

**MODULACIÓN DE EMOCIONES A TRAVÉS DE LA MÚSICA
EN PERSONAS MAYORES**

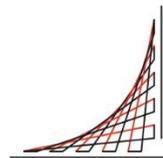
YOSLINE KATERINN JARAMILLO LOAIZA

Trabajo Dirigido

**Tutor
SANDRA CANCINO PhD (C)**



**Universidad del
Rosario**



**ESCUELA
COLOMBIANA
DE INGENIERÍA
JULIO GARAVITO**

**UNIVERSIDAD DEL ROSARIO
ESCUELA COLOMBIANA DE INGENIERÍA JULIO GARAVITO
PROGRAMA DE INGENIERÍA BIOMÉDICA
BOGOTÁ D.C
2022**

AGRADECIMIENTOS

Primero que todo agradezco a Dios porque con este documento culmino mis estudios de pregrado, gracias a él tuve la oportunidad de estudiar una carrera profesional.

También agradezco a mi tutora de tesis Sandra Cancino quien me guio y me dio la confianza de poder trabajar con ella, agradezco por todos los conocimientos aprendidos y el esfuerzo puesto para ello, por las experiencias en diferentes eventos, por los consejos y críticas que ayudan a ser mejor persona y profesional.

También quiero agradecer a Julián Gonzalez, la persona que hizo que me interesara mucho más esta línea de énfasis al presentarme su proyecto, agradezco su paciencia al explicarme y hacerme aterrizar como ingeniera. Agradezco su amistad y compañía porque personas de este calibre, pocas. Quiero agradecerle porque fue un esfuerzo en conjunto y siempre estuvo ahí para que no me rindiera y siempre avanzara en cualquier tipo de situación.

Por último, agradezco a la persona que se tomará el tiempo de leer esta investigación, la cual es el fruto de 5 años de estudio y la cual finaliza una gran etapa de mi vida.

TABLA DE CONTENIDO

1. INTRODUCCIÓN.....	3
2. OBJETIVOS	8
2.1. General.....	8
2.2. Específicos	8
3. METODOLOGÍA.....	9
4. RESULTADOS	36
5. DISCUSIÓN.....	42
6. RECOMENDACIONES Y TRABAJOS FUTUROS.....	44
7. CONCLUSIONES	45
REFERENCIAS	46
ANEXOS.....	50

1. INTRODUCCIÓN

LAS EMOCIONES

A pesar de que las emociones no tienen una definición exacta, en el libro de Psicología de la Emoción se condensan diferentes premisas para formar una, la cual plantea que “es un proceso psicológico que nos prepara para adaptarnos y responder al entorno”. Dicho proceso implica cambios cognitivos como en el aprendizaje, la atención y la memoria, cambios fisiológicos como tensión muscular, aumento de la respiración o de la temperatura, y cambios conductuales como afrontamiento o evitación [1].

La hipótesis del marcador somático propuesto por Damasio (1998) establece que “un cambio fisiológico manifestado a nivel corporal, que refleja un estado emocional (somatización), puede afectar directamente la toma de decisiones”. Esto quiere decir que las emociones se vuelven un factor influyente al momento de dictaminar un juicio, planificar una acción y expresar una decisión. Un claro ejemplo, es cuando se tiene una experiencia en la cual se produjo una emoción determinada y es almacenada en nuestro cerebro; en el momento en que se vuelve a pasar por la misma experiencia, al recordar lo que se había sentido en ese momento, decidimos cómo actuar. Por otro lado, una forma de comprobación de esta afirmación es cuando las personas sufren una lesión en la corteza prefrontal ventromedial, donde hay tanto déficit emocional como una discapacidad severa en la toma de decisiones personales y sociales [2] [3][4].

Las emociones son controladas por el sistema límbico bajo estructuras principales como la amígdala, corteza prefrontal, hipotálamo y glándula pituitaria. La amígdala desempeña funciones como el aprendizaje emocional, la modulación de la memoria, la modulación en las contribuciones emocionales al comportamiento social y la toma de decisiones [5]. La corteza prefrontal, diferencia al ser humano con los demás seres vivos debido a la dificultad de sus funciones como lo es la inteligencia, la creatividad, la ejecución de actividades complejas, la toma de decisiones o el juicio ético y moral [6]. El Hipotálamo regula múltiples actividades viscerales que influyen sobre la conducta emocional, y participa con áreas del lóbulo temporal asociadas a la memoria; junto con la glándula pituitaria, desempeñan un papel fundamental en la fisiología de las emociones, generando respuestas endocrinas (secreción de neuropéptidos o neurohormonas) [7]. Así pues, el área más común y fuertemente relacionada con el comportamiento emocional y social humano, son los lóbulos frontales y temporales, ya que el primero es responsable de procesos cognitivos, emocionales y motivacionales, en cambio el segundo es fundamental para escuchar, el lenguaje y también las emociones [8][9][10].

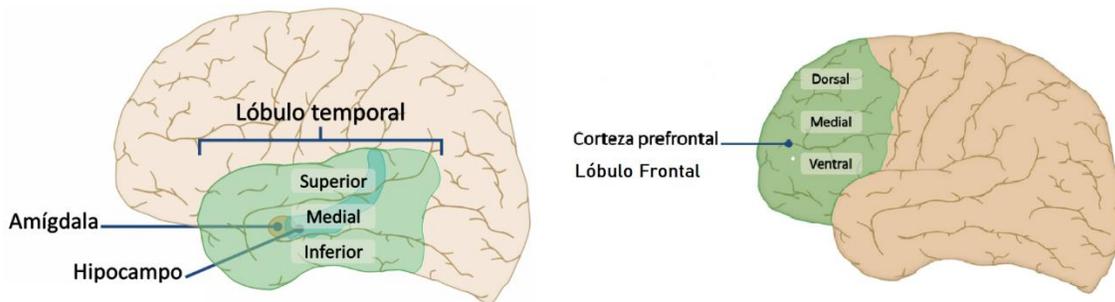


Ilustración 1. Lóbulos del cerebro donde se presentan las emociones. Tomado de: Asociación educar.

En la psicología se encuentran modelos que permiten el procesamiento emocional, uno de ellos es el de emoción discreta propuesto por Paul Ekman, el cual está representado solo por 6 emociones básicas: felicidad, tristeza, asco, ira, miedo y sorpresa, sin embargo, para los investigadores existen limitaciones al no poder describir otras emociones, ni poder medir la intensidad de la misma [11]. A su vez, se encuentra el de emoción continua desarrollado por Russell, el cual plantea que las emociones están distribuidas en un espacio circular de dos dimensiones, la activación y la valencia. El modelo usa la activación para expresar el estado emocional de relajado a activo, y la valencia se divide en polos positivo y negativo. La valencia positiva se usa para expresar emociones en un estado agradable, mientras que la valencia negativa representa un estado desagradable [12]. Se encuentra el de emoción de base cognitiva, que define 22 reglas para la generación de toma de decisiones en modelos de inteligencia artificial, donde solo cuenta con 3 emociones las cuales son acontecimientos, agentes y objetos. Dadas estas emociones se busca responder las siguientes preguntas: ¿Qué sucede cuando hay acontecimientos?, ¿Cuál es la razón de las acciones de los agentes?, y, ¿Cuáles son las propiedades atribuidas a los objetos? [13].

La música es un estímulo que se suele presentar mucho en la vida cotidiana, ya que según la Federación Internacional de la Industria Fonográfica (IFPI) a nivel mundial, las personas escuchan música más de 18.4 horas a la semana, esto es debido a que permite evocar recuerdos y experiencias [14]. Existen diversos estudios donde se observa que la música influye en las emociones y la salud, por ejemplo, el trabajo realizado por Lehmborg et al., consiste en una revisión bibliográfica sobre los beneficios que tiene la música en adultos mayores, ya sean físicos, psicológicos y sociales, concluyendo que se produce un efecto positivo en la calidad de vida como generar un bienestar físico y mental, disminución del estrés, el dolor y el uso de medicamentos, ralentiza el envejecimiento, nuevo aprendizaje, autoexpresión creativa, entre otros [15]. Para agregar, en el estudio desarrollado por Miranda et al, se hace una revisión bibliográfica de las aplicaciones favorables que puede tener la musicoterapia, describe que es útil y se puede aplicar para el tratamiento de diferentes patologías, así pues los beneficios que se pueden tener son la disminución de descargas epilépticas, mejorar la función motora y del lenguaje en personas que tuvieron un ictus, mejora del control de la agitación, ánimo, ansiedad y función cognitiva global para personas con demencia, disminución del trastorno de la marcha en pacientes con Parkinson y disminución del dolor y ansiedad en enfermedades somáticas y cáncer [16].

