzando sistemas de monitorización que se incorporen en joyas, ropa o análogos y que resulten prácticamente imperceptibles para el usuario con una muy buena calidad en la señal (Haag et al., 2004).

Otra de las ventajas del uso de señales fisiológicas para la identificación de emociones consiste en la capacidad de obtener las señales fisiológicas siempre que se requiera, ya que el cuerpo reacciona continuamente a los estímulos del entorno y genera respuestas a diferentes niveles que pueden ser captadas en forma de señales (Verma & Tiwary, 2014). Por contra, cuando se utilizan métodos exosomáticos se requiere de acciones específicas como hablar, gesticular o mostrar expresiones faciales que no siempre se pueden obtener con tanta precisión como con unos sensores en el cuerpo del individuo. Además, mientras que las medidas exosomáticas pueden ser gravemente influenciadas por factores externos como la iluminación o la presencia de objetos físicos, las señales biológicas, al ser medidas de forma directa en el cuerpo, son menos susceptibles a estas variaciones (Verma & Tiwary, 2014).

Como última ventaja a destacar del uso de señales fisiológicas, la mayoría de los estudios resaltan la capacidad de estas señales para evitar la influencia intencionada en la expresión de las emociones por parte de las personas (Canento et al., 2011; K. H. Kim et al., 2004; Perez-Rosero et al., 2017; Verma & Tiwary, 2014). El sistema nervioso autónomo responde de forma automática en función del estado emocional en el que se encuentre el individuo y no puede ser ocultado o engañado tan fácilmente como manteniendo una expresión facial neutra, modulando el tono y ritmo de la voz, o siendo consciente de dónde se está mirando (Egger et al., 2019). Todo ello supone superar las limitaciones introducidas por factores como el enmascaramiento social, pues la verdadera emoción de la persona queda reflejada en la variación de las respuestas de su sistema nervioso (Canento et al., 2011).

Aunque son muchas las ventajas introducidas del uso de señales biológicas para el reconocimiento de emociones, no es un método infalible. Las emociones son unos estados que están fuertemente ligados a la persona que los experimenta (Egger et al., 2019). Una persona puede sentir una emoción de felicidad más fuerte al escuchar o visualizar un estímulo que le recuerde a alguna experiencia pasada feliz, mientras que otra persona podría reaccionar de forma opuesta si tiene algún trauma asociado; también existen personas más sensibles que otras que pueden experimentar las emociones con más intensidad. Esto supone diferencias en la expresión de emociones de forma interna y, por tanto, variaciones en las respuestas del sistema nervioso autónomo entre personas; este hecho implica un claro factor limitante para alcanzar el objetivo de independizar el reconocimiento del individuo (J. Kim & André, 2008). Dejando a un lado las diferencias entre individuos particulares, la cultura, la edad, el contexto y el espacio son factores que también influyen en la expresión endosomática de las emociones (J. Kim & André, 2008).

Al utilizar bioseñales para el reconocimiento de emociones es complicado capturar con exactitud las variaciones emocionales empleando una sola señal (Shu et al., 2018). Una de las soluciones podría ser el uso de una señal biológica junto con técnicas de reconocimiento de emociones exosomáticas, como datos de voz o de expresiones fáciles, para obtener una identificación mejorada (Verma & Tiwary, 2014). Sin embargo, la mayoría de los estudios utilizan un enfoque multimodal basado en el empleo de distintas señales fisiológicas (Ali et al., 2018; J. Kim & André, 2008; K. H. Kim et al., 2004; Li & Chen, 2006; Lima et al., 2024; Verma & Tiwary, 2014), utilizando algunas como la respuesta galvánica de la piel (GSR), ECG,

respiración (RSP) o electroencefalograma. De esta forma, para algunas emociones se puede obtener redundancia de información que ayude a mejorar la precisión de la identificación, mientras que otras son más complejas y pueden involucrar múltiples respuestas que pueden ser captadas por diferentes señales. Además, el hecho de disponer de un sistema multimodal basado en señales fisiológicas también puede reducir la influencia del contexto y los sesgos individuales, aumentando la robustez del sistema (Shu et al., 2018).

Para obtener una mayor precisión de los resultados en este trabajo, el personal investigador recopiló tres señales fisiológicas de cada uno de los participantes: GSR, RSP y ECG. Estas señales se consideran medidas estrechamente vinculadas con la actividad autónoma, no intrusivas para los participantes de los estudios, fáciles de medir, de bajo coste, y numerosos estudios han respaldado su uso para el reconocimiento de emociones (Canento et al., 2011; Egger et al., 2019; Haag et al., 2004; Shu et al., 2018; Takahashi et al., 2012). Así, la monitorización de señales fisiológicas como estas precisa de dispositivos de registro de alta calidad que aseguren la precisión y la fiabilidad de los datos recopilados. Un equipo de medida de buenas características permitirá el almacenamiento de grandes cantidades de datos; un procesamiento en tiempo real, en caso de ser necesario; y una correcta interoperabilidad que asegure la fácil integración con otros dispositivos y facilite el flujo de datos. Por lo que respecta al diseño, el sistema debe estar pensado tanto para el usuario del dispositivo, con un sistema de cableado y unas dimensiones del equipo que reduzcan al máximo la incomodidad y las molestias, como para el operador del sistema, desarrollando una interfaz de usuario amigable y eficiente que facilite el manejo y la interpretación de los datos.

Por otra parte, la calidad del *software* y *hardware* empleado debe tenerse en cuenta para la creación de estudios de reconocimiento de emociones basados en señales fisiológicas. El *hardware* afecta directamente a la percepción del estímulo por parte de los sujetos y puede condicionar en gran medida las respuestas emocionales y, consecuentemente, los resultados obtenidos. En cuanto al *software*, muchos estudios neurofisiológicos precisan de un sistema capaz de llevar a cabo un control preciso de la entrega de estímulos, una captación de las respuestas adecuada y una sincronización de sistemas externos (Canto et al., 2011). Concretamente, el estudio realizado para este proyecto está basado en la correlación existente entre los estímulos auditivos y las respuestas de las señales fisiológicas periféricas, por lo que el uso de un *software* que garantice la mayor exactitud y coherencia en términos de sincronización resulta clave. La principal ventaja de utilizar sistemas de control y gestión experimental radica en que están optimizados específicamente para ofrecer una precisión temporal muy elevada (Canto et al., 2011).

A continuación, se analizará con más profundidad las señales fisiológicas de GSR y RSP, que fueron las analizadas en este estudio.

a) Respuesta galvánica de la piel

La respuesta galvánica de la piel (GSR, por sus siglas en inglés *Galvanic Skin Response*), también conocida como actividad electrodérmica, es una señal biológica que mide la conductancia eléctrica de la piel (Ali et al., 2018; Egger et al., 2019). Las glándulas sudoríparas, controladas por el sistema nervioso autónomo, son las encargadas de secretar el sudor, aumentando la salinidad de la piel y, por tanto, disminuyendo la resistencia eléctrica. En otras palabras, la activación de estas glándulas produce humedad en la

superficie de la piel que produce una variación en el equilibrio iónico y genera cambios en la propiedad de flujo de las corrientes eléctricas de la piel (Ayata et al., 2017).

Diversos estudios han demostrado que la señal GSR es un reflejo de la actividad del sistema nervioso autónomo y, más concretamente, del sistema nervioso simpático, que está estrechamente vinculado con la actividad de las glándulas ecrinas responsables de la termorregulación (Egger et al., 2019; K. H. Kim et al., 2004; Zhang et al., 2016). Estas glándulas repartidas por toda la piel, al estar exclusivamente inervadas por la rama simpática del sistema nervioso autónomo, son consideradas un excelente indicador del nivel de excitación del individuo ante estímulos sensoriales y cognitivos que pueden proceder de vídeos, imágenes, audios, eventos o cualquier estímulo cargado de emoción (Ayata et al., 2017; K. H. Kim et al., 2004). Otras medidas, como la variabilidad en la frecuencia cardíaca, no han demostrado ser tan efectivas como la GSR para determinar la dinámica simpática (Greco et al., 2017).

La secreción de sudor es una respuesta fisiológica que no puede manipularse de forma consciente, por lo que se considera un biomarcador muy útil para el reconocimiento de emociones (Kipli et al., 2022). Cuando una persona experimente una emoción que genere un estado fisiológico más relajado (como felicidad o calma), las glándulas sudoríparas no estarán tan activas, la conductancia de la piel disminuirá y la señal GSR registrará valores más bajos; mientras que la vivencia de emociones que producen una mayor excitación (como estrés o sorpresa), produce una activación de las glándulas, un incremento de la conductancia de la piel y, consecuentemente, un aumento en el registro de valores de GSR (Ayata et al., 2017; Egger et al., 2019).

La medición de esta señal se suele realizar mediante dos electrodos (Kipli et al., 2022; Zhang et al., 2016). Así, la aplicación de una pequeña corriente constante y conocida en uno de ellos genera una diferencia de potencial entre los dos electrodos en contacto con la piel. Las variaciones en la diferencia de potencial se deberán a los cambios de conductancia de la piel, lo cual se refleja en el voltaje registrado y se utiliza para obtener la señal de GSR.

El sudor producido por los cambios emocionales en el individuo es especialmente común en las palmas de las manos, los dedos y las plantas de los pies (Ayata et al., 2017). Por ello, la señal GSR suele medirse con sensores situados sobre esas zonas. Cuando el individuo se encuentra en un contexto en el que no se requiere movimiento de las manos, como escuchando un audio o visualizado un video, se recomienda colocar los electrodos en el dedo índice o en el corazón. Si los individuos utilizan las dos manos de forma un poco más activa, como manejando un *mouse* o un teclado, la ubicación recomendada de los electrodos es en la palma de las manos. Como última situación, un uso más extensivo de ambas manos, como en situaciones que requieran la interacción con objetos de la vida real, precisará de la ubicación de los electrodos en las plantas de los pies con el objetivo de evitar artefactos en la señal. En este último caso, los sensores deben colocarse en las superficies internas para evitar que al estar de pie o caminando la presión los afecte (Ayata et al., 2017).

La señal GSR obtenida en el registro se puede dividir en dos componentes principales: la respuesta de conductancia de la piel (SCR, por sus siglas en inglés *Skin Conductance Response*), también conocida como el nivel fásico, y el nivel de conductancia de la piel (SCL, que corresponde a las siglas en inglés *Skin Conductance Level*), denominado por muchos autores nivel tónico (Kipli et al., 2022). El primero hace referencia a los cambios rápidos y

transitorios que ocurren en la conductancia de la piel. Dentro de SCR encontramos dos subcomponentes, donde uno representa aumentos momentáneos de la señal ante ciertos estímulos, como el representado en la Ilustración 5, y otro ocurre de forma espontánea sin necesidad de estímulos, conocido como respuesta de conductancia cutánea no específica (Ali et al., 2018; Kipli et al., 2022). Por otra parte, el SCL representa la línea base de la conductancia de la piel, con cambios más graduales que dependen de la hidratación, humedad y regulación autonómica de cada piel (Kipli et al., 2022).

En la Ilustración 5 se aprecia una forma de onda típica de una señal de GSR en la que se observa un incremento rápido de la señal continuado de un decremento más lento hasta el nivel inicial. Desde que el individuo recibe un estímulo, como un vídeo, música u olor, hasta que se produce la secreción de sudor por la acción del sistema nervioso simpático, transita un tiempo que se conoce como periodo de latencia (*latency*). Al desencadenar la producción de sudor por parte de las glándulas sudoríparas, la conductancia aumenta hasta un máximo de amplitud para luego decrecer. El tiempo desde que se comienza a secretar el sudor hasta que se alcanza el máximo de amplitud se conoce como tiempo de rampa o *rise time* en inglés, mientras que el periodo de tiempo desde que se alcanza el máximo de amplitud hasta que se vuelve al estado basal se denomina tiempo de recuperación o *recovery time* en inglés (Shukla et al., 2021).




Ilustración 5. Forma de onda típica de señal GSR. Recogida de (Kipli et al., 2022)

El uso de GSR se ha posicionado como una de las opciones más asequibles para la obtención de datos que ayuden al reconocimiento de emociones (Kipli et al., 2022; Zhang et al., 2016); no obstante, el uso de señales fisiológicas como esta introduce ciertos problemas que deben ser tratados para conseguir un registro del individuo lo más realista y preciso posible. Los artefactos son uno de los principales problemas que se deben lidiar, ya que casi siempre van a existir interferencias externas producidas por fuentes ajenas al fenómeno estudiado. Por lo que respecta a los artefactos más comunes en la señal de GSR producidos por el entorno, destacan los siguientes (Tobii, 2023):

- Artefacto de movimiento. La inadecuada fijación de los electrodos a la piel del individuo puede producir movimientos que modifican la superficie de contacto. Este fenómeno se ve reflejado en la señal de GSR como picos y valles que suelen tener una amplitud y una frecuencia más elevada que las ondas de SCR, como se puede observar en la Ilustración 6A. A parte de la mala fijación, el movimiento brusco del individuo o de los cables también puede provocar estos artefactos, con la distinción

de que estas situaciones suelen reflejarse mediante componentes de amplitud y frecuencia parecidas a SCR. No existen herramientas de procesamiento que eliminen los artefactos de movimiento sin perjudicar a la señal de GSR, por lo que es preferible implementar técnicas que ayuden al correcto contacto de los electrodos con la piel, como el uso de cinta para una mejor fijación, y la concienciación del sujeto para que evite movimientos repentinos. En última instancia, si se detectan estos artefactos en la señal registrada, se recomienda cortar el segmento de señal correspondiente.

- Ruido de alta frecuencia. SCL varía con una frecuencia de 1 Hz como máximo, consecuentemente, las fluctuaciones caracterizadas por una frecuencia superior a esta suponen artefactos de alta frecuencia, como las observadas en la Ilustración 6B. Los más habituales son la red eléctrica, con una frecuencia de 50 Hz, o el error de precisión de los electrodos. La solución radica en aplicar filtros que eliminen estas componentes, como los filtros de paso bajo.
- Artefacto transitorio rápido. El movimiento rápido de algún electrodo puede causar este tipo de artefacto, reflejándose en la señal de GSR como picos altos y muy estrechos, como el contemplado en la Ilustración 6C. La eliminación de este artefacto requiere filtros capaces de eliminar las componentes frecuenciales rápidas, como el filtro de mediana móvil.

En cuanto a los artefactos producidos por el propio organismo, el cambio de temperatura es el que más destaca, ya que este produce una disminución gradual de la señal GSR que no está relacionada con las emociones del individuo. Dicho problema afecta cuando se quieren estudiar los cambios lentos de la señal, es decir, el SCL. En este caso la solución reside en mantener un control de la temperatura y la humedad de la zona donde se va a realizar el registro (Tobii, 2023).




Ilustración 6. Artefactos de GSR generados por el entorno. A) Artefacto de movimiento generado por la mala adhesión de los electrodos a la piel. B) Artefacto de alta frecuencia. C) Artefacto transitorio rápido. Recogidas de (Tobii, 2023)

Una vez procesada la señal, el reconocimiento de emociones precisa de la extracción de características de la señal de GSR para obtener indicadores más directos y comprensibles de las respuestas emocionales, así como para facilitar el análisis de la señal. En el dominio del tiempo algunas de las características más utilizadas son (Ali et al., 2018; Egger et al., 2019; Kipli et al., 2022; Shu et al., 2018): media, mediana, desviación estándar, valor eficaz, curtosis, asimetría, máximo, mínimo, media de la primera derivada, media de la segunda derivada, media de las diferencias absolutas o media de las variaciones locales.

La extracción de características basada en el dominio del tiempo únicamente es capaz de recopilar información de la señal de forma superficial, siendo insuficiente para parámetros

que varían con el tiempo (Pan et al., 2020). Así, se suelen extraer diferentes características en el dominio de la frecuencia para una mejor evaluación de las propiedades transitorias de la señal. Algunos estudios han demostrado que GSR muestra un comportamiento no estacionario, pues son señales no periódicas que muestran cambios en amplitud, fase y frecuencia (Kipli et al., 2022). Para solucionar los problemas que introduce la transformada de Fourier sobre señales no estacionarias y mejorar la sensibilidad al ruido, diversos autores han optado por emplear la Transformada Wavelet Discreta (DWT), que descompone la señal en componentes de tiempo-frecuencia (Ayata et al., 2017; Kipli et al., 2022). La DWT realiza una descomposición de la señal en diferentes niveles de resolución mediante filtros paso bajo, para extraer la estructura general (componentes de aproximación), y filtros paso alto, para extraer los detalles (componentes de detalle). Para la descomposición en cada uno de estos niveles se utilizan *wavelets* hijas, que son funciones obtenidas a partir de la *wavelet* madre mediante escalamientos y desplazamientos (Guo et al., 2022). La selección de la *wavelet* madre (la función a partir de la cual se obtienen todas las demás) y del nivel de descomposición (el número de veces que la señal se descompone en coeficientes de aproximación y detalle) es fundamental para obtener una óptima representación de las características relevantes de la señal (Ayata et al., 2017). En este sentido, algunos estudios, como el llevado a cabo por (Ayata et al., 2017), han optado por utilizar la *wavelet* de Daubechies porque ofrecen buenas representaciones de señales suaves y regulares, son capaces de capturar cambios sutiles, y tienen la capacidad de capturar y representar de forma eficiente la información temporal y frecuencial.

De esta forma, algunas de las características frecuenciales más utilizadas son: descomposición de modelo empírico, funciones de modo intrínseco, área de la magnitud de la señal, frecuencia máxima, varianza, curtosis o asimetría (Kipli et al., 2022).

A nivel de los componentes tónico y fásico de la señal GSR también se suelen extraer algunas características relevantes, como la latencia de la respuesta del primer SCR significativo, el tiempo de recuperación medio, el número de picos SCR del segmento de señal, la amplitud media de todos los picos SCR encontrados, suma de las amplitudes de los picos SCR, suma de las áreas de SCR o la desviación estándar de la amplitud SCL (Ali et al., 2018; Greco et al., 2017; Jang et al., 2015; Kipli et al., 2022; Shu et al., 2018).

b) Señal de respiración

La señal de respiración (RSP) proporciona una representación del desplazamiento torácico del individuo para monitorizar la ventilación (Lima et al., 2024). La ventilación es el proceso por el cual el diafragma y los músculos intercostales se contraen arrastrando a los pulmones, de tal forma que se genera una presión negativa en el interior de estos órganos que produce la entrada de aire desde el exterior (inspiración) y, posteriormente, se produce la relajación de los músculos, volviendo los pulmones a su estado original y expulsando el aire inspirado (expiración) (Vries et al., 2018). La señal producida por estas dos fases se puede apreciar en la Ilustración 7, en la que se observa una onda semejante a una sinusoidal, donde las variaciones positivas representan el flujo inspiratorio y las variaciones negativas el flujo expiratorio. La ventilación permite que se lleve a cabo la respiración tanto a nivel externo como interno, es decir, el intercambio de gases tanto en los alveolos pulmonares como a nivel de todos los tejidos del cuerpo.

La ventilación es una función involuntaria controlada automáticamente por el sistema nervioso autónomo. Los centros respiratorios encargados de controlar la ventilación se encuentran situados en el tronco del encéfalo y en el bulbo raquídeo. Dichos centros envían impulsos a través de las vías nerviosas al diafragma y músculos intercostales, provocando su contracción y relajación en intervalos concretos (Chung et al., 2019). Una de las principales vías sensoriales autónomas de los pulmones es el nervio vago, que regula varios aspectos respiratorios como el volumen tidal, la frecuencia respiratoria o el tono de las vías respiratorias (Vries et al., 2018).

Debido al control autónomo de la ventilación, numerosos estudios han afirmado la relación existente entre las emociones y los cambios en los patrones respiratorios, concluyendo que es una de las señales fisiológicas más evidentes para el reconocimiento de estas (Siddiqui et al., 2021; Wu et al., 2012; Zhang et al., 2017). La velocidad y la profundidad de la respiración están fuertemente influenciadas por el tipo de emoción que se esté experimentando. Una emoción de felicidad, enfado, ansiedad o miedo conducirá a un patrón respiratorio profundo y rápido que denota un estado de excitación en el individuo, con unas 40-50 respiraciones por minuto como máximo; la tensión se percibe como una respiración superficial y rápida; el disgusto se expresa mediante una supresión de la respiración; mientras que las personas en un estado de calma, relajación o depresión suelen presentar un patrón más profundo y lento con menos de 20 respiraciones por minuto (Egger et al., 2019; Lima et al., 2024; Siddiqui et al., 2021; Zhang et al., 2017). Sin embargo, el estado afectivo del individuo no es el único elemento que influye sobre la respiración, ya que existen otros factores como el grado de autorregulación corporal, los movimientos corporales, la concentración de oxígeno y dióxido de carbono, el estrés de los tejidos o las señales de los centros cerebrales que también pueden modificar los patrones respiratorios (Chung et al., 2019; Wu et al., 2012).

Para la monitorización respiratoria se pueden encontrar técnicas que precisan contacto directo con el cuerpo del individuo y técnicas en las que el dispositivo no requiere ningún contacto. En cuanto a las primeras, se pueden encontrar técnicas basadas en el flujo de aire, que detectan la temperatura del aire inspirado/espirdo, miden la presión del flujo, o monitorean el dióxido de carbono o la humedad; técnicas basadas en el movimiento del tórax, que utilizan piezoeléctricos, acelerómetros o sistemas de ultrasonidos; técnicas de detección de la conductividad pulmonar, en las que una bobina genera un campo magnético cuyos parámetros son modificados por la conductividad pulmonar en función de la respiración; o técnicas basadas en fotopleletismografía y electrocardiografía, que estiman la respiración mediante las variaciones volumétricas producidas por el pulso sanguíneo y por la actividad eléctrica del corazón, respectivamente (Ali et al., 2021). Por lo que respecta a los métodos de monitorización sin contacto, existen enfoques basados en cámaras, en los que se utilizan termografía infrarroja para detectar la temperatura en las fosas nasales o vídeos para analizar los movimientos del tórax; técnicas basadas en radar, que se basan en los cambios producidos en las ondas electromagnéticas por el movimiento de los pulmones; o métodos basados en ultrasonidos sin contacto, en los que se utilizan ondas mecánicas para monitorizar la respiración (Ali et al., 2021). La elección de un método u otro dependerá de las características del estudio y de la precisión de los datos que se quiera obtener.

Algunos estudios también utilizan sensores basados en bioimpedancia para el registro de la señal de RSP, los cuales captan los cambios en la impedancia eléctrica de los tejidos

cuando estos se mueven debido al proceso de ventilación (Blanco-Almazan et al., 2019; Qiu et al., 2022). Cuando se produce la inspiración, la mayor cantidad de gas en los pulmones, junto con la expansión de las vías respiratorias, producen un aumento de la impedancia eléctrica, generándose un efecto contrario en la espiración (Qiu & Yuze, 2021).




Ilustración 7. Forma de onda típica de la señal de RSP. Recogida de (MindWare Technologies Ltd., 2017)

En cuanto a las interferencias producidas por factores externos a la respiración, el artefacto de movimiento se posiciona como uno de los más típicos (Zhang et al., 2017). Esto se debe a que cualquier cambio de posición del sujeto puede amplificar o distorsionar los movimientos naturales del tórax que son medidos para la obtención de la señal. Además, los desajustes en los sensores debido a la agitación del individuo también generan problemas de este tipo. Típicamente los artefactos de movimiento son de una frecuencia inferior a la del rango respiratorio típico (0,20 – 0,33 Hz) (University of Rochester), por lo que se suelen implementar filtros paso bajo para mitigarlos (Mirmohamadsadeghi et al., 2017).

Análogamente a GSR, la extracción de características resulta esencial para realizar un análisis más simple a la par que preciso de la señal de la respiración. Algunas de las características empleadas en el estado del arte para el reconocimiento de emociones son (J. Kim & André, 2008; Li & Chen, 2006; Mirmohamadsadeghi et al., 2017): frecuencia respiratoria instantánea, duración de la inspiración/espiración, amplitud respiratoria media, desviación estándar de las amplitudes, simetría mínimo-máximo, simetría entre la inspiración y la espiración o métricas estadísticas de los intervalos respiratorios. En cuanto al dominio de la frecuencia, se obtiene la densidad espectral de potencia en la banda de frecuencia baja y alta, la relación entre ellas y métricas asociadas a la entropía.

Diversos estudios utilizan la arritmia sinusal respiratoria (RSA), junto con otras medidas de la señal de respiración, para obtener características empleadas en los modelos de reconocimiento de emociones (Mirmohamadsadeghi et al., 2017; Shu et al., 2018). La RSA es una variación natural de la frecuencia cardíaca que se origina en el ciclo respiratorio, caracterizada por un aumento de la frecuencia cardíaca en la inspiración y una disminución en la espiración (Mirmohamadsadeghi et al., 2017). Las características que se obtienen son: relación de amplitud de la RSA con la oscilación respiratoria, diferencia entre las frecuencias respiratorias y la RSA, diferencia entre las fases respiratorias y la RSA, pendiente de la diferencia entre las fases respiratorias y la RSA, o desviación estándar de la diferencia entre las fases respiratorias y la RSA (Mirmohamadsadeghi et al., 2017; Shu et al., 2018).

1.2.2. Autoevaluación de emociones

La autoevaluación de emociones se considera como una fase importante en los estudios de reconocimiento de emociones por la información adicional que proporciona del estado del individuo, ya que la percepción de un observador externo puede no ser la misma que la experimentada por la propia persona. Asimismo, los datos subjetivos obtenidos se pueden utilizar para correlacionarlos con medidas más objetivas, como las señales fisiológicas, ayudando a la generación o validación de algoritmos.

El *Self-Assessment Manikin* (SAM) es un cuestionario basado en imágenes diseñado para autoevaluar las respuestas emocionales de individuos cuando son estimulados mediante herramientas como videos, audios u olores. La escala SAM utiliza el modelo dimensional de las emociones introducido por Russell y Mehrabian por el que se definen las respuestas emocionales mediante tres características: valencia, dominancia y excitación (Bynion & Feldner, 2017).

La Escala Diferencial Semántica era una de las escalas más utilizadas antes de la introducción del SAM, evaluando también las tres dimensiones principales de la emoción a través de pares de adjetivos opuestos (Bynion & Feldner, 2017). Esta escala, por lo general, se basaba en un sistema de siete puntos en el que los extremos representaban estados opuestos de cada par de adjetivos, diseñados para capturar las tres dimensiones emocionales. Sin embargo, la evaluación de múltiples pares de adjetivos suponía un tiempo elevado para los participantes, que debían de comprender cada una de las parejas y establecer una puntuación, y un volumen de datos difícil de manejar (Bynion & Feldner, 2017).

Para solucionar las limitaciones que introducía la Escala Diferencial Semántica, Peter Lang desarrolló la escala SAM. Inicialmente, este cuestionario se proporcionaba como una escala de 21 puntos, pero actualmente se suele utilizar una escala de 9 puntos por la mayor simplicidad que supone (Bynion & Feldner, 2017). Al entregar el cuestionario SAM se debe explicar de forma correcta el significado de las tres dimensiones de la emoción, pues algunas, como la dominancia, se consideran más difíciles de comprender para la mayoría de los participantes. Una vez entendido, el individuo deberá evaluar la emoción que ha experimentado para las diferentes dimensiones. En la Ilustración 8 se observa que la valencia se representa con nueve figuras desde un nivel negativo, con un maniquí con cara triste, hasta un nivel positivo, simbolizado por un maniquí con una cara sonriente. Seguidamente, la segunda fila de la ilustración representa la escala SAM para la excitación, en la que una intensidad de la emoción baja se representa con un maniquí con los ojos cerrados y un pinchazo pequeño en el abdomen, mientras que una intensidad alta viene reflejada por un maniquí con los ojos muy abiertos y una gran explosión en el abdomen. Por último, la tercera fila de la Ilustración 8 identifica el grado de dominancia generado por la emoción experimentada, que varía desde un estado en el que el participante no siente ningún control sobre sí mismo o sobre la situación, simbolizado con un maniquí de pequeño tamaño, hasta un estado en el que el individuo siente el control total, reflejado mediante un maniquí de gran tamaño.

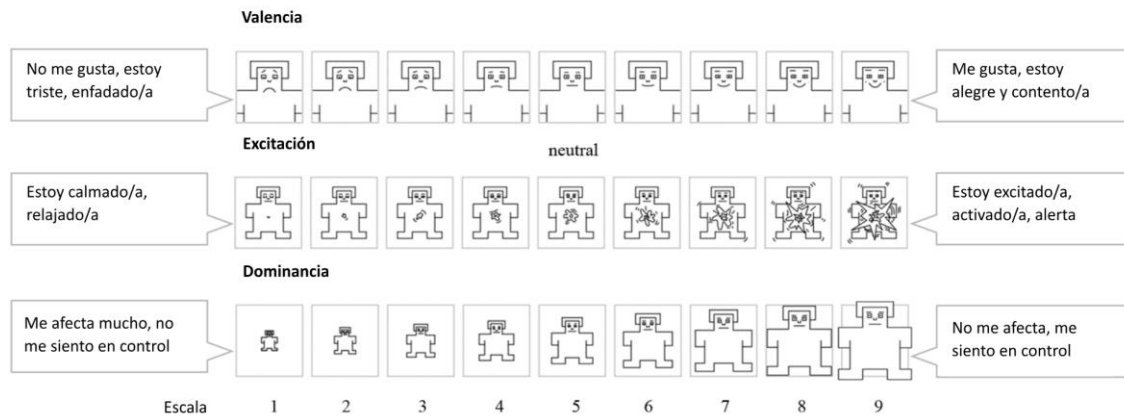


Ilustración 8. Escala SAM para las tres dimensiones de emoción: valencia, excitación y dominancia. Adaptada de (Lima et al., 2024)

Se ha demostrado que la escala SAM se puede aplicar para diferentes culturas y países por ser un cuestionario basado en imágenes que únicamente requieren una breve explicación; además, se puede utilizar tanto en niños como en adultos, así como en casos clínicos diferentes (Bynion & Feldner, 2017). Otra de las ventajas que caracteriza a este método de autoevaluación de emociones es su brevedad, ya que el individuo únicamente debe responder a tres escalas diferentes. Esto permite reducir la carga cognitiva de los participantes y obtener resultados rápidos y fiables (Bynion & Feldner, 2017).

1.2.3. Inducción de emociones

La inducción de emociones es el proceso por el que se provocan diferentes estados afectivos en las personas con el objetivo de recopilar datos que sirvan para analizar y mejorar la capacidad de un sistema de identificar estas emociones (Wang et al., 2022). Para ello, se podrían utilizar diversas modalidades y canales sensoriales, pero se debe tener en cuenta que estos siempre van a estar influenciados por factores externos e internos, como la atención de los participantes, la interacción social, el clima y entorno natural, o el grado de nerviosismo del individuo (Valenza et al., 2012). De esta forma, recoger datos fisiológicos de calidad para el análisis de las emociones no es una tarea sencilla, ya que, aunque se utilicen señales fisiológicas controladas por el sistema nervioso autónomo consideradas no manipulables por el individuo, van a existir ciertos factores que influyen de forma considerable.

Según Picard et al., la configuración óptima para la recopilación de datos mediante la inducción de emociones sería un supuesto donde la emoción ha sido provocada únicamente por el estímulo, el individuo se encuentra en un espacio habitual y cotidiano, la emoción es sentida de forma interna, el comportamiento del sujeto no es alterado por el hecho de estar en un ambiente experimental, y este no tiene conocimiento de la intencionalidad del estudio de reconocer sus emociones (Picard, 2001). Sin embargo, esta situación experimental se considera casi imposible de conseguir por motivos de privacidad y ética. Aun así, los avances en dispositivos *wearables* o la labor de los investigadores por crear situaciones lo más naturales posibles pueden ayudar a que el individuo se sienta y actúe de forma natural (Picard, 2001).

1.2.3.1. Métodos de inducción de emociones

Los métodos de inducción de emociones son los procedimientos utilizados para provocar estados afectivos específicos en los individuos. En los estudios de reconocimiento de emociones se han empleado técnicas de diversos tipos en función del objetivo y del contexto del experimento. Cada método presenta ventajas y limitaciones que se deben valorar teniendo presente factores como la naturaleza de la emoción estudiada, la duración del estado emocional inducido en el sujeto o la capacidad de controlar variables externas (McGinley & Friedman, 2017).

La imaginación es uno de los mecanismos a los que muchos estudios han recurrido para tratar de evocar emociones en los participantes (Chanel et al., 2009; J. Kim & André, 2008). Esta técnica basada en la experiencia personal de cada individuo permite inducir emociones profundas mediante la ayuda de profesionales que sepan guiar y adaptar los escenarios imaginativos de cada sujeto. El principal problema introducido por el uso de la imaginación como método de inducción de estados afectivos es la gran variabilidad entre personas para imaginar y sentir con intensidad las emociones ideadas. Esto lleva a una dificultad mayor para verificar si los participantes están experimentando una emoción concreta, en comparación con otros métodos que utilicen herramientas estandarizadas (Chanel et al., 2009).

La gran mayoría de estudios actuales utilizan estímulos visuales para inducir las emociones deseadas en los sujetos (Ali et al., 2018; Canento et al., 2011; Li & Chen, 2006; Mirmohamadsadeghi et al., 2017; Valenza et al., 2012). Entre ellos, los más destacados son los vídeos, ya que se ha demostrado que tienen la capacidad de desencadenar emociones intensas; disponen de una elevada estandarización y homogeneidad, al poder regular la visualización y los estímulos inducidos; y el tiempo de reproducción es fácilmente controlable, por lo que se pueden adaptar a los requisitos del estudio y de los participantes (Canento et al., 2011).

En el contexto científico también existen investigaciones que emplean sonidos para evocar emociones en los participantes (Eerola & Vuoskoski, 2010). Así, algunos estudios se han encargado de analizar el uso de estos sonidos y la relación con las señales fisiológicas que desencadenan. Estímulos auditivos positivos o música de carácter animado generan ciertas emociones positivas que activan zonas del cerebro como la ínsula anterior o la corteza orbitofrontal, mientras que los estímulos auditivos negativos o la música triste activan áreas cerebrales involucradas en estados afectivos negativos vinculados con la ansiedad, como la amígdala, el hipocampo o las zonas del lóbulo temporal medial (Greco et al., 2017). El sonido se considera un buen método para inducir emociones en las personas, ya que se ha demostrado que determina en gran medida los sentimientos y las reacciones frente a diversas situaciones (Vitale et al., 2020). Asimismo, se ha evidenciado que alteraciones en la frecuencia, intensidad o tono de los sonidos generan cambios de valencia y excitación en los individuos (Vitale et al., 2020).

Por lo que respecta a este trabajo, se emplearon estímulos auditivos para la inducción de las emociones. Así, aunque no son muchos los estudios que utilizan este tipo de estímulos, se ha demostrado que los sonidos tienen una elevada influencia en el reconocimiento de emociones entre personas (Choi et al., 2015). Los humanos tienen la capacidad de reconocer emociones como la felicidad, la tristeza o el miedo incluso cuando escuchan a otros sujetos

que no hablan su mismo idioma; o también tienen la habilidad de reconocer el estado afectivo únicamente por el tono. En esta línea, es necesario diferenciar entre los sonidos verbales y los sonidos no verbales: los primeros hacen referencia a los sonidos que contienen contenido lingüístico, formando palabras u oraciones; mientras que los segundos abarcan diferentes tipos de sonidos naturales, artificiales, humanos no verbales (risas, llantos, gritos, etc) o instrumentales (Choi et al., 2015). Estudios, como el llevado a cabo por Paquette et al., han sugerido que los sonidos no verbales son un medio de comunicación natural que se ve menos influenciado por la cultura y que ayudan a desencadenar respuestas emocionales más intensas (Paquette et al., 2013).

En cuanto a la cantidad de estímulos empleados, aunque en el estado del arte se hayan utilizado mayoritariamente métodos unimodales para la inducción de emociones en los que se emplea un único estímulo, la utilización de un sistema multimodal permite reducir sesgos, al inducir una estimulación emocional más intensa en los sujetos; simular una experiencia más cercana a la realidad, en la que todos los sentidos reciben información del entorno; y capturar una mayor variedad en los datos, que conduce a análisis más precisos (Verma & Tiwary, 2014). Sin embargo, cuando se trabaja con métodos de inducción multimodales en los que la información se recoge por separado, surge el problema de procesar los datos de forma independiente y unirlos solo al final. A su vez, esto genera problemas de desincronización temporal y de integración de los datos, ya que puede haber desfases temporales que dificulten la correlación o disponer de datos con diferentes escalas o frecuencias (Verma & Tiwary, 2014).

1.2.3.2. Bases de datos para la inducción de emociones

El estado del arte revela una gran variedad de métodos de inducción de emociones utilizados por diversos estudios. Se ha demostrado que cada uno de estos métodos tiene resultados variables en términos de efectividad para inducir emociones y pueden llevar a diferentes expresiones por parte del sistema nervioso autónomo (McGinley & Friedman, 2017). Esta gran variabilidad entre métodos introduce una varianza adicional en los resultados de los estudios que puede limitar la generalización de los mismos y la comparación con otras investigaciones (McGinley & Friedman, 2017). Por ello, se considera fundamental escoger métodos fiables que se ajusten a los estados afectivos que se pretendan inducir en los sujetos del estudio.

De esta forma, las investigaciones se pueden decantar por utilizar estímulos escogidos por los propios investigadores para promover una mayor personalización del experimento o para explorar fenómenos que no están bien representados en sistemas estandarizados; sin embargo, la mayoría de los estudios recurren a bases de datos para evocar las emociones en sus participantes (Mirmohamadsadeghi et al., 2017; Valenza et al., 2012; Verma & Tiwary, 2014; Zhang et al., 2017). Esta elección se debe a diferentes causas: las bases de datos proporcionan estímulos que han sido validados previamente, demostrando que estos producen las emociones indicadas en una muestra representativa; suelen incluir una amplia variedad de estímulos que sirvan para inducir diferentes estados emocionales; supone un ahorro de tiempo y de recursos para la investigación; y permite una fácil replicación por parte de otros investigadores (Jang et al., 2015).

En la Tabla 1 se presentan algunas de las bases de datos más empleadas por los estudios de reconocimiento de emociones para la inducción de estados afectivos en los participantes.

En ella, se menciona el nombre de la base de datos, el tipo de estímulo que se utiliza, los autores que la crearon, el número de elementos con estímulos asociados, la duración de cada uno de estos elementos, la clasificación realizada de cada uno de ellos y algunos estudios que las utilizaron; donde los elementos pueden ser videos, imágenes, sonidos o palabras. Concretamente, cuando se recoge la duración de los estímulos en la Tabla 1, las casillas que contienen un guion hacen referencia a que no hay un tiempo de estímulos determinado, ya que las imágenes y las palabras son medios que no evolucionan en el tiempo y no se ven acotados por este, como sí ocurre con los vídeos y los sonidos.

Debido a la relevancia de los estímulos auditivos para la realización de este trabajo, se llevará a cabo una explicación de una de las bases de datos de sonidos estandarizadas más importantes.

Los Sonidos Digitalizados Afectivos Internacionales (IADS, por sus siglas en inglés *International Affective Digitized Sounds*) constituyen una base de datos compuesta por una serie de sonidos diseñados para evaluar las respuestas emocionales de las personas. Esta surgió como solución a otras bases de datos que venían limitadas por el reducido número y tipos de estímulos empleados (Yang et al., 2018). La última versión, denominada IADS-E, incorpora 935 sonidos afectivos divididos en diez categorías: animales, personas, naturaleza, sonidos de la rutina diaria, transporte, sonidos eléctricos, efectos de sonido, sonidos de ruptura, música y escenarios (Yang et al., 2018). Esta versión expandida del IADS, que en su versión anterior disponía de 167 sonidos, surge para solucionar el problema del limitado número de estímulos auditivos disponibles, un desafío que persistía incluso después de la creación de esta base de datos destinada a superar esa deficiencia.