DETECCIÓN DE LAS EMOCIONES

Los métodos que permiten la detección emocional se realizan bajo la monitorización de los cambios en las expresiones faciales, los gestos, la postura corporal y el habla, pero son poco eficaces porque pueden ser alterados conscientemente, a comparación de las respuestas fisiológicas como lo son la respuesta galvánica de la piel (GSR), la presión del volumen sanguíneo, temperatura, electrocardiograma (ECG), electroencefalograma (EEG), etc. [17]. Según estudios, resulta más efectivo la detección de la emoción mediante el EEG, debido a que se mide la actividad eléctrica del cerebro, la cual no se puede sesgar de forma subjetiva [18]. Para su registro, el EEG se rige bajo el sistema 10-20 definido por la American Encephalographic Society (1994) y por Ostenveld & Praamstra (2001). Una técnica que consiste en la localización de los electrodos, los cuales están separados por un 10% o 20% de una distancia determinada entre el inión y el nasión. Este utiliza una nomenclatura para identificar cada región: Fp – Frontopolar, F- Frotal, C – Central, P – Parietal, O – Occipital y T – Temporal, sin embargo, también cuenta con números impares que hacen referencia al hemisferio izquierdo, números pares que referencia al hemisferio derecho y los z a la zona central [10]. Por otro lado, para su registro se cuenta con dos opciones de medición, una monopolar o dipolar, el primero registra la diferencia de potencial entre un punto neutro (oreja o mastoides) y un electrodo, en cambio el segundo, registra la diferencia de potencial entre dos electrodos.

La señal de electroencefalografía es muy utilizada sobre todo para anticipar crisis epiléptica, analizar potenciales evocados, estudiar la apnea del sueño, entre otras. Es una señal no estacionaria y no lineal, que a través de múltiples algoritmos se puede caracterizar dependiendo el objetivo de la investigación. Una vez obtenidas las características, estas pueden ser utilizadas para entrenar modelos de aprendizaje automático y predecir una determinada clase. Estos modelos son una rama de la inteligencia artificial, dedicada al desarrollo de técnicas que permitan a las computadoras generalizar comportamientos y reconocer patrones a partir de la información suministrada [19]. En la literatura existen diversos modelos como lo pueden ser las Máquinas de soporte vectorial (SVM), Redes neuronales, Redes neuronales convolucionales (CNN), Regresión lineal (RL), Random Forest, K-vecino más cercano (KNN), entre otros.

A continuación, se presentarán determinados estudios que tienen el mismo objetivo, el cual es la detección de emociones mediante señales de electroencefalografía.

En el estudio desarrollado por Galvão et al., se trabajan 3 diferentes bases de datos que registraron la señal de EEG cuando la persona escuchaba un estímulo musical, de tal forma que se etiquetaron utilizando el Self-Assessment Manikin (SAM). Las características analizadas en las ondas cerebrales beta, alpha y gamma, fueron los parámetros de Hjorth que son un análisis en tiempo y provee propiedades estadísticas de la señal. La entropía Espectral que mide la irregularidad o complejidad de las señales digitales en el dominio de la frecuencia. La Transformada de Wavelet, que permite una representación de la señal en el espacio tiempo-frecuencia. Dichas características fueron utilizadas para entrenar los 7 diferentes modelos: Regresión lineal (LR), Regresión aditiva (AR), Árbol de decisión (DT), K Vecinos más cercanos (KNN), Bosque aleatorio (RF) y Máquinas de vectores de soporte para regresión (SVR). Como resultado se obtuvo que el modelo KNN logró la mayor precisión, obteniendo un valor de 89,8 % para dos clases (activación baja/alta, valencia baja/alta) y 84,4 % para cuatro clases, el cuadrante en el espacio de valencia / excitación, dando como conclusión que las características basadas en beta y gamma generaron las mejores precisiones [18].

En el estudio planteado por Xua et al., se genera una base de datos de señales de EEG, las cuales registraron cuando se le indujeron a los participantes emociones por medio de varios videos con el fin de producir alegría, tristeza y calma. Una vez recolectadas las señales se preprocesan por medio de técnicas como reducción de la tasa de muestreo y filtro pasa bajas de 30 Hz. Para la extracción de características, se realiza una reducción de la dimensión por medio del análisis de componentes principales (PCA) y análisis de la dimensión fractal para medir la complejidad de los datos. Una vez obtenido el vector de características, se utilizan los algoritmos de clasificación SVM y KNN, obteniendo exactitudes de 83.3% para la clase feliz, 41.67% para calma y 33.33 para triste en SVM. Para KNN se obtiene 75%, 83.33% y 58%, concluyendo que en la clase de felicidad y tranquilidad se obtuvieron los mejores resultados a comparación con otros experimentos en la literatura, además, el experimento de clasificación emocional basado en la dimensión fractal tiene una cantidad computacional más baja, lo que puede acortar significativamente el tiempo requerido para la clasificación emocional y es más adecuado para el análisis de sentimientos en tiempo real [11].

En el estudio desarrollado por Islam et al., se trabaja con la base de datos DEAP, la cual obtiene los registros de EEG que se tomaron cuando se le presentaron videos a los participantes, donde respondieron como se sentían en términos de valencia y activación bajo la prueba SAM. Realizan un preprocesamiento con el fin de disminuir la tasa de muestreo para reducir el volumen de los datos y se realiza un filtro pasa banda entre los 4 y 45 Hz. Para el procesamiento se utiliza la transformada discreta de wavelet para separar las sub-bandas cerebrales alpha, beta y gamma, para entrenar una CNN, la cual necesita de muchos datos para un rendimiento exclusivo, por ende, se segmentan las señales de EEG para luego formar imágenes por medio del coeficiente de correlación de Pearson (PCC), que es la escala que representa la relación estadística entre dos variables continuas, en este caso se correlacionan entre diferentes canales. Estas imágenes se dividen en un grupo de entrenamiento (90%), prueba (5%) y validación (5%) y se incorporan a un algoritmo de clasificación basado en redes neuronales convolucionales, dando como resultados un 78,22 % y un 70,23 % de precisión en la tarea de clasificación de valencia y un 74,92 % y un 70,25 % de precisión en la tarea de clasificación de activación para la clasificación de dos y tres clases, respectivamente. Así pues, se concluye que solo la parte triangular superior del PCC, presentaba imágenes que reducían la complejidad computacional y el tamaño de la memoria sin obstaculizar la precisión del modelo [20].

El investigador Yang et al., utiliza también la base de datos DEAP, de tal forma que estos datos son preprocesados mediante la segmentación de las señales para luego sacar el promedio y restarlo a cada segmento correspondiente. Para el análisis se hace comparaciones entre los datos preprocesados y los no preprocesado. En el caso del procesamiento se convierten las señales de EEG en matrices bidimensionales, de acuerdo con el mapa de distribución de electrodos, estas imágenes entrenan el modelo referente a una red neuronal recurrente convolucional paralela. Finalmente, se concluye que el preprocesamiento puede mejorar la precisión en un 32 % y que el modelo podría lograr una alta precisión de alrededor del 90,80 % y el 91,03 %, para la tarea de clasificación de valencia y excitación, respectivamente [21].

2. OBJETIVOS

2.1.General

Clasificar las respuestas emocionales en términos de valencia y activación de señales cerebrales obtenidas en adultos mayores en respuesta a estímulos musicales.

2.2.Específicos

- a) Realizar el preprocesamiento del EEG para eliminar ruido y realzar la información de relevancia.
- b) Extraer las características de la señal de EEG que permitan identificar los estados emocionales relacionados con las dimensiones de valencia y activación.
- c) Utilizar modelos de aprendizaje automático para la clasificación de respuestas emocionales de la valencia y activación.
- d) Evaluar el desempeño de los modelos de aprendizaje automático con las métricas apropiadas.

3. METODOLOGÍA

PREGUNTA DE INVESTIGACIÓN

¿Existe una relación significativa entre la música y el estado emocional en una persona adulto mayor?

HIPOTESIS

- Una sola característica es suficiente para entrenar modelos de aprendizaje automático de tal forma que, clasifiquen los estados de la emoción de arousal (activante, control y relajado) y de valencia (agradable, control y desagradable), obteniendo una exactitud mayor al 70%.

PROTOCOLO EXPERIMENTAL

PRUEBAS PSICOMÉTRICAS

Estas son consideradas como instrumentos que permiten obtener información relevante respecto al participante. Estas pruebas son:

Consentimiento Informado: Este [documento](#) busca que el participante tenga total conocimiento del objetivo del proyecto y el proceso a realizar. Además, autoriza el tratamiento de sus datos, en donde los investigadores dejan en claro que la información recolectada será de gran confidencialidad con fines académicos e investigativos.

Entrevista Sociodemográfica: Cuenta con 32 preguntas y tres diferentes enfoques, el primero, es un registro respecto al entorno social, familiar y personal como, por ejemplo: edad, estrato, barrio, ciudad, profesión, entre otras. En el segundo, se examinan los antecedentes médicos y psicológicos, con el fin de observar que cumple con los criterios de inclusión para que no se afecte el registro de la señal de EEG. Dichos criterios son:

- Deben ser personas mayores entre los 60 a 85 años.
- No debe tener antecedentes de alguna cardiopatía, alguna patología neuropsiquiátrica o neurodegenerativa.
- Sin problemas de escucha como discapacidad auditiva congénita, enfermedades del oído o de la apófisis matoides.
- Con capacidad para realizar actividades básicas de la vida diaria (alimentación, vestirse, continencia urinaria y/o rectal, uso del sanitario). Que no padezca alguna discapacidad múltiple, es decir, presencia de discapacidad física, sensorial, intelectual y/ mental.

Por último, se hacen preguntas referentes a la pandemia y como esta tuvo influencia en sus emociones. Las preguntas se encuentran en el siguiente [link](#).

Cuestionario sobre preferencia musical (MPQ-R): Por medio del [cuestionario](#) se busca conocer los gustos musicales, la frecuencia y las conductas habituales al escuchar música. Se toma la adaptación de Nater 2003, sin embargo, se agregan otras preguntas con el fin de conocer qué piezas musicales relajan o activan a los participantes [22].

Trait Meta-Mood Scale TMMS-24: Es una escala de autopercepción, ya que mide la inteligencia emocional (IE), la cual es definida como la habilidad para comprender, manejar las emociones propias y las de los demás [23]. Es una de las herramientas más utilizadas a nivel mundial. Cuenta con 24 ítems, los cuales analizan 3 diferentes dimensiones de la IE como lo son atención emocional, claridad y reparación emocional, de tal forma que son 8 ítems por dimensión.[24] Los participantes deberán responder marcando con una x una de las siguientes opciones: 1 (nada de acuerdo), 2 (Algo de acuerdo), 3 (bastante de acuerdo), 4 (Muy de acuerdo) y 5 (totalmente de acuerdo).

A continuación, se presentan los 24 ítems:

- Presto mucha atención a los sentimientos
- Normalmente me preocupo mucho por lo que siento
- Normalmente dedico tiempo a pensar en mis emociones
- Pienso que merece la pena prestar atención a mis emociones y estado de ánimo
- ¿Dejo que mis sentimientos afecten a mis pensamientos?
- ¿Pienso en mi estado de ánimo constantemente?
- ¿A menudo pienso en mis sentimientos?
- ¿Presto mucha atención a cómo me siento?
- ¿Tengo claros mis sentimientos?
- ¿Frecuentemente puedo definir mis sentimientos?
- ¿Casi siempre sé cómo me siento?
- ¿Normalmente conozco mis sentimientos sobre las personas?
- ¿A menudo me doy cuenta de mis sentimientos en diferentes situaciones?
- ¿Siempre puedo decir cómo me siento?
- ¿A veces puedo decir cuáles son mis emociones?
- ¿Puedo llegar a comprender mis sentimientos?
- ¿Aunque a veces me siento triste, suelo tener una visión optimista?
- ¿Aunque me sienta mal, procuro pensar en cosas agradables?
- ¿Cuándo estoy triste, pienso en todos los placeres de la vida?
- ¿Intento tener pensamientos positivos, aunque me sienta mal?
- ¿Si doy demasiadas vueltas a las cosas, complicándolas, trato de calmarme?
- ¿Me preocupo por tener un buen estado de ánimo?
- ¿Tengo mucha energía cuando me siento feliz?
- ¿Cuándo estoy enfadado(a) intento cambiar mi estado de ánimo?

La Escala de Depresión Geriátrica de Yesavage: Se adopta la escala generada por Aguado et al., (2000), con el fin de que solo se evalúen 15 ítems y se determine si el participante tiene algún trastorno de depresión mayor, permitiendo así clasificar como: sin riesgo de depresión, riesgo de depresión leve y riesgo de depresión severa [25]. Es común utilizar esta herramienta en la población del adulto mayor, debido a que según la OMS el 5.7% de las personas mayores se diagnostica con depresión, siendo una de las poblaciones más propensas debido a factores como el abandono, vivir en lugares

geriátricos, contar con problemas somáticos, sentimientos de culpa, insomnio, maltrato, etc. [26][27][28]. Esta escala cuenta con 10 preguntas directas o positivas que miden los síntomas (¿Siente que su vida está vacía) y 5 preguntas inversas o negativas (“¿En el fondo está satisfecho con su vida?”). El participante solo responde SI o NO.

A continuación, se presenta los ítems evaluados en donde los 5 primeros son preguntas negativas y las otras 10, preguntas positivas.

- ¿Se siente básicamente satisfecho con su vida?
- ¿Se siente aburrido frecuentemente?
- ¿Se siente inútil o despreciable como está usted en este momento?
- ¿Prefiere quedarse en casa en vez de salir?
- ¿Se siente con frecuencia desamparado?
- ¿Siente que su vida está vacía?
- ¿Está de buen ánimo la mayor parte del tiempo?
- ¿Está preocupado o teme que algo malo le va a suceder?
- ¿Se siente feliz la mayor parte del tiempo?
- ¿Ha disminuido o abandonado muchas de sus actividades previas?
- ¿Tiene más problemas con su memoria que la gente de su edad?
- ¿Cree usted que es maravilloso estar vivo?
- ¿Se siente lleno de energía?
- ¿Se encuentra sin esperanza ante una situación actual?
- ¿Cree usted que en general las otras personas están mejor que usted?

Nota: Estas pruebas se realizan debido a que, al tomar datos, solo se busca que haya la mayor expresión de la emoción provocada por la música, más no, la emoción provocada por algún trastorno, entre ellos la depresión.

Inventario de Ansiedad Rasgo-Estado IDARE: Esta herramienta permite medir los niveles de ansiedad en dos diferentes dimensiones, y cada una cuenta con 20 diferentes ítems [29]. La primera dimensión es la Ansiedad-Estado, la cual indica el nivel de intensidad y se divide en 4 categorías (1. No en absoluto, 2. Un poco, 3. Bastante, 4. Mucho) a su vez expresa cómo se siente el participante “ahora” o “en ese mismo instante”. La segunda dimensión Estado-Rasgo, cuenta con una escala que mide la frecuencia, también en 4 categorías (1. Casi nunca, 2. Algunas Veces, 3. Frecuentemente, 4. Casi siempre) en cuanto a que refiere a cómo se siente el participante “habitualmente” o “por lo general” [30].