La calificación emocional de los estímulos se realizó con una escala SAM de cinco figuras (maniquís) con un espacio entre cada dos imágenes, de tal forma que se entregaba a los participantes un cuestionario con 9 puntuaciones posibles para cada una de las dimensiones de valencia, excitación y dominancia. Esta escala se proporcionó a 207 sujetos después de escuchar cada sonido, junto con otras que calificaban emociones básicas, para obtener una puntuación en la escala SAM para cada uno de los estímulos (Yang et al., 2018).

Sin embargo, IADS-E sigue presentando limitaciones que deben ser solventadas (Yang et al., 2018). A pesar de aumentar el número de estímulos auditivos, la base de datos no consiguió equilibrar de forma uniforme el número de estímulos entre las combinaciones de los niveles de excitación y valencia, lo que permitiría obtener resultados más generalizables y representativos. Además, existen sonidos con grandes diferencias de género y los resultados se obtuvieron para universitarios japoneses, por lo que cabe la posibilidad de que existan diferencias al aplicarse en otro rango de edad o en una población distinta.

Tabla 1. Bases de datos más utilizadas para diferentes tipos de estímulos.

Nombre base de datos	Tipo de estímulo	Autores	Número de estímulos	Duración de estímulos	Clasificación estímulos	Estudios	Referencia
FilmStim	Videos	Schaefer et al.	70 extractos de películas	1 - 7 mins	Valencia - excitación	(Dumoulin et al., 2015; Pham & Tran, 2012)	(Schaefer et al., 2010)
IAPS*	Imágenes	Peter Lang et al.	1182 imágenes	-	Valencia - excitación	(Flynn et al., 2020; Valenza et al., 2012)	(M. M. Bradley & Lang, 2017)
IADS-E*	Sonidos	David Bradley y Peter Lang	935 sonidos	6 seg	Valencia - excitación - dominancia	(Liu & Sourina, 2013; Qi et al., 2021)	(Yang et al., 2018)
ANEW*	Texto	Margaret Bradley y Peter Lang	1034 palabras	-	Valencia - excitación - dominancia	(De Choudhury et al., 2013; Jaidka et al., 2018)	(M. Bradley & Lang, 1999)

* *International Affective Picture System (IAPS)*

* *International Affective Digitized Sounds Expanded (IADS-E)*

* *Affective Norms for English Words (ANEW)*

1.2.4. Reconocimiento de emociones en señales fisiológicas

El reconocimiento de emociones basado en señales fisiológicas es uno de los métodos más empleados por las investigaciones recientes (Egger et al., 2019; Shu et al., 2018). El primer paso para llegar a la identificación de dichos estados afectivos consiste en la recopilación de datos de los individuos mediante sensores de calidad. Posteriormente, se suele realizar un procesado digital de los datos que ayude a reducir el ruido, corregir los errores y suavizar la señal. Una vez realizados estos procedimientos, se aplican los sistemas de reconocimiento de emociones propiamente dichos, que, en la gran mayoría dentro de este ámbito, consisten en algoritmos categorizados en dos grandes grupos: el aprendizaje automático tradicional (conocido en inglés como *machine learning*) y el aprendizaje profundo (también conocido como *deep learning*). Este proceso genérico seguido por las investigaciones de reconocimiento de emociones se encuentra esquematizado en la Ilustración 9.

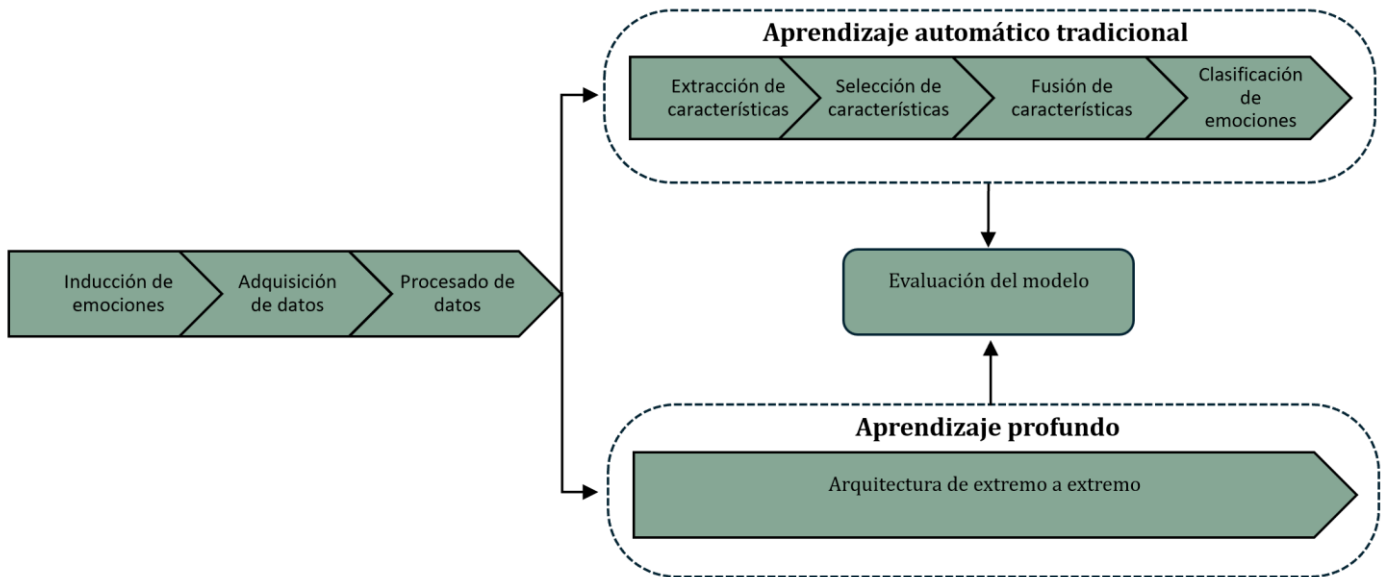


Ilustración 9. Proceso para el reconocimiento de emociones utilizando modelos de aprendizaje automático para señales fisiológicas. Adaptada de (Shu et al., 2018).

El aprendizaje automático es un campo de la inteligencia artificial enfocado en el desarrollo de técnicas y algoritmos que doten a los sistemas de la capacidad de aprender y mejorar sus predicciones partiendo de la experiencia (Wang et al., 2022). Funciona identificando patrones en grandes conjuntos de datos y aplicando esos patrones aprendidos a nuevos conjuntos. Los modelos tradicionales precisan de la extracción de características de las señales fisiológicas para obtener valores discretos que representen la complejidad y los patrones relevantes del conjunto de la señal (Wang et al., 2022). Posteriormente, se puede llevar a cabo una selección de características, considerada un paso importante en muchas ocasiones por paliar problemas como la introducción de ruido por la redundancia entre características (Campbell et al., 2019). Seguidamente, en caso de precisar modelos entrenados con las características de diferentes señales, se realizaría la fusión de estas en un único conjunto de datos que debe ser consistente y sincronizado. Por último, se procedería al entrenamiento del modelo y obtención de las métricas correspondientes.

Los algoritmos de aprendizaje automático se pueden dividir en tres grandes grupos (IBM):

- Aprendizaje supervisado: se basa en el uso de un conjunto de datos etiquetados para el entrenamiento de los algoritmos. Así, las características de entrada del modelo para cada muestra están asociadas a la respuesta correcta que se debería proporcionar. El objetivo principal es aprender una función que sea capaz de relacionar las características de datos no etiquetados con la salida correcta con la máxima precisión.
- Aprendizaje no supervisado: se fundamenta en el análisis de conjuntos de datos no etiquetados mediante algoritmos de aprendizaje automático. Estos modelos analizan los datos en busca de patrones ocultos, estructuras o agrupaciones con el objetivo de encontrar relaciones y clasificaciones entre ellos que puedan facilitar tareas de análisis.
- Aprendizaje semisupervisado: se sitúa entre el aprendizaje supervisado y el no supervisado, haciendo uso tanto de datos etiquetados como de no etiquetados para obtener mayores precisiones. El entrenamiento de los modelos emplea datos

etiquetados para realizar una clasificación inicial, que después será refinada mediante el uso de los datos no etiquetados. Esta técnica suele utilizarse cuando el volumen de datos etiquetados no es suficiente para realizar el entrenamiento.

Las investigaciones sobre reconocimiento de emociones más recientes utilizan modelos de aprendizaje automático supervisados como Máquinas de Vectores de Soporte (SVM, por sus siglas en inglés *Support Vector Machines*), K-Vecinos más cercanos (KNN, que corresponde a las siglas en inglés de *K-Nearest Neighbors*), bosques aleatorios (RF, que se traduce del inglés como *Random Forest*) o Análisis Discriminante Cuadrático; y modelos no supervisados como la Proyección Discriminante Lineal de Fisher o el Análisis Canónico de Correlación (Egger et al., 2019; Shu et al., 2018). En cambio, los modelos de aprendizaje semisupervisado no suelen emplearse en este ámbito.

Por otra parte, el aprendizaje profundo es una subrama del aprendizaje automático que se basa en el uso de redes neuronales artificiales con tres o más capas, llamadas capas ocultas. Cada una de estas capas detecta patrones específicos de los datos de salida de la capa anterior, de tal forma que las capas más profundas revelarán patrones más sutiles. En el entrenamiento, se presentan datos etiquetados para que la red neuronal ajuste los parámetros de cada una de las neuronas que se encuentran en cada capa. Así, a medida que se presentan más datos de entrenamiento, el algoritmo aprenderá a realizar predicciones más precisas sobre los nuevos datos de entrada que no han sido etiquetados. Suelen estar diseñadas con una arquitectura de extremo a extremo, por la que el modelo aprende a realizar una tarea sin la necesidad de llevar a cabo pasos intermedios. Estas herramientas están siendo utilizadas cada vez más en el ámbito de reconocimiento de emociones, encontrando estudios que emplean Redes Neuronales Convolucionales (Ali et al., 2018) o Redes Neuronales Recurrentes (Semerci et al., 2022), entre otras.

1.3. HIPÓTESIS Y OBJETIVOS

1.3.1. Hipótesis general

La hipótesis principal de este trabajo es que los estímulos emocionales positivos, negativos y eróticos, así como las percepciones de valencia, excitación y dominancia, generan diferentes respuestas fisiológicas, las cuales se reflejan en las señales de GSR y RSP.

1.3.2. Objetivos

Los objetivos de este trabajo son los siguientes:

- Validar los estímulos empleados mediante las puntuaciones de la escala SAM.
- Investigar las diferencias de la señal GSR y RSP ante distintos estímulos emocionales con estadística multivariante y clasificadores de aprendizaje automático.
- Analizar las diferencias de la señal GSR y RSP entre las distintas subescalas del SAM con estadística multivariante y clasificadores de aprendizaje automático.
- Investigar si la combinación de GSR y RSP consigue una mejor clasificación de emociones por los modelos de aprendizaje automático.

2. MATERIALES Y MÉTODOS

2.1. PARTICIPANTES DEL ESTUDIO

En el estudio participaron un total de 45 participantes cuyo rango de edades oscilaba entre los 19 y los 40 años, con una media y desviación estándar de $26,06 \pm 4,42$. La mayoría de los voluntarios fueron personas del Instituto Universitario de Investigación en Tecnología Centrada en el Ser Humano de la *Universitat Politècnica de València*, con una representación de mujeres del 42,22% frente al 57,78% de los hombres.

Los criterios de inclusión para los participantes del estudio fueron:

- Ser mayor de 18 años.
- No presentar o haber presentado enfermedades cardíacas o neurológicas conocidas.
- No presentar alteraciones en la capacidad auditiva.

2.2. INSTRUMENTACIÓN

Esta sección recoge la descripción de las herramientas empleadas para la realización del estudio. Cabe destacar que la recopilación de los datos se llevó a cabo por personal del centro de investigación.

2.2.1. Estímulos

La inducción de emociones decidió llevarse a cabo mediante estímulos sonoros no verbales.

Con el objetivo de maximizar las diferencias entre las emociones generadas en los participantes y, por tanto, las reacciones fisiológicas consecuentes, el personal decidió emplear un bloque de estímulos positivos y otro de estímulos negativos. Dichos estímulos se recopilaban de la base de datos IADS-E, en la que se buscaron diferentes sonidos que tuvieran una valencia alta y una excitación baja para incluirlos dentro del bloque de estímulos positivos, es decir, se incluyeron secuencias que generaban una sensación agradable y tranquila en el sujeto. Entre estos sonidos se encontraban melodías, agua fluyendo, el ruido de las teclas de una máquina de escribir, café cayendo a un vaso, lluvia, el sonido de unos tacones al pisar el suelo o el canto de pájaros. Por otra parte, se utilizaron sonidos caracterizados por una valencia baja y una excitación elevada, generando una sensación desagradable y agitada en el participante, y se incluyeron dentro del grupo de estímulos negativos. Algunos de los sonidos que se incluyeron fueron alarmas, gritos de personas, explosiones, perros enrabados ladrando, el ruido de una persona vomitando, pitidos de coche o bebés llorando. Para los dos bloques de estímulos se escogieron 30 sonidos con una duración de 6 segundos cada uno, por lo que se presentaban a los participantes como grupos de estímulos de 3 minutos de duración.

La elección realizada por el personal investigador de presentar los estímulos en bloques y no uno por uno se basó en dos premisas principales. La primera radica en que la evaluación de tantos sonidos mediante la escala SAM hubiera causado una fatiga elevada en los

participantes. La segunda considera que las características intrínsecas de las respuestas emocionales reflejadas en las señales de GSR y RSP hubieran condicionado el tiempo de presentación de los estímulos. A diferencia de otras técnicas como la electroencefalografía, estas señales no presentan cambios inmediatos tras la presentación de los estímulos. En lugar de eso, requieren un tiempo mayor para evidenciar de manera estable cambios significativos. La señal de RSP suele reflejar entre 9 y 24 ciclos por minuto (Mirmohamadsadeghi et al., 2017), mientras que la señal de GSR muestra variaciones muy lentas de la señal (SCL) (Kipli et al., 2022), por lo que haber presentado los estímulos en periodos cortos de tiempo no hubiera permitido ver reflejados los cambios en estas señales de forma precisa ni haber realizado un análisis adecuado de las señales.

De esta forma, se presentó a los participantes 3 bloques de estímulos positivos y 3 bloques de negativos, cada uno de los cuales tenía una secuencia diferente de los estímulos de 6 segundos escogidos. Al final del experimento, el participante debía valorar los bloques en una escala SAM de 9 puntos, para ratificar que los estímulos generados concordasen con los adjudicados por la base de datos IADS-E.

Además de los bloques de estímulos positivos y negativos, se incluyó un tercer bloque de estímulos eróticos. La razón de esta decisión radicó en la idea de que sonidos de este tipo inducirían respuestas emocionales muy intensas en los participantes, con las consecuentes alteraciones en las señales fisiológicas. La base de datos IADS-E dispone de estímulos eróticos categorizados dentro del bloque de positivos, pero la ausencia de convicción por parte del personal investigador sobre la posibilidad de que este tipo de estímulos fueran recibidos positivamente por los participantes les llevó a escoger fragmentos del sitio web www.bellesa.es con duraciones de 5 a 15 segundos. Análogamente a los otros estímulos, los sonidos eróticos se presentaron a los sujetos en 3 bloques de 3 minutos cada uno, obteniendo en total 9 grupos de estímulos. De la misma forma, al final del experimento los sujetos valoraron el grupo de estímulos eróticos con la escala SAM de 9 puntos. Esta valoración se consideraba necesaria para establecer las emociones experimentadas por los participantes, sobre todo en términos de valencia.

2.2.2. Registro

Para este proyecto el personal utilizó el dispositivo de registro NIRxWINGS de la empresa NIRx (NIRx Medical Technologies, Orlando, Estados Unidos). Este sistema está específicamente diseñado para la recopilación de señales fisiológicas periféricas como la variabilidad de la frecuencia cardíaca, la saturación de oxígeno, la temperatura, la oximetría de pulso, el electromiograma, la respiración o la GSR (NIRx, 2021).

Las características del NIRxWINGS se especifican de forma detallada en la Tabla 2.

Tabla 2. Características del sistema de registro NIRxWINGS (NIRx, 2021)

Amplificador	Resolución convertor A/D	24 bits, pudiendo diferenciar 2^{24} niveles distintos que aportan una precisión muy elevada para el registro de las señales analógicas. Este convertidor realiza un muestreo simultáneo de los diferentes canales de entrada, permitiendo una completa sincronización entre las distintas señales
--------------	--------------------------	--

	Frecuencia de muestreo	500 Hz para todos los canales
	Ancho de banda	rango de 0 a 131 Hz, en el que el dispositivo capta y procesa datos de forma óptima. El fabricante afirma que el dispositivo cuenta con un acoplamiento de continua verdadero, lo que significa que el amplificador no está eliminando ninguna parte de la señal y puede llevar a cabo un registro completo sin eliminar componentes de continua
	Ruido	menor de 1 μ V en términos de valor cuadrático medio, dentro del rango de frecuencias de 1 a 30 Hz
Físicas	Tamaño	101 mm x 96 mm x 30 mm (ancho x largo x alto)
	Peso	190 g, aproximadamente
Comunicación	Comunicación	Bluetooth
	Alcance inalámbrico	10 m
	Transmisión en tiempo real	Software <i>Lab Streaming Layer</i> para la transmisión de los datos de las diferentes entradas en tiempo real, con baja latencia y de forma sincronizada
	Formato de archivo exportado	CSV (texto)

Debido a que en el estudio se recopilaban las señales de GSR, RSP y ECG (aunque esta última no se llegó a emplear para este trabajo), únicamente se usaron los sensores correspondientes a estas tres señales. En la Ilustración 10 se observa el dispositivo NIRxWINGS con diferentes números que marcan las conexiones de los distintos sensores. Solo se utilizaron 2, 3 y 4, donde se conecta RSP, GSR y ECG, respectivamente; la conexión de tierra (8); y la del dongle Bluetooth (9). La conexión de tierra es necesaria para las tres señales, por lo que el personal investigador colocó el sensor en el cuerpo del participante lo más lejos posible de los otros sensores (NIRx, 2021).

Los sensores utilizados para la señal de RSP radican en dos paletas basadas en sensores de bioimpedancia que utilizan electrodos desechables *SkinTact*, permitiendo que el participante pueda llevar a cabo movimientos con naturalidad en caso de ser necesario. Estas paletas deben colocarse justo debajo de la clavícula en ambos pectorales del participante (NIRx, 2021).

La señal GSR se capta mediante dos electrodos *SkinTact* que se sitúan en la palma de la mano del participante: uno se colocará en la zona de la palma situada debajo del dedo índice y otro en la zona palmar opuesta al inicio del dedo pulgar (NIRx, 2021).



Ilustración 10. Dispositivo NIRxWINGS. Para este estudio solo aplican 2, 3, 8 y 9. Recogida de (NIRx, 2021)

2.2.3. Hardware y software

A lo largo de esta subsección se describirán las diferentes características del *hardware* y *software* empleado para la presentación de los estímulos.

Por lo que respecta al *hardware*, los sonidos se presentaron a los participantes mediante unos cascos JBL Tune 510BT (JBL, Northridge, Estados Unidos). Estos disponen de una autonomía y ligereza elevada que facilita ser utilizados de forma cómoda por los sujetos durante el periodo de tiempo que dura el estudio. Asimismo, la conexión Bluetooth permite liberar de cables el dispositivo y garantizar un mayor bienestar en los participantes.

Los auriculares presentan las especificaciones técnicas mostradas en la Tabla 3 (Harman International Industries).

Tabla 3. Especificaciones técnicas de los auriculares JBL Tune 510BT (Harman International Industries)

Peso	160g
Tiempo de reproducción con Bluetooth	hasta 40 horas
Respuesta de frecuencia	20 Hz – 20 kHz (rango de audición humana)
Resistencia a la corriente de audio	30 Ω
Sensibilidad	103,5 dB de nivel de presión sonora a 1 kHz/1mV Nota: conversión de señal eléctrica en sonido
Nivel de presión sonora máxima	95 dB Nota: por encima de este nivel el sonido puede comenzar a distorsionarse
Versión Bluetooth	5.0
Rango de frecuencias del transmisor Bluetooth	2,4 GHz – 2,4835 GHz
Potencia del transmisor Bluetooth	<8 dBm

En cuanto al *software*, se utilizó E-prime 3.0, una herramienta para la presentación de estímulos y el registro de respuestas que permite a los investigadores crear experimentos con videos, imágenes, sonidos y texto (Psychology Software Tools). El fabricante afirma que el *software* dispone de una precisión de sincronización de milisegundos y aporta diferentes herramientas para ratificar que el *hardware* que se está utilizando para el estudio tiene la capacidad de cumplir con las especificaciones.

El *software* utilizado para el análisis de los datos obtenidos de los 45 sujetos fue Python 3.11, en el entorno de desarrollo integrado Spyder. Las librerías empleadas para el análisis y visualización de los datos incluyen:

- Matplotlib: para la creación de gráficos y visualizaciones.
- Pandas: para la manipulación y el análisis de datos.
- Os: para interactuar con el sistema operativo.
- NumPy: para operaciones matemáticas y manejo de *arrays*.
- SciPy: para pruebas estadísticas e interpolación.
- Seaborn: para la visualización de datos estadísticos.
- NeuroKit2: para el procesamiento de las señales fisiológicas.
- PyWavelets: para el análisis de GSR mediante transformada *wavelet*.
- Statsmodels: para las correcciones de pruebas estadísticas.
- Scikit-learn: para el modelado y evaluación de algoritmos de aprendizaje automático.

Este entorno de programación, junto con las herramientas empleadas, facilitó un análisis preciso y completo de los datos obtenidos, permitiendo la aplicación de distintas técnicas de procesamiento de la señal, modelado y visualización.

2.3. PROCEDIMIENTO

Asegurar la mayor aproximación a la configuración experimental expuesta por Picard y mencionada en el apartado 1.2.3 *Inducción de emociones*, por la que se aseguran las condiciones de laboratorio óptimas para la obtención de datos durante la inducción de emociones, llevó al personal investigador a realizar el estudio en una sala con luz y ruidos controlados instruyendo a los sujetos a cerrar los ojos durante el tiempo que duraba el experimento, con el objetivo de propiciar niveles mayores de concentración.

El estudio tiene una duración aproximada de 1 hora por cada sujeto y se encuentra dividido en las siguientes cinco fases, que se pueden observar de una forma más gráfica y directa en la Ilustración 11.

1. Firma de consentimiento y explicación de experimento: antes de comenzar el experimento, los participantes fueron informados sobre las bases del mismo. Así, se les comunicó la metodología que se iba a seguir, haciéndoles saber que se utilizarían sensores que no ponían en riesgo su salud y que tendrían que rellenar el cuestionario SAM. Por otra parte, se firmó un consentimiento informado en el que se hizo saber al participante que sus datos iban a ser anonimizados y que la investigación seguía los criterios éticos recogidos en la Declaración de Helsinki. La duración aproximada fue de 5 minutos.

2. Colocación del dispositivo de registro: se ubicaron todos los sensores sobre el individuo de la forma detallada en el apartado 2.2.2 Registro y se comprobó tanto el correcto registro de las señales, como la sincronización del sistema de monitoreo con el *software* de presentación de estímulos E-prime. Además, se colocaron los auriculares en el sujeto. Esta fase duró alrededor de 10 minutos.
3. Fase de relajación: una vez comprobado que todo funcionaba correctamente el experimento comenzaba, iniciando con un periodo de estabilización emocional de 2 minutos en el que el participante debía estar con los ojos cerrados, sin recibir ningún tipo de estimulación y evitando pensar en nada concreto.
4. Fase de estimulación emocional pasiva: esta fase consistía en el paradigma de estimulación emocional, en el que el sujeto debía prestar atención a los audios presentados por los auriculares y mantener los ojos cerrados. Se escucharon los 9 bloques auditivos, cada uno de ellos con una duración de 3 minutos, intercalados con bloques de descanso de 1 minuto que servían para estabilizar el estado generado por el estímulo anterior. El orden en el que aparecen los bloques de estímulos era aleatorio para cada uno de los participantes, de tal forma que se evitaba el condicionamiento por el orden de visualización. La fase tuvo una duración total de 36 minutos.
5. Fase de evaluación: el participante evaluó mediante la escala SAM de 9 puntos los tres tipos de bloques escuchados, requiriendo unos 2 minutos, aproximadamente.

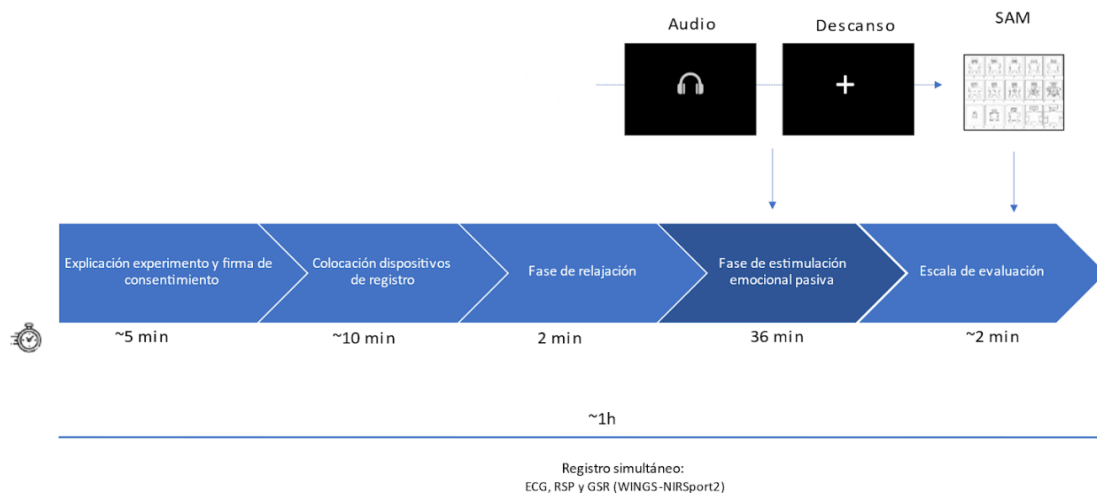


Ilustración 11. Esquema del protocolo experimental.

2.4. ANÁLISIS DE DATOS

Esta sección describe el procesamiento de las señales de GSR y RSP, la extracción de características de las mismas, el análisis estadístico utilizado para el análisis de las características y los métodos de aprendizaje automático empleados para la clasificación de los estados emocionales.

2.4.1. Procesado de señal y extracción de características

El análisis de las señales de GSR y RSP siguió el esquema mostrado en la Ilustración 12. Primero se obtuvieron las señales crudas y se realizó el preprocesamiento, que incluyó un remuestreo, filtrado, segmentación y eliminación de artefactos. Una vez limpiados los

segmentos de señal, se procedió a realizar el eventanado para extraer las características correspondientes a cada señal en cada ventana. Finalmente, se normalizaron las características extraídas.




Ilustración 12. Esquema del análisis seguido para las señales de GSR y RSP.

2.4.1.1. Respuesta galvánica de la piel

a) Preprocesado

El análisis de la señal GSR obtenida de cada uno de los participantes del estudio inició con el remuestreo de la señal de 500 Hz a 250 Hz, pues estudios análogos que han empleado la señal de GSR para el reconocimiento de emociones han utilizado esta frecuencia de muestreo para el análisis de sus datos (Ali et al., 2018; Jang et al., 2015; Valenza et al., 2012; Verma & Tiwary, 2014). Asimismo, se aplicó un filtro paso bajo con una frecuencia de corte de 5 Hz, porque la señal está relacionada con cambios fisiológicos lentos (Kipli et al., 2022), de tipo Butterworth de 4º orden, para conseguir una respuesta en frecuencia lo más plana posible en la banda de paso que asegure la atenuación uniforme. De la misma forma que el remuestreo, esta elección vino determinada por la existencia de investigaciones similares que aplicaban filtros análogos (Canento et al., 2011; Haag et al., 2004; Pinto et al., 2019; Zhang et al., 2016).

Posteriormente, se separaron las señales de cada sujeto en segmentos correspondientes a cada estímulo (180 segundos) y descanso (60 segundos).

Una vez segmentada la señal, se realizó una inspección visual de los segmentos de cada sujeto para comprobar la calidad de la señal y la posible existencia de artefactos. La GSR es muy propensa a la pérdida de señal debido a movimientos de la mano del paciente o sudor excesivo que provocan un mal contacto con la piel y la pérdida de señal. En la Ilustración 13A se muestra una de las señales que tuvo que ser eliminada por pérdida de datos, en la que la mitad del tiempo que duraba la presentación del bloque de estímulos negativos no se muestra registro de actividad GSR. Por otra parte, en la Ilustración 13B se observa el ruido que se mantuvo en la señal tras la aplicación del filtro.




Ilustración 13. Distorsiones de la señal GSR. A) Señal con pérdida de datos. B) Señal con ruido

La inspección manual de las señales también ayudó al reconocimiento de diferentes artefactos en los segmentos de señal. Para solucionarlos, se identificaron los intervalos de tiempo de la señal en los que sucedía el artefacto, se eliminaron y se decidió aplicar una interpolación cúbica, ya que se observó que seguía de forma adecuada la forma de onda de GSR. En la Ilustración 14A se observa un artefacto de movimiento en el intervalo de 555 – 560 segundos, uno de los artefactos más comunes encontrados a lo largo de este estudio; mientras que en la Ilustración 14B se visualiza cómo este artefacto queda eliminado aplicando la interpolación cúbica.




Ilustración 14. Procesado de artefactos. A) Artefacto de movimiento. B) Artefacto de movimiento interpolado

b) Extracción de características

El procesamiento de la señal vino seguido de la extracción de características. En primer lugar, se cortaron los segmentos en ventanas de diferente duración: ventanas de 15 segundos sin solapar, obteniendo 12 intervalos por estímulo; ventanas de 60 segundos sin solapar, con 3 intervalos por estímulo; y ventanas de 60 segundos con un solapamiento del 50%, logrando 5 ventanas por estímulo.

De esta forma, para cada una de las ventanas temporales se obtuvieron las características presentadas en la Tabla 4, que se escogieron teniendo en cuenta las características más empleadas para la señal de GSR en investigaciones análogas, presentadas en la sección 1.2.1.2 Nivel endosomático. En esta misma sección, se explica la Transformada Wavelet Discreta, que fue la empleada en este estudio para el análisis tiempo-frecuencia, utilizando una *wavelet* de Daubechies de 4^º orden. Se empleó esta *wavelet* por su uso en la extracción de características de otras señales fisiológicas, como ECG (A.Mohamed & A. Deriche, 2014; J. Villanueva J, 2005). En la Tabla 4, x_i representa cada muestra de la señal, t_i el tiempo asociado a la muestra x_i , N el número total de muestras del intervalo, μ_{SCL} la media de las ocurrencias SCL en el intervalo N , $coefs$ la concatenación de los coeficientes de detalle de la transformada wavelet asociados a los diferentes niveles de detalle, N_{coefs} el número de coeficientes de detalle concatenados y μ_{coefs} la media de los coeficientes de detalle concatenados. La omisión de los coeficientes de aproximación se basa en la eliminación del ruido de baja frecuencia en el análisis y en la focalización en las ocurrencias SCR, que tienen una elevada relevancia en el análisis frecuencial (Blanco-Almazan et al., 2019). Por otra parte, la adquisición de las características relacionada con los eventos SCR y SCL se realizó con la ayuda de la biblioteca Neurokit2.

Tabla 4. Características extraídas de la señal GSR.

Dominio	Características	Fórmula
Tiempo	Media (μ)	$\frac{1}{N} \sum_{i=1}^N x_i$
	Mediana	N impar: $\frac{N+1}{2}$; N par: $\frac{x_{\frac{N}{2}} + x_{\frac{N}{2}+1}}{2}$
	Desviación estándar (σ)	$\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}$
	Valor cuadrático medio (RMS)	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
	Curtosis	$\frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{(\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2)^2} - 3$
	Asimetría	$\frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^3}{(\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2)^{3/2}}$
	Máximo	$\max(x_i)$
	Mínimo	$\min(x_i)$
	Media 1ª derivada	$\frac{1}{N-1} \sum_{i=1}^{N-1} \left \frac{x_{i+1} - x_i}{t_{i+1} - t_i} \right $
	Media 2ª derivada	$\frac{1}{N-2} \sum_{i=1}^{N-2} \left \frac{x_{i+2} - 2x_{i+1} + x_i}{(t_{i+2} - t_{i+1})(t_{i+1} - t_i)} \right $
	Media de las diferencias absolutas (Δx)	$\frac{1}{N-1} \sum_{i=1}^{N-1} x_{i+1} - x_i $
	Media de las diferencias absolutas normalizada	$\frac{\Delta x}{\sigma}$
	Media de las variaciones locales (δx)	$\frac{1}{N-2} \sum_{i=2}^{N-1} x_{i+1} - 2x_i + x_{i-1} $
	Media de las variaciones locales normalizada	$\frac{\delta x}{\sigma}$
	Número picos SCR	N_{SCR}
	Amplitud media picos SCR	$\frac{1}{N_{SCR}} \sum_{i=1}^{N_{SCR}} Amplitud_i$

	Desviación estándar de la amplitud SCL	$\sqrt{\frac{1}{N} \sum_{i=1}^N (Amplitud_i - \mu_{SCL})^2}$
Tiempo - frecuencia	Área de la magnitud	$\sum_{i=1}^{N_{coefs}} coefs_i ^2$
	Frecuencia máxima	$\max (coefs_{\text{último nivel detalle}})$
	Varianza	$\frac{1}{N_{coefs}} \sum_{i=1}^{N_{coefs}} (coefs_i - \mu_{coefs})^2$
	Curtosis	$\frac{\frac{1}{N_{coefs}} \sum_{i=1}^{N_{coefs}} (coefs_i - \mu_{coefs})^4}{\left(\frac{1}{N_{coefs}} \sum_{i=1}^{N_{coefs}} (coefs_i - \mu_{coefs})^2\right)^2} - 3$
	Asimetría	$\frac{\frac{1}{N_{coefs}} \sum_{i=1}^{N_{coefs}} (coefs_i - \mu_{coefs})^3}{\left(\frac{1}{N_{coefs}} \sum_{i=1}^{N_{coefs}} (coefs_i - \mu_{coefs})^2\right)^{3/2}}$

c) Normalización de las características

Diversos estudios han demostrado la variabilidad existente entre las respuestas fisiológicas de diferentes sujetos cuando experimentan situaciones con carga afectiva (Lima et al., 2024; Pinto et al., 2019; Takahashi et al., 2012). Para paliar el problema se suelen aplicar métodos de normalización de características que reduzcan las diferencias interpersonales. En este estudio se probaron dos métodos de normalización: la normalización de cada característica con respecto a la media y la desviación estándar de cada sujeto (llamada normalización 01) y la desviación absoluta mediana (MAD).

La normalización 01 se aplicó en algunos estudios de reconocimiento de emociones siguiendo la Ecuación (1), en la que X_i representa cada una de las características para las i ventanas de los estímulos de un sujeto, X_{norm_01} la característica normalizada, \bar{X}_{sujeto} la media de todas las características X_i de cada sujeto y σ_{sujeto} la desviación estándar asociada a esa media (Lima et al., 2024). De esta forma, se consigue normalizar la variabilidad de las características debida a las diferencias entre sujetos.

$$X_{norm_01} = \frac{X_i - \bar{X}_{sujeto}}{\sigma_{sujeto}} \quad (1)$$

Por otra parte, la normalización MAD se ha aplicado también por algunos investigadores con el objetivo de normalizar la variabilidad de una característica con respecto al nivel basal que presentaba el sujeto antes de la presentación del estímulo (Nardelli et al., 2015). Este método se aplica como se muestra en la Ecuación (2), donde X_{norm_MAD} es la característica normalizada, $X_{i_estímulo}$ el valor de la característica para una ventana i de un estímulo concreto y $X_{descanso}$ la característica del descanso anterior al estímulo. Debido a que hubieron descansos que tuvieron que ser eliminados por distorsiones en la señal, si el descanso anterior al estímulo se encontraba faltante se utilizaba la característica del

descanso anterior a este y, en caso de este tampoco estar disponible, se empleaba la característica del descanso posterior.

$$X_{norm_MAD} = \frac{X_{i_estímulo} - X_{descanso}}{\text{mediana}|X_{i_estímulo} - \text{mediana}(X_{i_estímulo})|} \quad (2)$$

2.4.1.2. Señal de respiración

Debido a la similitud del método seguido para procesar la señal de RSP con el procesado de GSR, los pasos idénticos se mencionarán por encima haciendo hincapié en las particularidades.

a) Preprocesado

En primer lugar, se remuestreó de 500 Hz a 250 Hz, un paso comúnmente realizado en la bibliografía (Valenza et al., 2012; Verma & Tiwary, 2014). Seguidamente, se aplicó un filtro Butterworth de 2º orden, para conseguir una banda de paso lo más plana posible (Valenza et al., 2012), del tipo paso banda con frecuencias de corte entre 0,1 y 0,35 Hz, siendo habituales en estudios de este tipo (Shu et al., 2018). Esta banda de paso permite tener en cuenta frecuencias tan bajas como 6 respiraciones por minuto y tan altas como 21 respiraciones por minuto, por lo que se capta perfectamente el rango fisiológico de 12 a 20 respiraciones por minuto (University of Rochester).

Análogamente a GSR, se realizó la segmentación de la señal en estímulos y descansos y se llevó a cabo una inspección visual de cada uno de los segmentos extraídos. La señal de RSP no requirió de la eliminación de artefactos, pero algunos segmentos fueron descartados al presentar pérdidas de señal, como la que se puede observar en la Ilustración 15.

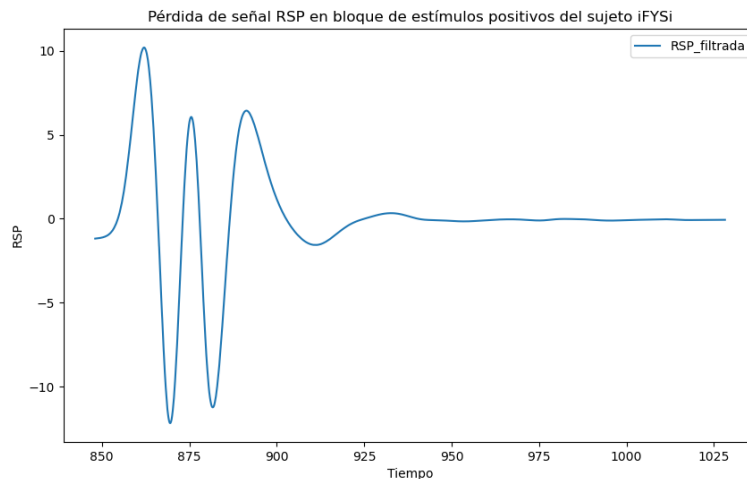


Ilustración 15. Pérdida de datos en la señal RSP.

b) Extracción de características

Una vez procesada y limpiada la señal, se procedió a la extracción de las características. Los segmentos de la señal de RSP se inventanaron de diferentes formas: ventanas de 60 segundos sin solapar, consiguiendo 3 intervalos por estímulo; y ventanas de 60 segundos solapadas un 50%, logrando 5 intervalos por estímulo. La obtención de características en ventanas de 15 segundos sin solapar no se pudo llevar a cabo, ya que la información de la

señal dentro de estos intervalos temporales tan cortos era demasiado escasa para calcular las características, por ser una señal con una dinámica de cambio lenta (Mirmohamadsadeghi et al., 2017).

De la misma manera que para la señal GSR, las características de RSP se basaron en las más utilizadas por los estudios de reconocimiento de emociones, recopiladas en la sección 1.2.1.2 Nivel endosomático. En la Tabla 5 se observan las características extraídas de la señal RSP con la ayuda de la librería Neurokit2. En ella, RSP_Rate representa la frecuencia respiratoria instantánea, N el número total de muestras de la ventana, BB el intervalo de respiración a respiración, $\mu_{\Delta BB}$ la media de las diferencias sucesivas entre BB , t_{fin} el tiempo de fin de la fase de inspiración/espriación, t_{ini} el tiempo de inicio de la fase de inspiración/espriación, N_{ciclos} el número de ciclos de la ventana, $Duración_{insp/esp}$ el periodo de tiempo que dura la inspiración/espriación, $N_{periodos}$ el número de periodos de la ventana, $Ancho_{pico/valle}$ el ancho desde la mitad de la subida/bajada de un ciclo hasta la siguiente mitad de la bajada/subida de ese mismo ciclo y $P(f)$ la densidad espectral de potencia.

Cabe destacar que para calcular la densidad espectral de potencia se utiliza el método de Welch, por el que cada una de las ventanas de señal se divide en diferentes segmentos calculados de la forma establecida en la Ecuación (3), donde L es la longitud de los segmentos en número de muestras, f_{min} la frecuencia mínima a resolver en el análisis y f_s la frecuencia de muestreo. De esta forma, se consigue capturar al menos dos ciclos de la frecuencia mínima y tener una buena representación de esta. Para determinar el valor de la frecuencia mínima que se utiliza en el análisis se emplea la Ecuación (4), en la que N es la longitud total del intervalo de la señal. Así, la multiplicación por 2 ayuda a obtener una resolución frecuencial adecuada que permita captar bajas frecuencias y $N/2$ normaliza en función de la longitud del intervalo.

$$L = 2 \cdot \frac{1}{f_{min}} \cdot f_s \quad (3)$$

$$\frac{2 \cdot f_s}{N/2} \quad (4)$$

Tras la división en segmentos, se aplica una ventana de Hanning para suavizar los bordes de la señal con el objetivo de, seguidamente, calcular una estimación del periodograma mediante la Transformada Rápida de Fourier de cada uno de esos segmentos. Por último, se calcula el promedio de las estimaciones para obtener la densidad espectral de potencia, que indicará la potencia presente en la señal para cada frecuencia (Alkan & Yilmaz, 2007).

Por otra parte, se considera importante realizar una breve explicación de la entropía aproximada por el grado de complejidad que presenta en comparación con métricas estadísticas más directas. Esta medida es un método de análisis no lineal que se encarga de evaluar el grado de irregularidad en secuencias temporales. Se basa en la idea de que al aumentar la dimensionalidad del espacio en el que se representa la señal, se puede predecir la probabilidad de que ocurra un nuevo estado en la secuencia de la señal, siendo este estado otra configuración diferente de la serie temporal inicial. Si la probabilidad es alta al pasar de

una dimensión m a otra dimensión $m+1$, la señal será más compleja y su entropía aproximada será mayor (Pan et al., 2020). Así, ϕ^m representa la función que calcula la regularidad en la dimensión m , mientras que ϕ^{m+1} es la función que la calcula en la dimensión $m+1$. r es un parámetro que determina la sensibilidad del método.

Tabla 5. Características extraídas de la señal RSP.

Dominio	Características	Fórmula
Tiempo	Media frecuencia instantánea (RSP_Rate_Mean)	$\frac{1}{N} \sum_{i=1}^N RSP_Rate_i$
	Raíz cuadrática media de las diferencias sucesivas de BB (RRV_RMSSD)	$\sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (BB_{i+1} - BB_i)^2}$
	Promedio de los intervalos de tiempo entre BB (RRV_Mean_BB)	$\sqrt{\frac{1}{N} \sum_{i=1}^N BB_i}$
	Desviación estándar de BB (RRV_SDBB)	$\sqrt{\frac{1}{N-1} \sum_{i=1}^N (BB_i - RRV_MeanBB)^2}$
	Desviación estándar de las diferencias sucesivas entre BB (RRV_SDSD)	$\sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} ((BB_{i+1} - BB_i) - \mu_{\Delta BB})^2}$
	Coefficiente de variación de BB (RRV_CVBB)	$\frac{RRV_SDBB}{RRV_MeanBB}$
	Coefficiente de variación de diferencias sucesivas entre BB (RRV_CVSD)	$\frac{RRV_SDSD}{\mu_{\Delta BB}}$
	Mediana de los intervalos de tiempo entre BB (RRV_MedianBB)	mediana(BB)
	MAD de BB (RRV_MadBB)	mediana BB _i - mediana(BB)
	Coefficiente de variación modificado de BB (RRV_MCVBB)	$\frac{RRV_MadBB}{RRV_MedianBB}$
	Índice de variabilidad a corto plazo (RRV_SD1)	$\sqrt{\frac{1}{2} RRV_SDSD^2}$
	Índice de variabilidad a largo plazo (RRV_SD2)	$\sqrt{2 \cdot RRV_SDBB^2 - \frac{1}{2} RRV_SDSD^2}$
	Relación variabilidad a corto y largo plazo (RRV_SD2SD1)	$\frac{RRV_SD2}{RRV_SD1}$
	Amplitud respiratoria media (RAV_Mean)	$\frac{1}{N} \sum_{i=1}^N Amplitud_i$

	Desviación estándar de la amplitud de la respiración (RAV_SD)	$\sqrt{\frac{1}{N-1} \sum_{i=1}^N (Amplitud_i - RAV_Mean)^2}$
	Raíz cuadrática media de las diferencias sucesivas de la amplitud respiratoria (RAV_RMSSD)	$\sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (Amplitud_{i+1} - Amplitud_i)^2}$
	Coefficiente de variación de diferencias sucesivas de la amplitud respiratoria (RAV_CVSD)	$\frac{RAV_SD}{RAV_Mean}$
	Simetría de ascenso/descenso (RSP_Symmetry_RiseDecay)	$\frac{1}{N_{ciclos}} \sum_i^{N_{ciclos}} \frac{Duración_{insp,i}}{Duración_{insp,i} + Duración_{esp,i}}$
	Simetría pico/valle (RSP_Symmetry_PeakTrough)	$\frac{1}{N_{periodos}} \sum_i^{N_{periodos}} \frac{Ancho_{pico,i}}{Ancho_{pico,i} + Ancho_{valle,i}}$
	Duración fase inspiración (RSP_Phase_Duration_Insp)	$\frac{1}{N_{insp} - 1} \sum_{i=1}^{N_{insp}} (t_{fin,i} - t_{ini,i})^2$
	Duración fase espiración (RSP_Phase_Duration_Exp)	$\frac{1}{N_{esp} - 1} \sum_{i=1}^{N_{esp}} (t_{fin,i} - t_{ini,i})^2$
	Ratio inspiración/espiración (RSP_Phase_Duration_Ratio)	$\frac{RSP_Phase_Duration_Insp}{RSP_Phase_Duration_Exp}$
Frecuencia	Densidad de potencia espectral banda de baja frecuencia [0,04 - 0,15 Hz] (RRV_LF)	$\int_{0,04}^{0,15} P(f)df$
	Densidad de potencia espectral banda de alta frecuencia [0,15 - 0,40 Hz] (RRV_HF)	$\int_{0,15}^{0,40} P(f)df$
	Ratio RRV_LF - RRV_HF (RRV_LFHF)	$\frac{RRV_LF}{RRV_HF}$
	Entropía aproximada (RRV_ApEn)	$\phi^m(r) - \phi^{m+1}(r)$

c) Normalización de las características

Por último, tras la extracción de las características se les aplicó la misma normalización que en GSR, mostradas en la Ecuación (1) y Ecuación (2).

2.4.2. Análisis estadístico

El análisis estadístico se centró en determinar qué características mostraban diferencias significativas para cada una de las señales de GSR y RSP y para cada combinación de pares de estímulos. Además, también se evaluó esta diferencia entre las características asociadas a muestras de valencia alta con respecto a aquellas de valencia baja, y se realizó el mismo análisis para excitación y dominancia. En la Ilustración 16 se puede observar la distribución de puntuaciones de la escala SAM obtenidas para todos los sujetos. Se decidió que las muestras pertenecían a una dimensión alta si su estímulo asociado había sido evaluado por el sujeto con una puntuación mayor de 7 (color verde en Ilustración 16), mientras que las muestras cuyos estímulos correspondientes fueron puntuados con un número menor de 3 se consideraron pertenecientes a una dimensión baja (color amarillo en Ilustración 16).

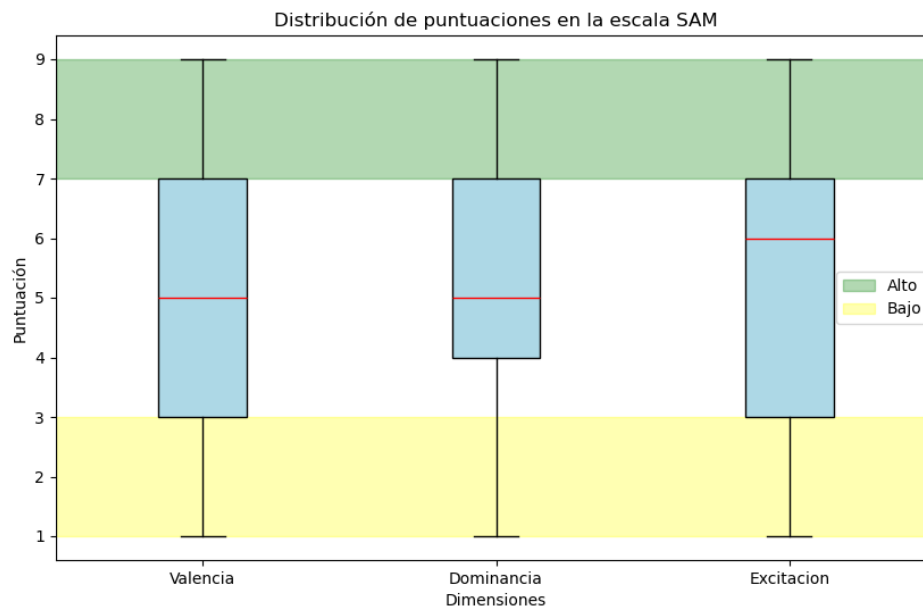


Ilustración 16. Distribución de puntuaciones en la escala SAM y división entre valores altos y bajos de cada dimensión.

De esta forma, los pares de grupos de datos para los que se aplicó el análisis estadístico explicado a continuación son: estímulos positivos VS estímulos negativos, estímulos positivos VS estímulos eróticos, estímulos negativos VS estímulos eróticos, valencia alta VS valencia baja, excitación alta VS excitación baja y dominancia alta VS dominancia baja.

El primer paso para el análisis estadístico consistió en la comprobación de la normalidad de las distribuciones de cada característica en cada grupo de datos. Para ello, se aplicó la prueba de Shapiro-Wilk en la que la hipótesis nula plantea que la distribución es normal y la hipótesis alternativa afirma que la distribución no es normal (Aleksander Dietrichson, 2019). Se escogió un nivel de significancia del 0,05 y se observó que, para todas las distribuciones de cada combinación de características y grupo de datos, el test proporcionaba un valor p que estaba por debajo del nivel de significancia. De esta forma, la hipótesis nula quedaba rechazada para todos los conjuntos de datos, evidenciando la no normalidad de cada una de las distribuciones.

Las pruebas estadísticas se pueden separar en paramétricas y no paramétricas (MJ Campbell, 2016). Las primeras asumen que los datos que se están manejando provienen de

una población que sigue una determinada distribución, generalmente, la distribución normal. De forma contraria, las pruebas no paramétricas no realizan suposiciones sobre la distribución de los datos en la población. Así, la comprobación de la no normalidad de las distribuciones llevó a escoger las pruebas no paramétricas para la comparación entre características de diferentes grupos. Para este caso, las variables de entrada eran el tipo de estímulo y el nivel de las dimensiones de la escala SAM, ya que fueron las que se seleccionaron para investigar su efecto sobre las señales fisiológicas; mientras que las variables de salida eran las características de las señales, por ser las que se miden para determinar su variación en función de los diferentes estímulos. Así, las variables de entrada eran de tipo categórico y las de salida se consideraron como cuantitativas no normales. Estos dos tipos de variables determinaron la prueba de Mann-Whitney como una de las mejores para la comparación entre los grupos. Esta prueba establece como hipótesis nula la inexistencia de diferencia y, como hipótesis alternativa, la existencia de diferencia entre las dos clases. El estadístico U de la prueba se calcula usando la Ecuación (5) para uno de los grupos comparados y la Ecuación (6) para el otro, donde n_1 y n_2 son los tamaños de las dos muestras y R_1 y R_2 la suma de los rangos que se establecen para cada una de las observaciones de los dos grupos. El estadístico U es el menor valor entre U_1 y U_2 , y se utiliza para calcular el valor p mediante tablas de distribución de Mann-Whitney, o mediante la aproximación a la distribución normal en muestras mayores a 20, como es este caso (DATAtab). Por tanto, la comparación del estadístico U con un nivel de significancia de 0,01 y 0,05 ayudó a establecer las diferencias entre características.

$$U_1 = n_1 \cdot n_2 + \frac{n_1(n_1 + 1)}{2} - R_1 \quad (5)$$

$$U_2 = n_1 \cdot n_2 + \frac{n_2(n_2 + 1)}{2} - R_2 \quad (6)$$

Las pruebas post hoc permiten analizar los datos experimentales después de realizar las pruebas estadísticas principales para analizar con más profundidad las diferencias entre los diferentes grupos (Statistics How To, 2020). Esta investigación se decantó por emplear la corrección de Bonferroni, utilizada en estudios que llevan a cabo una gran cantidad de pruebas estadísticas al mismo tiempo (Statistics How To, 2020). Este aspecto resulta importante para el análisis estadístico de las características entre grupos porque permite controlar el error de tipo I, cuya probabilidad de ocurrencia se ve aumentada por la comparación de múltiples características de las señales al mismo tiempo. En otras palabras, la probabilidad de afirmar que hay una diferencia entre los grupos, cuando realmente no la hay, aumenta a medida que se hacen más pruebas. La corrección de Bonferroni controla este error disminuyendo el nivel de significancia al dividirlo entre el número de pruebas simultáneas, como se establece en la Ecuación (7), donde α' es el nivel de significancia obtenido por la corrección, α el nivel de significancia inicial y m el número de hipótesis. De esta forma, el nivel de significancia para las pruebas de GSR quedó dividido entre 22 y para RSP entre 26, siendo estos valores el número de características para cada señal.

$$\alpha' = \frac{\alpha}{m} \quad (7)$$

2.4.3. Modelos de aprendizaje automático

El uso de clasificadores pretende el reconocimiento de los estados emocionales inducidos mediante métodos de aprendizaje automático, utilizando por separado las características de la señal de GSR, las de la señal de RSP y el conjunto combinado de ambas. Para el análisis combinado de las señales, se unieron las estructuras de datos correspondientes a cada señal en una sola. Esto se pudo realizar porque ambas señales fueron segmentadas y enventanadas de manera uniforme, asegurando que cada ventana representase el mismo segmento temporal entre los dos conjuntos de datos.

Estos clasificadores fueron entrenados con las características extraídas de cada señal, probando para los diferentes tipos de enventanado mencionados en la sección 2.4.1 Procesado de señal y extracción de características. Así, se obtuvieron para los dos tipos de normalización (01 y MAD), al mismo tiempo que se probó para cada una de las combinaciones de pares de estímulos y niveles de dimensión del SAM. Además, para cada combinación de señal, enventanado, normalización y pares de elementos a clasificar se entrenaron dos tipos de modelos:

1. Independientes del sujeto: el entrenamiento se realizó teniendo en cuenta los datos de todos los sujetos
2. Dependientes del sujeto: se entrenó un clasificador específico para cada uno de los sujetos.

Seguidamente, se aplicó una normalización de las características empleadas entre 0 y 1 por sujeto, de tal forma que se aplicó la Ecuación (8), en la que X_{norm} representa la característica con la normalización para el sujeto i , X_i la característica sin normalizar para ese sujeto, $X_{min,i}$ el valor mínimo de la característica y $X_{max,i}$ el valor máximo de la característica. Esta normalización permite eliminar las diferencias individuales en la escala de características, reduciendo el sesgo hacia los sujetos que tengan un rango de características mayor.

$$X_{norm,i} = \frac{X_i - X_{min,i}}{X_{max,i} - X_{min,i}} \quad (8)$$

Este proceso se siguió para las diferentes combinaciones mencionadas anteriormente, pero, tras analizar los resultados obtenidos para cada una de ellas, se decidió reportar los modelos que mejor funcionaban: modelos dependientes del sujeto con características extraídas del enventanado de intervalos de 60 segundos solapados al 50% y con una normalización MAD, sin aplicar ninguna selección de características. Por ello, de aquí en adelante se explicará únicamente y de forma detallada la obtención de estos modelos. Los resultados obtenidos para las otras combinaciones se pueden encontrar en el Anexo 2.

De esta forma, la obtención de las predicciones de los distintos clasificadores precisa la división del conjunto de datos en un subconjunto de entrenamiento, que será el utilizado para el propio entrenamiento del modelo, y en un subconjunto de validación, que serán datos que no se han introducido en el entrenamiento y sirvan para obtener las métricas de evaluación. Para llevar a cabo esta escisión de los datos se utilizó la validación cruzada, una técnica que divide los datos en múltiples pliegues con el objetivo de entrenar y validar el modelo de forma iterativa y obtener así métricas más precisas.

El método de validación cruzada empleado para los modelos con ventanas solapadas al 50%, en los que se disponía de 5 ventanas por estímulo, consistió en un *Leave One Out* (LOO) modificado. De esta forma, como se observa en la Ilustración 17, en cada iteración de validación cruzada se escogía como subconjunto de validación una de las ventanas de un estímulo y, como subconjunto de entrenamiento, el resto de los estímulos junto con las ventanas de ese mismo estímulo que no se encontraban junto a la ventana de validación. Con ello, se eliminaban las ventanas que estaban solapadas con la de validación y se conseguía evitar la inclusión de datos en validación que ya se habían introducido en entrenamiento.




Ilustración 17. Validación L00 modificada para solucionar el problema de solapamiento al 50%.

Una vez separados los datos, el estudio se decantó por emplear los siguientes clasificadores supervisados, debido a su amplio uso en el reconocimiento de emociones: KNN (Ali et al., 2018; Canento et al., 2011; Egger et al., 2019; Shu et al., 2018); RF (Pan et al., 2020; Shu et al., 2018); y SVM (Egger et al., 2019; K. H. Kim et al., 2004; Pan et al., 2020; Pinto et al., 2019; Shu et al., 2018). Debido a la relevancia del algoritmo SVM para este trabajo, será el que se explique en mayor detalle.

El modelo SVM tiene por objetivo encontrar fronteras de decisión óptimas que separen los datos en las diferentes clases, de tal forma que se maximicen las distancias entre los puntos más cercanos de cada clase (Pan et al., 2020). El modelo se utiliza para problemas en los que se deben separar dos clases, por lo que en situaciones con varias clases se reduce el problema a análisis binarios. En este trabajo, utilizando el subconjunto de datos de entrenamiento, SVM aplica un kernel *Radial Basis Function* que calcula la similitud entre pares de puntos en el espacio de características original. Posteriormente, el kernel aplica una función gaussiana para transformar los datos a un espacio de características de alta dimensionalidad, donde las distancias entre los datos se interpretarán en forma de similitud radial y será más probable que estos se puedan separar de forma más efectiva. En el espacio de características transformado, SVM calculará el hiperplano de separación.

En la Ilustración 18 se observan signos positivos y negativos que representan las clases a separar. Los signos rodeados identifican los vectores de soporte, es decir, los puntos de

datos del conjunto de entrenamiento que están más cercanos al hiperplano de separación, representado con una línea continua azul. La línea amarilla de la ilustración marca el margen, considerado como la distancia entre el hiperplano de separación y los vectores de soporte, el cual no incluye puntos de datos internos. De esta forma, el algoritmo SVM determina como el hiperplano aquel que maximiza el margen. No obstante, el modelo solo es capaz de realizar separaciones lineales entre los datos, por lo que se suelen aplicar transformaciones, como la *Radial Basis Function*, y ampliaciones del margen, que suponen una pequeña tasa de errores.

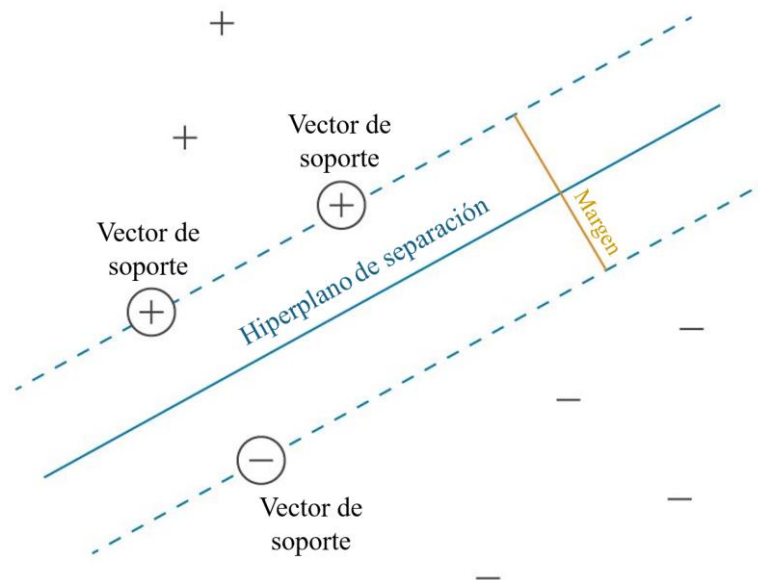


Ilustración 18. Funcionamiento del algoritmo SVM. Adaptada de (MATLAB).

Una vez calculada la frontera de decisión, se introducen en el modelo los datos correspondientes al conjunto de validación, se les aplica la misma transformación para mapearlos al espacio transformado, se evalúa en qué lado del hiperplano se encuentran y, consecuentemente, se establece la clase a la que pertenecen.

Los hiperparámetros de un modelo son parámetros que se configuran antes del entrenamiento y permanecen constantes, determinando el comportamiento del algoritmo y su aprendizaje. A diferencia de estos, los parámetros del modelo son los que se van ajustando a medida que se ejecuta el entrenamiento. En SVM se pueden encontrar tres hiperparámetros principales:

- C: se encarga de asegurar el equilibrio entre ajustar la frontera de decisión a los datos de entrenamiento y mantener la capacidad del modelo para generalizar a otros datos. Un valor alto de este parámetro llevará a un mayor ajuste a los datos de entrenamiento y a una menor capacidad de generalizar, y viceversa.
- Tipo de *kernel*: define la función de transformación que se emplea para mapear los datos del espacio original al espacio de características de mayor dimensionalidad. Los más comunes son el lineal, el polinómico, el *Radial Basis Function* o el sigmoide.
- γ : se considera un hiperparámetro específico de los *kernels* no lineales, como el polinómico o el *Radial Basis Function*, y se encarga de controlar la influencia de cada dato del entrenamiento. Un valor bajo supone un radio de influencia más grande

para cada punto, mientras que uno más alto otorga menos influencia y, por tanto, una frontera de decisión más compleja.

Para cada modelo se realizó una búsqueda iterativa del hiperparámetro C entre los valores 0,01; 0,1; 1; 10; y 100, de tal forma que se escogía el valor que maximizaba las métricas del modelo. El *kernel* empleado fue el *Radial Basis Function* y el γ se calculó como se establece en la Ecuación (9), donde n es el número de características en el conjunto de datos y X_{var} la varianza de esas características. Considerar estas dos variables permite obtener un valor del hiperparámetro ajustado al conjunto de datos.

$$\gamma = \frac{1}{n \cdot X_{var}} \quad (9)$$

El entrenamiento de los modelos se acompañaba de la obtención de métricas que validasen las configuraciones del modelo para las diferentes iteraciones de validación cruzada. Para ello, se emplearon las métricas de exactitud, precisión y F1-Score cuyas fórmulas son las establecidas en las Ecuaciones (10), (11) y (13), respectivamente. La Ecuación (12) calcula la sensibilidad, siendo necesaria para la obtención de la métrica F1-Score. Esta decisión se fundamentó en las métricas más utilizadas por investigaciones análogas (Ali et al., 2018; Canento et al., 2011; Lima et al., 2024; Shu et al., 2018). En estas ecuaciones VP representa los verdaderos positivos, muestras que fueron clasificadas como una clase específica y verdaderamente eran de esa clase; VN los verdaderos negativos, casos que se clasificaron como no pertenecientes a una clase y realmente no pertenecían a esa clase; FP los falsos positivos, muestras que se clasificaron pertenecientes a una clase concreta que en verdad no pertenecían a esa clase; y FN los falsos negativos, casos que el modelo clasificó como no pertenecientes a una clase, pero que sí pertenecían a ella.

$$Exactitud = \frac{VP + VN}{VP + VN + FP + FN} \quad (10)$$

$$Precisión = \frac{VP}{VP + FP} \quad (11)$$

$$Sensibilidad = \frac{VP}{VP + FN} \quad (12)$$

$$F1 - Score = 2 * \frac{Precisión * Sensibilidad}{Precisión + Sensibilidad} \quad (13)$$

Para los modelos independientes del sujeto (no reportados en este trabajo) se calculó la media y desviación estándar de cada una de las métricas obtenidas para cada iteración de validación cruzada; mientras que para los modelos dependientes del sujeto se obtuvieron estos dos estadísticos para las métricas derivadas de cada sujeto.

Por otra parte, con el objetivo de validar las clasificaciones para el modelo que mejores resultados obtuvo, se aplicó un método estadístico no paramétrico para evaluar si los resultados obtenidos eran significativos o si se debían a causas de azar. Concretamente, se aplicaron pruebas de permutación para cada uno de estos modelos, en las que se reordenaban aleatoriamente las etiquetas de entrenamiento del modelo y se obtenían las métricas para cada una de estas permutaciones aleatorias (Combrisson & Jerbi, 2015). En

este caso concreto, se realizaron 200 iteraciones para cada modelo, obteniendo la precisión en cada iteración para cada uno de los sujetos. De esta forma, se conseguía una distribución nula empírica que representaba lo que se esperaría si no existiera una verdadera relación entre las clases de cada modelo y las observaciones correspondientes. Posteriormente, se contrastaba la media de la precisión del modelo correctamente etiquetado con el percentil 95 y el percentil 99 de la distribución nula. Si la precisión de la clasificación original resultaba mayor que alguno de estos dos percentiles, significaría que hay menos del 5% o del 1% de probabilidad, respectivamente, de que la métrica obtenida fuese por azar.

3. RESULTADOS

El personal encargado de llevar a cabo la recopilación de los datos obtuvo registros para 46 sujetos. De estos, en 1 hubo problemas en el software, por lo que la muestra final fue de 45 sujetos.

En cuanto al análisis específico de GSR, hubo que descartar 3 sujetos debido a pérdidas en la señal superiores al 10% con respecto al total de la misma, quedando 42 restantes. De estos 42 se eliminó el 10,85% de los segmentos de estímulos y el 12,62% de los segmentos de descansos debido al problema de falta de señal, en los que la pérdida era superior al 10% respecto al total del segmento; mientras que por ruido únicamente hubo que eliminar el 1,32% de los segmentos de estímulos (los porcentajes se obtienen con respecto al total de segmentos de estímulos/descansos). En cuanto a los artefactos en los segmentos restantes, se aplicó la interpolación cúbica en 11 segmentos de estímulos y 13 segmentos de descansos respecto al total de sujetos.

Por lo que respecta a RSP, la inspección visual realizada para los distintos segmentos no supuso la eliminación de ningún sujeto, por lo que se mantuvieron los 45 iniciales. No obstante, debido a pérdidas de datos superiores al 10% respecto al total del segmento, se tuvo que eliminar el 1,23% de los segmentos de estímulos y el 0,89% de los segmentos de descansos, ambos porcentajes con respecto al total de estímulos/descansos.

3.1. VALIDACIÓN DE LOS ESTÍMULOS EMPLEADOS MEDIANTE LA ESCALA SAM

Esta sección recoge los resultados obtenidos para la validación de los estímulos empleados en el presente trabajo utilizando las puntuaciones de la escala SAM de los participantes.

En la Tabla 6 se pueden observar las medias y desviaciones estándar obtenidas para la puntuación realizada por los participantes sobre los bloques de estímulos en las tres dimensiones de la escala SAM. Se comprueba que el bloque de estímulos positivos presenta una valencia alta y una excitación baja, mientras que en el grupo de estímulos negativos ocurre lo contrario. Asimismo, se aprecia que el control que sienten los participantes es mayor en los estímulos positivos comparados con los negativos.

En la misma tabla se observa que la valencia obtenida para el bloque de estímulos eróticos se encuentra en un valor un poco elevado, suponiendo una percepción un tanto agradable para los participantes. El alto valor de excitación revela una elevada percepción de intensidad emocional por parte de los sujetos, posiblemente debida a la naturaleza estimulante de este tipo de estímulos. Asimismo, la dominancia muestra un valor central que implicaría una percepción equilibrada en cuanto al control experimentado.

Tabla 6. Medias y desviaciones estándar obtenidas de la escala SAM rellenada por los participantes del estudio

	Valencia		Excitación		Dominancia	
	Media	Std	Media	Std	Media	Std
Positivos	7,00	1,46	3,07	1,62	6,67	2,03
Negativos	2,85	1,43	6,22	1,41	4,48	1,80
Eróticos	5,41	1,61	6,20	1,47	5,04	1,93

Por otra parte, se analizaron las diferencias entre las puntuaciones de la escala en función de cada bloque de estímulos para cada una de las dimensiones. En la Ilustración 19 se pueden observar las diferentes distribuciones de las puntuaciones obtenidas de las dimensiones del SAM para cada uno de los bloques de estímulos. Las líneas en rojo marcan en sus extremos los bloques de estímulos entre los que el test de Mann-Whitney halló diferencias significativas. El símbolo * situado encima de estas líneas indica que el valor p para esa pareja es menor que 0,05; mientras que el símbolo ** significa que el valor p es menor que 0,01.

Para la dimensión de valencia se observa que existen diferencias significativas entre todas las combinaciones de estímulos. En cuanto a la excitación y la dominancia, las diferencias son significativas en todas las combinaciones menos en la comparación de estímulos negativos con eróticos.

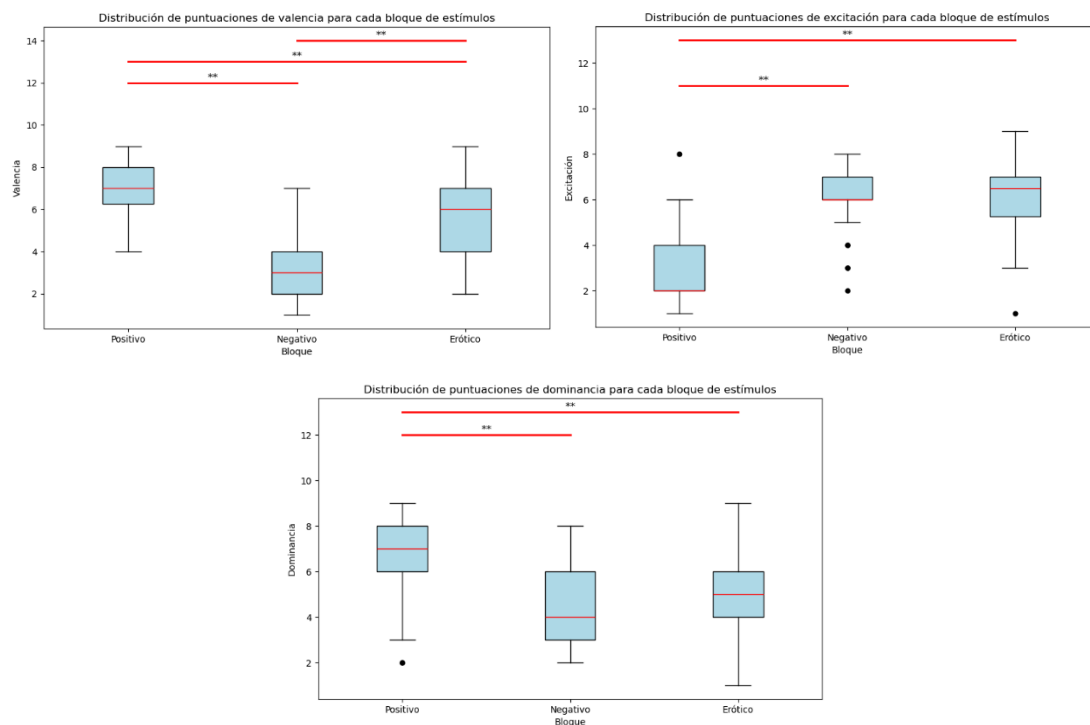


Ilustración 19. Distribuciones de puntuaciones de las dimensiones del SAM en función de los bloques de estímulos.

3.2. DIFERENCIAS ESTADÍSTICAS ENTRE CLASES DE ESTÍMULOS Y NIVELES DE DIMENSIONES DEL SAM PARA LAS SEÑALES DE GSR Y RSP

El análisis de los datos llevó a escoger de forma definitiva el inventariado de 60 segundos con un solapamiento del 50%, debido a que era la opción que mayor volumen de datos proporcionaba y que, al mismo tiempo, permitía el análisis conjunto de las señales de GSR y RSP. De la misma forma, se decidió finalmente decantarse por la normalización MAD, ya que proporcionaba resultados mejores en términos de métricas de modelos de aprendizaje automático (ver Anexo 2). Por ello, únicamente se presentarán los resultados de este inventariado y normalización.

De esta forma, en la Tabla 7 se pueden observar las medias y desviaciones estándar para las distintas características de GSR y combinaciones de estímulos, además del nivel de significancia obtenido tras la corrección post hoc de la prueba estadística. Únicamente se presentan las características que proporcionaban una diferencia estadísticamente significativa. De la misma forma, en la Tabla 8 se encuentran los resultados para las distintas dimensiones de SAM de GSR, en la Tabla 9 para las combinaciones de estímulos de RSP y en la Tabla 10 para las dimensiones SAM de RSP. En la comparación de las distintas dimensiones para GSR y para RSP no se obtuvieron diferencias estadísticamente significativas para los niveles alto y bajo de valencia. Los resultados completos se muestran en el Anexo 1.

Tabla 7. Medias, desviaciones estándar y significancia de la comparación de las características de GSR con diferencia significativa para los distintos estímulos

Característica	Estímulo positivo (media ± std)	Estímulo negativo (media ± std)	Estímulo erótico (media ± std)	Significancia Positivo VS Negativo	Significancia Positivo VS Erótico	Significancia Negativo VS Erótico
Media	0,68 ± 4,92	-0,02 ± 1,80	0,32 ± 11,51	**	**	**
Mediana	0,70 ± 5,31	-0,02 ± 1,98	0,37 ± 12,10	**	**	**
Std	-1,27 ± 6,26	0,01 ± 2,98	0,10 ± 9,38	**	**	**
RMS	0,67 ± 4,92	-0,02 ± 1,79	0,32 ± 11,50	**	**	**
Asimetría	0,03 ± 2,54	-0,35 ± 2,84	0,35 ± 2,84	*		*
Máximo	0,57 ± 4,55	0,01 ± 1,44	0,32 ± 10,21	*	**	*
Mínimo	0,92 ± 5,81	-0,06 ± 1,97	0,51 ± 13,67	**	**	**
Media 1ª derivada	0,20 ± 4,67	0,51 ± 3,07	-0,89 ± 6,95		**	
Media diferencias absolutas	-1,11 ± 4,74	-0,29 ± 2,79	0,26 ± 12,46	**	**	**
Área magnitud	10,02 ± 295,31	-1,81 ± 15,90	9,09 ± 263,75		**	
Varianza frecuencia	10,11 ± 297,74	-1,81 ± 15,95	9,01 ± 263,70		**	
Número picos SCR	-0,10 ± 2,11	-0,05 ± 1,85	0,31 ± 2,20		*	
Amplitud media picos SCR	0,15 ± 8,71	-0,51 ± 3,81	0,82 ± 12,10		**	
Std amplitud SCL	-1,19 ± 6,12	0,07 ± 2,87	0,10 ± 8,60	**	**	**

Tabla 8. Medias, desviaciones estándar y significancia de la comparación de las características de GSR con diferencia significativa para las distintas dimensiones

Característica	Dominancia alta (media ± std)	Dominancia baja (media ± std)	Significancia alta VS baja
Media	-0,07 ± 1,50	-0,45 ± 1,88	*
Mediana	-0,08 ± 1,54	-0,45 ± 2,04	*
Std	-0,62 ± 4,04	0,83 ± 5,42	**
RMS	-0,07 ± 1,50	-0,45 ± 1,88	*
Máximo	-0,10 ± 1,59	-0,36 ± 1,59	*
Mínimo	0,07 ± 1,55	-0,45 ± 2,32	**
Media diff absolutas	-0,64 ± 2,32	1,32 ± 7,68	**
Área magnitud	-1,46 ± 7,93	27,68 ± 328,71	**
Varianza frecuencia	-1,46 ± 7,93	27,64 ± 328,24	**
Amplitud media picos SCR	-0,52 ± 2,80	1,97 ± 14,14	**
Std amplitud SCL	-0,56 ± 4,03	0,74 ± 5,05	**
Característica	Excitación alta (media ± std)	Excitación baja (media ± std)	Significancia alta VS baja
Media	-0,48 ± 2,69	1,62 ± 13,55	**
Mediana	-0,49 ± 2,86	1,70 ± 14,25	**
Std	0,27 ± 4,96	-1,51 ± 9,57	**
RMS	-0,48 ± 2,68	1,62 ± 13,54	**
Máximo	-0,36 ± 2,25	1,35 ± 12,02	**
Mínimo	-0,54 ± 2,87	2,01 ± 16,17	**
Media diff absolutas	0,76 ± 5,53	-1,88 ± 13,01	**
Asimetría frecuencia	0,13 ± 2,49	-0,37 ± 2,49	*
Std amplitud SCL	0,23 ± 4,80	-1,36 ± 8,73	*

Tabla 9. Medias, desviaciones estándar y significancia de la comparación de las características de RSP con diferencia significativa para los distintos estímulos.

Característica	Estímulo positivo (media ± std)	Estímulo negativo (media ± std)	Estímulo erótico (media ± std)	Significancia Positivo VS Negativo	Significancia Positivo VS Erótico	Significancia Negativo VS Erótico
RSP Rate Mean	1,20 ± 2,99	1,33 ± 2,81	1,33 ± 2,81		**	
RRV MeanBB	-1,44 ± 3,90	-1,49 ± 3,86	-1,49 ± 3,86		*	
RRV CVBB	-0,40 ± 4,03	0,00 ± 3,27	0,00 ± 3,27		*	
RRV CVSD	-0,53 ± 4,72	0,13 ± 3,70	0,13 ± 3,70	*		*
RRV MedianBB	-1,52 ± 4,46	-1,70 ± 4,51	-1,70 ± 4,51		**	
RRV LFHF	-0,35 ± 4,27	-1,16 ± 5,01	-1,16 ± 5,01		*	
RSP Phase Duration Inspiration	-1,26 ± 4,04	-1,45 ± 3,90	-1,45 ± 3,90		*	

Tabla 10. Medias, desviaciones estándar y significancia de la comparación de las características de RSP con diferencia significativa para las distintas dimensiones.