A continuación, se presentan ambos IDARE

IDARE-Estado

- Me siento calmado(a)
- Me siento seguro(a)
- Estoy tenso(a)
- Estoy contrariado(a)
- Estoy a gusto(a)6. Me siento alterado(a)
- Estoy preocupado(a) actualmente por algún posible contratiempo
- Me siento cansado(a)

- Me siento ansioso(a)
- Me siento cómodo(a)
- Me siento con confianza en mí mismo(a)
- Me siento nervioso(a)
- Me siento agitado(a)
- Me siento "a punto de explotar"
- Me siento reposado(a)
- Me siento satisfecho(a)
- Estoy preocupado(a)
- Me siento muy agitado(a) y aturdido(a)
- Me siento alegre
- Me siento bien

IDARE-Rasgo

- Me siento bien
- Me canso rápidamente
- Siento ganas de llorar
- Quisiera ser tan feliz como otros parecen serlo
- Pierdo oportunidades por no poder decidirme rápidamente
- Me siento descansado(a)
- Soy una persona "tranquila", serena, y sosegada
- Siento que las dificultades se me amontonan al punto de no poder superarlas
- Me preocupo demasiado por cosas sin importancia
- Soy feliz
- Tomo las cosas muy a pecho
- Me falta confianza en mí mismo(a)
- Me siento seguro(a)
- Procuero evitar enfrentarme a las crisis y dificultades(a)
- Me siento melancólico(a)³⁶. Me siento satisfecho(a)
- Algunas ideas poco importantes pasan por mi mente y me molestan
- Me afectan tanto los desengaños que no me los puedo quitar de la cabeza
- Soy una persona estable
- Cuando pienso en mis preocupaciones actuales me pongo tenso(a) y alterador(a)

Montreal Cognitive Assessment (MoCA): Es una prueba que se realiza dependiendo a la edad y el nivel de escolaridad, en donde busca determinar la presencia de deterioro cognitivo mediante habilidades como funciones ejecutivas, lenguaje, orientación, cálculo, razonamiento conceptual, percepción visual, atención y concentración. Para personas analfabetas se aplica el Montreal Cognitive Assessment Basic (MOCA-B) y para personas que si cursaron la primaria se les presenta el Montreal Cognitive Assessment Basic (MOCA-A) [31].

Maniquí de autoevaluación (Self-Assessment Manikin. SAM): Es una herramienta diseñada por Lang en 1994, en donde se representa mediante dibujos humanoides las dimensiones emocionales, las cuales son la valencia, arousal y dominancia. Se cuenta con un total de 15 imágenes, 5 por cada dimensión. En el caso de la valencia, los rostros

representan desde la felicidad hasta la tristeza, para arousal, varían desde intensidad de activación a calma y, para la dominancia, hay diferentes niveles de percepción de control [32]. En la escala original, hay cuatro espacios entre cada figura para dar una escala de 1 a 9, sin embargo, en este caso solo se evaluará la puntuación de cada imagen, es decir, de 1 a 5, ya que, durante pruebas piloto, se observó que al tener una escala muy grande (1 a 9) generaba indecisión en los participantes y no les era muy claro el tipo de emoción que representaba cada espacio.

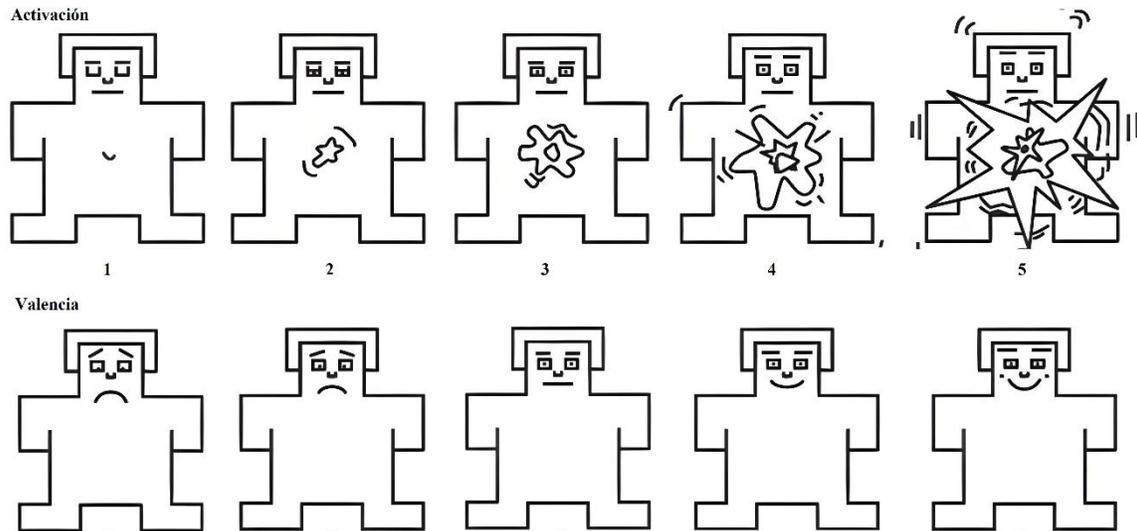


Ilustración 2. Maniqués de autoevaluación (SAM).

Cuestionario 24 Horas: Se hacen 10 preguntas en las cuales se verifica que el participante esté apto para la toma de datos. Es un cuestionario que se hace un día antes de la toma de datos fisiológicos. A continuación, se presentan:

- ¿Desayunó el día de hoy?
- ¿Qué desayunó el día de hoy?
- ¿Ha consumido chocolate durante las últimas horas?
- ¿Ha consumido bebida energizante durante las últimas horas?
- ¿Cuántas horas ha dormido?
- ¿Consume algún medicamento?
- Si la respuesta es afirmativa ¿Cuál?
- ¿Lo ha consumido durante las últimas 24 horas?
- ¿Fumaste durante las últimas 24 horas?
- ¿Cómo te sientes emocionalmente en estos momentos?

Lista de adjetivos para evaluar la personalidad (AEP): Este es un modelo desarrollado en Argentina para evaluar el modelo de los cinco grandes factores de personalidad. El modelo de los Cinco Grandes (MCF) se fundamenta en la consideración de que cinco amplias dimensiones de personalidad pueden abarcar la mayor parte de los rasgos de personalidad existentes, estos son extraversión o surgencia, amabilidad, responsabilidad, estabilidad emocional y cultura.[33] Se trata de un instrumento que mediante 67 adjetivos evalúa el perfil de personalidad de acuerdo con el MCF. Los sujetos deben responder a

los adjetivos en función de cuánto lo describen, en una escala Likert de 5 puntos (desde “No me describe en absoluto” a “Me describe tal como soy”) [34].

PROCEDIMIENTO PRUEBAS PSICOMÉTRICAS

Momento 0: Convocatoria

- Primer contacto con la población, donde se les explicó generalidades del proyecto y se tomaron los datos a las personas que querían participar. En el segundo contacto, se comunicaron con los participantes vía telefónica o presencial (ya que no todos contaban con teléfono), y se siguió el guion que determina los lineamientos de presentación como lo son el objetivo de la llamada, momentos de encuentro, dudas y aclaraciones, agendamiento de momento 1 y confirmación de datos.

Codificación de Participantes

- Cada participante tuvo la denominación PM (persona mayor) acompañada del número correspondiente, dicho número será asignado según el orden de agendamiento para el momento 1.
- Se debe tener en cuenta que se lleva a cabo un registro que determina en qué momento se encuentra cada participante y quiénes son los investigadores asignados.

Momento 1: Entrevista Inicial

Para el desarrollo del siguiente momento es necesario tener a la mano los siguientes materiales e instrumentos:

Materiales e instrumentos

- Consentimiento informado para cada persona mayor.
- Cuestionario Sociodemográfico.
- Cuestionario sobre preferencia musical (MPQ-R).
- Tapabocas quirúrgico.
- Bitácora.
- El protocolo General de Aplicación (PGA) a la mano para tener presente todas las indicaciones de la sesión.

Nota: Importante recordar un día antes a los participantes la asignación de la cita y las indicaciones previas como no tomar bebidas energizantes, dormir bien, llevar gafas si las necesitan y tener presente su historial clínico y medicamentos que toma. También, recomendar utilizar zapatos de suela de goma antideslizante o con tacón bajo, que sean un buen soporte para los pies.

Indicaciones para el consentimiento informado

Se le describió el proceso que se le llevaría a cabo, se le mostró los instrumentos y se resolvieron dudas. Terminado esto, se le entregó el consentimiento informado y a su vez, se le explicó cada una de sus componentes para que procediera a firmarlo, si estaba de acuerdo.

Entrevista sociodemográfica

Se le presentó en la pantalla del computador el cuestionario donde, se les da la posibilidad de que fueran ellos mismos los que leyeran o el investigador leyera por ellos.

Cuestionario de Preferencias

El investigador se dirigió al cuestionario de preferencias musicales para identificar los gustos de cada participante y los momentos en que escucha música, se debe tener en cuenta que el cuestionario no abarcó la totalidad de sus gustos, pero si los más importante que el participante consideraba.

Momento 2: Evaluación Psicológica

Materiales e Instrumentos

- Inventario de Ansiedad Rasgo (IDARE).
- Montreal Cognitive Assessment (MoCA)
- La Escala de Depresión Geriátrica de Yesavage
- Trait Meta-Mood Scale TMMS-24
- Prueba de personalidad
- Escritorio con altura que permita a la persona mayor trabajar de manera cómoda y pueda manipular los materiales.
- 3 a 5 sillas: Durante todo el proceso la persona mayor estará acompañada por máximo 3 estudiantes investigadores, pertenecientes a la Escuela Colombiana de Ingeniería y la Corporación Universitaria Minuto de Dios, quienes acompañarán la aplicación de las pruebas y resolverán las dudas de los participantes en caso de que sea necesario.
- Tapabocas quirúrgico.
- 1 bitácora: Los estudiantes que acompañen al participante deberán hacer las anotaciones correspondientes únicamente al final de cada prueba.
- El protocolo General de Aplicación (PGA) a la mano para tener presente todas las indicaciones de la sesión.
- 1 lápiz.
- 2 esferos.
- 1 equipo de cómputo empleado para responder a las preguntas de las pruebas psicométricas sistematizadas.

Se realizó pausas activas entre cada prueba psicométrica de 5 minutos y cuando se vio necesario. Si el adulto mayor utilizaba gafas, se le recomendó que se las retirara durante los minutos de pausa.

Las pruebas psicométricas se realizaron con el fin de observar si se presentaba indicios de ansiedad, depresión o algún deterioro cognitivo, más no, de diagnosticar o fin jurídico.

La aplicación de las pruebas va en el siguiente orden:

- IDARE-Rasgo
- Actividad 1: Subir los brazos → Descansar y repetir por lo menos de 6 a 8 veces
- Montreal Cognitive Assessment- MOCA
- Actividad 2: Flexión de hombros → Descansar y repetir al menos de 8 a 10 veces
- Escala de depresión Geriátrica de Yesavage
- Estiramiento de muñecas → Descansar y repetir al menos unas 6 a 8 veces.
- Trait Meta-Mood Scale TMMS-24
- Equilibrio fácil: Caminar en línea recta
- Lista de adjetivos para evaluar la personalidad (AEP)

Una vez finalizada la sesión, se explicó cuál era el siguiente momento y se dio las siguientes indicaciones:

- Llevar el cabello limpio y seco, sin crema para peinar o gel para el cabello.
- Los participantes deben comer normalmente, no es necesario el ayuno.
- Vestir con ropa cómoda, preferiblemente no usar joyas o accesorios o los que usen que sean fáciles de retirar.
- Haber tomado previamente medicamentos si es necesario para el participante.
- No consumir café o energizantes el día de las pruebas.
- Dormir el número habitual de horas
- Llevar una peinilla.

REGISTRO NEUROFISIOLÓGICO – Momento 3

Pasados como mínimo las 24 horas se realizó la captura de la señal de electroencefalografía.

Instrumento

Enobio: Instrumento y dispositivo que permite la medición de electroencefalografía, cuenta con 32 canales y una tasa de muestreo dinámica de 500 Hz, funciona por puerto USB o por conexión wifi. La conexión se hace mediante la interfaz NIC que está equipada con modos básicos y avanzados para diseñar y monitorear cualquier experimento de EGG. Cuenta con electrodos Geltrode NG, compuestos por el cierre (parte superior) y la arandela roscada (parte inferior) [35].

En este caso, se registraron 10 canales los cuales son: Fp1, Fp2, Af3, Af4, F3, F4, T7, T8, P7, P8 y 1 en polo a tierra (VG). Estos fueron ubicados en el cuero cabelludo y la oreja. Se escogieron porque son los suficientes para abarcar las zonas relacionadas con las respuestas emocionales tales como el córtex prefrontal [36]; el lóbulo temporal y el lóbulo parietal, este último porque se encarga de integrar la información sensorial [37]. Además, se escoge esta cantidad de electrodos con el fin de que el proceso no consuma mucho tiempo y la población no comience a aburrirse o dormirse.

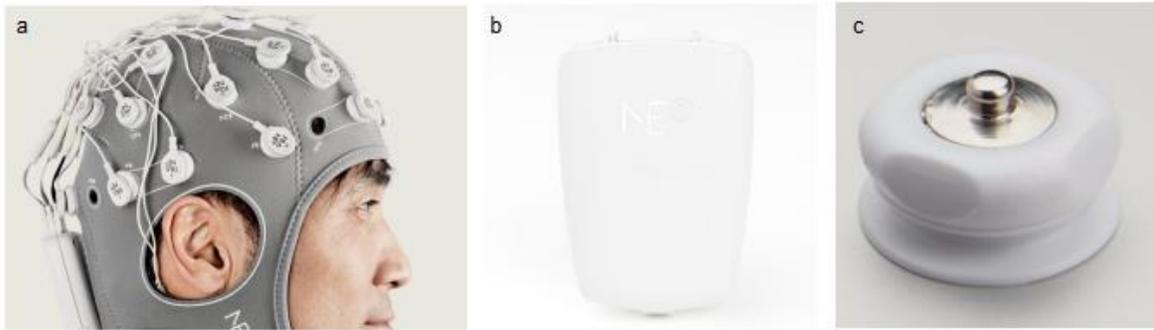


Ilustración 3. En a se observa a la persona con el cap y electrodos conectados, en b, se muestra el Enobio y c, el electrodo NG. Tomado de Neuroelectrics User Manual Enobio

Materiales e Instrumentos

- Escritorio con altura que permita a la persona mayor trabajar de manera cómoda y pueda manipular los materiales.
- 3 a 5 sillas.
- Tapabocas quirúrgico.
- Bitácora.
- El protocolo General de Aplicación (PGA).
- Lápiz.
- 2 esferos.
- Equipo de cómputo empleado para la toma de datos e interfaz.
- Enobio
- Jeringa para apartar el cabello.
- Palo de paleta para que sea más fácil aplicar el gel.
- Electrodo
- Planilla de apoyo.
- Pañitos húmedos
- Alcohol.
- Gel conductor
- Extensión
- Bolsa para depositar la basura

Toma de Datos

En principio se le explicó el procedimiento de puesta de electrodos y conexión del equipo al participante, con el fin de darle la confianza, de que no es un procedimiento invasivo o que genere algún tipo de dolor.

Luego se colocaron los electrodos, las arandelas enroscadas se colocan en los orificios del cap o gorro, una vez puestos, se le indicó al adulto mayor que se colocara el gorro lo más ajustado posible, pero sin que le molestara o causara daño. Se procedió a apartar el cabello para que se viera lo mejor posible el cuero cabelludo, se le aplicó el gel conductor y se colocó el cierre. Apenas se ajustó el cable del electrodo con el sujetador del cierre, se observó en la interfaz NIC la impedancia de este, si se encontraba en verde, significaba

que estaba puesto correctamente y tenía buen contacto para la captación de la señal, dado el caso que estuviera en amarillo o rojo, es mejor quitar el electrodo y volverlo a colocar, ya que se pierden muchos detalles dando como resultado una señal defectuosa. Por último, se le dijo al participante que debía mantener una postura relajada sin mayor movimiento, tratar de no reírse y si tiene tos, avisar a los investigadores.

PROCEDIMIENTO

1. Se realizó una prueba de sonido con una pieza neutra, con el fin de verificar el volumen adecuado para los participantes.

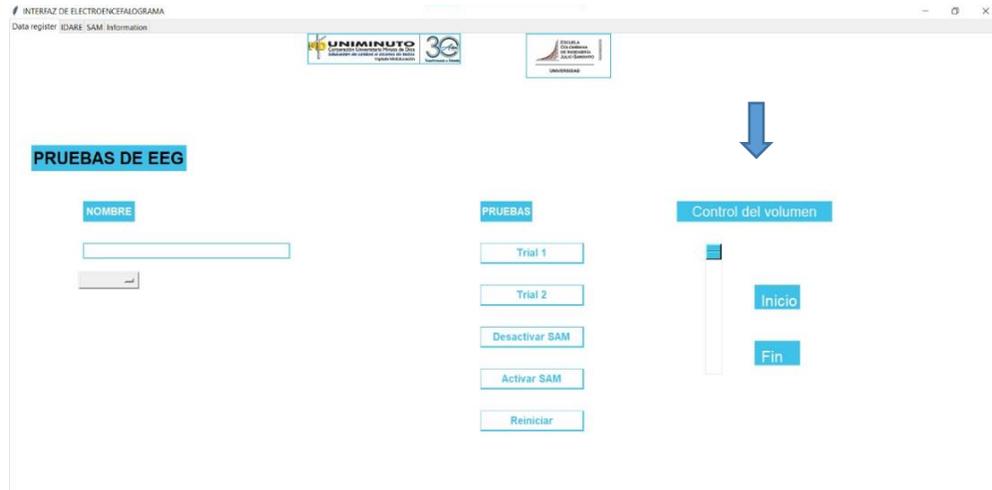


Ilustración 4. Ventana principal de la interfaz que se les presenta a los participantes. La flecha azul indica la zona que se manipula para el control de volumen.