Característica	Dominancia alta (media ± std)	Dominancia baja (media ± std)	Significancia alta VS baja
RAV RMSSD	-1,37 ± 7,12	-0,82 ± 7,87	*
Característica	Excitación alta (media ± std)	Excitación baja (media ± std)	Significancia alta VS baja
RSP Rate Mean	1,94 ± 2,86	1,48 ± 3,23	**
RRV MeanBB	-2,18 ± 3,87	-1,68 ± 4,30	*
RRV MedianBB	-2,51 ± 4,20	-1,74 ± 5,09	**
RSP Phase Duration Inspiration	-2,09 ± 3,81	-1,48 ± 4,47	**

3.3. MODELOS DE RECONOCIMIENTO DE EMOCIONES UTILIZANDO LAS SEÑALES FISIOLÓGICAS DE GSR Y RSP

El análisis de los resultados de las diferentes combinaciones del estudio llevó a decantarse por los modelos dependientes del sujeto, con una normalización MAD y con un solapamiento del 50% de ventanas de 60 segundos, como se ha mencionado en secciones anteriores. Asimismo, los mejores resultados iniciales, reflejados en el Anexo 2, llevaron a entrenar estos modelos con todas las características extraídas.

La Tabla 11 muestra las medias y desviaciones estándar para la precisión de los modelos SVM que se utilizaron para cada combinación de señal y pares de estímulos o dimensiones. Se reporta este clasificador por ser el modelo que mejores métricas proporcióna para todas las combinaciones, pudiendo observar los resultados para todos los clasificadores en el Anexo 3. Al realizar un tipo de validación LOO, las métricas de exactitud, precisión y F1-Score coinciden debido a la evaluación repetida de una sola observación y a la consistencia en las predicciones del modelo. Por ello, el valor que se da en las tablas para la media y la desviación estándar es únicamente el de precisión, que representa a todos los demás.

Tabla 11. Medias y desviaciones estándar de la precisión de los modelos SVM obtenidos para cada señal y combinación de estímulos y niveles de dimensión.

Señal	Dominio	Clases	Precisión (media ± std) (%)
GSR	ESTÍMULOS	Positivo Vs Negativo	80,12 ± 32,95
		Positivo VS Erótico	82,59 ± 31,52
		Negativo VS Erótico	78,00 ± 35,40
	DIMENSIONES	Valencia alta VS baja	81,95 ± 32,81
		Dominancia alta VS baja	82,75 ± 31,09
		Excitación alta VS baja	82,46 ± 32,06
RSP	ESTÍMULOS	Positivo Vs Negativo	75,04 ± 41,37
		Positivo VS Erótico	80,00 ± 37,18
		Negativo VS Erótico	82,48 ± 33,60
	DIMENSIONES	Valencia alta VS baja	74,97 ± 41,52
		Dominancia alta VS baja	79,76 ± 38,08
		Excitación alta VS baja	79,61 ± 38,53

GSR+RSP	ESTÍMULOS	Positivo Vs Negativo	85,52 ± 31,52
		Positivo VS Erótico	89,61 ± 24,17
		Negativo VS Erótico	86,61 ± 29,76
	DIMENSIONES	Valencia alta VS baja	86,41 ± 30,15
		Dominancia alta VS baja	87,91 ± 27,97
		Excitación alta VS baja	90,06 ± 24,82

Para cada uno de los modelos SVM, se extrajeron los resultados de las pruebas de permutación. En la Ilustración 20 y la Ilustración 21 se representa, para la combinación de las características de GSR y RSP y para los pares de estímulos/niveles de dimensión, la distribución nula, obtenida mediante permutaciones aleatorias, mediante barras azules; la media de precisión (*accuracy*) de la distribución nula con una línea azul; la distribución del modelo correctamente etiquetado a través de barras verdes; la media de precisión de la distribución entrenada con las etiquetas correctas mediante una línea verde; y el percentil 95 y 99 de la distribución nula con líneas rojas y amarillas, respectivamente. Estos modelos, en los que se combinaron ambas señales, fueron los que mejores métricas obtuvieron. El resto de pruebas de permutación se puede encontrar en el Anexo 4.

Como se puede observar en las ilustraciones, para todos los modelos la media de la distribución correctamente etiquetada está por encima del percentil 99, por lo que la probabilidad de que el resultado de estos modelos sea aleatorio es menor al 1%.




Ilustración 20. Distribuciones de la precisión obtenida de los clasificadores de estímulos emocionales con los datos reales (verde) y las etiquetas permutadas (azul) empleando las señales de GSR y RSP combinadas.

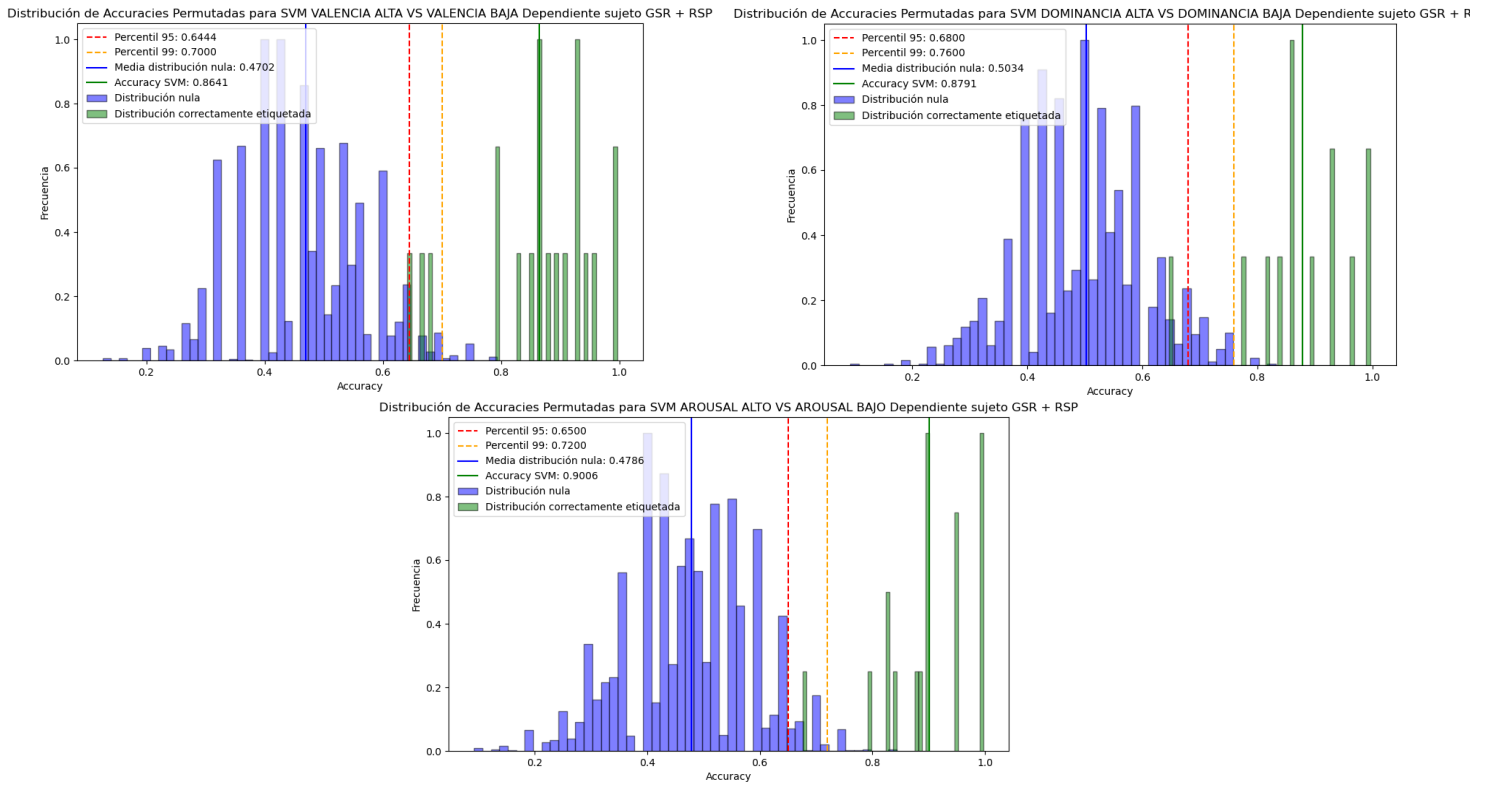


Ilustración 21. Distribuciones de la precisión obtenida de los clasificadores de niveles de dimensiones emocionales con los datos reales (verde) y las etiquetas permutadas (azul) empleando las señales de GSR y RSP combinadas.

4. DISCUSIÓN

4.1. ESTÍMULOS EMPLEADOS PARA EL RECONOCIMIENTO DE EMOCIONES

La validación de los estímulos empleados en el estudio es fundamental para asegurar la reproducibilidad y para comprobar que realmente se están induciendo las emociones esperadas.

La valencia reveló diferencias significativas entre todos los tipos de estímulos con un valor p menor a 0,01. Esto sugiere que los estímulos positivos, negativos y eróticos se perciben de manera distinta en términos de agrado. Los estímulos positivos fueron percibidos como agradables, los negativos como desagradables y los eróticos revelaron una respuesta mixta, pero diferenciada de los dos restantes.

La dominancia mostró diferencias significativas entre la mayoría de los estímulos, exceptuando la combinación de los estímulos negativos con los eróticos. Esto sugiere que los participantes podrían haber experimentado sensaciones análogas de control cuando se presentaron los estímulos. Este hecho podría ser por la sensación de sobrecarga emocional similar que se produce en los estímulos negativos, en los que se pueden generar respuestas de defensa que generen una sensación de pérdida de control, y en los estímulos eróticos, los cuales tienen distintos tabúes o convenciones sociales que pueden llevar a la misma sensación de pérdida de control.

La excitación también presentó diferencias significativas en todas las combinaciones, excluyendo la comparación de estímulos negativos y eróticos. Los primeros suelen ser excitantes debido a su capacidad de generar respuestas de estrés/ansiedad; mientras que los eróticos, debido a que son naturalmente excitantes para las personas, pueden haber ocasionado percepciones similares. Esto podría revelar que ambos estímulos pueden generar respuestas fisiológicas con la misma intensidad.

En cuanto a los estímulos negativos y positivos, los resultados obtenidos en el estudio confirman las puntuaciones estandarizadas de la base de datos IADS-E, en las que los estímulos positivos se caracterizaban por una valencia elevada y una excitación baja, y los estímulos negativos por una valencia baja y una excitación alta. Esto indica que estos dos estímulos han sido aplicados correctamente, otorgando fiabilidad al protocolo experimental.

Por lo que respecta a los estímulos eróticos, se confirma la sospecha de que este tipo de estímulos no son categorizados de la misma forma que los positivos por parte de los sujetos del estudio, de forma contraria a como considera la IADS-E. Así, se obtienen diferencias estadísticamente significativas entre los estímulos positivos y eróticos para las tres dimensiones de valencia, dominancia y excitación, demostrando respuestas emocionales diferentes para los dos tipos de estímulos.

Los resultados obtenidos de la autoevaluación de los participantes de los bloques de estímulos empleados, mostrados en la sección 3.1 VALIDACIÓN DE LOS ESTÍMULOS EMPLEADOS MEDIANTE LA ESCALA SAM, revelan que los estímulos seleccionados para inducir las emociones positivas, negativas y eróticas son efectivos y diferenciables en términos de las dimensiones de valencia, dominancia y excitación.

4.2. DIFERENCIAS EN LAS SEÑALES DE GSR Y RSP ANTE DIFERENTES ESTÍMULOS Y NIVELES DE DIMENSIÓN EMOCIONALES

El estudio pretendía determinar la existencia de diferencias entre los estímulos positivos, negativos y eróticos, así como entre los niveles alto y bajo de valencia, dominancia y excitación, utilizando las señales de GSR y RSP recopiladas en un paradigma de inducción de emociones.

De forma general, se pudo observar que, tanto en los análisis estadísticos como en la clasificación mediante modelos de aprendizaje automático, la aplicación de una normalización de los segmentos de señal con respecto al descanso anterior (MAD) proporcionaba resultados más elevados que si se aplicaba una normalización por sujeto, teniendo en cuenta la media y la desviación estándar de cada uno de ellos (01). Así, se puede afirmar que haber tenido en cuenta el estado del sujeto en el instante anterior al estímulo, permitió obtener mejores resultados para el reconocimiento de emociones utilizando señales fisiológicas.

Centrándose en el uso de modelos de aprendizaje automático, se comprobó que los resultados obtenidos en clasificadores entrenados específicamente para cada sujeto eran mayores que los que habían sido entrenados teniendo en cuenta a toda la muestra. Este hecho revela la ventaja adicional que supone adquirir modelos individualizados para cada persona, hallando investigaciones en las que, de la misma forma, se obtienen mejores resultados para modelos dependientes del sujeto (Egger et al., 2019; Kolodyazhniy et al., 2011). La explicación podría residir en la gran variabilidad interpersonal de la expresión emocional, ya que esta depende de diversos factores que pueden generar diferentes formas de reaccionar ante los estímulos y, consecuentemente, distintas respuestas de las funciones controladas por el sistema nervioso autónomo.

4.2.1. Respuesta galvánica de la piel

El análisis estadístico multivariante expuesto en la sección 3.2 DIFERENCIAS ESTADÍSTICAS ENTRE CLASES DE ESTÍMULOS Y NIVELES DE DIMENSIONES DEL SAM PARA LAS SEÑALES DE GSR Y RSP, mostró diferencias significativas entre distintas características de la señal de GSR para las diferentes combinaciones de estímulos. Así, hubo características que mostraron diferencias para las tres combinaciones de estímulos, siendo estas la media, mediana, desviación estándar, valor cuadrático medio, máximo, mínimo, media de las diferencias absolutas y desviación estándar de la amplitud SCL. Estas características coinciden con las reportadas en el estado del arte, en revisiones como la llevada a cabo por Shu y colaboradores (2018) o en investigaciones específicas como las realizadas por Ali y colaboradores (2018) o Zhang y colaboradores (2016). Esto demuestra

la existencia de respuestas fisiológicas diferentes reflejadas en la señal de GSR al experimentar cada tipo de estímulos.

La comparación entre estímulos que mostró mayor número de características estadísticamente diferenciables fue la de los positivos con los eróticos. En ella se hallaron características adicionales a las antes mencionadas: media de la primera derivada, área de la magnitud, varianza en la frecuencia, número de picos SCR o amplitud media de los picos SCR. Estas características también fueron reportadas por algunos estudios como útiles para la clasificación de emociones utilizando GSR (Greco et al., 2017; Kipli et al., 2022).

Por lo que respecta a las diferencias entre los niveles alto y bajo de las dimensiones del SAM, y como cabría esperar con el primer apartado de la discusión en el que se ratifica la validez de las dimensiones para distinguir las emociones, la prueba de Mann-Whitney junto con la corrección de Bonferroni identificó diferencias significativas para la comparativa entre los niveles de dominancia y excitación. Las características que ayudaron a determinar esta diferenciación fueron las mismas que distinguieron entre los tres tipos de estímulos, añadiendo la asimetría en frecuencia para la excitación y el área de la magnitud, la varianza en la frecuencia y la amplitud media de los picos SCR para la dominancia. Sin embargo, no hubo diferencias significativas entre los niveles de valencia. Esto demuestra la capacidad de la señal de GSR para determinar las diferencias entre niveles de percepción de las tres dimensiones del SAM.

Por otra parte, para los modelos SVM dependientes del sujeto que clasificaban tipos de estímulos, se obtuvieron precisiones con un valor en torno al 80%, logrando la mayor métrica para la clasificación de estímulos positivos y eróticos, con una precisión de 82,59%. Esto indica una elevada capacidad del modelo para clasificar los estímulos basados en las características de GSR y, sobre todo, para clasificar estímulos positivos y eróticos; coincidiendo con los resultados del análisis estadístico. La aplicación del modelo SVM dependiente del sujeto reportado en el presente estudio para clasificar estados emocionales ha proporcionado métricas superiores a la gran mayoría de estudios recopilados en revisiones existentes (Egger et al., 2019; Kipli et al., 2022; Shu et al., 2018), en las que las precisiones se encuentran entre el 50% y el 75%, mayoritariamente, para los modelos entrenados con una única señal. Esto podría reflejar una ventaja significativa de emplear una configuración del modelo similar a la utilizada en este trabajo. Cabe destacar que algunos estudios que emplearon la señal de electroencefalograma para el reconocimiento de emociones obtuvieron métricas similares, o incluso un tanto mayores, en comparación con las obtenidas para GSR en este trabajo. Sin embargo, la señal de GSR en comparación con la del electroencefalograma es mucho más fácil de adquirir; por lo que la leve disminución de la precisión podría verse compensada con la mayor simplicidad que proporciona.

Los clasificadores encargados de diferenciar entre los dos niveles de las distintas subescalas del SAM también obtuvieron precisiones superiores al 80%, consiguiendo el mejor resultado para la clasificación de los dos niveles de dominancia con un 82,75%. Además, se observa que la valencia es la subescala que obtiene resultados más bajos, coincidiendo así con los resultados de la prueba estadística y con algunos artículos que mencionan la mayor dificultad para clasificar en términos de esta dimensión utilizando señales fisiológicas; como la llevada a cabo por Haag y colaboradores (2004) en donde se utilizó una red neuronal. Tomando como referencia los artículos de las revisiones

mencionadas en el párrafo anterior, la clasificación de valencia y excitación obtenida en el presente estudio superó a la gran mayoría de las obtenidas por diferentes autores que utilizaron, de forma similar, una única señal fisiológica. La dominancia no suele utilizarse en el estado del arte para la diferenciación de estados emocionales, sin embargo, fue la que mejores métricas proporcionó en este trabajo.

Las pruebas de permutación para cada uno de estos modelos indicaron que la probabilidad de que los resultados fueran al azar era menor al 1%, por lo que hubo una fuerte evidencia de que los patrones que el clasificador SVM identificó fueran reales y significativos en los datos.

Los resultados obtenidos por los análisis estadísticos y por los modelos de aprendizaje automático para GSR demuestran que sí existen diferencias en la respuesta de esta señal ante la experimentación de estímulos positivos, negativos y eróticos; y ante los correspondientes niveles de percepción alto y bajo para las diferentes subescalas del SAM. Además, revelan que estos estados afectivos y su correspondencia en el espacio dimensional se pueden clasificar y reconocer con una elevada precisión. Por tanto, se ratifica que diferentes emociones generan distintas respuestas fisiológicas reflejadas en la sudoración de la piel, controlada por el sistema nervioso autónomo; como ya habían confirmado antes otros autores (Ayata et al., 2017; Kipli et al., 2022; Shu et al., 2018; Zhang et al., 2016).

4.2.2. Señal de respiración

Análogamente a GSR, el análisis estadístico fue capaz de evidenciar diferencias estadísticamente significativas para cada una de las combinaciones de estímulos positivos, negativos y eróticos utilizando las características. Sin embargo, al contrario que GSR, no se encontró ninguna característica que presentara diferencias significativas en las tres combinaciones de estímulos al mismo tiempo. Para la comparativa de los positivos con negativos y de los negativos con los eróticos la única característica que presentó diferencias significativas fue el coeficiente de variación de diferencias sucesivas entre intervalos respiratorios. Por el contrario, la comparación de los estímulos positivos con los eróticos demostró un mayor número de características estadísticamente significativas: media de la frecuencia instantánea, promedio de los intervalos de tiempo entre respiraciones, coeficiente de variación entre intervalos respiratorios, mediana de los intervalos de tiempo entre respiraciones, ratio entre la densidad de potencia espectral de la banda de baja frecuencia y la de alta frecuencia y la duración de la fase inspiración. Estas características ya fueron indicadas por otras investigaciones como útiles para diferenciar estados emocionales mediante la señal de RSP (J. Kim & André, 2008; Mirmohamadsadeghi et al., 2017; Shu et al., 2018). De esta forma, se comprueba que los estímulos son capaces de generar cambios fisiológicos diferentes reflejados en la señal de RSP.

En cuanto a los niveles de las dimensiones emocionales, la valencia no obtuvo ninguna característica con diferencias significativas entre sus niveles y la dominancia únicamente la raíz cuadrática media de las diferencias sucesivas de la amplitud respiratoria. La prueba estadística sí que determinó un mayor número de características con diferencias estadísticamente significativas para los niveles de excitación, siendo estos la media de la frecuencia instantánea, el promedio y la mediana de los intervalos de tiempo entre respiraciones, y la duración de la fase de inspiración.

Los modelos SVM empleados para el reconocimiento de los tres tipos de estímulos mostraron precisiones parecidas a GSR, con resultados mejores en la diferenciación de estímulos negativos y eróticos (82,48%). Así, aunque la comparación entre positivos y eróticos mostró un mayor número de diferencias en el análisis estadístico, los modelos predictivos pudieron clasificar con mejor precisión los negativos y eróticos, aun habiendo encontrado una sola característica en el análisis estadístico comparativo de estos. Esto podría deberse a que el modelo es capaz de capturar las interacciones complejas entre las características, a diferencia del análisis estadístico. De la misma forma, se realizaron las pruebas de permutación para todos los modelos, confirmando la no aleatoriedad de los resultados obtenidos. Comparando con los artículos de las revisiones llevadas a cabo por Egger y colaboradores (2019), Kipli y colaboradores (2022) y Shu y colaboradores (2018), el entrenamiento del modelo SVM dependiente del sujeto reportado utilizando la señal de RSP también mostró resultados prometedores, ya que iguala a las precisiones obtenidas por algunos autores que también utilizaron configuraciones unimodales y, en algunos casos, las supera.

Por lo que respecta al uso de modelos para separar los niveles alto y bajo de las dimensiones emocionales, se obtuvieron precisiones un tanto inferiores al 80%, resultando la comparación entre dominancia alta y baja la que otorgó una mejor métrica, con el 79,6% de precisión. Confirmando el análisis estadístico, la valencia continuó siendo la dimensión con la métrica más baja. Haciendo referencia a las revisiones mencionadas en el párrafo anterior, las métricas obtenidas en este trabajo para los modelos entrenados para clasificar dos niveles de valencia y excitación son superadas por autores que utilizan la señal de EEG para el reconocimiento.

La evaluación estadística y el uso de modelos de aprendizaje automático para la señal de RSP también demostró la existencia de diferencias entre los estímulos y niveles de dimensiones empleados, así como la capacidad de clasificarlos. Sin embargo, cabe destacar que la precisión de clasificación obtenida tanto para los diferentes niveles de valencia, dominancia y excitación; como para la pareja de estímulos positivos y negativos, y la de positivos y eróticos, fue menor que la obtenida para GSR. La clasificación de estímulos negativos y eróticos fue la única que obtuvo una mejor precisión en RSP comparado con GSR, con un 4% adicional aproximado.

De esta forma, se confirma la capacidad de las emociones de generar cambios diferentes y específicos a nivel de la respiración, otra de las funciones controladas por el sistema nervioso autónomo.

4.3. USO COMBINADO DE LAS SEÑALES DE GSR Y RSP EN MODELOS DE APRENDIZAJE AUTOMÁTICO PARA EL RECONOCIMIENTO DE EMOCIONES Y NIVELES DE DIMENSIÓN EMOCIONALES

El reconocimiento de emociones y de diferentes niveles de las subescalas del SAM obtuvo resultados prometedores para las señales de GSR y RSP por separado. Sin embargo, se quiso comprobar en el trabajo si la constitución de un modelo multimodal que emplease la información de ambas señales podría obtener clasificaciones capaces de diferenciar entre las distintas clases con niveles más elevados de precisión.

La clasificación entre pares de estímulos positivos, negativos y eróticos proporcionó precisiones superiores al 85%, obteniendo la mejor métrica para la categorización de estímulos positivos y eróticos, con un 89,61%. Así, la combinación de la información de ambas señales permitió que el grado de precisión con el que se diferenciaban los estímulos aumentase considerablemente. El aumento para la pareja de estímulos con mayor precisión (positivos y eróticos) fue de un 7,02% con respecto a GSR y un 9,61% comparado con RSP. Revisando las precisiones obtenidas para clasificadores multimodales en diferentes artículos de las revisiones realizadas por Egger y colaboradores (2019), Kipli y colaboradores (2022) y Shu y colaboradores (2018), se puede observar que las métricas obtenidas en este trabajo son notablemente elevadas empleando únicamente dos señales fisiológicas. Estos niveles de precisión son igualados o superados por estudios que emplean clasificadores como redes neuronales o clasificadores bayesianos con un mayor número de señales fisiológicas, por lo que el uso de otras señales, como el ECG, podría suponer información adicional que proporcionase niveles de precisión más elevados. Cabe resaltar que esta similitud de resultados obtenida con respecto a otros estudios destaca por la facilidad de obtención de las señales de GSR y RSP en comparación con otras como el electroencefalograma.

Por otra parte, la distinción entre los niveles alto y bajo de las tres dimensiones emocionales utilizando ambas señales, también supuso el incremento de la precisión de los modelos. El mejor resultado se obtuvo para la distinción entre la excitación alta y baja, alcanzando un 90,06% de precisión. El uso de ambas señales permitió que las precisiones aumentaran para todas las dimensiones, con un incremento para la excitación del 7,6% comparado con GSR y del 10,45% con respecto a RSP. De la misma forma que para la clasificación de estímulos, la distinción entre las dimensiones emocionales utilizando dos señales fisiológicas presentó resultados que se posicionan entre los más elevados del estado del arte (Egger et al., 2019; Kipli et al., 2022; Shu et al., 2018), siendo superados en el uso de clasificadores como el Análisis Discriminante Cuadrático o el Análisis Discriminante Lineal.

Las pruebas de permutación se realizaron para los distintos modelos en los que se aplicó la señal de GSR y RSP de forma combinada, obteniendo una probabilidad menor al 1% de que los resultados obtenidos fueran aleatorios.

La mejora al utilizar un modelo entrenado con la información de ambas señales, en comparación con utilizar clasificadores unimodales, podría explicarse por el hecho de que las emociones no se expresan únicamente por una vía. En cambio, generan un conjunto de alteraciones tanto en las diferentes funciones controladas por el sistema nervioso autónomo como en las funciones gestionadas por otros sistemas. Así, diferentes emociones podrían generar las mismas alteraciones en una de estas funciones, como la GSR o la RSP, y no serían diferenciadas de forma independiente. Sin embargo, al introducir información de diferentes señales fisiológicas, que se ha demostrado que generan variaciones ante los cambios emocionales, los modelos dispondrían de más información para reducir la ambigüedad que produce el disponer de información aislada. Además, el uso de dos señales puede compensar el ruido o la pérdida de datos que podría originarse en momentos específicos para alguna de las mediciones. Esto es lo que ocurre con las señales de GSR y RSP, que aunque reflejan respuestas relacionadas por estar controladas por el sistema nervioso autónomo, aportan información complementaria y diferenciada.

El uso de sistemas multimodales de varias señales fisiológicas para aumentar la precisión de los sistemas de reconocimiento de emociones ya ha sido reportado por varias revisiones y artículos (Egger et al., 2019; Shu et al., 2018). Por ejemplo, el estudio llevado a cabo por Ali y colaboradores (2018) utilizó un clasificador SVM independiente del sujeto para clasificar cuatro emociones diferentes. Utilizando únicamente la señal de ECG obtuvo una precisión del 62,91%, teniendo en cuenta solo GSR la precisión fue del 68,40%, y la combinación de ambas proporcionó una métrica de 72,64%.

El análisis llevado a cabo de los modelos entrenados con señales de GSR y RSP confirma la mejor clasificación que proporciona un sistema multimodal de clasificación de emociones. En un futuro, se podría optar por incluir la información de otras señales fisiológicas reportadas en la literatura como el ECG o la temperatura de la piel (Shu et al., 2018). Con ello, se hipotetiza que se podrían conseguir métricas mejores para la clasificación de diferentes estados afectivos, por considerarse un modelo que tendría en consideración una gama más amplia de señales que muestran respuestas ante estímulos emocionales. Estas métricas más elevadas podrían equiparar, e incluso superar, a otros tipos de clasificadores más complejos y a los resultados obtenidos con señales más difíciles de adquirir, como el electroencefalograma.

Asimismo, aunque los algoritmos de aprendizaje profundo tienen un mayor coste computacional que los métodos tradicionales, también se podría optar por utilizar estos algoritmos. De esta forma, se podría verificar si su elevada capacidad de integración de información multimodal y su potencial de modelar relaciones altamente no lineales entre los datos ayudarían a la obtención de métricas más elevadas para el reconocimiento de emociones.

Adicionalmente, la implementación de un sistema multimodal de inducción de emociones que incluyera otros estímulos diferentes a los sonoros, como visuales o táctiles, podría acercarse más a un escenario real para los participantes del estudio. Este nivel de realismo podría generar un mayor grado de inmersión en los individuos y, por tanto, unas respuestas más cercanas a las que se producirían en una situación habitual.

5. CONCLUSIONES

El presente trabajo investiga el uso de las señales de GSR y RSP como herramientas para el reconocimiento de emociones. Para ello, se examinó la diferencia en las respuestas fisiológicas de individuos ante estímulos emocionales positivos, negativos y eróticos y entre los niveles alto y bajo de las dimensiones emocionales de valencia, excitación y dominancia a través de un análisis estadístico y mediante la aplicación de un clasificador SVM para cada sujeto, tanto para ambas señales por separado, como para la combinación de ellas. De esta forma, los resultados llevaron a concluir que las diferentes emociones inducidas mediante estímulos auditivos producían respuestas fisiológicas distintas y reconocibles reflejadas en las señales de GSR y RSP. Además, estos resultados evidenciaron la necesidad de aplicar modelos específicos para cada sujeto por la amplia variabilidad existente entre individuos. Esta personalización de los modelos supondría un mayor gasto de recursos, pero se vería compensada por mayores precisiones y, por tanto, por una mejor atención de los pacientes en el ámbito de la salud. Asimismo, conocer para cada sujeto la precisión del reconocimiento de sus emociones podría ayudar a los médicos a valorar la validez de los resultados aportados por el modelo y, así, poder valorar el mejor diagnóstico o tratamiento para problemas de rehabilitación, trastornos mentales, dolor crónico o estrés. Al aplicar cada uno de estos modelos, se observó que un enfoque multimodal, en el que se combinaba la información de GSR y RSP, proporcionaba resultados notablemente mejores en comparación con el enfoque unimodal. Cabe destacar la elevada tasa de reconocimiento que tuvo la diferenciación entre estímulos positivos y eróticos en comparación con el resto de las combinaciones, pudiendo ser de gran utilidad para aplicaciones que precisen de una elevada diferenciación y reconocimiento de emociones.

6. REFERENCIAS

- Aleksander Dietrichson, P. (2019). *Métodos Cuantitativos*.
<https://bookdown.org/dietrichson/metodos-cuantitativos/>
- Ali, M., Al Machot, F., Mosa, A. H., Jdeed, M., Al Machot, E., & Kyamakya, K. (2018). A Globally Generalized Emotion Recognition System Involving Different Physiological Signals. *Sensors 2018, Vol. 18, Page 1905, 18(6)*, 1905. <https://doi.org/10.3390/S18061905>
- Ali, M., Elsayed, A., Mendez, A., Savaria, Y., & Sawan, M. (2021). Contact and Remote Breathing Rate Monitoring Techniques: A Review. *IEEE Sensors Journal, 21(13)*, 14569–14586. <https://doi.org/10.1109/JSEN.2021.3072607>
- Alkan, A., & Yilmaz, A. S. (2007). Frequency domain analysis of power system transients using Welch and Yule–Walker AR methods. *Energy Conversion and Management, 48(7)*, 2129–2135. <https://doi.org/10.1016/J.ENCONMAN.2006.12.017>
- A.Mohamed, M., & A. Deriche, M. (2014). An Approach for ECG Feature Extraction using Daubechies 4 (DB4) Wavelet. *International Journal of Computer Applications, 96(12)*, 36–41. <https://doi.org/10.5120/16850-6712>
- Athavale, Y., & Krishnan, S. (2017). Biosignal monitoring using wearables: Observations and opportunities. *Biomedical Signal Processing and Control, 38*, 22–33. <https://doi.org/10.1016/J.BSPC.2017.03.011>
- Ayata, D., Yaslan, Y., & Kamasak, M. (2017). Emotion recognition via galvanic skin response: Comparison of machine learning algorithms and feature extraction methods. *Istanbul University - Journal of Electrical and Electronics Engineering, 17*, 3129–3136. <https://research.itu.edu.tr/en/publications/emotion-recognition-via-galvanic-skin-response-comparison-of-mach>
- Barrett, L. F. (2017). The theory of constructed emotion: an active inference account of interoception and categorization. *Social Cognitive and Affective Neuroscience, 12(1)*, 1–23. <https://doi.org/10.1093/SCAN/NSW154>
- Blanco-Almazan, D., Groenendaal, W., Catthoor, F., & Jane, R. (2019). Wearable Bioimpedance Measurement for Respiratory Monitoring during Inspiratory Loading. *IEEE Access, 7*, 89487–89496. <https://doi.org/10.1109/ACCESS.2019.2926841>
- Bradley, M., & Lang, P. (1999). *Affective Norms for English Words (ANEW): Instruction Manual and Affective Ratings*.
- Bradley, M. M., & Lang, P. J. (2017). International Affective Picture System. *Encyclopedia of Personality and Individual Differences, 1–4*. https://doi.org/10.1007/978-3-319-28099-8_42-1
- Bynion, T.-M., & Feldner, M. T. (2017). Self-Assessment Manikin. *Encyclopedia of Personality and Individual Differences, 1–3*. https://doi.org/10.1007/978-3-319-28099-8_77-1
- Campbell, E., Phinyomark, A., & Scheme, E. (2019). Feature extraction and selection for pain recognition using peripheral physiological signals. *Frontiers in Neuroscience, 13(MAY)*, 424828. <https://doi.org/10.3389/FNINS.2019.00437/BIBTEX>

- Canento, F., Fred, A., Silva, H., Gamboa, H., & Lourenço, A. (2011). Multimodal biosignal sensor data handling for emotion recognition. *Proceedings of IEEE Sensors*, 647–650. <https://doi.org/10.1109/ICSENS.2011.6127029>
- Canto, R., Bufalari, I., & D'Ausilio, A. (2011). A convenient and accurate parallel Input/Output USB device for E-Prime. *Behavior Research Methods*, 43(1), 292–296. <https://doi.org/10.3758/S13428-010-0022-3/TABLES/2>
- Chanel, G., Kierkels, J. J. M., Soleymani, M., & Pun, T. (2009). Short-term emotion assessment in a recall paradigm. *International Journal of Human-Computer Studies*, 67(8), 607–627. <https://doi.org/10.1016/J.IJHCS.2009.03.005>
- Choi, Y., Lee, S., Jung, S. S., Choi, I. M., Park, Y. K., & Kim, C. (2015). Development of an auditory emotion recognition function using psychoacoustic parameters based on the International Affective Digitized Sounds. *Behavior Research Methods*, 47(4), 1076–1084. <https://doi.org/10.3758/S13428-014-0525-4/TABLES/5>
- Chung, Y. M., Lou, S. L., Tsai, P. Z., & Wang, M. C. (2019). The Efficacy of Respiratory Regulation on Parasympathetic Nervous System Appraised by Heart Rate Variability. *Journal of Medical and Biological Engineering*, 39(6), 960–966. <https://doi.org/10.1007/S40846-019-00472-Z/FIGURES/5>
- Combrisson, E., & Jerbi, K. (2015). Exceeding chance level by chance: The caveat of theoretical chance levels in brain signal classification and statistical assessment of decoding accuracy. *Journal of Neuroscience Methods*, 250, 126–136. <https://doi.org/10.1016/J.JNEUMETH.2015.01.010>
- DATAtab. (n.d.). *Prueba U de Mann-Whitney - Explicación sencilla - DATAtab*. Retrieved June 20, 2024, from <https://datatab.es/tutorial/mann-whitney-u-test>
- De Choudhury, M., Counts, S., & Horvitz, E. (2013). Social media as a measurement tool of depression in populations. *Proceedings of the 5th Annual ACM Web Science Conference, WebSci'13, volume*, 47–56. <https://doi.org/10.1145/2464464.2464480>
- Dumoulin, J., Affi, D., Mugellini, E., Khaled, O. A., Bertini, M., & Del Bimbo, A. (2015). Affect recognition in a realistic movie dataset using a hierarchical approach. *ASM 2015 - Proceedings of the 1st International Workshop on Affect and Sentiment in Multimedia, Co-Located with ACM MM 2015*, 15–20. <https://doi.org/10.1145/2813524.2813526>
- Eerola, T., & Vuoskoski, J. K. (2010). A comparison of the discrete and dimensional models of emotion in music. [Http://Dx.Doi.Org/10.1177/0305735610362821](http://Dx.Doi.Org/10.1177/0305735610362821), 39(1), 18–49. <https://doi.org/10.1177/0305735610362821>
- Egger, M., Ley, M., & Hanke, S. (2019). Emotion Recognition from Physiological Signal Analysis: A Review. *Electronic Notes in Theoretical Computer Science*, 343, 35–55. <https://doi.org/10.1016/J.ENTCS.2019.04.009>
- Flynn, M., Effraimidis, D., Angelopoulou, A., Kapetanios, E., Williams, D., Hemanth, J., & Towell, T. (2020). Assessing the Effectiveness of Automated Emotion Recognition in Adults and Children for Clinical Investigation. *Frontiers in Human Neuroscience*, 14, 527508. <https://doi.org/10.3389/FNHUM.2020.00070/BIBTEX>
- Fu, J., Gao, Q., & Li, S. (2023). Application of Intelligent Medical Sensing Technology. *Biosensors* 2023, Vol. 13, Page 812, 13(8), 812. <https://doi.org/10.3390/BIOS13080812>

- Greco, A., Valenza, G., Citi, L., & Scilingo, E. P. (2017). Arousal and valence recognition of affective sounds based on electrodermal activity. *IEEE Sensors Journal*, 17(3), 716–725. <https://doi.org/10.1109/JSEN.2016.2623677>
- Grossard, C., Chaby, L., Hun, S., Pellerin, H., Bourgeois, J., Dapogny, A., Ding, H., Serret, S., Foulon, P., Chetouani, M., Chen, L., Bailly, K., Grynszpan, O., & Cohen, D. (2018). Children facial expression production: Influence of age, gender, emotion subtype, elicitation condition and culture. *Frontiers in Psychology*, 9(APR), 329029. <https://doi.org/10.3389/FPSYG.2018.00446/BIBTEX>
- Guo, T., Zhang, T., Lim, E., Lopez-Benitez, M., Ma, F., & Yu, L. (2022). A Review of Wavelet Analysis and Its Applications: Challenges and Opportunities. *IEEE Access*, 10, 58869–58903. <https://doi.org/10.1109/ACCESS.2022.3179517>
- Haag, A., Goronzy, S., Schaich, P., & Williams, J. (2004). Emotion Recognition Using Biosensors: First Steps towards an Automatic System. *Lecture Notes in Artificial Intelligence (Subseries of Lecture Notes in Computer Science)*, 3068, 36–48. https://doi.org/10.1007/978-3-540-24842-2_4
- Harman International Industries, J. (n.d.). *JBL Tune 510BT | Auriculares inalámbricos on-ear*. Retrieved June 13, 2024, from https://www.jbl.es/outlet/JBLT510BTBLUEU.html?gad_source=1&gclid=CjwKCAiA_5WvBhBAEiwAZtCU78SzaR4iZLVAW1EzWPtIOXl_G0aqCui2ND0CMhT_cIrhsGd-xkDzzRoCONgQAvD_BwE
- IBM. (n.d.). *¿Qué es el machine learning (ML)?* Retrieved June 20, 2024, from <https://www.ibm.com/es-es/topics/machine-learning>
- J. Villanueva J. (2005). *ECG feature extraction using Daubechies wavelets*. 747.
- Jaidka, K., Chhaya, N., Wadbude, R., Kedia, S., & Nallagatla, M. (2018). BATframe: An unsupervised approach for domain-sensitive affect detection. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10762 LNCS, 20–34. https://doi.org/10.1007/978-3-319-77116-8_2/TABLES/5
- Jang, E. H., Park, B. J., Park, M. S., Kim, S. H., & Sohn, J. H. (2015). Analysis of physiological signals for recognition of boredom, pain, and surprise emotions. *Journal of Physiological Anthropology*, 34(1). <https://doi.org/10.1186/S40101-015-0063-5>
- Khoury Karayanni, M. (2017). *The contribution of culture to emotional expression and regulation among children*.
- Kim, J., & André, E. (2008). Four-Channel Biosignal Analysis and Feature Extraction for Automatic Emotion Recognition. *Communications in Computer and Information Science*, 25 CCIS, 265–277. https://doi.org/10.1007/978-3-540-92219-3_20
- Kim, K. H., Bang, S. W., & Kim, S. R. (2004). Emotion recognition system using short-term monitoring of physiological signals. *Medical and Biological Engineering and Computing*, 42(3), 419–427. <https://doi.org/10.1007/BF02344719/METRICS>
- Kipli, K., Latip, A. A. A., Lias, K., Bateni, N., Yusoff, S. M., Tajudin, N. M. A., Jalil, M. A., Ray, K., Shamim Kaiser, M., & Mahmud, M. (2022). GSR Signals Features Extraction for Emotion Recognition. *Lecture Notes in Networks and Systems*, 376, 329–338. https://doi.org/10.1007/978-981-16-8826-3_28/TABLES/1