2. Se le mostró al participante la interfaz diseñada para mostrar el inventario IDARE-Estado y para reproducir la instrucción de cómo debe responderlo. Una vez terminada la instrucción, se le preguntó si entendió o si tenía alguna duda al respecto, para que procediera a contestarla.



Ilustración 5. Pestaña que presenta la prueba IDARE – ESTADO.

- En la misma interfaz, se le presentó el Self Assessment Manikin (SAM) y se reprodujo la correspondiente instrucción de cómo contestarlo, de tal forma que se le hizo la prueba de cómo se sentía en ese mismo instante, con el fin de que entendiera completamente cómo funcionaba.

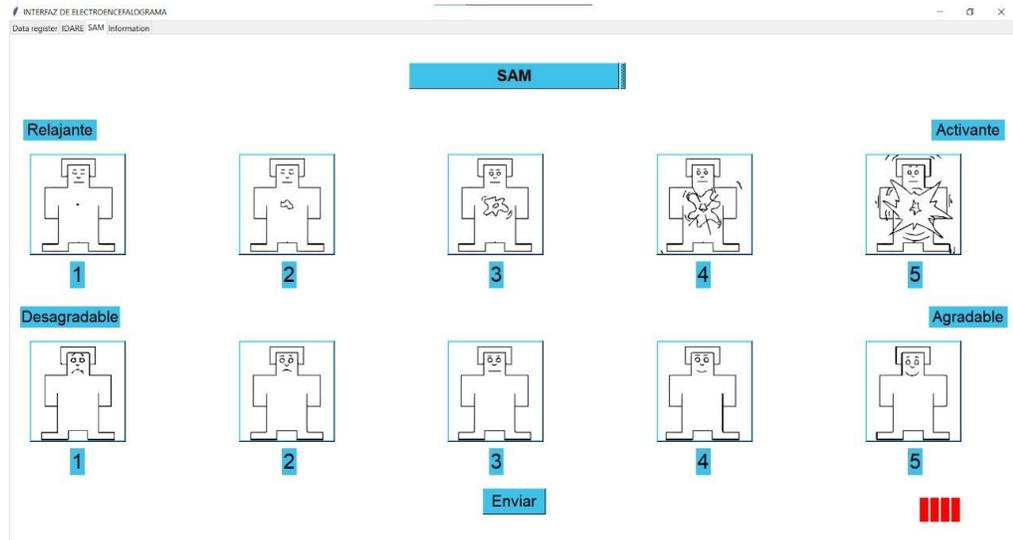


Ilustración 6. Pestaña con la prueba SAM.

- Se presentaron 28 estímulos musicales aleatorios con una duración de 30 s, estos se dividieron en dos trials, es decir, cada trial tiene 14 diferentes estímulos. Una vez terminados, vuelve y se repiten para un total de 56 estímulos. 14 de ellos son elegidos por los investigadores y los 14 restantes por los participantes, teniendo en cuenta el cuestionario de preferencia musical. 7 de ellos son piezas musicales relajantes y las otras 7 activantes. Se debe tener en cuenta que, una vez terminado el estímulo, se presentaron 30 s de silencio, es decir, una línea base para que el adulto mayor volviera a su estado inicial, sin ninguna emoción. Adicionalmente, se aplicó el SAM en 8 momentos diferentes al terminar cierta pieza en específico, con el fin de hacer un registro subjetivo de la emoción, donde cada participante indicó el nivel de activación y valencia de la emoción que presenta al escuchar las piezas. Hay 4 SAM para estímulos activantes y 4 para estímulos relajantes. Se tiene en cuenta que solo se buscó aplicar un estímulo auditivo, por ende, en la interfaz se mostró un fondo blanco cuando se reprodujo el estímulo, una vez pasado 30 s de silencio, ahí si aparece el SAM, esto se hace para que la persona se concentre en lo que escucha más no en lo que ve.

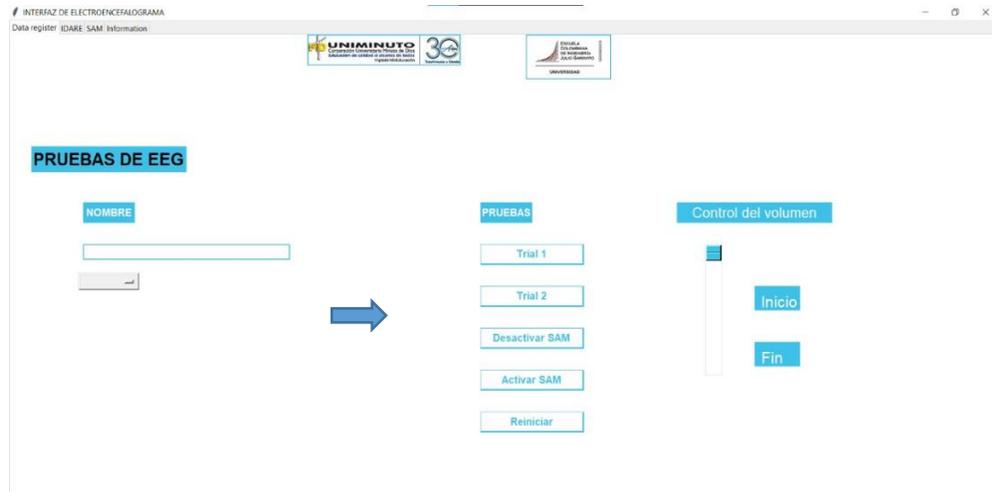


Ilustración 7. Ventana principal de la interfaz que se les presenta a los participantes. La flecha azul indica la zona que permite escuchar los diferentes estímulos.

5. Se volvió a responder el Inventario de IDARE-Estado, permitiendo corroborar diferencias frente al estado de ansiedad inicial de la persona mayor, previo a la aplicación.
6. Para culminar, se procedió a retirar los equipos y cerrarlos. Como parte del proceso psicoeducativo, los investigadores preguntan cómo se sintió durante la aplicación, y a partir de ello socializan sobre el tipo de emociones que se experimentaron, por consiguiente, describir toda reacción a nivel psicológico y fisiológico con respecto a sus estados emocionales durante la aplicación (Estas descripciones deberán estar detalladas en la bitácora). Posterior a ello los participantes se retiran de la sala de medición del laboratorio de psicología de la Corporación Universitaria Minuto de Dios, indicando por parte de los investigadores por donde queda la salida.

NOTA: Los registros obtenidos serán guardados con el código de participante y serán procesados por el investigador especializado en procesamiento de señales a partir del software MATLAB,

A continuación, se presenta un resumen del anterior procedimiento en las figuras 2 Y 3.



Ilustración 8. Procedimiento de la prueba fisiológica. Momento 3.

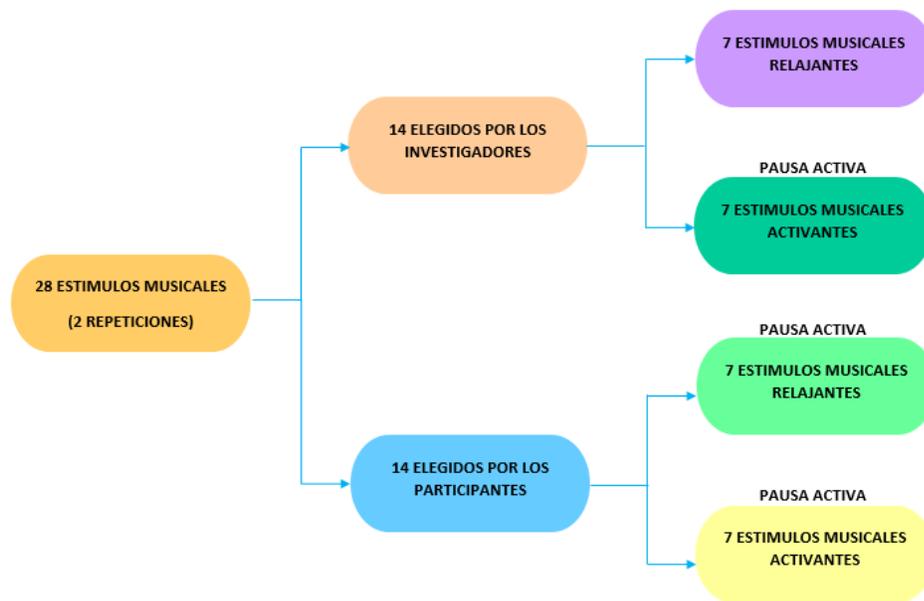


Ilustración 9: Esquema gráfico con la clasificación de los estímulos presentados en la interfaz.

Hay que tener en cuenta, que esta investigación permite ser analizada desde muchos puntos de vista, sin embargo, en este proyecto lo que se busca es obtener las señales de EEG que fueron grabadas cuando se escuchó el estímulo musical y su respectiva etiqueta (SAM).

BASE DE DATOS

La base de datos está compuesta por 15 señales de EEG que se les tomaron a 5 participantes, donde cada participante cuenta con 3 registros diferentes. Cada registro dura aproximadamente 15 min, ya que se graba el momento en que se presentan los 14 estímulos musicales y los momentos de silencio.

Para tener control de los tiempos de la señal, la interfaz que se diseñó registró en un archivo txt, el momento en que comienza y termina la prueba SAM, ya que esta prueba no tiene un tiempo de duración estipulado, así pues, solo es tener presente que 1 min antes del SAM se presenta el estímulo que dura 30s, los 30s restantes son de silencio.

PROCESAMIENTO DE LA SEÑAL

La señal de EEG suele ser contaminada por diversos componentes no deseados denominados artefactos, los cuales se pueden clasificar en endógenos y exógenos.

Los endógenos son aquellos que hacen referencia a movimientos voluntarios e involuntarios, producidos por descargas neuromusculares que se derivan de una tensión muscular, estos pueden ser el movimiento ocular (EOG) que es provocado por los parpadeos, los cuales se manifiestan como patrones de baja frecuencia o señales transitorias en áreas de los lóbulos frontales [38]. El movimiento muscular (EMG), que implica señales de alta frecuencia causada por los movimientos de la mandíbula, la lengua, la cabeza o el cuerpo. Y las señales eléctricas producidas por el latido del corazón (ECG), que aparecen como picos en la señal de EEG que resultan del complejo QRS [39].

Los exógenos son aquellos que proceden directamente de los equipos como el ruido de la red eléctrica que se presenta entre los 50 – 60 Hz, el ruido por movimiento de los electrodos y ruido de los circuitos del equipo [39].

Así pues, se debe considerar que se puede confundir los diferentes tipos de ruido con alguna actividad cognitiva o patológica [40], siendo necesario un médico profesional para diagnosticar correctamente un paciente, aunque puede haber mal interpretaciones, por ende, es fundamental el preprocesamiento de estas señales con el fin de disminuir el error y obtener una señal pura. Así pues, se muestran las técnicas aplicadas para obtener una señal limpia para que pueda ser caracterizada y clasificada según la dimensión de la emoción.

PREPROCESAMIENTO

REFERENCIA PROMEDIO COMÚN (CAR)

Este se basa en mejorar la relación señal a ruido que hace referencia a la proporción existente entre la potencia de la señal que se transmite y la potencia del ruido que la corrompe [41]. CAR es un filtro espacial que depende del número de electrodos y consiste en calcular la magnitud del voltaje de un electrodo de referencia, menos el promedio de los demás electrodos [42]. Además, este busca quitar aquello que es común en todas las lecturas y disminuye la amplitud de la señal [43] [44].

Su representación matemática en la siguiente:

$$V_i^C = V_i - \frac{1}{n} \sum_{j=1}^n V_j$$

Donde V_i^C es la señal filtrada con CAR, n es la cantidad de electrodos y V_i es el potencial entre el electrodo y la referencia.

A continuación, en la Ilustración 10, se presenta los 30 s de señal de EEG adquirida y la señal después de aplicar el filtro CAR del participante PM58, observando que se cumple las anteriores premisas.

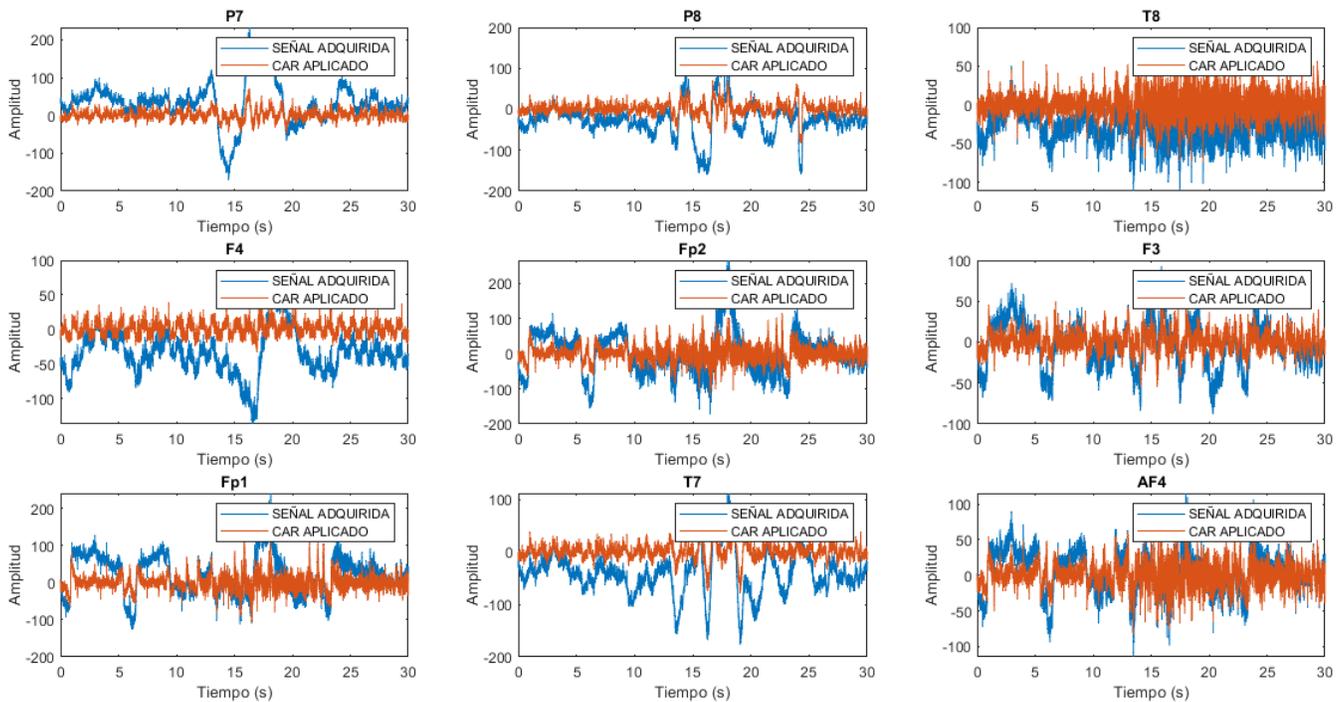


Ilustración 10. Señales adquiridas y filtradas con CAR del participante PM58. Amplitud en Microvoltios.

ANÁLISIS AUTOMÁTICO DE COMPONENTES INDEPENDIENTES DE WAVELET (AWICA)

En esta investigación se opta por trabajar con este método, debido a que busca eliminar artefactos como el EOG, EMG, desplazamiento eléctrico y tendencia lineal, de tal forma que se preserve los componentes neuronales y la actividad cerebral [45].

Para la eliminación de ruido primero se utiliza la transformada de wavelet discreta (DWT).

Transformada de Wavelet Discreta:

Esta permite un eficiente análisis de señales no estacionarias, las cuales se mapean con el fin de obtener una representación en tiempo-escala. Es un análisis multiresolución, es decir, analiza la señal en múltiples bandas de frecuencia por medio de ventanas variables [46].