- Kolodyazhniy, V., Kreibig, S. D., Gross, J. J., Roth, W. T., & Wilhelm, F. H. (2011). An affective computing approach to physiological emotion specificity: Toward subject-independent and stimulus-independent classification of film-induced emotions. *Psychophysiology*, 48(7), 908–922. <https://doi.org/10.1111/j.1469-8986.2010.01170.x>
- Li, L., & Chen, J. H. (2006). Emotion recognition using physiological signals from multiple subjects. *Proceedings - 2006 International Conference on Intelligent Information Hiding and Multimedia Signal Processing, IIH-MSP 2006*, 355–358. <https://doi.org/10.1109/IIH-MSP.2006.265016>
- Lifeder. (2022). *Sistema nervioso autónomo: funciones, estructura, enfermedades*. <https://www.lifeder.com/sistema-nervioso-autonomo/>
- Lima, R., Chirico, A., Varandas, R., Gamboa, H., Gaggioli, A., & i Badia, S. B. (2024). Multimodal emotion classification using machine learning in immersive and non-immersive virtual reality. *Virtual Reality*, 28(2), 1–23. <https://doi.org/10.1007/S10055-024-00989-Y/TABLES/7>
- Liu, Y., & Sourina, O. (2013). EEG databases for emotion recognition. *Proceedings - 2013 International Conference on Cyberworlds, CW 2013*, 302–309. <https://doi.org/10.1109/CW.2013.52>
- MATLAB. (n.d.). *Support Vector Machine (SVM) - MATLAB & Simulink*. Retrieved June 20, 2024, from <https://es.mathworks.com/discovery/support-vector-machine.html>
- McGinley, J. J., & Friedman, B. H. (2017). Autonomic specificity in emotion: The induction method matters. *International Journal of Psychophysiology*, 118, 48–57. <https://doi.org/10.1016/j.ijpsycho.2017.06.002>
- MindWare Technologies Ltd. (2017, September 26). *All About HRV Part 4: Respiratory Sinus Arrhythmia - MindWare Technologies Support*. <https://support.mindwaretech.com/2017/09/all-about-hrv-part-4-respiratory-sinus-arrhythmia/>
- Mirmohamadsadeghi, L., Yazdani, A., & Vesin, J. M. (2017). Using cardio-respiratory signals to recognize emotions elicited by watching music video clips. *2016 IEEE 18th International Workshop on Multimedia Signal Processing, MMSP 2016*. <https://doi.org/10.1109/MMSP.2016.7813349>
- MJ Campbell, S. S. (2016). *Parametric and Non-parametric tests for comparing two or more groups | Health Knowledge*. <https://www.healthknowledge.org.uk/public-health-textbook/research-methods/1b-statistical-methods/parametric-nonparametric-tests>
- Nardelli, M., Valenza, G., Greco, A., Lanata, A., & Scilingo, E. P. (2015). Recognizing emotions induced by affective sounds through heart rate variability. *IEEE Transactions on Affective Computing*, 6(4), 385–394. <https://doi.org/10.1109/TAFFC.2015.2432810>
- NIRx. (2021). *WINGS | fNIRS Systems | NIRS Devices | NIRx*. <https://nirx.net/wings>
- Pan, L., Yin, Z., She, S., & Song, A. (2020). Emotional State Recognition from Peripheral Physiological Signals Using Fused Nonlinear Features and Team-Collaboration Identification Strategy. *Entropy*, 22(5). <https://doi.org/10.3390/E22050511>

- Paquette, S., Peretz, I., & Belin, P. (2013). The “Musical Emotional Bursts”: A validated set of musical affect bursts to investigate auditory affective processing. *Frontiers in Psychology*, 4(AUG), 52505. <https://doi.org/10.3389/FPSYG.2013.00509/ABSTRACT>
- Perez-Rosero, M. S., Rezaei, B., Akcakaya, M., & Ostadabbas, S. (2017). Decoding emotional experiences through physiological signal processing. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, 881–885. <https://doi.org/10.1109/ICASSP.2017.7952282>
- Pessoa, L. (2017). A Network Model of the Emotional Brain. *Trends in Cognitive Sciences*, 21(5), 357–371. <https://doi.org/10.1016/J.TICS.2017.03.002>
- Pham, T. D., & Tran, D. (2012). Emotion Recognition Using the Emotiv EPOC Device. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7667 LNCS(PART 5), 394–399. https://doi.org/10.1007/978-3-642-34500-5_47
- Picard, R. W. V. E. H. J. (2001). Toward machine emotional intelligence: Analysis of affective physiological state. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(10), 1175–1191.
- Pinto, J., Fred, A., & Da Silva, H. P. (2019). Biosignal-Based Multimodal Emotion Recognition in a Valence-Arousal Affective Framework Applied to Immersive Video Visualization. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 3577–3583. <https://doi.org/10.1109/EMBC.2019.8857852>
- Porges, S. W. (1997). Emotion: an evolutionary by-product of the neural regulation of the autonomic nervous system. *Annals of the New York Academy of Sciences*, 807, 62–77. <https://doi.org/10.1111/J.1749-6632.1997.TB51913.X>
- Psychology Software Tools. (n.d.). *E-Prime® / Psychology Software Tools*. Retrieved June 13, 2024, from <https://pstnet.com/products/e-prime/>
- Qi, Y., Jia, W., & Gao, S. (2021). Emotion Recognition Based on Piezoelectric Keystroke Dynamics and Machine Learning. *FLEPS 2021 - IEEE International Conference on Flexible and Printable Sensors and Systems*. <https://doi.org/10.1109/FLEPS51544.2021.9469843>
- Qiu, C., Wu, F., Han, W., & Yuce, M. R. (2022). A Wearable Bioimpedance Chest Patch for Real-Time Ambulatory Respiratory Monitoring. *IEEE Transactions on Bio-Medical Engineering*, 69(9), 2970–2981. <https://doi.org/10.1109/TBME.2022.3158544>
- Qiu, C., & Yuce, M. R. (2021). A Wearable Bioimpedance Chest Patch for IoHT-Connected Respiration Monitoring. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 6924–6927. <https://doi.org/10.1109/EMBC46164.2021.9629974>
- Schaefer, A., Nils, F., Philippot, P., & Sanchez, X. (2010). Assessing the effectiveness of a large database of emotion-eliciting films: A new tool for emotion researchers. *COGNITION AND EMOTION*, 24(7), 1153–1172. <https://doi.org/10.1080/02699930903274322>
- Semerci, Y. C., Akgün, G., Toprak, E., & Barkana, D. E. (2022). A Comparative Analysis of Deep Learning Methods for Emotion Recognition using Physiological Signals for Robot-Based Intervention Studies. *TIPTEKNO 2022 - Medical Technologies Congress, Proceedings*. <https://doi.org/10.1109/TIPTEKNO56568.2022.9960200>

- Shaqra, F. A., Duwairi, R., & Al-Ayyoub, M. (2019). Recognizing Emotion from Speech Based on Age and Gender Using Hierarchical Models. *Procedia Computer Science*, 151, 37–44. <https://doi.org/10.1016/j.PROCS.2019.04.009>
- Shu, L., Xie, J., Yang, M., Li, Z., Li, Z., Liao, D., Xu, X., & Yang, X. (2018). A Review of Emotion Recognition Using Physiological Signals. *Sensors (Basel, Switzerland)*, 18(7). <https://doi.org/10.3390/S18072074>
- Shukla, J., Barreda-Angeles, M., Oliver, J., Nandi, G. C., & Puig, D. (2021). Feature Extraction and Selection for Emotion Recognition from Electrodermal Activity. *IEEE Transactions on Affective Computing*, 12(4), 857–869. <https://doi.org/10.1109/TAFFC.2019.2901673>
- Siddiqui, H. U. R., Shahzad, H. F., Saleem, A. A., Khakwani, A. B. K., Rustam, F., Lee, E., Ashraf, I., & Dudley, S. (2021). Respiration Based Non-Invasive Approach for Emotion Recognition Using Impulse Radio Ultra Wide Band Radar and Machine Learning. *Sensors 2021, Vol. 21, Page 8336, 21(24)*, 8336. <https://doi.org/10.3390/S21248336>
- Srivastava, T. (2024). *Guide to K-Nearest Neighbors (KNN) Algorithm [2024 Edition]*. <https://www.analyticsvidhya.com/blog/2018/03/introduction-k-neighbours-algorithm-clustering/>
- Statistics How To. (2020). *Post Hoc Definition and Types of Tests - Statistics How To*. <https://www.statisticshowto.com/probability-and-statistics/statistics-definitions/post-hoc/>
- Takahashi, K., Namikawa, S. Y., & Hashimoto, M. (2012). Computational emotion recognition using multimodal physiological signals: Elicited using Japanese kanji words. *2012 35th International Conference on Telecommunications and Signal Processing, TSP 2012 - Proceedings*, 615–620. <https://doi.org/10.1109/TSP.2012.6256370>
- Tobii. (2023). Galvanic Skin Response (GSR). *Electrodermal Activity: Second Edition*, 9781461411260, 1–618. <https://doi.org/10.1007/978-1-4614-1126-0>
- University of Rochester. (n.d.). *Vital Signs (Body Temperature, Pulse Rate, Respiration Rate, Blood Pressure) - Health Encyclopedia - University of Rochester Medical Center*. Retrieved June 15, 2024, from <https://www.urmc.rochester.edu/encyclopedia/content.aspx?ContentTypeID=85&ContentID=P03963>
- Valenza, G., Lanata, A., & Scilingo, E. P. (2012). The role of nonlinear dynamics in affective valence and arousal recognition. *IEEE Transactions on Affective Computing*, 3(2), 237–249. <https://doi.org/10.1109/T-AFFC.2011.30>
- Verma, G. K., & Tiwary, U. S. (2014). Multimodal fusion framework: A multiresolution approach for emotion classification and recognition from physiological signals. *NeuroImage*, 102(P1), 162–172. <https://doi.org/10.1016/j.NEUROIMAGE.2013.11.007>
- Vitale, C., De Stefano, P., Lolatto, R., & Bianchi, A. M. (2020). Physiological responses related to pleasant and unpleasant sounds. *20th IEEE Mediterranean Electrotechnical Conference, MELECON 2020 - Proceedings*, 330–334. <https://doi.org/10.1109/MELECON48756.2020.9140579>

- Vries, H. de, Jonkman, A., Shi, Z.-H., Man, A. S., & Heunks, L. (2018). Assessing breathing effort in mechanical ventilation: physiology and clinical implications. *Annals of Translational Medicine*, 6(19), 387–387. <https://doi.org/10.21037/ATM.2018.05.53>
- Wang, Y., Song, W., Tao, W., Liotta, A., Yang, D., Li, X., Gao, S., Sun, Y., Ge, W., Zhang, W., & Zhang, W. (2022). A systematic review on affective computing: emotion models, databases, and recent advances. *Information Fusion*, 83–84, 19–52. <https://doi.org/10.1016/j.INFFUS.2022.03.009>
- Wu, C. K., Chung, P. C. J., & Wang, C. J. (2012). Representative segment-based emotion analysis and classification with automatic respiration signal segmentation. *IEEE Transactions on Affective Computing*, 3(4), 482–495. <https://doi.org/10.1109/T-AFFC.2012.14>
- Yang, W., Makita, K., Nakao, T., Kanayama, N., Machizawa, M. G., Sasaoka, T., Sugata, A., Kobayashi, R., Hiramoto, R., Yamawaki, S., Iwanaga, M., & Miyatani, M. (2018). Affective auditory stimulus database: An expanded version of the International Affective Digitized Sounds (IADS-E). *Behavior Research Methods*, 50(4), 1415–1429. <https://doi.org/10.3758/S13428-018-1027-6/TABLES/8>
- Zhang, Q., Chen, X., Zhan, Q., Yang, T., & Xia, S. (2017). Respiration-based emotion recognition with deep learning. *Computers in Industry*, 92–93, 84–90. <https://doi.org/10.1016/j.COMPIND.2017.04.005>
- Zhang, Q., Lai, X., & Liu, G. (2016). Emotion recognition of GSR based on an improved quantum neural network. *Proceedings - 2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics, IHMSC 2016*, 1, 488–492. <https://doi.org/10.1109/IHMSC.2016.66>

PRESUPUESTO

1. Introducción

La elaboración de un presupuesto resulta indispensable para la correcta ejecución y planificación de un estudio científico. Este permite gestionar de la mejor forma posible los recursos económicos disponibles y analizar si el coste que supone es viable y compensa los beneficios que se esperan obtener.

De esta forma, para proporcionar un presupuesto lo más detallado y completo posible, se desglosará en diferentes categorías. Se proporcionará el cuadro de mano de obra, que detalla los precios asociados al personal involucrado; el cuadro de maquinaria, que recoge los costos asociados al *software* y *hardware* empleado; el cuadro de presupuestos parciales, en el que se pueden visualizar los gastos de las diferentes secciones del proyecto; el cuadro de precios descompuestos, donde se detallan los precios unitarios de cada recurso utilizado en cada sección del estudio; y el presupuesto total, en el que se suman todos los costes detallados en los cuadros anteriores.

2. Cuadro de mano de obra

Núm.	Código	Denominación de la mano de obra	Precio (€)	Horas	Total (€)
1	MO.01	Técnico de investigación	15,00	70,50 h	1057,50
2	MO.02	Ingeniero biomédico estudiante	12,50	603,00 h	7.537,50
3	MO.03	Ingeniero biomédico doctorando	16,00	91,00 h	1.416,00
4	MO.04	Doctor en ingeniería	22,00	8,00 h	176,00
Total mano de obra:					10.187,00

3. Cuadro de maquinaria

El cálculo de los costes asociados a la maquinaria se realiza considerando la amortización, lo que permite distribuir el coste total a lo largo de la vida útil. Este cálculo se exceptúa para los electrodos *Skin Tact*, en los que se contempló el precio por unidad. Utilizando la amortización se consigue una visión más precisa y realista del gasto en la investigación, proporcionando unos costes que tienen en cuenta el tiempo de uso de cada recurso. En la Ecuación (1) se muestra la fórmula empleada para la amortización anual, en la que el valor residual hace referencia al valor del recurso al final de su vida útil, considerado como 0; y donde la vida útil se refiere al período de tiempo en el que se espera que el recurso se pueda utilizar con normalidad, considerado 5 años para todos los recursos, menos para el ordenador portátil (4 años), los cascos JBL (2 años) y la licencia de Office 365 (1 año).

$$\text{Amortización anual} = \frac{\text{Costo del recurso} - \text{Valor residual}}{\text{Vida útil}} \quad (1)$$

La amortización anual calculada para cada recurso se divide entre 2080 horas, correspondientes a un uso diario de 8 horas. Así, se obtiene el precio amortizado de cada recurso por hora, que se multiplicará por el tiempo de uso para este estudio.

Núm.	Código	Denominación de la maquinaria	Precio (€)	Cantidad	Total (€)
1	MAQ.01	Cascos JBL Tune 510BT	0,01	47,00 h	0,47
2	MAQ.02	Dispositivo de registro NIRxWINGS	3,37	47,00 h	158,39
3	MAQ.03	Electrodos <i>Skin Tact</i>	0,15	276,00 u	41,40
4	MAQ.04	Ordenador	0,21	47,00 h	9,87
5	MAQ.05	Software E-prime	0,09	47,00 h	4,23
6	MAQ.06	Ordenador portátil	0,14	550,00 h	77,00
7	MAQ.07	Licencia Office 365	0,03	200,00 h	6,00
Total maquinaria:					297,36

4. Cuadro de presupuestos parciales

1. RECOPIACIÓN DE DATOS

Núm.	Ud	Denominación	Cantidad	Precio (€)	Total (€)
1.1	u	Registro de datos	1,00	1.271,86	1.271,86
Total presupuesto parcial nº 1:					1.271,86

2. TRATAMIENTO DE DATOS Y ADQUISIÓN Y ANÁLISIS DE RESULTADOS

Núm.	Ud	Denominación	Cantidad	Precio (€)	Total (€)
2.1	u	Análisis de datos y extracción de resultados	1,00	4.938,00	4.938,00
2.2	u	Reuniones	1,00	721,50	721,50
Total presupuesto parcial nº 2:					5.659,50

3. REDACCIÓN Y ELABORACIÓN DE LA PRESENTACIÓN DEL TFG

Núm.	Ud	Denominación	Cantidad	Precio (€)	Total (€)
3.1	u	Redacción del documento escrito	1,00	3.090,00	3.090,00
3.2	u	Elaboración de la presentación	1,00	503,00	503,00
Total presupuesto parcial nº 3:					3.593,00

5. Cuadro de precios descompuestos

Núm.	Ud	Descripción	Precio por Ud	Total
1. RECOPIACIÓN DE DATOS.				
1.1	u	Registro de datos.		
MO.01	70,50 h	Técnico de investigación	15,00	1057,5
MAQ.01	47,00 h	Cascos JBL Tune 510BT	0,01	0,47
MAQ.02	47,00 h	Dispositivo de registro NIRxWINGS	3,37	158,39
MAQ.03	276,00 u	Electrodos <i>Skin Tact</i>	0,15	41,40
MAQ.04	47,00 h	Ordenador	0,21	9,87
MAQ.05	47,00 h	Software E-prime	0,09	4,23
Total por u				1.271,86
2. TRATAMIENTO DE DATOS Y ADQUISICIÓN Y ANÁLISIS DE RESULTADOS.				
2.1	u	Análisis de datos y extracción de resultados.		
MO.02	350,000 h	Ingeniero biomédico estudiante	12,50	4.375,00
MO.03	30,000 h	Ingeniero biomédico doctorando	16,00	480,00
MAQ.06	550,000 h	Ordenador portátil	0,14	77,00
MAQ.07	200,000 h	Licencia Office 365	0,03	6,00
Total por u				4.938,00
2.2	u	Reuniones.		
MO.02	23,000 h	Ingeniero biomédico estudiante	12,50	287,50
MO.03	23,000 h	Ingeniero biomédico doctorando	16,00	368,00
MO.05	3,000 h	Doctor en ingeniería	22,00	66,00
Total por u				721,50
3. REDACCIÓN Y ELABORACIÓN DE LA PRESENTACIÓN DEL TFG.				
3.1	u	Redacción del documento escrito.		
MO.03	200,000 h	Ingeniero biomédico estudiante	12,50	2.500,00
MO.04	30,000 h	Ingeniero biomédico doctorando	16,00	480,00
MO.05	5,000 h	Doctor en ingeniería	22,00	110,00
Total por u				3.090,00
3.2	u	Elaboración de la presentación.		

MO.03	30,000	h	Ingeniero biomédico estudiante	12,50	375,00
MO.04	8,000	h	Ingeniero biomédico doctorando	16,00	128,00
Total por u					503,00

6. Presupuesto total

<i>Capítulo</i>	Importe (€)
Capítulo 1. Recopilación de datos	1.271,86
Capítulo 2. Tratamiento de datos y adquisición y análisis de resultados	5.659,50
Capítulo 3. Redacción y elaboración de la presentación del tfg	3.593,00
<i>Presupuesto de ejecución material</i>	10.524,36
Gastos generales (13%)	1.368,17
Beneficio industrial (6%)	631,46
<i>Presupuesto de ejecución por contrata</i>	12.523,99
IVA (21%)	2.630,04
<i>Presupuesto total</i>	15.154,03

El presupuesto total asciende a la cantidad de QUINCE MIL CIENTO CINCUENTA Y CUATRO CON TRES.

ANEXOS

1. Estadísticos para las características extraídas y nivel de significancia

El anexo recoge las medias y desviaciones estándar obtenidas para cada una de las características extraídas de los bloques de estímulos positivos, negativos y eróticos; así como para los niveles alto y bajo de valencia, dominancia y excitación. El nivel alto de cualquiera de las tres dimensiones se considera a partir de la puntuación 7, mientras que el nivel bajo a partir de la 3. Asimismo, también se proporciona el nivel de significancia para cada combinación de estímulos y niveles de dimensiones del SAM obtenido tras la prueba de Mann-Whitney con la corrección de Bonferroni. Todo ello se recoge para la señal de GSR, por un lado, y para la señal de RSP, por otro, enventanadas con intervalos de 60 segundos solapados al 50%.

GSR Ventanas 60 seg solapamiento 50% Estímulos

Característica	Estímulo positivo media \pm std	Estímulo negativo media \pm std	Estímulo erótico media \pm std	Significancia Positivo VS Negativo	Significancia Positivo VS Erótico	Significancia Negativo VS Erótico
Media	0,68 \pm 4,92	-0,02 \pm 1,80	0,32 \pm 11,51	**	**	**
Mediana	0,70 \pm 5,31	-0,02 \pm 1,98	0,37 \pm 12,10	**	**	**
Std	-1,27 \pm 6,26	0,01 \pm 2,98	0,10 \pm 9,38	**	**	**
RMS	0,67 \pm 4,92	-0,02 \pm 1,79	0,32 \pm 11,50	**	**	**
Curtosis	0,01 \pm 3,98	-0,07 \pm 4,49	0,17 \pm 4,91			
Asimetría	0,03 \pm 2,54	-0,35 \pm 2,84	0,35 \pm 2,84	*		*
Máximo	0,57 \pm 4,55	0,01 \pm 1,44	0,32 \pm 10,21	*	**	*
Mínimo	0,92 \pm 5,81	-0,06 \pm 1,97	0,51 \pm 13,67	**	**	**
Media 1ª derivada	0,20 \pm 4,67	0,51 \pm 3,07	-0,89 \pm 6,95		**	
Media 2ª derivada	-0,45 \pm 6,38	-0,86 \pm 6,37	-0,76 \pm 7,64			
Media diferencias absolutas	-1,11 \pm 4,74	-0,29 \pm 2,79	0,26 \pm 12,46	**	**	**
Media diferencias absolutas norm	-0,29 \pm 2,38	-0,27 \pm 2,08	-0,09 \pm 3,08			
Media variaciones locales	-0,45 \pm 6,37	-0,86 \pm 6,37	-0,76 \pm 7,64			
Media variaciones locales norm	-1,04 \pm 8,05	-0,71 \pm 5,91	-1,02 \pm 9,65			
Área magnitud	10,02 \pm 295,31	-1,81 \pm 15,90	9,09 \pm 263,75		**	
Frecuencia máxima	-0,10 \pm 2,83	0,06 \pm 2,68	-0,22 \pm 2,91			
Varianza frecuencia	10,11 \pm 297,74	-1,81 \pm 15,95	9,01 \pm 263,70		**	
Curtosis frecuencia	-0,01 \pm 2,91	0,16 \pm 2,98	-0,19 \pm 3,02			

Análisis de las respuestas fisiológicas ante estímulos auditivos con distinta carga emocional

Asimetría frecuencia	-0,23 ± 2,57	-0,03 ± 2,71	0,06 ± 2,65			
Número picos SCR	-0,10 ± 2,11	-0,05 ± 1,85	0,31 ± 2,20		*	
Amplitud media picos SCR	0,15 ± 8,71	-0,51 ± 3,81	0,82 ± 12,10		**	
Std amplitud SCL	-1,19 ± 6,12	0,07 ± 2,87	0,10 ± 8,60	**	**	**

GSR Ventanas 60 seg solapamiento 50% SAM

Característica	Valencia alta media \pm std	Valencia baja media \pm std	Significancia alta VS baja
Media	-0,22 \pm 2,25	-0,17 \pm 2,14	
Mediana	-0,21 \pm 2,28	-0,21 \pm 2,41	
Std	-0,29 \pm 4,57	-0,02 \pm 3,09	
RMS	-0,22 \pm 2,25	-0,17 \pm 2,13	
Curtosis	0,01 \pm 4,04	-0,02 \pm 4,55	
Asimetría	0,00 \pm 2,61	-0,24 \pm 3,01	
Máximo	-0,30 \pm 2,16	-0,07 \pm 1,62	
Mínimo	-0,12 \pm 2,44	-0,16 \pm 2,31	
Media 1ª derivada	0,32 \pm 4,68	0,12 \pm 2,99	
Media 2ª derivada	-1,12 \pm 5,86	-1,42 \pm 6,48	
Media diferencias absolutas	-0,06 \pm 2,58	-0,34 \pm 2,72	
Media diferencias absolutas norm	-0,11 \pm 2,22	-0,16 \pm 2,03	
Media variaciones locales	-1,12 \pm 5,86	-1,42 \pm 6,48	
Media variaciones locales norm	-1,16 \pm 8,24	-1,37 \pm 6,59	
Área magnitud	0,18 \pm 7,38	-2,81 \pm 16,82	
Frecuencia máxima	0,07 \pm 2,77	0,10 \pm 2,73	
Varianza frecuencia	0,19 \pm 7,38	-2,82 \pm 16,87	
Curtosis frecuencia	0,04 \pm 2,89	0,09 \pm 2,90	
Asimetría frecuencia	-0,09 \pm 2,58	-0,06 \pm 2,67	
Número picos SCR	0,07 \pm 2,13	0,00 \pm 1,75	
Amplitud media picos SCR	0,14 \pm 3,19	-0,58 \pm 3,92	
Std amplitud SCL	-0,26 \pm 4,56	0,02 \pm 2,88	
Característica	Dominancia alta media \pm std	Dominancia baja media \pm std	Significancia alta VS baja
Media	-0,07 \pm 1,50	-0,45 \pm 1,88	*
Mediana	-0,08 \pm 1,54	-0,45 \pm 2,04	*
Std	-0,62 \pm 4,04	0,83 \pm 5,42	**
RMS	-0,07 \pm 1,50	-0,45 \pm 1,88	*
Curtosis	0,09 \pm 3,40	-0,13 \pm 5,22	
Asimetría	0,26 \pm 2,56	-0,09 \pm 2,84	
Máximo	-0,10 \pm 1,59	-0,36 \pm 1,59	*
Mínimo	0,07 \pm 1,55	-0,45 \pm 2,32	**
Media 1ª derivada	0,22 \pm 3,92	-0,83 \pm 7,78	
Media 2ª derivada	-0,04 \pm 6,86	-0,59 \pm 6,46	
Media diff absolutas	-0,64 \pm 2,32	1,32 \pm 7,68	**
Media diff absolutas norm	-0,15 \pm 2,17	-0,02 \pm 2,74	
Media variaciones locales	-0,04 \pm 6,85	-0,59 \pm 6,48	

Media variaciones locales norm	-0,55 ± 6,68	-0,54 ± 5,55	
Área magnitud	-1,46 ± 7,93	27,68 ± 328,71	**
Frecuencia máxima	0,04 ± 2,72	0,09 ± 2,74	
Varianza frecuencia	-1,46 ± 7,93	27,64 ± 328,24	**
Curtosis frecuencia	-0,03 ± 2,67	0,18 ± 3,31	
Asimetría frecuencia	-0,22 ± 2,43	-0,19 ± 2,85	
Número picos SCR	-0,01 ± 1,99	0,20 ± 2,11	
Amplitud media picos SCR	-0,52 ± 2,80	1,97 ± 14,14	**
Std amplitud SCL	-0,56 ± 4,03	0,74 ± 5,05	**
Característica	Excitación alta media ± std	Excitación baja media ± std	Significancia alta VS baja
Media	-0,48 ± 2,69	1,62 ± 13,55	**
Mediana	-0,49 ± 2,86	1,70 ± 14,25	**
Std	0,27 ± 4,96	-1,51 ± 9,57	**
RMS	-0,48 ± 2,68	1,62 ± 13,54	**
Curtosis	0,16 ± 4,17	0,38 ± 3,52	
Asimetría	0,15 ± 2,66	-0,12 ± 2,40	
Máximo	-0,36 ± 2,25	1,35 ± 12,02	**
Mínimo	-0,54 ± 2,87	2,01 ± 16,17	**
Media 1ª derivada	-0,42 ± 6,89	-0,38 ± 3,72	
Media 2ª derivada	-0,70 ± 6,08	-0,90 ± 6,78	
Media diff absolutas	0,76 ± 5,53	-1,88 ± 13,01	**
Media diff absolutas norm	-0,16 ± 2,94	0,12 ± 2,08	
Media variaciones locales	-0,70 ± 6,09	-0,90 ± 6,78	
Media variaciones locales norm	-0,53 ± 6,14	-1,07 ± 7,21	
Área magnitud	3,26 ± 54,27	-13,20 ± 111,13	
Frecuencia máxima	0,18 ± 2,71	-0,21 ± 2,85	
Varianza frecuencia	3,26 ± 54,25	-13,31 ± 112,07	
Curtosis frecuencia	-0,35 ± 2,97	0,07 ± 2,91	
Asimetría frecuencia	0,13 ± 2,49	-0,37 ± 2,49	*
Número picos SCR	0,10 ± 2,16	-0,01 ± 1,95	
Amplitud media picos SCR	0,80 ± 8,73	-0,82 ± 6,65	
Std amplitud SCL	0,23 ± 4,80	-1,36 ± 8,73	*

RSP Ventanas 60 seg solapamiento 50% Estímulos

Característica	Estímulo positivo media ± std	Estímulo negativo media ± std	Estímulo erótico media ± std	Significancia Positivo VS Negativo	Significancia Positivo VS Erótico	Significancia Negativo VS Erótico
RSP Rate Mean	1,20 ± 2,99	1,33 ± 2,81	1,33 ± 2,81		**	
RRV RMSSD	-0,79 ± 5,94	-0,16 ± 4,57	-0,16 ± 4,57			
RRV MeanBB	-1,44 ± 3,90	-1,49 ± 3,86	-1,49 ± 3,86		*	
RRV SDBB	-0,66 ± 5,13	-0,28 ± 3,96	-0,28 ± 3,96			
RRV SDSD	-0,80 ± 6,01	-0,16 ± 4,76	-0,16 ± 4,76			
RRV CVBB	-0,40 ± 4,03	0,00 ± 3,27	0,00 ± 3,27		*	
RRV CVSD	-0,53 ± 4,72	0,13 ± 3,70	0,13 ± 3,70	*		*
RRV MedianBB	-1,52 ± 4,46	-1,70 ± 4,51	-1,70 ± 4,51		**	
RRV MadBB	-0,37 ± 3,80	-0,55 ± 6,06	-0,55 ± 6,06			
RRV MCVBB	-0,21 ± 3,18	-0,23 ± 3,80	-0,23 ± 3,80			
RRV LF	0,24 ± 2,24	0,42 ± 2,41	0,42 ± 2,41			
RRV HF	0,61 ± 4,60	1,00 ± 5,48	1,00 ± 5,48			
RRV LFHF	-0,35 ± 4,27	-1,16 ± 5,01	-1,16 ± 5,01		*	
RRV SD1	-0,80 ± 6,01	-0,16 ± 4,76	-0,16 ± 4,76			
RRV SD2	-0,58 ± 4,22	-0,36 ± 3,71	-0,36 ± 3,71			
RRV SD2SD1	-0,08 ± 2,82	-0,25 ± 2,93	-0,25 ± 2,93			
RRV ApEn	-0,23 ± 2,22	0,22 ± 2,98	0,22 ± 2,98			
RSP RVT	-0,75 ± 2,58	-0,38 ± 3,65	-0,38 ± 3,65			
RAV Mean	-1,38 ± 3,65	-0,79 ± 5,76	-0,79 ± 5,76			
RAV SD	-1,28 ± 7,74	-0,72 ± 5,74	-0,72 ± 5,74			
RAV RMSSD	-1,54 ± 8,39	-0,57 ± 5,73	-0,57 ± 5,73			
RAV CVSD	-0,37 ± 5,02	0,22 ± 3,23	0,22 ± 3,23			
RSP Symmetry PeakTrough	-1,19 ± 5,54	-1,11 ± 4,36	-1,11 ± 4,36			
RSP Symmetry RiseDecay	0,64 ± 4,26	-0,05 ± 4,11	-0,05 ± 4,11			
RSP Phase Duration Inspiration	-1,26 ± 4,04	-1,45 ± 3,90	-1,45 ± 3,90		*	
RSP Phase Duration Expiration	-1,54 ± 4,26	-1,43 ± 3,86	-1,43 ± 3,86			
RSP Phase Duration Ratio	1,02 ± 5,64	0,31 ± 6,00	0,31 ± 6,00			

RSP Ventanas 60 seg solapamiento 50% SAM

Característica	Valencia alta media ± std	Valencia baja media ± std	Significancia alta VS baja
RSP Rate Mean	1,46 ± 2,93	1,42 ± 2,81	
RRV RMSSD	-0,58 ± 5,26	-0,03 ± 4,56	
RRV MeanBB	-1,70 ± 3,98	-1,47 ± 3,72	
RRV SDBB	-0,44 ± 4,14	-0,12 ± 3,93	
RRV SDSD	-0,60 ± 5,29	-0,01 ± 4,75	
RRV CVBB	-0,14 ± 3,39	0,11 ± 3,35	
RRV CVSD	-0,28 ± 4,22	0,18 ± 3,78	
RRV MedianBB	-1,89 ± 4,79	-1,46 ± 4,03	
RRV MadBB	-0,40 ± 4,64	0,02 ± 5,16	
RRV MCVBB	-0,09 ± 3,47	0,07 ± 3,53	
RRV LF	0,30 ± 2,28	0,42 ± 2,35	
RRV HF	0,77 ± 4,83	1,12 ± 5,55	
RRV LFHF	-0,48 ± 3,51	-0,89 ± 3,70	
RRV SD1	-0,60 ± 5,29	-0,01 ± 4,75	
RRV SD2	-0,42 ± 3,57	-0,27 ± 3,69	
RRV SD2SD1	-0,02 ± 2,58	-0,12 ± 2,72	
RRV ApEn	-0,01 ± 2,44	0,33 ± 2,88	
RSP RVT	-0,86 ± 2,72	-0,19 ± 3,98	
RAV Mean	-1,47 ± 3,69	-0,57 ± 6,39	
RAV SD	-0,76 ± 6,65	-0,45 ± 5,48	
RAV RMSSD	-1,01 ± 7,92	-0,10 ± 4,77	
RAV CVSD	0,12 ± 4,43	0,31 ± 3,14	
RSP Symmetry PeakTrough	-1,03 ± 6,03	-1,42 ± 4,42	
RSP Symmetry RiseDecay	0,45 ± 4,09	-0,24 ± 4,24	
RSP Phase Duration Inspiration	-1,53 ± 3,97	-1,53 ± 3,94	
RSP Phase Duration Expiration	-1,74 ± 4,05	-1,40 ± 3,71	
RSP Phase Duration Ratio	0,86 ± 5,55	0,19 ± 6,63	
Característica	Dominancia alta media ± std	Dominancia baja media ± std	Significancia alta VS baja
RSP Rate Mean	1,93 ± 3,39	1,52 ± 3,02	
RRV RMSSD	-0,96 ± 6,96	-0,48 ± 5,87	
RRV MeanBB	-2,27 ± 4,76	-1,72 ± 3,98	
RRV SDBB	-0,79 ± 5,58	-0,44 ± 4,55	
RRV SDSD	-1,02 ± 7,20	-0,49 ± 6,17	
RRV CVBB	-0,43 ± 4,38	-0,01 ± 3,49	
RRV CVSD	-0,51 ± 5,07	-0,12 ± 4,57	
RRV MedianBB	-2,27 ± 5,06	-1,79 ± 3,69	
RRV MadBB	-0,48 ± 5,46	-0,38 ± 4,14	

RRV MCVBB	-0,22 ± 3,72	-0,11 ± 3,33	
RRV LF	0,18 ± 2,47	0,49 ± 2,41	
RRV HF	0,55 ± 4,94	0,62 ± 4,15	
RRV LFHF	-1,09 ± 4,52	-0,53 ± 4,90	
RRV SD1	-1,02 ± 7,20	-0,49 ± 6,17	
RRV SD2	-0,74 ± 4,51	-0,49 ± 4,15	
RRV SD2SD1	-0,14 ± 2,73	0,03 ± 2,57	
RRV ApEn	0,20 ± 2,90	0,19 ± 2,34	
RSP RVT	-1,01 ± 3,30	-0,58 ± 3,17	
RAV Mean	-2,10 ± 5,57	-1,05 ± 6,71	
RAV SD	-1,47 ± 7,76	-0,88 ± 6,66	
RAV RMSSD	-1,37 ± 7,12	-0,82 ± 7,87	*
RAV CVSD	-0,05 ± 4,15	0,16 ± 4,78	
RSP Symmetry PeakTrough	-1,17 ± 5,39	-1,59 ± 5,32	
RSP Symmetry RiseDecay	0,78 ± 4,45	0,10 ± 4,31	
RSP Phase Duration Inspiration	-2,06 ± 4,84	-1,73 ± 4,14	
RSP Phase Duration Expiration	-2,07 ± 4,49	-1,73 ± 4,22	
RSP Phase Duration Ratio	0,47 ± 6,93	0,61 ± 6,77	
Característica	Excitación alta media ± std	Excitación baja media ± std	Significancia alta VS baja
RSP Rate Mean	1,94 ± 2,86	1,48 ± 3,23	**
RRV RMSSD	-0,25 ± 4,82	-0,69 ± 6,61	
RRV MeanBB	-2,18 ± 3,87	-1,68 ± 4,30	*
RRV SDBB	-0,43 ± 4,18	-0,57 ± 5,88	
RRV SDSD	-0,23 ± 4,89	-0,70 ± 6,71	
RRV CVBB	0,01 ± 3,52	-0,27 ± 4,62	
RRV CVSD	0,12 ± 3,98	-0,42 ± 5,31	
RRV MedianBB	-2,51 ± 4,20	-1,74 ± 5,09	**
RRV MadBB	-0,91 ± 5,20	-0,14 ± 5,21	
RRV MCVBB	-0,31 ± 3,40	-0,03 ± 3,70	
RRV LF	0,42 ± 2,53	0,24 ± 2,27	
RRV HF	0,79 ± 4,44	0,72 ± 4,87	
RRV LFHF	-0,82 ± 4,52	-0,67 ± 3,71	
RRV SD1	-0,23 ± 4,89	-0,70 ± 6,71	
RRV SD2	-0,52 ± 3,87	-0,63 ± 4,74	
RRV SD2SD1	-0,08 ± 2,77	-0,19 ± 2,75	
RRV ApEn	0,11 ± 3,10	-0,07 ± 2,55	
RSP RVT	-0,75 ± 3,22	-0,98 ± 2,66	
RAV Mean	-1,33 ± 5,69	-1,72 ± 3,82	
RAV SD	-0,73 ± 5,50	-1,61 ± 8,54	
RAV RMSSD	-0,80 ± 6,13	-1,82 ± 9,30	

RAV CVSD	0,28 ± 3,67	-0,31 ± 5,49	
RSP Symmetry PeakTrough	-1,01 ± 5,21	-1,24 ± 5,01	
RSP Symmetry RiseDecay	0,27 ± 5,06	0,67 ± 4,61	
RSP Phase Duration Inspiration	-2,09 ± 3,81	-1,48 ± 4,47	**
RSP Phase Duration Expiration	-2,07 ± 3,99	-1,77 ± 4,59	
RSP Phase Duration Ratio	0,58 ± 6,58	1,12 ± 6,17	

2. Métricas para los clasificadores de emociones utilizados para la comparación inicial

El anexo recoge las métricas obtenidas para los clasificadores de pares de estímulos positivos, negativos o eróticos y los niveles alto y bajo de valencia, dominancia y excitación. Esto se realizó para modelos independientes del sujeto, en los que el entrenamiento tenía en cuenta a todos los sujetos, y para modelos dependientes del sujeto, por los que se obtenía un modelo para cada sujeto y se obtenía la media de todos los modelos. Al mismo tiempo, se probó para la normalización de características MAD, que normaliza el estímulo con respecto al descanso anterior, y para la normalización 01, que sustrae la media a la característica y la divide por la desviación estándar para cada sujeto. Todo ello se realizó para la señal GSR, RSP y la combinación de ambas con enventanados de 60 segundos y de 60 segundos con solapamiento al 50%. Adicionalmente, se probaron ventanas de 15 segundos para la señal de GSR.

El entrenamiento de los modelos se realizó con una selección de características basada en la elección de aquellas que fueron identificadas con una diferencia estadísticamente significativa por la prueba de Mann-Whitney tras la corrección de Bonferroni, marcados como '*Con selección de características*'. Si no se obtenían características con una diferencia significativa o el número de estas era mínimo, no se aplicó ninguna selección de características, identificado en el anexo como '*Sin selección de características*'.

En cuanto a la validación cruzada, se probó con diferentes métodos en función de la dependencia/independencia del modelo con respecto a los sujetos:

- Modelos independientes del sujeto: se aplicó una validación *Leave One Subject Out* (LOSO), en la que se realizaban N entrenamientos y validaciones del modelo, donde N es el número de sujetos. En cada una de las iteraciones se utilizó un sujeto como subconjunto de validación y los N-1 restantes como subconjunto de entrenamiento.
- Modelos dependientes del sujeto: en estos modelos se aplicó una validación diferente para el conjunto de datos que provenía de ventanas sin solapar y el que provenía de ventanas solapadas:
 - Ventanas sin solapamiento: se utilizó una validación *Stratified K-Fold* (SKF), por la que se realizaban K iteraciones, donde K se consideró como el mínimo de muestras entre las dos clases del sujeto. En cada una de las iteraciones uno de los K pliegues se utilizaba para validación y los K-1 restantes para entrenamiento, con la particularidad de que el método aseguraba que en cada pliegue existiera la misma proporción de clases que en el conjunto de datos original.
 - Ventanas con solapamiento: se eliminó la tercera ventana de cada estímulo para reducir la influencia del solapamiento y se empleó una validación *Leave One Group Out* (LOGO), por la que se extraían dos grupos para cada estímulo, uno formado por la primera y la tercera ventana, y otro formado por la

segunda y la cuarta. De esta forma, se pretendía reducir el efecto de introducir datos de validación en el entrenamiento. En cada iteración un grupo se usaba para validación y los demás para entrenamiento.

GSR: intervalos de 60 segundos

CON SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → SKF (k = min muestras entre clases)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media ± std
MAD	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.4598 ± 0.1611
				F1 Score	0.4328 ± 0.1692
				Precisión	0.4506 ± 0.1957
			RF	Exactitud	0.4821 ± 0.1351
				F1 Score	0.4493 ± 0.1481
				Precisión	0.4700 ± 0.1740
		SVM	Exactitud	0.5274 ± 0.1020	
			F1 Score	0.3546 ± 0.1052	
			Precisión	0.2756 ± 0.1185	
		DEPENDIENTE	KNN	Exactitud	0.7188 ± 0.2462
				F1 Score	0.6431 ± 0.3003
				Precisión	0.6081 ± 0.3279
			RF	Exactitud	0.7161 ± 0.2520
				F1 Score	0.6408 ± 0.3020
				Precisión	0.6057 ± 0.3279
	SVM		Exactitud	0.7351 ± 0.2360	
			F1 Score	0.6659 ± 0.2873	
			Precisión	0.6345 ± 0.3127	
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.6000 ± 0.1572
				F1 Score	0.5819 ± 0.1709
				Precisión	0.6050 ± 0.1724
			RF	Exactitud	0.6194 ± 0.1262
				F1 Score	0.5961 ± 0.1430
				Precisión	0.6252 ± 0.1543
		SVM	Exactitud	0.6083 ± 0.1776	
			F1 Score	0.5780 ± 0.1940	
			Precisión	0.6266 ± 0.2064	
		DEPENDIENTE	KNN	Exactitud	0.7446 ± 0.2330
				F1 Score	0.6765 ± 0.2825
				Precisión	0.6494 ± 0.3127
RF			Exactitud	0.7805 ± 0.2266	
			F1 Score	0.7205 ± 0.2824	
			Precisión	0.6955 ± 0.3104	
SVM	Exactitud		0.7940 ± 0.2090		
	F1 Score		0.7341 ± 0.2518		
	Precisión		0.7110 ± 0.2801		
NEGATIVO VS	INDEPENDIENTE	KNN	Exactitud	0.5873 ± 0.1485	
			F1 Score	0.5677 ± 0.1555	

	ERÓTICO		RF	Precisión	0.5959 ± 0.1739
				Exactitud	0.5798 ± 0.1331
				F1 Score	0.5629 ± 0.1426
			SVM	Precisión	0.5818 ± 0.1649
				Exactitud	0.5131 ± 0.0982
				F1 Score	0.3550 ± 0.1173
		DEPENDIENTE	KNN	Precisión	0.2759 ± 0.1337
				Exactitud	0.6992 ± 0.2633
				F1 Score	0.6232 ± 0.3098
			RF	Precisión	0.5915 ± 0.3369
				Exactitud	0.7215 ± 0.2625
				F1 Score	0.6521 ± 0.3114
		SVM	Precisión	0.6236 ± 0.3381	
			Exactitud	0.7046 ± 0.2375	
			F1 Score	0.6267 ± 0.2804	
Precisión	0.5955 ± 0.3060				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media ± std
01	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.4884 ± 0.1321
				F1 Score	0.4683 ± 0.1335
				Precisión	0.4918 ± 0.1448
			RF	Exactitud	0.5044 ± 0.1668
				F1 Score	0.4816 ± 0.1711
				Precisión	0.5072 ± 0.1907
		SVM	Exactitud	0.5574 ± 0.1828	
			F1 Score	0.5122 ± 0.1988	
			Precisión	0.5692 ± 0.2353	
		DEPENDIENTE	KNN	Exactitud	0.7066 ± 0.2546
				F1 Score	0.6383 ± 0.2946
				Precisión	0.6087 ± 0.3164
	RF		Exactitud	0.7215 ± 0.2485	
			F1 Score	0.6573 ± 0.2851	
			Precisión	0.6280 ± 0.3040	
	SVM	Exactitud	0.7161 ± 0.2335		
		F1 Score	0.6500 ± 0.2732		
		Precisión	0.6209 ± 0.2920		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5536 ± 0.1396
				F1 Score	0.5319 ± 0.1480
				Precisión	0.5499 ± 0.1529
			RF	Exactitud	0.5636 ± 0.1606
				F1 Score	0.5419 ± 0.1648
				Precisión	0.5619 ± 0.1745
SVM		Exactitud	0.5833 ± 0.1362		
		F1 Score	0.5574 ± 0.1473		
		Precisión	0.6047 ± 0.1505		
DEPENDIENTE		KNN	Exactitud	0.6572 ± 0.2638	

				F1 Score	0.5761 ± 0.2925
				Precisión	0.5427 ± 0.3103
			RF	Exactitud	0.6985 ± 0.2573
				F1 Score	0.6189 ± 0.2912
			SVM	Precisión	0.5871 ± 0.3128
				Exactitud	0.6762 ± 0.2547
	NEGATIVO VS ERÓTICO	INDEPENDIENTE	KNN	F1 Score	0.6025 ± 0.2884
				Precisión	0.5725 ± 0.3067
				Exactitud	0.5030 ± 0.1584
			RF	F1 Score	0.4793 ± 0.1633
				Precisión	0.4929 ± 0.1817
				Exactitud	0.4836 ± 0.1238
	SVM	F1 Score	0.4582 ± 0.1228		
		Precisión	0.4749 ± 0.1414		
		Exactitud	0.5091 ± 0.0842		
	NEGATIVO VS ERÓTICO	DEPENDIENTE	KNN	F1 Score	0.3509 ± 0.0991
				Precisión	0.2715 ± 0.1133
				Exactitud	0.7073 ± 0.2541
			RF	F1 Score	0.6281 ± 0.3007
				Precisión	0.5959 ± 0.3244
Exactitud				0.7161 ± 0.2609	
SVM	F1 Score	0.6469 ± 0.2976			
	Precisión	0.6172 ± 0.3177			
	Exactitud	0.6098 ± 0.3298			

RSP: intervalos de 60 segundos

CON SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → SKF (k = min muestras entre clases)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media ± std	
MAD	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5142 ± 0.1166	
				F1 Score	0.5045 ± 0.1202	
				Precisión	0.5160 ± 0.1237	
			RF	Exactitud	0.5309 ± 0.1096	
				F1 Score	0.5157 ± 0.1167	
				Precisión	0.5274 ± 0.1275	
		SVM	Exactitud	0.5037 ± 0.0246		
			F1 Score	0.3398 ± 0.0430		
			Precisión	0.2584 ± 0.0558		
		DEPENDIENTE	KNN	Exactitud	0.6944 ± 0.2640	
				F1 Score	0.6170 ± 0.3175	
				Precisión	0.5808 ± 0.3443	
	RF		Exactitud	0.6742 ± 0.2836		
			F1 Score	0.6027 ± 0.3248		
			Precisión	0.5669 ± 0.3485		
	SVM		Exactitud	0.7203 ± 0.2814		
			F1 Score	0.6545 ± 0.3330		
			Precisión	0.6218 ± 0.3608		
	POSITIVO VS ERÓTICO		INDEPENDIENTE	KNN	Exactitud	0.5648 ± 0.1271
					F1 Score	0.5537 ± 0.1317
					Precisión	0.5705 ± 0.1387
		RF		Exactitud	0.5820 ± 0.1614	
				F1 Score	0.5699 ± 0.1693	
				Precisión	0.5846 ± 0.1746	
		SVM	Exactitud	0.6045 ± 0.1466		
			F1 Score	0.5847 ± 0.1585		
			Precisión	0.6178 ± 0.1823		
		DEPENDIENTE	KNN	Exactitud	0.7358 ± 0.2689	
				F1 Score	0.6685 ± 0.3222	
				Precisión	0.6348 ± 0.3506	
RF			Exactitud	0.7385 ± 0.2772		
			F1 Score	0.6739 ± 0.3317		
			Precisión	0.6416 ± 0.3609		
SVM		Exactitud	0.7710 ± 0.2537			
		F1 Score	0.7100 ± 0.3097			
		Precisión	0.6795 ± 0.3395			
NEGATIVO VS	INDEPENDIENTE	KNN	Exactitud	0.5099 ± 0.1169		
			F1 Score	0.4988 ± 0.1184		

	ERÓTICO	DEPENDIENTE	RF	Precisión	0.5148 ± 0.1292
				Exactitud	0.4980 ± 0.1359
				F1 Score	0.4806 ± 0.1398
			SVM	Precisión	0.5007 ± 0.1542
				Exactitud	0.5017 ± 0.1532
				F1 Score	0.4783 ± 0.1658
		INDEPENDIENTE	KNN	Precisión	0.4873 ± 0.1894
				Exactitud	0.6824 ± 0.2478
				F1 Score	0.5911 ± 0.3053
			RF	Precisión	0.5464 ± 0.3353
				Exactitud	0.7064 ± 0.2802
				F1 Score	0.6346 ± 0.3318
		SVM	Precisión	0.5994 ± 0.3593	
			Exactitud	0.7229 ± 0.2730	
			F1 Score	0.6569 ± 0.3217	
Precisión	0.6250 ± 0.3482				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media ± std
01	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5056 ± 0.1179
				F1 Score	0.4974 ± 0.1228
				Precisión	0.5042 ± 0.1241
			RF	Exactitud	0.5222 ± 0.1264
				F1 Score	0.5060 ± 0.1367
				Precisión	0.5153 ± 0.1470
		SVM	Exactitud	0.5241 ± 0.1255	
			F1 Score	0.4883 ± 0.1426	
			Precisión	0.5237 ± 0.1811	
		DEPENDIENTE	KNN	Exactitud	0.6004 ± 0.2850
				F1 Score	0.5171 ± 0.3200
				Precisión	0.4776 ± 0.3400
	RF		Exactitud	0.5941 ± 0.3066	
			F1 Score	0.5145 ± 0.3352	
			Precisión	0.4763 ± 0.3535	
	SVM	Exactitud	0.6048 ± 0.2620		
		F1 Score	0.5120 ± 0.2959		
		Precisión	0.4675 ± 0.3146		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5277 ± 0.1145
				F1 Score	0.5114 ± 0.1197
				Precisión	0.5279 ± 0.1242
			RF	Exactitud	0.5254 ± 0.1463
				F1 Score	0.5087 ± 0.1539
				Precisión	0.5247 ± 0.1610
SVM		Exactitud	0.5435 ± 0.1683		
		F1 Score	0.5168 ± 0.1823		
		Precisión	0.5374 ± 0.2083		
DEPENDIENTE		KNN	Exactitud	0.6515 ± 0.2792	

				F1 Score	0.5695 ± 0.3229
				Precisión	0.5284 ± 0.3477
			RF	Exactitud	0.6528 ± 0.2815
				F1 Score	0.5740 ± 0.3245
			SVM	Precisión	0.5360 ± 0.3481
				Exactitud	0.6755 ± 0.2891
	F1 Score	0.5989 ± 0.3338			
	NEGATIVO VS ERÓTICO	INDEPENDIENTE	KNN	Precisión	0.5606 ± 0.3592
				Exactitud	0.5143 ± 0.1401
				F1 Score	0.4992 ± 0.1475
			RF	Precisión	0.5109 ± 0.1623
				Exactitud	0.5202 ± 0.1193
				F1 Score	0.5100 ± 0.1228
		SVM	Precisión	0.5200 ± 0.1283	
			Exactitud	0.5326 ± 0.1322	
			F1 Score	0.4994 ± 0.1480	
		DEPENDIENTE	KNN	Precisión	0.5368 ± 0.1891
				Exactitud	0.6225 ± 0.2860
				F1 Score	0.5463 ± 0.3206
	RF		Precisión	0.5098 ± 0.3414	
Exactitud			0.6199 ± 0.2808		
F1 Score			0.5398 ± 0.3142		
SVM	Precisión	0.5009 ± 0.3339			
	Exactitud	0.6225 ± 0.2830			
	F1 Score	0.5435 ± 0.3124			
			Precisión	0.5051 ± 0.3305	

GSR + RSP: intervalos de 60 segundos

SIN SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → SKF (k = min muestras entre clases)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media ± std
MAD	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5437 ± 0.1475
				F1 Score	0.5249 ± 0.1486
				Precisión	0.5466 ± 0.1562
			RF	Exactitud	0.5121 ± 0.1538
				F1 Score	0.4838 ± 0.1559
				Precisión	0.5004 ± 0.1680
		SVM	Exactitud	0.5099 ± 0.1429	
			F1 Score	0.4771 ± 0.1470	
			Precisión	0.5034 ± 0.1779	
		DEPENDIENTE	KNN	Exactitud	0.7895 ± 0.2133
				F1 Score	0.7284 ± 0.2639
				Precisión	0.7032 ± 0.2929
	RF		Exactitud	0.8107 ± 0.1997	
			F1 Score	0.7536 ± 0.2493	
			Precisión	0.7306 ± 0.2740	
	SVM	Exactitud	0.8977 ± 0.1588		
		F1 Score	0.8678 ± 0.2040		
		Precisión	0.8571 ± 0.2243		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5544 ± 0.1454
				F1 Score	0.5390 ± 0.1499
				Precisión	0.5631 ± 0.1532
			RF	Exactitud	0.6039 ± 0.1376
				F1 Score	0.5780 ± 0.1501
				Precisión	0.6217 ± 0.1694
SVM		Exactitud	0.5276 ± 0.0841		
		F1 Score	0.3435 ± 0.0342		
		Precisión	0.2638 ± 0.0420		
DEPENDIENTE		KNN	Exactitud	0.8757 ± 0.1509	
			F1 Score	0.8330 ± 0.1997	
			Precisión	0.8180 ± 0.2229	
	RF	Exactitud	0.8494 ± 0.1813		
		F1 Score	0.7989 ± 0.2385		
		Precisión	0.7803 ± 0.2656		
SVM	Exactitud	0.9094 ± 0.1321			
	F1 Score	0.8766 ± 0.1702			
	Precisión	0.8666 ± 0.1857			
NEGATIVO VS	INDEPENDIENTE	KNN	Exactitud	0.5197 ± 0.1328	
			F1 Score	0.4987 ± 0.1360	

	ERÓTICO		RF	Precisión	0.5231 ± 0.1532
				Exactitud	0.5689 ± 0.1632
				F1 Score	0.5506 ± 0.1608
			SVM	Precisión	0.5991 ± 0.1940
				Exactitud	0.4829 ± 0.0892
				F1 Score	0.3415 ± 0.0983
	DEPENDIENTE	KNN	Precisión	0.2722 ± 0.1404	
			Exactitud	0.8567 ± 0.1779	
			F1 Score	0.8043 ± 0.2376	
		RF	Precisión	0.7829 ± 0.2663	
			Exactitud	0.8560 ± 0.1965	
			F1 Score	0.8097 ± 0.2495	
	SVM	Precisión	0.7909 ± 0.2753		
		Exactitud	0.9064 ± 0.1390		
		F1 Score	0.8738 ± 0.1848		
Precisión	0.8604 ± 0.2062				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media ± std
01	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5218 ± 0.1180
				F1 Score	0.5099 ± 0.1201
				Precisión	0.5252 ± 0.1234
			RF	Exactitud	0.5181 ± 0.1441
				F1 Score	0.4852 ± 0.1507
				Precisión	0.5318 ± 0.1914
		SVM	Exactitud	0.5202 ± 0.0752	
			F1 Score	0.3406 ± 0.0322	
			Precisión	0.2601 ± 0.0376	
		DEPENDIENTE	KNN	Exactitud	0.6394 ± 0.2520
				F1 Score	0.5548 ± 0.2917
				Precisión	0.5222 ± 0.3105
	RF		Exactitud	0.6981 ± 0.2471	
			F1 Score	0.6103 ± 0.2960	
			Precisión	0.5760 ± 0.3205	
	SVM	Exactitud	0.6949 ± 0.2255		
		F1 Score	0.6173 ± 0.2748		
		Precisión	0.5892 ± 0.2998		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5371 ± 0.1060
				F1 Score	0.5188 ± 0.1113
				Precisión	0.5376 ± 0.1146
			RF	Exactitud	0.5897 ± 0.1635
				F1 Score	0.5666 ± 0.1725
				Precisión	0.6140 ± 0.1898
SVM		Exactitud	0.5963 ± 0.1354		
		F1 Score	0.5382 ± 0.1557		
		Precisión	0.6307 ± 0.2133		
DEPENDIENTE	KNN	Exactitud	0.7005 ± 0.2436		

				F1 Score	0.6205 ± 0.2769
				Precisión	0.5921 ± 0.3008
				Exactitud	0.6890 ± 0.2486
			RF	F1 Score	0.6090 ± 0.2825
				Precisión	0.5803 ± 0.3053
				Exactitud	0.7209 ± 0.2351
	SVM	F1 Score	0.6417 ± 0.2683		
		Precisión	0.6125 ± 0.2936		
		Exactitud	0.5258 ± 0.1360		
	NEGATIVO VS ERÓTICO	INDEPENDIENTE	KNN	F1 Score	0.5102 ± 0.1354
				Precisión	0.5307 ± 0.1519
				Exactitud	0.5517 ± 0.1470
			RF	F1 Score	0.5274 ± 0.1476
				Precisión	0.5464 ± 0.1633
				Exactitud	0.5629 ± 0.1743
		SVM	F1 Score	0.5394 ± 0.1824	
			Precisión	0.5636 ± 0.2018	
			Exactitud	0.6467 ± 0.2664	
		DEPENDIENTE	KNN	F1 Score	0.5560 ± 0.3041
				Precisión	0.5192 ± 0.3251
Exactitud				0.7104 ± 0.2510	
RF	F1 Score		0.6364 ± 0.2928		
	Precisión		0.6066 ± 0.3134		
	Exactitud		0.7171 ± 0.2572		
SVM	F1 Score	0.6468 ± 0.2996			
	Precisión	0.6180 ± 0.3233			
	Exactitud				

GSR + RSP: intervalos de 60 segundos

CON SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → SKF (k = min muestras entre clases)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media ± std
MAD	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5038 ± 0.1732
				F1 Score	0.4838 ± 0.1740
				Precisión	0.5063 ± 0.1953
			RF	Exactitud	0.5329 ± 0.1429
				F1 Score	0.4985 ± 0.1500
				Precisión	0.5385 ± 0.1719
		SVM	Exactitud	0.5282 ± 0.1245	
			F1 Score	0.4842 ± 0.1233	
			Precisión	0.5315 ± 0.1720	
		DEPENDIENTE	KNN	Exactitud	0.7727 ± 0.2163
				F1 Score	0.7047 ± 0.2708
				Precisión	0.6765 ± 0.2989
	RF		Exactitud	0.7683 ± 0.2223	
			F1 Score	0.7029 ± 0.2744	
			Precisión	0.6736 ± 0.3016	
	SVM	Exactitud	0.8341 ± 0.2036		
		F1 Score	0.7845 ± 0.2512		
		Precisión	0.7632 ± 0.2780		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5671 ± 0.1542
				F1 Score	0.5486 ± 0.1591
				Precisión	0.5782 ± 0.1655
			RF	Exactitud	0.6037 ± 0.1553
				F1 Score	0.5803 ± 0.1673
				Precisión	0.6158 ± 0.1792
		SVM	Exactitud	0.5276 ± 0.0841	
			F1 Score	0.3435 ± 0.0342	
			Precisión	0.2638 ± 0.0420	
DEPENDIENTE		KNN	Exactitud	0.8136 ± 0.1999	
			F1 Score	0.7554 ± 0.2502	
			Precisión	0.7343 ± 0.2744	
	RF	Exactitud	0.8121 ± 0.2089		
		F1 Score	0.7630 ± 0.2582		
		Precisión	0.7427 ± 0.2837		
SVM	Exactitud	0.8421 ± 0.1873			
	F1 Score	0.7963 ± 0.2335			
	Precisión	0.7807 ± 0.2559			
NEGATIVO VS	INDEPENDIENTE	KNN	Exactitud	0.5651 ± 0.1257	
			F1 Score	0.5480 ± 0.1257	

Normalización	Clases	Dependencia	Clasificador	Métrica	Media ± std	
01	ERÓTICO	DEPENDIENTE	RF	Precisión	0.5687 ± 0.1437	
				Exactitud	0.5410 ± 0.1537	
				F1 Score	0.5210 ± 0.1563	
			SVM	Precisión	0.5491 ± 0.1749	
				Exactitud	0.5091 ± 0.0802	
				F1 Score	0.3506 ± 0.0939	
			KNN	Precisión	0.2711 ± 0.1091	
				Exactitud	0.7785 ± 0.2108	
				F1 Score	0.7140 ± 0.2584	
	RF	Precisión	0.6875 ± 0.2826			
		Exactitud	0.7734 ± 0.2345			
		F1 Score	0.7137 ± 0.2838			
	SVM	Precisión	0.6879 ± 0.3096			
		Exactitud	0.7924 ± 0.2262			
		F1 Score	0.7371 ± 0.2746			
	Precisión	0.7164 ± 0.3038				
	01	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.4959 ± 0.1445
					F1 Score	0.4768 ± 0.1486
Precisión					0.4958 ± 0.1698	
RF				Exactitud	0.5755 ± 0.1345	
				F1 Score	0.5505 ± 0.1422	
				Precisión	0.5921 ± 0.1665	
SVM				Exactitud	0.5224 ± 0.0725	
				F1 Score	0.3417 ± 0.0307	
				Precisión	0.2612 ± 0.0362	
KNN		Exactitud	0.7259 ± 0.2616			
		F1 Score	0.6622 ± 0.3067			
		Precisión	0.6352 ± 0.3286			
RF		Exactitud	0.7420 ± 0.2367			
		F1 Score	0.6759 ± 0.2843			
		Precisión	0.6488 ± 0.3059			
SVM		Exactitud	0.7390 ± 0.2360			
		F1 Score	0.6784 ± 0.2807			
		Precisión	0.6553 ± 0.3026			
POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5600 ± 0.1616		
			F1 Score	0.5448 ± 0.1669		
			Precisión	0.5608 ± 0.1718		
		RF	Exactitud	0.6173 ± 0.1535		
			F1 Score	0.5930 ± 0.1690		
			Precisión	0.6278 ± 0.1805		
		SVM	Exactitud	0.6333 ± 0.1619		
			F1 Score	0.5972 ± 0.1787		
			Precisión	0.6613 ± 0.2056		
Exactitud	0.7266 ± 0.2407					

				F1 Score	0.6481 ± 0.2771
				Precisión	0.6184 ± 0.2998
			RF	Exactitud	0.7507 ± 0.2287
				F1 Score	0.6755 ± 0.2705
			SVM	Precisión	0.6458 ± 0.2949
				Exactitud	0.7171 ± 0.2495
	NEGATIVO VS ERÓTICO	INDEPENDIENTE	KNN	F1 Score	0.6423 ± 0.2883
				Precisión	0.6137 ± 0.3113
				Exactitud	0.7171 ± 0.2495
			RF	Exactitud	0.5012 ± 0.1445
				F1 Score	0.4839 ± 0.1506
				Precisión	0.4967 ± 0.1656
	SVM	Exactitud	0.5049 ± 0.1652		
		F1 Score	0.4807 ± 0.1743		
		Precisión	0.4920 ± 0.1862		
	DEPENDIENTE	KNN	Exactitud	0.5443 ± 0.1749	
			F1 Score	0.5152 ± 0.1861	
			Precisión	0.5403 ± 0.2139	
		RF	Exactitud	0.7434 ± 0.2530	
			F1 Score	0.6791 ± 0.3009	
Precisión			0.6528 ± 0.3253		
SVM	Exactitud	0.7580 ± 0.2506			
	F1 Score	0.7014 ± 0.3004			
	Precisión	0.6773 ± 0.3238			
			Exactitud	0.7719 ± 0.2440	
			F1 Score	0.7165 ± 0.2878	
			Precisión	0.6923 ± 0.3118	

GSR: intervalos de 60 segundos solapados al 50%

CON SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → LOGO (con secuencia par/impar)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.4800 ± 0.1258
				F1 Score	0.4565 ± 0.1350
				Precisión	0.4808 ± 0.1592
			RF	Exactitud	0.4671 ± 0.1499
				F1 Score	0.4346 ± 0.1584
				Precisión	0.4578 ± 0.1845
		SVM	Exactitud	0.5274 ± 0.1020	
			F1 Score	0.3546 ± 0.1052	
			Precisión	0.2756 ± 0.1185	
		DEPENDIENTE	KNN	Exactitud	0.6996 ± 0.2979
				F1 Score	0.6388 ± 0.3394
				Precisión	0.6996 ± 0.2979
	RF		Exactitud	0.7351 ± 0.2867	
			F1 Score	0.6818 ± 0.3300	
			Precisión	0.7351 ± 0.2867	
	SVM	Exactitud	0.7316 ± 0.3005		
		F1 Score	0.6834 ± 0.3417		
		Precisión	0.7316 ± 0.3005		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5336 ± 0.1279
				F1 Score	0.5122 ± 0.1351
				Precisión	0.5442 ± 0.1413
			RF	Exactitud	0.5872 ± 0.1156
				F1 Score	0.5643 ± 0.1289
				Precisión	0.6079 ± 0.1426
		SVM	Exactitud	0.5784 ± 0.1621	
			F1 Score	0.5417 ± 0.1793	
			Precisión	0.5923 ± 0.1945	
DEPENDIENTE		KNN	Exactitud	0.8100 ± 0.2328	
			F1 Score	0.7647 ± 0.2804	
			Precisión	0.8100 ± 0.2328	
	RF	Exactitud	0.8104 ± 0.2575		
		F1 Score	0.7668 ± 0.3081		
		Precisión	0.8104 ± 0.2575		
SVM	Exactitud	0.8454 ± 0.2268			
	F1 Score	0.8166 ± 0.2634			
	Precisión	0.8454 ± 0.2268			
NEGATIVO VS	INDEPENDIENTE	KNN	Exactitud	0.5487 ± 0.1473	
			F1 Score	0.5335 ± 0.1524	

	ERÓTICO		RF	Precisión	0.5482 ± 0.1746
				Exactitud	0.5386 ± 0.1435
				F1 Score	0.5210 ± 0.1456
			SVM	Precisión	0.5417 ± 0.1705
				Exactitud	0.5816 ± 0.1731
				F1 Score	0.5565 ± 0.1803
	DEPENDIENTE	KNN	Precisión	0.5954 ± 0.2119	
			Exactitud	0.6998 ± 0.2933	
			F1 Score	0.6392 ± 0.3294	
		RF	Precisión	0.6998 ± 0.2933	
			Exactitud	0.6986 ± 0.2970	
			F1 Score	0.6386 ± 0.3367	
		SVM	Precisión	0.6986 ± 0.2970	
			Exactitud	0.7419 ± 0.2672	
			F1 Score	0.6864 ± 0.3115	
Precisión	0.7419 ± 0.2672				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5132 ± 0.0890
				F1 Score	0.4894 ± 0.1047
				Precisión	0.5032 ± 0.1175
			RF	Exactitud	0.5088 ± 0.1173
				F1 Score	0.4852 ± 0.1255
				Precisión	0.5063 ± 0.1380
		SVM	Exactitud	0.5447 ± 0.1964	
			F1 Score	0.5068 ± 0.2039	
			Precisión	0.5648 ± 0.2262	
		DEPENDIENTE	KNN	Exactitud	0.7151 ± 0.2868
				F1 Score	0.6635 ± 0.3186
				Precisión	0.7151 ± 0.2868
	RF		Exactitud	0.7285 ± 0.2814	
			F1 Score	0.6768 ± 0.3138	
			Precisión	0.7285 ± 0.2814	
	SVM	Exactitud	0.7188 ± 0.2882		
		F1 Score	0.6720 ± 0.3196		
		Precisión	0.7188 ± 0.2882		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5660 ± 0.1466
				F1 Score	0.5543 ± 0.1510
				Precisión	0.5667 ± 0.1532
			RF	Exactitud	0.5781 ± 0.1474
				F1 Score	0.5509 ± 0.1479
				Precisión	0.5802 ± 0.1441
SVM		Exactitud	0.5853 ± 0.1507		
		F1 Score	0.5596 ± 0.1609		
		Precisión	0.5998 ± 0.1574		
DEPENDIENTE	KNN	Exactitud	0.6707 ± 0.3202		

				F1 Score	0.6135 ± 0.3494
				Precisión	0.6707 ± 0.3202
			RF	Exactitud	0.7246 ± 0.2988
				F1 Score	0.6743 ± 0.3378
			SVM	Precisión	0.7246 ± 0.2988
				Exactitud	0.7447 ± 0.2786
	NEGATIVO VS ERÓTICO	INDEPENDIENTE	KNN	F1 Score	0.6925 ± 0.3169
				Precisión	0.7447 ± 0.2786
				Exactitud	0.7447 ± 0.2786
			RF	Exactitud	0.5187 ± 0.1406
				F1 Score	0.4992 ± 0.1469
				Precisión	0.5115 ± 0.1611
	SVM	Exactitud	0.4990 ± 0.1115		
		F1 Score	0.4791 ± 0.1169		
		Precisión	0.4907 ± 0.1345		
	DEPENDIENTE	KNN	Exactitud	0.4966 ± 0.0960	
			F1 Score	0.3523 ± 0.1092	
			Precisión	0.2804 ± 0.1265	
		RF	Exactitud	0.7274 ± 0.2835	
			F1 Score	0.6709 ± 0.3238	
Precisión			0.7274 ± 0.2835		
SVM	Exactitud	0.7391 ± 0.2889			
	F1 Score	0.6886 ± 0.3247			
	Precisión	0.7391 ± 0.2889			
SVM	Exactitud	0.6919 ± 0.3178			
	F1 Score	0.6474 ± 0.3487			
	Precisión	0.6919 ± 0.3178			

RSP: intervalos de 60 segundos solapados al 50%

CON SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → LOGO (con secuencia par/impar)

Normalización	Clases	Dependencia	Clasificador	Métrica	Average
MAD	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.4856 ± 0.1202
				F1 Score	0.4752 ± 0.1204
				Precisión	0.4875 ± 0.1303
			RF	Exactitud	0.4931 ± 0.1226
				F1 Score	0.4811 ± 0.1234
				Precisión	0.4976 ± 0.1329
		SVM	Exactitud	0.5000 ± 0.0000	
			F1 Score	0.3373 ± 0.0254	
			Precisión	0.2599 ± 0.0635	
		DEPENDIENTE	KNN	Exactitud	0.7170 ± 0.3310
				F1 Score	0.6633 ± 0.3742
				Precisión	0.7170 ± 0.3310
	RF		Exactitud	0.7109 ± 0.3259	
			F1 Score	0.6572 ± 0.3674	
			Precisión	0.7109 ± 0.3259	
	SVM	Exactitud	0.7586 ± 0.3169		
		F1 Score	0.7154 ± 0.3581		
		Precisión	0.7586 ± 0.3169		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5000 ± 0.1200
				F1 Score	0.4805 ± 0.1263
				Precisión	0.4976 ± 0.1338
			RF	Exactitud	0.5396 ± 0.1720
				F1 Score	0.5194 ± 0.1853
				Precisión	0.5306 ± 0.1969
		SVM	Exactitud	0.5521 ± 0.1602	
			F1 Score	0.5282 ± 0.1746	
			Precisión	0.5483 ± 0.1881	
DEPENDIENTE		KNN	Exactitud	0.7265 ± 0.3215	
			F1 Score	0.6802 ± 0.3549	
			Precisión	0.7265 ± 0.3215	
	RF	Exactitud	0.7404 ± 0.3000		
		F1 Score	0.6873 ± 0.3443		
		Precisión	0.7404 ± 0.3000		
SVM	Exactitud	0.8045 ± 0.2633			
	F1 Score	0.7621 ± 0.3120			
	Precisión	0.8045 ± 0.2633			
NEGATIVO VS	INDEPENDIENTE	KNN	Exactitud	0.5365 ± 0.1428	
			F1 Score	0.5246 ± 0.1481	

	ERÓTICO		RF	Precisión	0.5387 ± 0.1612
				Exactitud	0.5215 ± 0.1592
				F1 Score	0.5111 ± 0.1642
			SVM	Precisión	0.5204 ± 0.1714
				Exactitud	0.4796 ± 0.1284
				F1 Score	0.4527 ± 0.1330
	DEPENDIENTE	KNN	Precisión	0.4763 ± 0.1559	
			Exactitud	0.6835 ± 0.3304	
			F1 Score	0.6299 ± 0.3610	
		RF	Precisión	0.6835 ± 0.3304	
			Exactitud	0.7246 ± 0.3041	
			F1 Score	0.6708 ± 0.3473	
	SVM	Precisión	0.7246 ± 0.3041		
		Exactitud	0.7390 ± 0.2786		
		F1 Score	0.6836 ± 0.3206		
Precisión	0.7390 ± 0.2786				
Normalización	Clases	Dependencia	Clasificador	Métrica	Average
01	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5144 ± 0.1048
				F1 Score	0.5054 ± 0.1102
				Precisión	0.5132 ± 0.1100
			RF	Exactitud	0.4921 ± 0.1196
				F1 Score	0.4807 ± 0.1213
				Precisión	0.4913 ± 0.1318
		SVM	Exactitud	0.5259 ± 0.1348	
			F1 Score	0.4916 ± 0.1548	
			Precisión	0.5141 ± 0.1779	
		DEPENDIENTE	KNN	Exactitud	0.5928 ± 0.3232
				F1 Score	0.5174 ± 0.3497
				Precisión	0.5928 ± 0.3232
	RF		Exactitud	0.5904 ± 0.3190	
			F1 Score	0.5215 ± 0.3428	
			Precisión	0.5904 ± 0.3190	
	SVM	Exactitud	0.6330 ± 0.3185		
		F1 Score	0.5644 ± 0.3507		
		Precisión	0.6330 ± 0.3185		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5032 ± 0.1103
				F1 Score	0.4925 ± 0.1155
				Precisión	0.4982 ± 0.1240
			RF	Exactitud	0.5314 ± 0.1273
				F1 Score	0.5153 ± 0.1330
				Precisión	0.5424 ± 0.1498
SVM		Exactitud	0.5382 ± 0.1436		
		F1 Score	0.5130 ± 0.1530		
		Precisión	0.5459 ± 0.1808		
DEPENDIENTE		KNN	Exactitud	0.6591 ± 0.3103	

				F1 Score	0.5942 ± 0.3469
				Precisión	0.6591 ± 0.3103
				Exactitud	0.6739 ± 0.3054
			RF	F1 Score	0.6115 ± 0.3457
				Precisión	0.6739 ± 0.3054
				Exactitud	0.6943 ± 0.3182
	SVM	F1 Score	0.6431 ± 0.3547		
		Precisión	0.6943 ± 0.3182		
		Exactitud	0.6943 ± 0.3182		
	NEGATIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5028 ± 0.1311
				F1 Score	0.4909 ± 0.1342
				Precisión	0.5020 ± 0.1412
			RF	Exactitud	0.4933 ± 0.1258
				F1 Score	0.4811 ± 0.1291
				Precisión	0.4933 ± 0.1406
		SVM	Exactitud	0.5215 ± 0.1518	
			F1 Score	0.4953 ± 0.1605	
			Precisión	0.5331 ± 0.2007	
		DEPENDIENTE	KNN	Exactitud	0.6445 ± 0.3158
				F1 Score	0.5807 ± 0.3481
Precisión				0.6445 ± 0.3158	
RF			Exactitud	0.6449 ± 0.3044	
			F1 Score	0.5766 ± 0.3388	
	Precisión		0.6449 ± 0.3044		
SVM	Exactitud	0.6602 ± 0.3083			
	F1 Score	0.5994 ± 0.3430			
	Precisión	0.6602 ± 0.3083			

GSR + RSP: intervalos de 60 segundos solapados al 50%*SIN SELECCIÓN DE CARACTERÍSTICAS*

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → LOGO (con secuencia par/impar)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5205 ± 0.1238
				F1 Score	0.4951 ± 0.1348
				Precisión	0.5114 ± 0.1474
			RF	Exactitud	0.5038 ± 0.1330
				F1 Score	0.4743 ± 0.1372
				Precisión	0.4952 ± 0.1700
		SVM	Exactitud	0.5236 ± 0.0703	
			F1 Score	0.3423 ± 0.0298	
			Precisión	0.2618 ± 0.0352	
		DEPENDIENTE	KNN	Exactitud	0.6777 ± 0.3466
				F1 Score	0.6273 ± 0.3778
				Precisión	0.6777 ± 0.3466
	RF		Exactitud	0.8205 ± 0.2490	
			F1 Score	0.7792 ± 0.3001	
			Precisión	0.8205 ± 0.2490	
	SVM	Exactitud	0.9221 ± 0.1433		
		F1 Score	0.8996 ± 0.1824		
		Precisión	0.9221 ± 0.1433		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5521 ± 0.1122
				F1 Score	0.5302 ± 0.1135
				Precisión	0.5635 ± 0.1320
			RF	Exactitud	0.5898 ± 0.1396
				F1 Score	0.5650 ± 0.1463
				Precisión	0.6257 ± 0.1637
		SVM	Exactitud	0.5222 ± 0.0777	
			F1 Score	0.3414 ± 0.0321	
			Precisión	0.2611 ± 0.0388	
DEPENDIENTE		KNN	Exactitud	0.8524 ± 0.2324	
			F1 Score	0.8243 ± 0.2712	
			Precisión	0.8524 ± 0.2324	
		RF	Exactitud	0.8788 ± 0.2033	
			F1 Score	0.8449 ± 0.2577	
			Precisión	0.8788 ± 0.2033	
SVM		Exactitud	0.9521 ± 0.1038		
		F1 Score	0.9384 ± 0.1336		
		Precisión	0.9521 ± 0.1038		
NEGATIVO VS	INDEPENDIENTE	KNN	Exactitud	0.5278 ± 0.1413	
			F1 Score	0.5125 ± 0.1438	

	ERÓTICO		RF	Precisión	0.5349 ± 0.1570
				Exactitud	0.5810 ± 0.1335
				F1 Score	0.5634 ± 0.1355
			SVM	Precisión	0.5956 ± 0.1536
				Exactitud	0.5041 ± 0.0619
				F1 Score	0.3339 ± 0.0297
	DEPENDIENTE	KNN	Precisión	0.2520 ± 0.0310	
			Exactitud	0.8538 ± 0.2423	
			F1 Score	0.8242 ± 0.2804	
		RF	Precisión	0.8538 ± 0.2423	
			Exactitud	0.8372 ± 0.2488	
			F1 Score	0.8022 ± 0.2953	
	SVM	Precisión	0.8372 ± 0.2488		
		Exactitud	0.9333 ± 0.1294		
		F1 Score	0.9155 ± 0.1615		
Precisión	0.9333 ± 0.1294				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5118 ± 0.1039
				F1 Score	0.4911 ± 0.1096
				Precisión	0.5123 ± 0.1193
			RF	Exactitud	0.5265 ± 0.1178
				F1 Score	0.4914 ± 0.1272
				Precisión	0.5190 ± 0.1548
		SVM	Exactitud	0.5223 ± 0.0725	
			F1 Score	0.3416 ± 0.0311	
			Precisión	0.2612 ± 0.0362	
		DEPENDIENTE	KNN	Exactitud	0.7288 ± 0.2831
				F1 Score	0.6697 ± 0.3287
				Precisión	0.7288 ± 0.2831
	RF		Exactitud	0.7210 ± 0.3062	
			F1 Score	0.6698 ± 0.3460	
			Precisión	0.7210 ± 0.3062	
	SVM	Exactitud	0.7228 ± 0.2940		
		F1 Score	0.6712 ± 0.3317		
		Precisión	0.7228 ± 0.2940		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5440 ± 0.1124
				F1 Score	0.5302 ± 0.1132
				Precisión	0.5541 ± 0.1188
			RF	Exactitud	0.5857 ± 0.1365
				F1 Score	0.5609 ± 0.1422
				Precisión	0.6104 ± 0.1606
SVM		Exactitud	0.6183 ± 0.1431		
		F1 Score	0.5613 ± 0.1684		
		Precisión	0.6551 ± 0.1867		
DEPENDIENTE	KNN	Exactitud	0.7044 ± 0.3168		

				F1 Score	0.6615 ± 0.3465
				Precisión	0.7044 ± 0.3168
				Exactitud	0.7373 ± 0.2970
			RF	F1 Score	0.6902 ± 0.3390
				Precisión	0.7373 ± 0.2970
				Exactitud	0.7793 ± 0.2681
	SVM	F1 Score	0.7318 ± 0.3129		
		Precisión	0.7793 ± 0.2681		
		Exactitud	0.5328 ± 0.1336		
	NEGATIVO VS ERÓTICO	INDEPENDIENTE	KNN	F1 Score	0.5154 ± 0.1393
				Precisión	0.5318 ± 0.1465
				Exactitud	0.5417 ± 0.1398
			RF	F1 Score	0.5252 ± 0.1416
				Precisión	0.5426 ± 0.1527
				Exactitud	0.5769 ± 0.1608
		SVM	F1 Score	0.5615 ± 0.1678	
			Precisión	0.5846 ± 0.1826	
			Exactitud	0.6573 ± 0.3365	
		DEPENDIENTE	KNN	F1 Score	0.6056 ± 0.3612
				Precisión	0.6573 ± 0.3365
Exactitud				0.7241 ± 0.2648	
RF	F1 Score		0.6746 ± 0.3000		
	Precisión		0.7241 ± 0.2648		
	Exactitud		0.7416 ± 0.2882		
SVM	F1 Score	0.6928 ± 0.3256			
	Precisión	0.7416 ± 0.2882			
	Exactitud				

GSR + RSP: intervalos de 60 segundos solapados al 50%*CON SELECCIÓN DE CARACTERÍSTICAS*

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → LOGO (con secuencia par/impar)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.4959 ± 0.1329
				F1 Score	0.4704 ± 0.1370
				Precisión	0.4890 ± 0.1509
			RF	Exactitud	0.5090 ± 0.1263
				F1 Score	0.4697 ± 0.1347
				Precisión	0.4967 ± 0.1598
		SVM	Exactitud	0.5268 ± 0.0723	
			F1 Score	0.3436 ± 0.0305	
			Precisión	0.2634 ± 0.0361	
		DEPENDIENTE	KNN	Exactitud	0.7875 ± 0.2868
				F1 Score	0.7446 ± 0.3292
				Precisión	0.7875 ± 0.2868
	RF		Exactitud	0.7830 ± 0.2662	
			F1 Score	0.7353 ± 0.3128	
			Precisión	0.7830 ± 0.2662	
	SVM	Exactitud	0.8581 ± 0.2249		
		F1 Score	0.8265 ± 0.2718		
		Precisión	0.8581 ± 0.2249		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5590 ± 0.1205
				F1 Score	0.5307 ± 0.1287
				Precisión	0.5679 ± 0.1393
			RF	Exactitud	0.5763 ± 0.1330
				F1 Score	0.5470 ± 0.1405
				Precisión	0.6112 ± 0.1637
		SVM	Exactitud	0.5222 ± 0.0777	
			F1 Score	0.3414 ± 0.0321	
			Precisión	0.2611 ± 0.0388	
DEPENDIENTE		KNN	Exactitud	0.8661 ± 0.2171	
			F1 Score	0.8356 ± 0.2601	
			Precisión	0.8661 ± 0.2171	
	RF	Exactitud	0.8368 ± 0.2540		
		F1 Score	0.8019 ± 0.3009		
		Precisión	0.8368 ± 0.2540		
SVM	Exactitud	0.9111 ± 0.1648			
	F1 Score	0.8867 ± 0.2086			
	Precisión	0.9111 ± 0.1648			
NEGATIVO VS	INDEPENDIENTE	KNN	Exactitud	0.5248 ± 0.1388	
			F1 Score	0.5124 ± 0.1395	

	ERÓTICO		RF	Precisión	0.5245 ± 0.1468
				Exactitud	0.5910 ± 0.1644
				F1 Score	0.5781 ± 0.1654
			SVM	Precisión	0.5975 ± 0.1785
				Exactitud	0.5131 ± 0.0982
				F1 Score	0.3543 ± 0.1152
		DEPENDIENTE	KNN	Precisión	0.2754 ± 0.1322
				Exactitud	0.8037 ± 0.2524
				F1 Score	0.7604 ± 0.2973
			RF	Precisión	0.8037 ± 0.2524
				Exactitud	0.7971 ± 0.2681
				F1 Score	0.7530 ± 0.3196
			SVM	Precisión	0.7971 ± 0.2681
				Exactitud	0.8451 ± 0.2086
				F1 Score	0.8063 ± 0.2527
Precisión	0.8451 ± 0.2086				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5300 ± 0.1096
				F1 Score	0.5053 ± 0.1230
				Precisión	0.5161 ± 0.1286
			RF	Exactitud	0.5177 ± 0.1221
				F1 Score	0.4885 ± 0.1333
				Precisión	0.5075 ± 0.1467
		SVM	Exactitud	0.5224 ± 0.0725	
			F1 Score	0.3417 ± 0.0307	
			Precisión	0.2612 ± 0.0362	
		DEPENDIENTE	KNN	Exactitud	0.6284 ± 0.3318
				F1 Score	0.5721 ± 0.3585
				Precisión	0.6284 ± 0.3318
	RF		Exactitud	0.7171 ± 0.2871	
			F1 Score	0.6636 ± 0.3278	
			Precisión	0.7171 ± 0.2871	
	SVM	Exactitud	0.6874 ± 0.3045		
		F1 Score	0.6338 ± 0.3451		
		Precisión	0.6874 ± 0.3045		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5555 ± 0.1268
				F1 Score	0.5341 ± 0.1305
				Precisión	0.5615 ± 0.1454
			RF	Exactitud	0.6053 ± 0.1383
				F1 Score	0.5782 ± 0.1504
				Precisión	0.6223 ± 0.1675
SVM		Exactitud	0.6217 ± 0.1457		
		F1 Score	0.5709 ± 0.1656		
		Precisión	0.6658 ± 0.1808		
DEPENDIENTE		KNN	Exactitud	0.7446 ± 0.2972	

				F1 Score	0.6986 ± 0.3326
				Precisión	0.7446 ± 0.2972
				Exactitud	0.7625 ± 0.2784
			RF	F1 Score	0.7160 ± 0.3207
				Precisión	0.7625 ± 0.2784
				Exactitud	0.7899 ± 0.2727
	SVM	F1 Score	0.7479 ± 0.3156		
		Precisión	0.7899 ± 0.2727		
		Exactitud	0.5389 ± 0.1199		
	NEGATIVO VS ERÓTICO	INDEPENDIENTE	KNN	F1 Score	0.5279 ± 0.1193
				Precisión	0.5404 ± 0.1221
				Exactitud	0.5314 ± 0.1687
			RF	F1 Score	0.5086 ± 0.1746
				Precisión	0.5335 ± 0.2007
				Exactitud	0.5942 ± 0.1493
		SVM	F1 Score	0.5601 ± 0.1644	
			Precisión	0.6049 ± 0.1893	
			Exactitud	0.6257 ± 0.3241	
		DEPENDIENTE	KNN	F1 Score	0.5616 ± 0.3518
				Precisión	0.6257 ± 0.3241
Exactitud				0.7563 ± 0.2760	
RF	F1 Score		0.7130 ± 0.3121		
	Precisión		0.7563 ± 0.2760		
	Exactitud		0.6174 ± 0.2985		
SVM	F1 Score	0.5713 ± 0.3182			
	Precisión	0.6174 ± 0.2985			
	Exactitud	0.6174 ± 0.2985			

GSR: intervalos de 15 segundos

CON SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → SKF (k = 10)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Exactitud	0.5103 ± 0.1378
				F1 Score	0.4814 ± 0.1452
				Precisión	0.5042 ± 0.1608
			RF	Exactitud	0.5004 ± 0.1205
				F1 Score	0.4621 ± 0.1265
				Precisión	0.4927 ± 0.1388
		SVM	Exactitud	0.5274 ± 0.1020	
			F1 Score	0.3546 ± 0.1052	
			Precisión	0.2756 ± 0.1185	
		DEPENDIENTE	KNN	Exactitud	0.8004 ± 0.1843
				F1 Score	0.7714 ± 0.2169
				Precisión	0.7983 ± 0.2216
	RF		Exactitud	0.8192 ± 0.1835	
			F1 Score	0.7956 ± 0.2104	
			Precisión	0.8223 ± 0.2085	
	SVM	Exactitud	0.8099 ± 0.1843		
		F1 Score	0.7757 ± 0.2221		
		Precisión	0.7902 ± 0.2342		
	POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Exactitud	0.5328 ± 0.1179
				F1 Score	0.5018 ± 0.1177
				Precisión	0.5309 ± 0.1221
			RF	Exactitud	0.5670 ± 0.1364
				F1 Score	0.5336 ± 0.1429
				Precisión	0.5734 ± 0.1498
		SVM	Exactitud	0.5824 ± 0.1619	
			F1 Score	0.5441 ± 0.1717	
			Precisión	0.5897 ± 0.1966	
DEPENDIENTE		KNN	Exactitud	0.8437 ± 0.1536	
			F1 Score	0.8237 ± 0.1726	
			Precisión	0.8493 ± 0.1626	
	RF	Exactitud	0.8747 ± 0.1473		
		F1 Score	0.8548 ± 0.1734		
		Precisión	0.8731 ± 0.1658		
SVM	Exactitud	0.8746 ± 0.1384			
	F1 Score	0.8538 ± 0.1594			
	Precisión	0.8691 ± 0.1502			
NEGATIVO VS	INDEPENDIENTE	KNN	Exactitud	0.5788 ± 0.1194	
			F1 Score	0.5594 ± 0.1267	

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	ERÓTICO	DEPENDIENTE	RF	Precisión	0.5798 ± 0.1399
				Exactitud	0.5538 ± 0.1108
				F1 Score	0.5313 ± 0.1228
			SVM	Precisión	0.5489 ± 0.1356
				Exactitud	0.5950 ± 0.1509
				F1 Score	0.5614 ± 0.1623
		KNN	Precisión	0.6178 ± 0.1897	
			Exactitud	0.7920 ± 0.1817	
			F1 Score	0.7640 ± 0.2098	
	DEPENDIENTE	RF	Precisión	0.7852 ± 0.2114	
			Exactitud	0.8138 ± 0.1740	
			F1 Score	0.7877 ± 0.2018	
	SVM	Precisión	0.8063 ± 0.2072		
		Exactitud	0.7857 ± 0.1736		
		F1 Score	0.7442 ± 0.2031		
	DEPENDIENTE	Precisión	0.7621 ± 0.2099		
		Exactitud	0.5118 ± 0.1094		
		F1 Score	0.4980 ± 0.1206		
01	POSITIVO VS NEGATIVO	INDEPENDIENTE	KNN	Precisión	0.5175 ± 0.1158
				Exactitud	0.5259 ± 0.1011
				F1 Score	0.5097 ± 0.1087
			RF	Precisión	0.5335 ± 0.1086
				Exactitud	0.5008 ± 0.0895
				F1 Score	0.3331 ± 0.0431
		SVM	Precisión	0.2616 ± 0.0595	
			Exactitud	0.7295 ± 0.1841	
			F1 Score	0.6968 ± 0.2090	
	DEPENDIENTE	KNN	Precisión	0.7248 ± 0.2220	
			Exactitud	0.7432 ± 0.1939	
			F1 Score	0.7134 ± 0.2196	
	DEPENDIENTE	RF	Precisión	0.7396 ± 0.2353	
			Exactitud	0.7154 ± 0.2016	
			F1 Score	0.6763 ± 0.2305	
	DEPENDIENTE	SVM	Precisión	0.6936 ± 0.2507	
			Exactitud	0.5174 ± 0.0945	
			F1 Score	0.5009 ± 0.0890	
POSITIVO VS ERÓTICO	INDEPENDIENTE	KNN	Precisión	0.5129 ± 0.0858	
			Exactitud	0.5749 ± 0.0922	
			F1 Score	0.5503 ± 0.0881	
		RF	Precisión	0.5830 ± 0.0948	
			Exactitud	0.5618 ± 0.1277	
			F1 Score	0.5328 ± 0.1301	
	DEPENDIENTE	SVM	Precisión	0.5715 ± 0.1433	
			Exactitud	0.6816 ± 0.1930	
			F1 Score		

				F1 Score	0.6454 ± 0.2079
				Precisión	0.6761 ± 0.2189
			RF	Exactitud	0.7402 ± 0.1896
				F1 Score	0.7037 ± 0.2161
			SVM	Precisión	0.7226 ± 0.2341
				Exactitud	0.6871 ± 0.1828
	F1 Score	0.6567 ± 0.1976			
	NEGATIVO VS ERÓTICO	INDEPENDIENTE	KNN	Precisión	0.6955 ± 0.2095
				Exactitud	0.5619 ± 0.1053
				F1 Score	0.5471 ± 0.1089
			RF	Precisión	0.5691 ± 0.1175
				Exactitud	0.5453 ± 0.0911
				F1 Score	0.5288 ± 0.0902
		SVM	Precisión	0.5519 ± 0.1068	
			Exactitud	0.5757 ± 0.1863	
			F1 Score	0.5443 ± 0.1987	
		DEPENDIENTE	KNN	Precisión	0.5732 ± 0.2282
				Exactitud	0.7430 ± 0.1984
				F1 Score	0.7129 ± 0.2218
	RF		Precisión	0.7409 ± 0.2282	
Exactitud			0.7493 ± 0.2019		
F1 Score			0.7177 ± 0.2300		
SVM	Precisión	0.7412 ± 0.2394			
	Exactitud	0.7305 ± 0.1852			
	F1 Score	0.6927 ± 0.2163			
			Precisión	0.7092 ± 0.2302	

GSR: intervalos de 60 segundos

CON SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → SKF (k = min muestras entre clases)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.4676 ± 0.1810
				F1 Score	0.3829 ± 0.1555
				Precisión	0.4691 ± 0.1600
			RF	Exactitud	0.4556 ± 0.2042
				F1 Score	0.3544 ± 0.1422
				Precisión	0.4678 ± 0.1697
		SVM	Exactitud	0.5746 ± 0.3314	
			F1 Score	0.4775 ± 0.3530	
			Precisión	0.4320 ± 0.3748	
		DEPENDIENTE	KNN	Exactitud	0.7548 ± 0.2371
				F1 Score	0.7013 ± 0.2881
				Precisión	0.6881 ± 0.3090
	RF		Exactitud	0.7483 ± 0.2168	
			F1 Score	0.6623 ± 0.2634	
			Precisión	0.6396 ± 0.2907	
	SVM	Exactitud	0.8171 ± 0.1991		
		F1 Score	0.7639 ± 0.2468		
		Precisión	0.7502 ± 0.2633		
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5222 ± 0.2205
				F1 Score	0.3743 ± 0.1524
				Precisión	0.4679 ± 0.1565
			RF	Exactitud	0.5562 ± 0.2329
				F1 Score	0.4200 ± 0.2112
				Precisión	0.5085 ± 0.2146
		SVM	Exactitud	0.6498 ± 0.3608	
			F1 Score	0.5787 ± 0.3899	
			Precisión	0.5455 ± 0.4141	
DEPENDIENTE		KNN	Exactitud	0.7846 ± 0.2157	
			F1 Score	0.7004 ± 0.2670	
			Precisión	0.6818 ± 0.2832	
	RF	Exactitud	0.7846 ± 0.2028		
		F1 Score	0.7183 ± 0.2538		
		Precisión	0.7049 ± 0.2742		
SVM	Exactitud	0.7790 ± 0.1842			
	F1 Score	0.6879 ± 0.2165			
	Precisión	0.6735 ± 0.2325			
Excitación alta VS	INDEPENDIENTE	KNN	Exactitud	0.4641 ± 0.1468	
			F1 Score	0.3872 ± 0.1365	

	Excitación baja		RF	Precisión	0.4844 ± 0.1113
				Exactitud	0.4612 ± 0.1707
				F1 Score	0.3797 ± 0.1385
			SVM	Precisión	0.4885 ± 0.1016
				Exactitud	0.5229 ± 0.3357
				F1 Score	0.4028 ± 0.3282
		DEPENDIENTE	KNN	Precisión	0.3587 ± 0.3372
				Exactitud	0.7388 ± 0.2307
				F1 Score	0.6571 ± 0.2809
			RF	Precisión	0.6293 ± 0.3059
				Exactitud	0.7266 ± 0.2291
				F1 Score	0.6343 ± 0.2780
			SVM	Precisión	0.6044 ± 0.3023
				Exactitud	0.7736 ± 0.2040
				F1 Score	0.6893 ± 0.2488
Precisión	0.6652 ± 0.2712				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.5214 ± 0.1655
				F1 Score	0.4153 ± 0.1276
				Precisión	0.5099 ± 0.1131
			RF	Exactitud	0.5184 ± 0.1728
				F1 Score	0.3847 ± 0.1324
				Precisión	0.4687 ± 0.1619
		SVM	Exactitud	0.5746 ± 0.3314	
			F1 Score	0.4775 ± 0.3530	
			Precisión	0.4320 ± 0.3748	
		DEPENDIENTE	KNN	Exactitud	0.7104 ± 0.2469
				F1 Score	0.6321 ± 0.2651
				Precisión	0.6071 ± 0.2748
	RF		Exactitud	0.7336 ± 0.2250	
			F1 Score	0.6480 ± 0.2538	
			Precisión	0.6203 ± 0.2704	
	SVM	Exactitud	0.7218 ± 0.2411		
		F1 Score	0.6445 ± 0.2769		
		Precisión	0.6215 ± 0.2967		
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5460 ± 0.1686
				F1 Score	0.3919 ± 0.0993
				Precisión	0.5043 ± 0.0676
			RF	Exactitud	0.5451 ± 0.1999
				F1 Score	0.3849 ± 0.1112
				Precisión	0.4920 ± 0.1144
SVM		Exactitud	0.6498 ± 0.3608		
		F1 Score	0.5787 ± 0.3899		
		Precisión	0.5455 ± 0.4141		
DEPENDIENTE	KNN	Exactitud	0.6642 ± 0.1699		

				F1 Score	0.5203 ± 0.2010
				Precisión	0.4929 ± 0.2187
				Exactitud	0.6457 ± 0.2008
			RF	F1 Score	0.5247 ± 0.2196
				Precisión	0.5034 ± 0.2356
				Exactitud	0.7031 ± 0.0845
			SVM	F1 Score	0.5004 ± 0.0948
				Precisión	0.4509 ± 0.1006
				Exactitud	0.5127 ± 0.1576
	Excitación alta VS Excitación baja	INDEPENDIENTE	KNN	F1 Score	0.4104 ± 0.1280
				Precisión	0.4919 ± 0.1140
				Exactitud	0.5406 ± 0.1644
			RF	F1 Score	0.4364 ± 0.1610
				Precisión	0.5258 ± 0.1358
				Exactitud	0.5229 ± 0.3357
		SVM	F1 Score	0.4028 ± 0.3282	
			Precisión	0.3587 ± 0.3372	
			Exactitud	0.6351 ± 0.2648	
		DEPENDIENTE	KNN	F1 Score	0.5363 ± 0.2947
				Precisión	0.5097 ± 0.3170
Exactitud				0.6647 ± 0.2507	
RF	F1 Score		0.5679 ± 0.3016		
	Precisión		0.5390 ± 0.3241		
	Exactitud		0.6552 ± 0.1670		
SVM	F1 Score	0.4924 ± 0.1814			
	Precisión	0.4414 ± 0.1931			
	Exactitud				

RSP: intervalos de 60 segundos*CON SELECCIÓN DE CARACTERÍSTICAS*

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → SKF (k = min muestras entre clases)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.5024 ± 0.1549
				F1 Score	0.4190 ± 0.1486
				Precisión	0.5046 ± 0.1141
			RF	Exactitud	0.5565 ± 0.2354
				F1 Score	0.4304 ± 0.1761
				Precisión	0.5089 ± 0.1680
		SVM	Exactitud	0.5833 ± 0.3193	
			F1 Score	0.4833 ± 0.3486	
			Precisión	0.4364 ± 0.3704	
		DEPENDIENTE	KNN	Exactitud	0.7751 ± 0.2521
				F1 Score	0.7125 ± 0.3084
				Precisión	0.6883 ± 0.3360
	RF		Exactitud	0.7866 ± 0.2576	
			F1 Score	0.7263 ± 0.3096	
			Precisión	0.7028 ± 0.3371	
	SVM	Exactitud	0.8192 ± 0.2245		
		F1 Score	0.7677 ± 0.2768		
		Precisión	0.7469 ± 0.3013		
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5283 ± 0.1640
				F1 Score	0.4015 ± 0.1068
				Precisión	0.4943 ± 0.0885
			RF	Exactitud	0.6166 ± 0.2613
				F1 Score	0.4417 ± 0.2159
				Precisión	0.4918 ± 0.2426
		SVM	Exactitud	0.6716 ± 0.3296	
			F1 Score	0.5941 ± 0.3729	
			Precisión	0.5564 ± 0.4015	
DEPENDIENTE		KNN	Exactitud	0.7741 ± 0.2407	
			F1 Score	0.7001 ± 0.3061	
			Precisión	0.6772 ± 0.3349	
	RF	Exactitud	0.7840 ± 0.2258		
		F1 Score	0.7040 ± 0.2984		
		Precisión	0.6809 ± 0.3299		
SVM	Exactitud	0.8185 ± 0.2025			
	F1 Score	0.7578 ± 0.2634			
	Precisión	0.7420 ± 0.2909			
Excitación alta VS	INDEPENDIENTE	KNN	Exactitud	0.5147 ± 0.1504	
			F1 Score	0.4435 ± 0.1455	

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	Excitación baja	DEPENDIENTE	RF	Precisión	0.5293 ± 0.0739
				Exactitud	0.5347 ± 0.1579
				F1 Score	0.4438 ± 0.1368
			SVM	Precisión	0.5184 ± 0.0901
				Exactitud	0.5085 ± 0.3179
				F1 Score	0.3927 ± 0.3161
		DEPENDIENTE	KNN	Precisión	0.3440 ± 0.3259
				Exactitud	0.7222 ± 0.2696
				F1 Score	0.6479 ± 0.3250
	DEPENDIENTE	RF	Precisión	0.6180 ± 0.3519	
			Exactitud	0.7110 ± 0.2742	
			F1 Score	0.6316 ± 0.3320	
	DEPENDIENTE	SVM	Precisión	0.5982 ± 0.3591	
			Exactitud	0.7339 ± 0.2608	
			F1 Score	0.6590 ± 0.3147	
	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Precisión	0.6290 ± 0.3392
				Exactitud	0.5138 ± 0.1438
				F1 Score	0.4352 ± 0.1464
RF			Precisión	0.5235 ± 0.1044	
			Exactitud	0.5439 ± 0.1746	
			F1 Score	0.4297 ± 0.1463	
INDEPENDIENTE		SVM	Precisión	0.5072 ± 0.1489	
			Exactitud	0.5749 ± 0.3145	
			F1 Score	0.4736 ± 0.3426	
DEPENDIENTE	KNN	Precisión	0.4250 ± 0.3647		
		Exactitud	0.5963 ± 0.2784		
		F1 Score	0.5067 ± 0.2910		
	RF	Precisión	0.4725 ± 0.3036		
		Exactitud	0.5856 ± 0.2902		
		F1 Score	0.4935 ± 0.3051		
DEPENDIENTE	SVM	Precisión	0.4585 ± 0.3180		
		Exactitud	0.6264 ± 0.2731		
		F1 Score	0.5365 ± 0.2983		
Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Precisión	0.5031 ± 0.3165	
			Exactitud	0.5617 ± 0.2097	
			F1 Score	0.4345 ± 0.1794	
		RF	Precisión	0.5199 ± 0.1609	
			Exactitud	0.6168 ± 0.2941	
			F1 Score	0.5121 ± 0.3026	
	INDEPENDIENTE	SVM	Precisión	0.5605 ± 0.2948	
			Exactitud	0.6829 ± 0.3250	
			F1 Score	0.6008 ± 0.3697	
DEPENDIENTE	KNN	Precisión	0.5637 ± 0.3983		
		Exactitud	0.6664 ± 0.1938		
		F1 Score			

				F1 Score	0.5272 ± 0.2320
				Precisión	0.4836 ± 0.2522
				Exactitud	0.6906 ± 0.2408
			RF	F1 Score	0.5808 ± 0.2837
				Precisión	0.5504 ± 0.3037
				Exactitud	0.7182 ± 0.1553
	SVM	F1 Score	0.5627 ± 0.1997		
		Precisión	0.5159 ± 0.2181		
		Exactitud	0.4817 ± 0.1357		
	Excitación alta VS Excitación baja	INDEPENDIENTE	KNN	F1 Score	0.4129 ± 0.1368
				Precisión	0.5014 ± 0.0891
				Exactitud	0.4368 ± 0.1728
			RF	F1 Score	0.3677 ± 0.1484
				Precisión	0.4645 ± 0.1241
				Exactitud	0.5085 ± 0.3179
		SVM	F1 Score	0.3927 ± 0.3161	
			Precisión	0.3440 ± 0.3259	
			Exactitud	0.6453 ± 0.2666	
		DEPENDIENTE	KNN	F1 Score	0.5696 ± 0.2958
				Precisión	0.5437 ± 0.3161
Exactitud				0.6719 ± 0.2759	
RF	F1 Score		0.5938 ± 0.3050		
	Precisión		0.5658 ± 0.3215		
	Exactitud		0.6727 ± 0.2014		
SVM	F1 Score	0.5513 ± 0.2329			
	Precisión	0.5066 ± 0.2499			
	Exactitud				

GSR + RSP: intervalos de 60 segundos

SIN SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → SKF (k = min muestras entre clases)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.5597 ± 0.1588
				F1 Score	0.4589 ± 0.1549
				Precisión	0.5338 ± 0.1183
			RF	Exactitud	0.4982 ± 0.2147
				F1 Score	0.3843 ± 0.1761
				Precisión	0.4661 ± 0.1970
		SVM	Exactitud	0.5765 ± 0.3368	
			F1 Score	0.4852 ± 0.3605	
			Precisión	0.4410 ± 0.3823	
		DEPENDIENTE	KNN	Exactitud	0.8137 ± 0.1906
				F1 Score	0.7573 ± 0.2367
				Precisión	0.7449 ± 0.2635
	RF		Exactitud	0.7988 ± 0.2090	
			F1 Score	0.7320 ± 0.2610	
			Precisión	0.7098 ± 0.2879	
	SVM	Exactitud	0.8905 ± 0.1344		
		F1 Score	0.8519 ± 0.1784		
		Precisión	0.8464 ± 0.1939		
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5051 ± 0.2177
				F1 Score	0.3697 ± 0.1355
				Precisión	0.4808 ± 0.1046
			RF	Exactitud	0.5661 ± 0.2878
				F1 Score	0.3925 ± 0.2052
				Precisión	0.4534 ± 0.2191
			SVM	Exactitud	0.6383 ± 0.3665
				F1 Score	0.5712 ± 0.3936
				Precisión	0.5379 ± 0.4174
DEPENDIENTE		KNN	Exactitud	0.8016 ± 0.1546	
			F1 Score	0.7166 ± 0.1894	
			Precisión	0.7030 ± 0.2164	
		RF	Exactitud	0.8439 ± 0.1563	
			F1 Score	0.7501 ± 0.2003	
			Precisión	0.7394 ± 0.2080	
		SVM	Exactitud	0.8862 ± 0.1405	
			F1 Score	0.8374 ± 0.1945	
			Precisión	0.8366 ± 0.2064	
Excitación alta VS	INDEPENDIENTE	KNN	Exactitud	0.4684 ± 0.1633	
			F1 Score	0.3849 ± 0.1408	

	Excitación baja		RF	Precisión	0.4933 ± 0.1194
				Exactitud	0.4890 ± 0.1810
				F1 Score	0.4164 ± 0.1791
			SVM	Precisión	0.5383 ± 0.1380
				Exactitud	0.5096 ± 0.3353
				F1 Score	0.3873 ± 0.3212
		DEPENDIENTE	KNN	Precisión	0.3430 ± 0.3282
				Exactitud	0.8611 ± 0.1658
				F1 Score	0.8110 ± 0.2193
			RF	Precisión	0.8032 ± 0.2465
				Exactitud	0.8157 ± 0.1918
				F1 Score	0.7335 ± 0.2611
			SVM	Precisión	0.7086 ± 0.2900
				Exactitud	0.8840 ± 0.1494
				F1 Score	0.8453 ± 0.2026
Precisión	0.8374 ± 0.2234				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.5055 ± 0.1453
				F1 Score	0.4093 ± 0.1257
				Precisión	0.4923 ± 0.1000
			RF	Exactitud	0.5060 ± 0.1754
				F1 Score	0.3754 ± 0.1337
				Precisión	0.4587 ± 0.1707
		SVM	Exactitud	0.5698 ± 0.3308	
			F1 Score	0.4756 ± 0.3536	
			Precisión	0.4296 ± 0.3756	
		DEPENDIENTE	KNN	Exactitud	0.7317 ± 0.2389
				F1 Score	0.6508 ± 0.2910
				Precisión	0.6273 ± 0.3167
	RF		Exactitud	0.7085 ± 0.2338	
			F1 Score	0.5985 ± 0.2834	
			Precisión	0.5660 ± 0.3048	
	SVM	Exactitud	0.7311 ± 0.2245		
		F1 Score	0.6445 ± 0.2856		
		Precisión	0.6202 ± 0.3124		
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.4973 ± 0.2071
				F1 Score	0.3961 ± 0.1794
				Precisión	0.5089 ± 0.1444
			RF	Exactitud	0.6331 ± 0.3101
				F1 Score	0.5535 ± 0.3204
				Precisión	0.6229 ± 0.2934
SVM		Exactitud	0.6522 ± 0.3612		
		F1 Score	0.5796 ± 0.3895		
		Precisión	0.5467 ± 0.4135		
DEPENDIENTE		KNN	Exactitud	0.7556 ± 0.1774	

				F1 Score	0.6189 ± 0.2194
				Precisión	0.5902 ± 0.2362
				Exactitud	0.7763 ± 0.1818
			RF	F1 Score	0.6444 ± 0.2505
				Precisión	0.6167 ± 0.2745
				Exactitud	0.7401 ± 0.1765
	SVM	F1 Score	0.6189 ± 0.2297		
		Precisión	0.5972 ± 0.2486		
		Exactitud	0.7401 ± 0.1765		
	Excitación alta VS Excitación baja	INDEPENDIENTE	KNN	Exactitud	0.4588 ± 0.1691
				F1 Score	0.3769 ± 0.1398
				Precisión	0.4806 ± 0.1127
			RF	Exactitud	0.5345 ± 0.1966
				F1 Score	0.4396 ± 0.1837
				Precisión	0.5558 ± 0.1419
		SVM	Exactitud	0.5217 ± 0.3359	
			F1 Score	0.4023 ± 0.3283	
			Precisión	0.3580 ± 0.3374	
		DEPENDIENTE	KNN	Exactitud	0.7472 ± 0.2073
				F1 Score	0.6649 ± 0.2572
Precisión				0.6451 ± 0.2786	
RF	Exactitud		0.7457 ± 0.2021		
	F1 Score		0.6370 ± 0.2566		
	Precisión		0.6075 ± 0.2877		
SVM	Exactitud	0.7545 ± 0.2125			
	F1 Score	0.6629 ± 0.2702			
	Precisión	0.6372 ± 0.3006			

SAM

GSR: intervalos de 60 segundos solapados al 50%

CON SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → LOGO (con secuencia par/impar)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.4776 ± 0.1280
				F1 Score	0.3997 ± 0.1197
				Precisión	0.4930 ± 0.0926
			RF	Exactitud	0.4597 ± 0.1935
				F1 Score	0.3575 ± 0.1422
				Precisión	0.4585 ± 0.1371
			SVM	Exactitud	0.5746 ± 0.3314
				F1 Score	0.4775 ± 0.3530
				Precisión	0.4320 ± 0.3748
		DEPENDIENTE	KNN	Exactitud	0.7702 ± 0.2511
				F1 Score	0.7179 ± 0.2944
				Precisión	0.7702 ± 0.2511
			RF	Exactitud	0.7712 ± 0.2960
				F1 Score	0.7311 ± 0.3289
				Precisión	0.7712 ± 0.2960
			SVM	Exactitud	0.8590 ± 0.2018
				F1 Score	0.8243 ± 0.2430
				Precisión	0.8590 ± 0.2018
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5758 ± 0.1999
				F1 Score	0.3923 ± 0.1023
				Precisión	0.4660 ± 0.1312
			RF	Exactitud	0.5490 ± 0.2269
				F1 Score	0.3760 ± 0.1134
				Precisión	0.4930 ± 0.1272
			SVM	Exactitud	0.6498 ± 0.3608
				F1 Score	0.5787 ± 0.3899
				Precisión	0.5455 ± 0.4141
		DEPENDIENTE	KNN	Exactitud	0.8031 ± 0.2512
				F1 Score	0.7585 ± 0.2951
				Precisión	0.8031 ± 0.2512
RF			Exactitud	0.8304 ± 0.2426	
			F1 Score	0.7962 ± 0.2817	
			Precisión	0.8304 ± 0.2426	
SVM			Exactitud	0.8211 ± 0.2678	
			F1 Score	0.7936 ± 0.3019	
			Precisión	0.8211 ± 0.2678	
Excitación alta VS	INDEPENDIENTE	KNN	Exactitud	0.4969 ± 0.1613	
			F1 Score	0.4246 ± 0.1660	

	Excitación baja	DEPENDIENTE	RF	Precisión	0.5114 ± 0.1341
				Exactitud	0.4802 ± 0.1715
				F1 Score	0.3923 ± 0.1491
			SVM	Precisión	0.4871 ± 0.1319
				Exactitud	0.5229 ± 0.3357
				F1 Score	0.4028 ± 0.3282
		DEPENDIENTE	KNN	Precisión	0.3587 ± 0.3372
				Exactitud	0.7755 ± 0.2887
				F1 Score	0.7283 ± 0.3344
			RF	Precisión	0.7755 ± 0.2887
				Exactitud	0.7940 ± 0.2638
				F1 Score	0.7466 ± 0.3142
		SVM	Precisión	0.7940 ± 0.2638	
			Exactitud	0.8246 ± 0.2435	
			F1 Score	0.7853 ± 0.2880	
Precisión	0.8246 ± 0.2435				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.4755 ± 0.1349
				F1 Score	0.3895 ± 0.1187
				Precisión	0.4820 ± 0.1045
			RF	Exactitud	0.4678 ± 0.1864
				F1 Score	0.3538 ± 0.1331
				Precisión	0.4250 ± 0.1547
		SVM	Exactitud	0.5746 ± 0.3314	
			F1 Score	0.4775 ± 0.3530	
			Precisión	0.4320 ± 0.3748	
		DEPENDIENTE	KNN	Exactitud	0.6506 ± 0.3658
				F1 Score	0.6072 ± 0.3871
				Precisión	0.6506 ± 0.3658
	RF		Exactitud	0.6767 ± 0.3187	
			F1 Score	0.6326 ± 0.3416	
			Precisión	0.6767 ± 0.3187	
	SVM	Exactitud	0.6469 ± 0.3513		
		F1 Score	0.6146 ± 0.3619		
		Precisión	0.6469 ± 0.3513		
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5617 ± 0.1672
				F1 Score	0.4263 ± 0.1448
				Precisión	0.5272 ± 0.1024
RF			Exactitud	0.5977 ± 0.1782	
			F1 Score	0.4319 ± 0.1146	
			Precisión	0.5351 ± 0.0646	
SVM		Exactitud	0.6498 ± 0.3608		
		F1 Score	0.5787 ± 0.3899		
		Precisión	0.5455 ± 0.4141		
DEPENDIENTE	KNN	Exactitud	0.6153 ± 0.3552		

				F1 Score	0.5622 ± 0.3778
				Precisión	0.6153 ± 0.3552
			RF	Exactitud	0.6231 ± 0.3439
				F1 Score	0.5710 ± 0.3599
			SVM	Precisión	0.6231 ± 0.3439
				Exactitud	0.6733 ± 0.3874
	F1 Score	0.6434 ± 0.4024			
	Excitación alta VS Excitación baja	INDEPENDIENTE	KNN	Precisión	0.6733 ± 0.3874
				Exactitud	0.5017 ± 0.1950
				F1 Score	0.4206 ± 0.1751
			RF	Precisión	0.5390 ± 0.1169
				Exactitud	0.4698 ± 0.1741
				F1 Score	0.4011 ± 0.1657
		SVM	Precisión	0.5228 ± 0.1273	
			Exactitud	0.5229 ± 0.3357	
			F1 Score	0.4028 ± 0.3282	
		DEPENDIENTE	KNN	Precisión	0.3587 ± 0.3372
				Exactitud	0.6326 ± 0.3344
				F1 Score	0.5749 ± 0.3598
	RF		Precisión	0.6326 ± 0.3344	
Exactitud			0.6432 ± 0.2998		
F1 Score			0.5741 ± 0.3285		
SVM	Precisión	0.6432 ± 0.2998			
	Exactitud	0.6460 ± 0.3333			
	F1 Score	0.5987 ± 0.3520			
				Precisión	0.6460 ± 0.3333



RSP: intervalos de 60 segundos solapados al 50%

CON SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → LOGO (con secuencia par/impar)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.5127 ± 0.1607
				F1 Score	0.4286 ± 0.1406
				Precisión	0.5013 ± 0.1030
			RF	Exactitud	0.5231 ± 0.1921
				F1 Score	0.4147 ± 0.1532
				Precisión	0.4851 ± 0.1371
		SVM	Exactitud	0.5880 ± 0.3055	
			F1 Score	0.4824 ± 0.3381	
			Precisión	0.4329 ± 0.3615	
		DEPENDIENTE	KNN	Exactitud	0.7771 ± 0.3015
				F1 Score	0.7341 ± 0.3473
				Precisión	0.7771 ± 0.3015
	RF		Exactitud	0.7791 ± 0.2909	
			F1 Score	0.7306 ± 0.3404	
			Precisión	0.7791 ± 0.2909	
	SVM	Exactitud	0.8300 ± 0.2574		
		F1 Score	0.7888 ± 0.3121		
		Precisión	0.8300 ± 0.2574		
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5417 ± 0.1669
				F1 Score	0.4073 ± 0.1063
				Precisión	0.5036 ± 0.0795
			RF	Exactitud	0.6159 ± 0.2425
				F1 Score	0.4288 ± 0.1685
				Precisión	0.4883 ± 0.1886
			SVM	Exactitud	0.6667 ± 0.3333
				F1 Score	0.5896 ± 0.3748
				Precisión	0.5521 ± 0.4028
DEPENDIENTE		KNN	Exactitud	0.8006 ± 0.2943	
			F1 Score	0.7593 ± 0.3375	
			Precisión	0.8006 ± 0.2943	
		RF	Exactitud	0.7837 ± 0.3148	
			F1 Score	0.7447 ± 0.3540	
			Precisión	0.7837 ± 0.3148	
		SVM	Exactitud	0.8710 ± 0.2188	
			F1 Score	0.8380 ± 0.2706	
			Precisión	0.8710 ± 0.2188	
Excitación alta VS	INDEPENDIENTE	KNN	Exactitud	0.4813 ± 0.1359	
			F1 Score	0.4033 ± 0.1248	

	Excitación baja	DEPENDIENTE	RF	Precisión	0.4806 ± 0.0975
				Exactitud	0.5110 ± 0.1340
				F1 Score	0.4343 ± 0.1375
			SVM	Precisión	0.5226 ± 0.0974
				Exactitud	0.5085 ± 0.3179
				F1 Score	0.3927 ± 0.3161
			KNN	Precisión	0.3440 ± 0.3259
				Exactitud	0.7415 ± 0.3109
				F1 Score	0.6914 ± 0.3493
		RF	Precisión	0.7415 ± 0.3109	
			Exactitud	0.7150 ± 0.3198	
			F1 Score	0.6584 ± 0.3601	
		SVM	Precisión	0.7150 ± 0.3198	
			Exactitud	0.7367 ± 0.2891	
			F1 Score	0.6804 ± 0.3351	
Precisión	0.7367 ± 0.2891				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.4826 ± 0.1520
				F1 Score	0.4010 ± 0.1359
				Precisión	0.4855 ± 0.1223
			RF	Exactitud	0.5112 ± 0.1733
				F1 Score	0.3885 ± 0.1067
				Precisión	0.4896 ± 0.1365
			SVM	Exactitud	0.5738 ± 0.3159
				F1 Score	0.4728 ± 0.3433
				Precisión	0.4244 ± 0.3652
		DEPENDIENTE	KNN	Exactitud	0.5728 ± 0.3569
				F1 Score	0.5078 ± 0.3742
				Precisión	0.5728 ± 0.3569
			RF	Exactitud	0.6098 ± 0.3254
				F1 Score	0.5409 ± 0.3553
				Precisión	0.6098 ± 0.3254
			SVM	Exactitud	0.6589 ± 0.3304
				F1 Score	0.5962 ± 0.3677
				Precisión	0.6589 ± 0.3304
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5670 ± 0.1594
				F1 Score	0.4127 ± 0.0959
				Precisión	0.5007 ± 0.0905
			RF	Exactitud	0.6298 ± 0.2727
				F1 Score	0.4747 ± 0.2385
				Precisión	0.5291 ± 0.2153
			SVM	Exactitud	0.6826 ± 0.3246
				F1 Score	0.6008 ± 0.3696
				Precisión	0.5635 ± 0.3982
DEPENDIENTE	KNN		Exactitud	0.6577 ± 0.3266	

				F1 Score	0.5886 ± 0.3644
				Precisión	0.6577 ± 0.3266
			RF	Exactitud	0.6756 ± 0.3158
				F1 Score	0.6197 ± 0.3512
			SVM	Precisión	0.6756 ± 0.3158
				Exactitud	0.7047 ± 0.3070
	F1 Score	0.6403 ± 0.3531			
	Excitación alta VS Excitación baja	INDEPENDIENTE	KNN	Precisión	0.7047 ± 0.3070
				Exactitud	0.5361 ± 0.1041
				F1 Score	0.4558 ± 0.1237
			RF	Precisión	0.5227 ± 0.0822
				Exactitud	0.5118 ± 0.1164
				F1 Score	0.4439 ± 0.1341
			SVM	Precisión	0.5270 ± 0.0785
				Exactitud	0.5085 ± 0.3179
				F1 Score	0.3927 ± 0.3161
		DEPENDIENTE	KNN	Precisión	0.3440 ± 0.3259
				Exactitud	0.6588 ± 0.3228
				F1 Score	0.5982 ± 0.3569
			RF	Precisión	0.6588 ± 0.3228
Exactitud				0.6812 ± 0.3123	
F1 Score				0.6236 ± 0.3473	
SVM			Precisión	0.6812 ± 0.3123	
			Exactitud	0.7150 ± 0.3014	
			F1 Score	0.6578 ± 0.3435	
Precisión	0.7150 ± 0.3014				

GSR + RSP: intervalos de 60 segundos solapados al 50%

SIN SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → LOGO (con secuencia par/impar)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.5087 ± 0.1603
				F1 Score	0.4138 ± 0.1214
				Precisión	0.4931 ± 0.0704
			RF	Exactitud	0.5237 ± 0.1800
				F1 Score	0.4049 ± 0.1114
				Precisión	0.4987 ± 0.0915
		SVM	Exactitud	0.5810 ± 0.3241	
			F1 Score	0.4843 ± 0.3505	
			Precisión	0.4375 ± 0.3739	
		DEPENDIENTE	KNN	Exactitud	0.8585 ± 0.2252
				F1 Score	0.8255 ± 0.2716
				Precisión	0.8585 ± 0.2252
	RF		Exactitud	0.8057 ± 0.2702	
			F1 Score	0.7629 ± 0.3195	
			Precisión	0.8057 ± 0.2702	
	SVM	Exactitud	0.9278 ± 0.1401		
		F1 Score	0.9095 ± 0.1753		
		Precisión	0.9278 ± 0.1401		
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5183 ± 0.1873
				F1 Score	0.3859 ± 0.1218
				Precisión	0.4989 ± 0.0990
			RF	Exactitud	0.5437 ± 0.2339
				F1 Score	0.3866 ± 0.1635
				Precisión	0.4978 ± 0.1616
			SVM	Exactitud	0.6225 ± 0.3718
				F1 Score	0.5616 ± 0.3979
				Precisión	0.5279 ± 0.4216
DEPENDIENTE		KNN	Exactitud	0.8952 ± 0.2001	
			F1 Score	0.8704 ± 0.2404	
			Precisión	0.8952 ± 0.2001	
		RF	Exactitud	0.8567 ± 0.2281	
			F1 Score	0.8291 ± 0.2644	
			Precisión	0.8567 ± 0.2281	
		SVM	Exactitud	0.9252 ± 0.1533	
			F1 Score	0.9051 ± 0.1924	
			Precisión	0.9252 ± 0.1533	
Excitación alta VS	INDEPENDIENTE	KNN	Exactitud	0.4691 ± 0.1907	
			F1 Score	0.3731 ± 0.1562	

	Excitación baja	DEPENDIENTE	RF	Precisión	0.4665 ± 0.1390
				Exactitud	0.4697 ± 0.1658
				F1 Score	0.3932 ± 0.1575
			SVM	Precisión	0.5206 ± 0.1202
				Exactitud	0.5102 ± 0.3456
				F1 Score	0.3907 ± 0.3308
			KNN	Precisión	0.3488 ± 0.3375
				Exactitud	0.8995 ± 0.1987
				F1 Score	0.8742 ± 0.2446
		RF	Precisión	0.8995 ± 0.1987	
			Exactitud	0.8601 ± 0.2387	
			F1 Score	0.8281 ± 0.2841	
		SVM	Precisión	0.8601 ± 0.2387	
			Exactitud	0.9351 ± 0.1424	
			F1 Score	0.9180 ± 0.1763	
Precisión	0.9351 ± 0.1424				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.5297 ± 0.1421
				F1 Score	0.4412 ± 0.1452
				Precisión	0.5255 ± 0.1170
			RF	Exactitud	0.5080 ± 0.2013
				F1 Score	0.3911 ± 0.1589
				Precisión	0.4826 ± 0.1641
			SVM	Exactitud	0.5691 ± 0.3324
				F1 Score	0.4749 ± 0.3542
				Precisión	0.4293 ± 0.3760
		DEPENDIENTE	KNN	Exactitud	0.7044 ± 0.3099
				F1 Score	0.6515 ± 0.3368
				Precisión	0.7044 ± 0.3099
			RF	Exactitud	0.7096 ± 0.3140
				F1 Score	0.6593 ± 0.3498
				Precisión	0.7096 ± 0.3140
			SVM	Exactitud	0.7345 ± 0.2814
				F1 Score	0.6867 ± 0.3101
				Precisión	0.7345 ± 0.2814
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5461 ± 0.1838
				F1 Score	0.4275 ± 0.1630
				Precisión	0.5203 ± 0.1311
			RF	Exactitud	0.6384 ± 0.2941
				F1 Score	0.5214 ± 0.2804
				Precisión	0.6134 ± 0.2442
			SVM	Exactitud	0.6513 ± 0.3610
				F1 Score	0.5793 ± 0.3896
				Precisión	0.5462 ± 0.4137
DEPENDIENTE			KNN	Exactitud	0.7577 ± 0.3247

				F1 Score	0.7214 ± 0.3540
				Precisión	0.7577 ± 0.3247
				RF	Exactitud
			F1 Score		0.7570 ± 0.3393
			Precisión		0.7950 ± 0.2962
			SVM	Exactitud	0.7789 ± 0.2775
	F1 Score	0.7278 ± 0.3309			
	Precisión	0.7789 ± 0.2775			
	Excitación alta VS Excitación baja	INDEPENDIENTE	KNN	Exactitud	0.4973 ± 0.1925
				F1 Score	0.4111 ± 0.1633
				Precisión	0.5115 ± 0.1329
			RF	Exactitud	0.5137 ± 0.1929
				F1 Score	0.4264 ± 0.1817
				Precisión	0.5335 ± 0.1576
		SVM	Exactitud	0.5246 ± 0.3357	
			F1 Score	0.4036 ± 0.3281	
			Precisión	0.3595 ± 0.3370	
		DEPENDIENTE	KNN	Exactitud	0.7525 ± 0.2944
				F1 Score	0.7077 ± 0.3299
				Precisión	0.7525 ± 0.2944
RF	Exactitud		0.7764 ± 0.2724		
	F1 Score		0.7318 ± 0.3159		
	Precisión		0.7764 ± 0.2724		
SVM	Exactitud	0.8005 ± 0.2582			
	F1 Score	0.7576 ± 0.3041			
	Precisión	0.8005 ± 0.2582			

GSR: intervalos de 15 segundos

CON SELECCIÓN DE CARACTERÍSTICAS

- Modelos independientes del sujeto → LOSO
- Modelos dependientes del sujeto → SKF (k = 10)

Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
MAD	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.5319 ± 0.1323
				F1 Score	0.4346 ± 0.1170
				Precisión	0.5152 ± 0.0618
			RF	Exactitud	0.5294 ± 0.1526
				F1 Score	0.4143 ± 0.1062
				Precisión	0.4977 ± 0.0661
		SVM	Exactitud	0.5657 ± 0.2772	
			F1 Score	0.3991 ± 0.2092	
			Precisión	0.4929 ± 0.2170	
		DEPENDIENTE	KNN	Exactitud	0.7415 ± 0.1676
				F1 Score	0.7032 ± 0.1942
				Precisión	0.7291 ± 0.2053
	RF		Exactitud	0.7617 ± 0.1683	
			F1 Score	0.7275 ± 0.1968	
			Precisión	0.7540 ± 0.2053	
	SVM	Exactitud	0.7354 ± 0.1784		
		F1 Score	0.6863 ± 0.2035		
		Precisión	0.7130 ± 0.2172		
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5147 ± 0.1697
				F1 Score	0.3854 ± 0.1162
				Precisión	0.4796 ± 0.1054
			RF	Exactitud	0.5440 ± 0.2335
				F1 Score	0.3713 ± 0.1222
				Precisión	0.4757 ± 0.1077
		SVM	Exactitud	0.6482 ± 0.3609	
			F1 Score	0.5781 ± 0.3902	
			Precisión	0.5447 ± 0.4145	
DEPENDIENTE		KNN	Exactitud	0.8511 ± 0.1369	
			F1 Score	0.8266 ± 0.1623	
			Precisión	0.8526 ± 0.1555	
	RF	Exactitud	0.8817 ± 0.1424		
		F1 Score	0.8516 ± 0.1753		
		Precisión	0.8800 ± 0.1607		
SVM	Exactitud	0.8638 ± 0.1229			
	F1 Score	0.8324 ± 0.1501			
	Precisión	0.8624 ± 0.1370			
Excitación alta VS	INDEPENDIENTE	KNN	Exactitud	0.5278 ± 0.1160	
			F1 Score	0.4328 ± 0.1185	

	Excitación baja		RF	Precisión	0.5133 ± 0.0747
				Exactitud	0.5330 ± 0.1968
				F1 Score	0.4209 ± 0.1575
			SVM	Precisión	0.5180 ± 0.1115
				Exactitud	0.5229 ± 0.3357
				F1 Score	0.4028 ± 0.3282
		DEPENDIENTE	KNN	Precisión	0.3587 ± 0.3372
				Exactitud	0.8289 ± 0.1539
				F1 Score	0.7938 ± 0.1840
			RF	Precisión	0.8161 ± 0.1854
				Exactitud	0.8348 ± 0.1747
				F1 Score	0.7952 ± 0.2132
			SVM	Precisión	0.8199 ± 0.2167
				Exactitud	0.8457 ± 0.1593
				F1 Score	0.8147 ± 0.1907
Precisión	0.8373 ± 0.1912				
Normalización	Clases	Dependencia	Clasificador	Métrica	Media + std
01	Valencia alta VS Valencia baja	INDEPENDIENTE	KNN	Exactitud	0.4907 ± 0.0862
				F1 Score	0.4152 ± 0.1036
				Precisión	0.5012 ± 0.0531
			RF	Exactitud	0.4793 ± 0.1284
				F1 Score	0.3829 ± 0.0930
				Precisión	0.4783 ± 0.0643
		SVM	Exactitud	0.5746 ± 0.3314	
			F1 Score	0.4775 ± 0.3530	
			Precisión	0.4320 ± 0.3748	
		DEPENDIENTE	KNN	Exactitud	0.7204 ± 0.1917
				F1 Score	0.6738 ± 0.2194
				Precisión	0.6919 ± 0.2482
	RF		Exactitud	0.7281 ± 0.2093	
			F1 Score	0.6881 ± 0.2277	
			Precisión	0.7084 ± 0.2351	
	SVM	Exactitud	0.7260 ± 0.2079		
		F1 Score	0.6482 ± 0.2352		
		Precisión	0.6532 ± 0.2648		
	Dominancia alta VS Dominancia baja	INDEPENDIENTE	KNN	Exactitud	0.5375 ± 0.1830
				F1 Score	0.3907 ± 0.1047
				Precisión	0.4959 ± 0.0491
			RF	Exactitud	0.5733 ± 0.2137
				F1 Score	0.3940 ± 0.1065
				Precisión	0.4833 ± 0.0770
SVM		Exactitud	0.6491 ± 0.3609		
		F1 Score	0.5785 ± 0.3900		
		Precisión	0.5452 ± 0.4142		
DEPENDIENTE	KNN	Exactitud	0.6746 ± 0.1365		

				F1 Score	0.5631 ± 0.1563
				Precisión	0.5775 ± 0.1864
			RF	Exactitud	0.6628 ± 0.1630
				F1 Score	0.5701 ± 0.1871
			SVM	Precisión	0.5876 ± 0.2090
				Exactitud	0.6934 ± 0.1037
	Excitación alta VS Excitación baja	INDEPENDIENTE	KNN	F1 Score	0.5082 ± 0.1014
				Precisión	0.4811 ± 0.1153
				Exactitud	0.6934 ± 0.1037
			RF	F1 Score	0.5043 ± 0.1477
				Precisión	0.5178 ± 0.0629
				Exactitud	0.5003 ± 0.1476
	SVM	F1 Score	0.4217 ± 0.1407		
		Precisión	0.5203 ± 0.0784		
		Exactitud	0.5232 ± 0.3354		
	DEPENDIENTE	KNN	F1 Score	0.4030 ± 0.3281	
			Precisión	0.3588 ± 0.3371	
			Exactitud	0.6370 ± 0.1760	
		RF	F1 Score	0.5772 ± 0.1990	
			Precisión	0.5867 ± 0.2180	
Exactitud			0.6674 ± 0.1790		
SVM	F1 Score	0.6043 ± 0.2065			
	Precisión	0.6251 ± 0.2333			
	Exactitud	0.6585 ± 0.1304			
				Precisión	0.5152 ± 0.1284
				Precisión	0.5011 ± 0.1487

3. Métricas para los clasificadores finales reportados en el trabajo

El anexo recoge las métricas para los tres tipos de clasificadores que se probaron en los modelos reportados finalmente en el trabajo: modelos dependientes del sujeto, con una normalización MAD, un enventanado con intervalos de 60 segundos solapados al 50% y sin selección de características. Cabe resaltar que las métricas empleadas (exactitud, precisión y F1-Score) coinciden totalmente por el método de validación LOO empleado, por lo que solo se reporta la media y desviación estándar de la precisión. Estos resultados se proporcionan para la señal GSR, la señal RSP y la combinación de ambas, así como para la clasificación de pares de estímulos y de niveles altos y bajos de las dimensiones del SAM.

El algoritmo KNN se fundamenta en el concepto de que puntos de datos que están cercanos entre sí en el espacio de características tienden a tener etiquetas o valores parecidos (Srivastava, 2024). En el entrenamiento del modelo se almacena el conjunto de datos proporcionado como referencia, en el que cada muestra está relacionada con unas etiquetas que pueden ser los tipos de estímulos o los niveles de dimensiones del SAM. En este estudio, KNN utiliza para la predicción la distancia euclídea entre el punto de los datos de entrada y los k puntos de datos del entrenamiento. Posteriormente, calcula el promedio ponderado de los k vecinos, de tal forma que los que se encuentran más cerca del punto de entrada tienen un mayor peso, y el resultado será la etiqueta asignada. El valor de k se ajusta para cada modelo de tal forma que maximice las métricas.

El algoritmo RF se considera un método ensamblado por emplear diferentes árboles de decisión en el entrenamiento. Los árboles de decisión son modelos que se organizan como un árbol invertido, en los que cada nodo representa una característica que se divide en ramas que reflejan las posibles opciones basadas en esa característica (Pan et al., 2020). De esta forma, para construir cada árbol de decisión, RF selecciona aleatoriamente una muestra del conjunto de datos de entrenamiento, permitiendo que algunas muestras puedan repetirse. Además, cada árbol realiza un muestreo aleatorio de las características, permitiendo la focalización en diferentes aspectos del conjunto de los datos. Una vez entrenado, se evaluará el conjunto de datos de validación con el modelo y cada árbol de decisión emitirá su propia predicción. La clase más votada será la que se asigne como etiqueta. Para cada modelo se ajustó el número de árboles de decisión para maximizar las métricas.

De esta forma, se proporcionan tablas en las que se marca en naranja el algoritmo SVM, que fue el que mejores resultados proporcionó.

Métricas de GSR sin selección de características, estímulos.

Estímulos	Clasificador	Precisión (media ± std) (%)
Positivo Negativo	KNN	72,97 ± 39,75
	RF	68,59 ± 40,83
	SVM	80,12 ± 32,95
Positivo Erótico	KNN	76,11 ± 37,56
	RF	75,35 ± 40,36
	SVM	82,59 ± 31,52
Negativo Erótico	KNN	71,97 ± 39,64
	RF	69,65 ± 41,23
	SVM	78,00 ± 35,40

Métricas de RSP sin selección de características, estímulos.

Estímulos	Clasificador	Precisión (media ± std) (%)
Positivo Negativo	KNN	69,83 ± 44,05
	RF	69,32 ± 44,38
	SVM	75,04 ± 41,37
Positivo Erótico	KNN	75,47 ± 40,74
	RF	75,21 ± 40,44
	SVM	80,00 ± 37,18
Negativo Erótico	KNN	74,53 ± 41,27
	RF	77,26 ± 39,49
	SVM	82,48 ± 33,60

Métricas de GSR+RSP sin selección de características, estímulos.

Estímulos	Clasificador	Precisión (media ± std) (%)
Positivo Negativo	KNN	80,31 ± 36,99
	RF	73,24 ± 40,54
	SVM	85,52 ± 31,52
Positivo Erótico	KNN	82,93 ± 33,15
	RF	80,43 ± 36,46
	SVM	89,61 ± 24,17
Negativo Erótico	KNN	83,34 ± 32,26
	RF	78,31 ± 38,07
	SVM	86,61 ± 29,76

Métricas de GSR sin selección de características, dimensiones.

Dimensión	Clasificador	Precisión (media ± std) (%)
Valencia alta Valencia baja	KNN	73,05 ± 38,17
	RF	69,00 ± 40,86
	SVM	81,95 ± 32,81
Dominancia alta Dominancia baja	KNN	75,40 ± 38,27
	RF	82,49 ± 33,13
	SVM	82,75 ± 31,09
Excitación alta Excitación baja	KNN	77,98 ± 37,53
	RF	76,11 ± 39,24
	SVM	82,46 ± 32,06

Métricas de RSP sin selección de características, dimensiones.

Dimensión	Clasificador	Precisión (media ± std) (%)
Valencia alta Valencia baja	KNN	70,69 ± 44,08
	RF	69,58 ± 44,47
	SVM	74,97 ± 41,52
Dominancia alta Dominancia baja	KNN	75,08 ± 42,24
	RF	74,05 ± 42,30
	SVM	79,76 ± 38,08
Excitación alta Excitación baja	KNN	75,33 ± 42,13
	RF	73,06 ± 41,61
	SVM	79,61 ± 38,53

Métricas de GSR+RSP sin selección de características, dimensiones.

Dimensión	Clasificador	Precisión (media ± std) (%)
Valencia alta Valencia baja	KNN	79,37 ± 36,69
	RF	72,53 ± 40,46
	SVM	86,41 ± 30,15
Dominancia alta Dominancia baja	KNN	84,39 ± 32,31
	RF	84,09 ± 31,38
	SVM	87,91 ± 27,97
Excitación alta Excitación baja	KNN	85,39 ± 32,85
	RF	83,11 ± 32,62
	SVM	90,06 ± 24,82


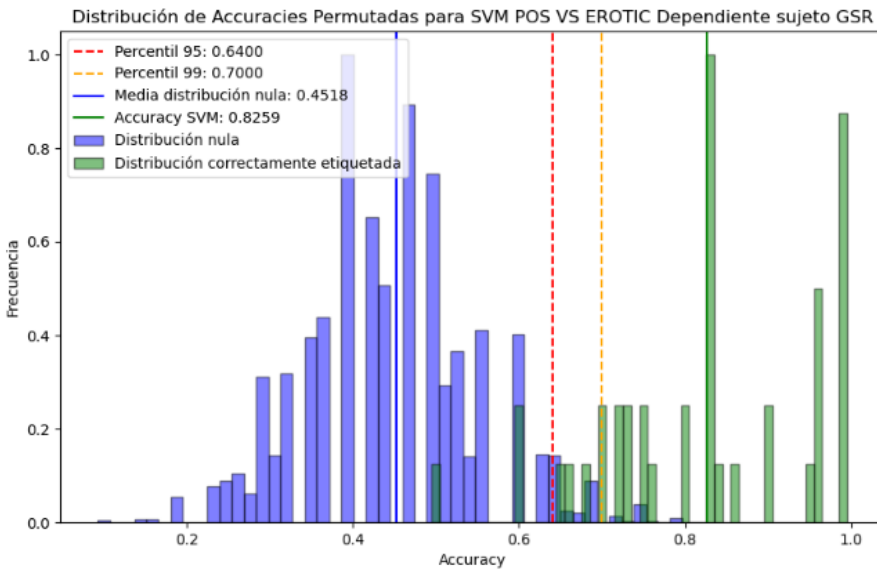
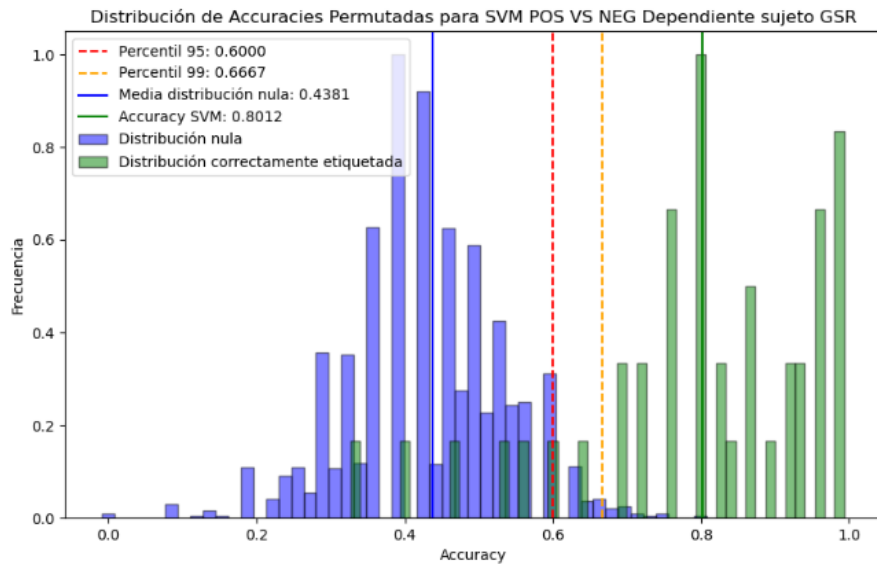
4. Pruebas de permutación para los modelos SVM reportados en el trabajo

El anexo recoge las pruebas de permutación realizadas a los modelos reportados en el trabajo, es decir, clasificadores SVM de estímulos y niveles de las diferentes dimensiones emocionales, dependientes del sujeto, con una normalización MAD y cuyos datos son obtenidos en ventanas de 60 segundos solapadas al 50%.

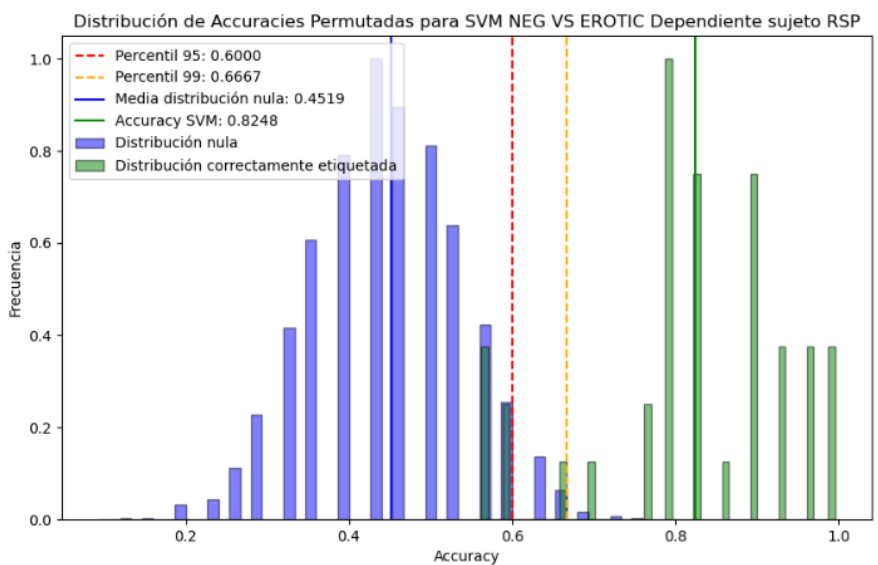


Se recuerda que estas pruebas se realizaron para validar los resultados obtenidos en cada uno de los modelos, en las que se buscaba que las medias de la distribución de exactitudes de SVM se encontrasen por encima del percentil 95 o 99 de la distribución nula, obtenida mediante 200 iteraciones en las que se permutaban aleatoriamente las etiquetas de los datos de entrenamiento y se obtenía la precisión para cada sujeto. Esto suponía una probabilidad menor al 5% (percentil 95) o al 1% (percentil 99) de que los valores de precisión de los modelos (que coinciden con los de exactitud y F1-Score por aplicar una validación LOO consistente) hubieran sido obtenidos por causa de azar.

En las ilustraciones la distribución nula se representa mediante barras azules; la media de precisión (*accuracy*) de la distribución nula con una línea azul; la distribución del modelo correctamente etiquetado a través de barras verdes; la media de precisión de la distribución entrenada con las etiquetas correctas mediante una línea verde; y el percentil 95 y 99 de la distribución nula con líneas rojas y amarillas, respectivamente.

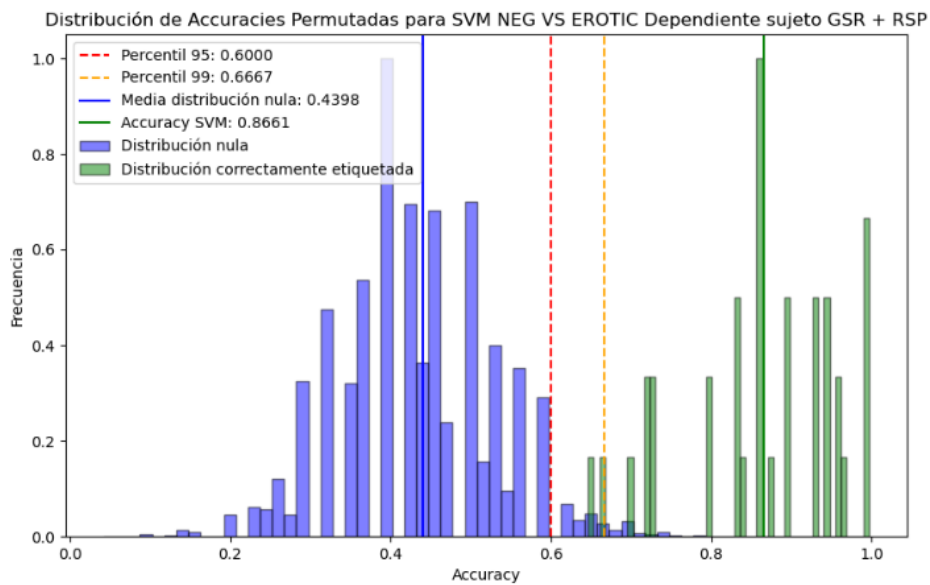
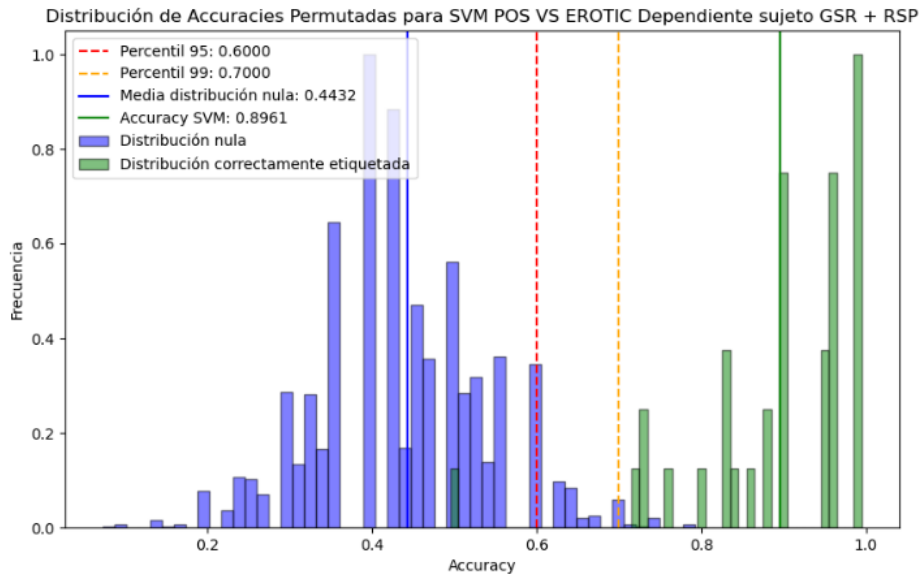
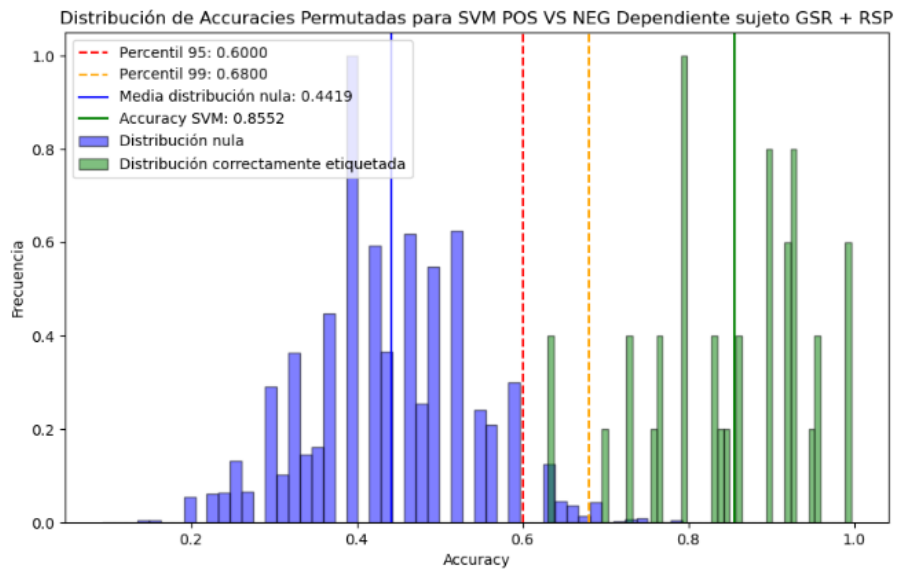
Pruebas de permutación para GSR, estímulos.



Pruebas de permutación para RSP, estímulos.




Pruebas de permutación para GSR+RSP, estímulos.

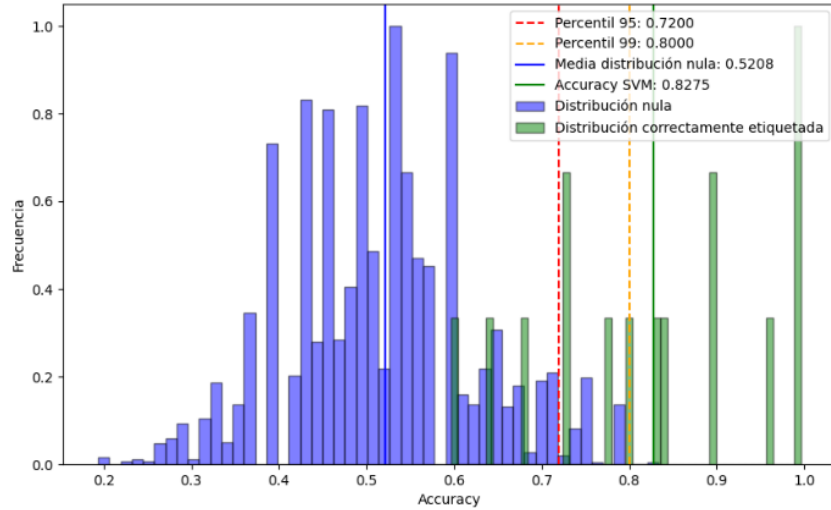


Pruebas de permutación para GSR, dimensiones.


Distribución de Accuracías Permutadas para SVM VALENCIA ALTA VS VALENCIA BAJA Dependiente sujeto GSR



Distribución de Accuracías Permutadas para SVM DOMINANCIA ALTA VS DOMINANCIA BAJA Dependiente sujeto GSR




Distribución de Accuracías Permutadas para SVM AROUSAL ALTO VS AROUSAL BAJO Dependiente sujeto GSR




Pruebas de permutación para RSP, dimensiones.


Distribución de Accuracies Permutadas para SVM VALENCIA ALTA VS VALENCIA BAJA Dependiente sujeto RSP



Distribución de Accuracies Permutadas para SVM DOMINANCIA ALTA VS DOMINANCIA BAJA Dependiente sujeto RSP




Distribución de Accuracies Permutadas para SVM AROUSAL ALTO VS AROUSAL BAJO Dependiente sujeto RSP




Pruebas de permutación para GSR+RSP, dimensiones.

Distribución de Accuracías Permutadas para SVM VALENCIA ALTA VS VALENCIA BAJA Dependiente sujeto GSR + RSP



Distribución de Accuracías Permutadas para SVM DOMINANCIA ALTA VS DOMINANCIA BAJA Dependiente sujeto GSR + R



Distribución de Accuracías Permutadas para SVM AROUSAL ALTO VS AROUSAL BAJO Dependiente sujeto GSR + RSP