Las señales son representadas utilizando un grupo de funciones básicas, producidas por el desplazamiento y el escalado de una función madre o función principal. La transformada wavelet es la descomposición de una señal en grupos de funciones [47]. Esta se representa como una convolución discreta entre la señal de entrada y los filtros pasa bajas, que corresponden a los coeficientes de aproximación de la señal y pasa altas que contiene los coeficientes de detalle [45].

La DWT se define a partir de la función de escala $\phi(t)$, que se relaciona con el filtro de paso bajo $h[n]$ mediante la fórmula recursiva

$$\phi(t) = \sqrt{2} \sum_n h[n] \phi(t - n)$$

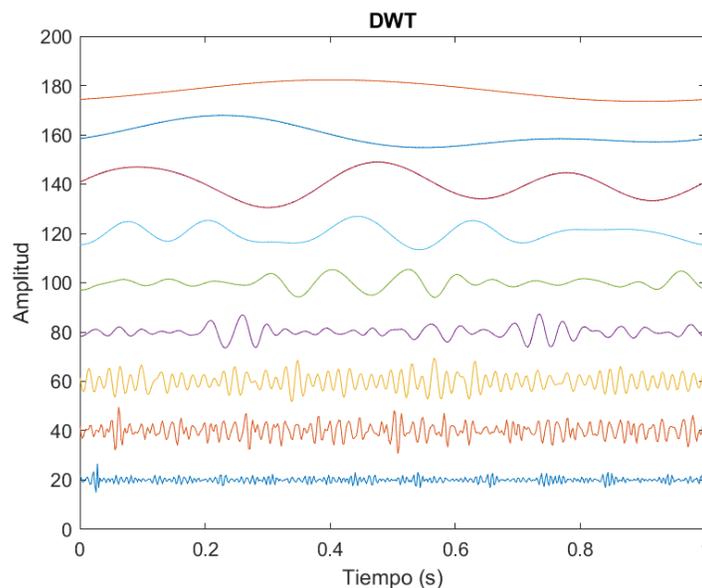
Y la ondícula madre, que se relaciona con el filtro de paso alto $g[n]$ mediante la fórmula

$$\psi(t) = \sqrt{2} \sum_n g[n] \psi(t - n)$$

La señal original es la suma del primer nivel de aproximación a_1 y el primer nivel de detalle d_1 ; el primer nivel de aproximación, a_1 , es la suma del segundo nivel de aproximación, a_2 , y el segundo nivel de detalle, d_2 ; y así sucesivamente al obtener los n niveles de descomposición.

Los coeficientes representan una medida de similitud entre la señal y las funciones base, por ende, se debe buscar una familia de ondículas que sea similar al EEG, una de ellas es la familia Daubechies, por tanto, se escoge la db9 con el fin de descomponer la señal en 9 niveles para obtener mayor cantidad de información, además, es escogida, ya que se determina que esta wavelet madre aporta y es la más adecuada para analizar y caracterizar la señal de EEG [48][49]. Una ventaja de esta descomposición es que, si el ruido se distribuye en diversos canales, por medio de la curtosis e ICA se puede detectar si se enfoca en un solo canal o en varios.

A continuación, se presenta los niveles de descomposición de una de las señales de EEG.



Curtosis y umbralización

La curtosis es una estadística de orden superior donde su función es la medida de lo no gaussianidad, es decir, compara la distribución de los datos con una distribución normal. Además, esta proporciona una medida de los picos de la señal, por ende, se considera ruido o componentes wavelet críticos (WC), aquellos que sobrepasen el umbral de ± 1.5 [45][50]. En el caso en que la curtosis que se calculó en los 9 niveles de descomposición sea mayor a 1.5 en más de un 10%, se considera que son artefactos supergaussianos, por ejemplo, el parpadeo de ojos, artefactos cardíacos y artefactos musculares; por el contrario, las menores a -1.5 en más de un 10%, son subgaussianos que implica distribuciones de actividad planas, típicas del ruido [51].

La curtosis se calcula mediante la siguiente expresión:

$$k = m_4 - 3m_2^2$$

Donde m_n hace referencia al momento central n, ya que este permite describir las características de una distribución. Para su cálculo se utilizan las siguientes ecuaciones:

$$m_4 = \alpha_4 - 4\alpha\alpha_3 + 6\alpha^2\alpha_2 - 3\alpha^4$$

$$m_2 = \alpha_2 - \alpha^2$$

$$\alpha = \frac{\sum_i x_i}{n} \qquad \alpha_3 = \frac{\sum_i x_i^3}{n}$$
$$\alpha_2 = \frac{\sum_i x_i^2}{n} \qquad \alpha_4 = \frac{\sum_i x_i^4}{n}$$

Una vez obtenidos los WC, se normaliza cada señal de EEG, es decir, se le resta la media y se divide por su desviación estándar, de tal manera que se eliminan las posiciones donde se encuentran los WC en esta.

Análisis de Componentes Independientes (ICA)

Una vez obtenida la señal sin los WC, se aplica ICA, con el fin de separar las señales o fuentes (s) que son estadísticamente independientes; en este caso las fuentes son el ruido que sigue presente y el EEG puro, que al combinarse linealmente (A) producen una señal ruidosa (x). Por tanto, se puede describir matemáticamente de la siguiente forma:

$$x = A \cdot s$$

Donde, de manera más técnica, A es la matriz de mezcla, s el vector de componentes independientes y x el vector de mezcla.

Así pues, el objetivo de ICA es buscar la matriz de desmezcla W, que hace referencia a la inversa de x, de tal forma que se obtengan las componentes independientes $y \cong s$.

$$y = W \cdot x$$

Para lograr esto, se debe seguir el siguiente procedimiento:

Blanqueo de datos: Se centran los datos, es decir, se determina el promedio del vector de mezcla x y se le resta a cada muestra. Luego se elimina la correlación entre señales, para ello se determina la matriz cuadrada de covarianza en datos centrados

$$Q = \frac{xx^T}{n}$$

Se realiza la descomposición espectral de la matriz de covarianza en sus valores propios para obtener $Q = UDU^T$, donde D son los autovalores y U la matriz de autovectores de la matriz de covarianza de x , por tanto, se elimina la covarianza entre las señales mezcladas al calcular la raíz cuadrada de la matriz de covarianza y demostrando que la covarianza se ajusta a la matriz identidad.

$$Q^{-\frac{1}{2}} = U D^{-\frac{1}{2}} U^T$$

Al multiplicar el vector de señales mezcladas por la matriz $D^{-\frac{1}{2}} U^T$, se elimina la covarianza entre las señales, por ende, se comprueba que la matriz de covarianza de los datos blanqueados es la matriz identidad.

$$V = D^{-\frac{1}{2}} U^T x$$

$$Cov(V) = \frac{V V^T}{n}$$

$$Cov(V) = \frac{D^{-\frac{1}{2}} U^T x x^T U D^{-\frac{1}{2}}}{n}$$

$$Cov(V) = D^{-\frac{1}{2}} U^T \frac{x x^T}{n} U D^{-\frac{1}{2}}$$

$$Cov(V) = D^{-\frac{1}{2}} U^T Cov(x^T) U D^{-\frac{1}{2}}$$

$$Cov(V) = D^{-\frac{1}{2}} U^T U D U^T U D^{-\frac{1}{2}}$$

$$Cov(V) = I_n$$

Así pues, V se le denomina la matriz de desmezcla, ya que se demuestra en el anterior proceso la no correlación de las señales.

Hay que tener en cuenta que existen muchas formas de calcular ICA como por ejemplo algoritmos como FASTICA, InfoMax y JADE, los cuales varían en la forma en cómo se determina la no gaussianidad, en este caso se utiliza Jade, la cual se basa en el cálculo de estadísticos de cuarto orden y cálculo matricial, lo que implica la diagonalización de la matriz de mezcla, así como se vio anteriormente [52].

Reconstrucción de la señal

Una vez obtenida la matriz de desmezcla, se le aplica el ICA inverso a la matriz que contiene los niveles anteriormente filtrados, para luego aplicar de nuevo la umbralización y eliminar los artefactos faltantes. Una vez eliminados, se reconstruye la señal mediante la transformada inversa de wavelet y se obtiene la señal limpia.

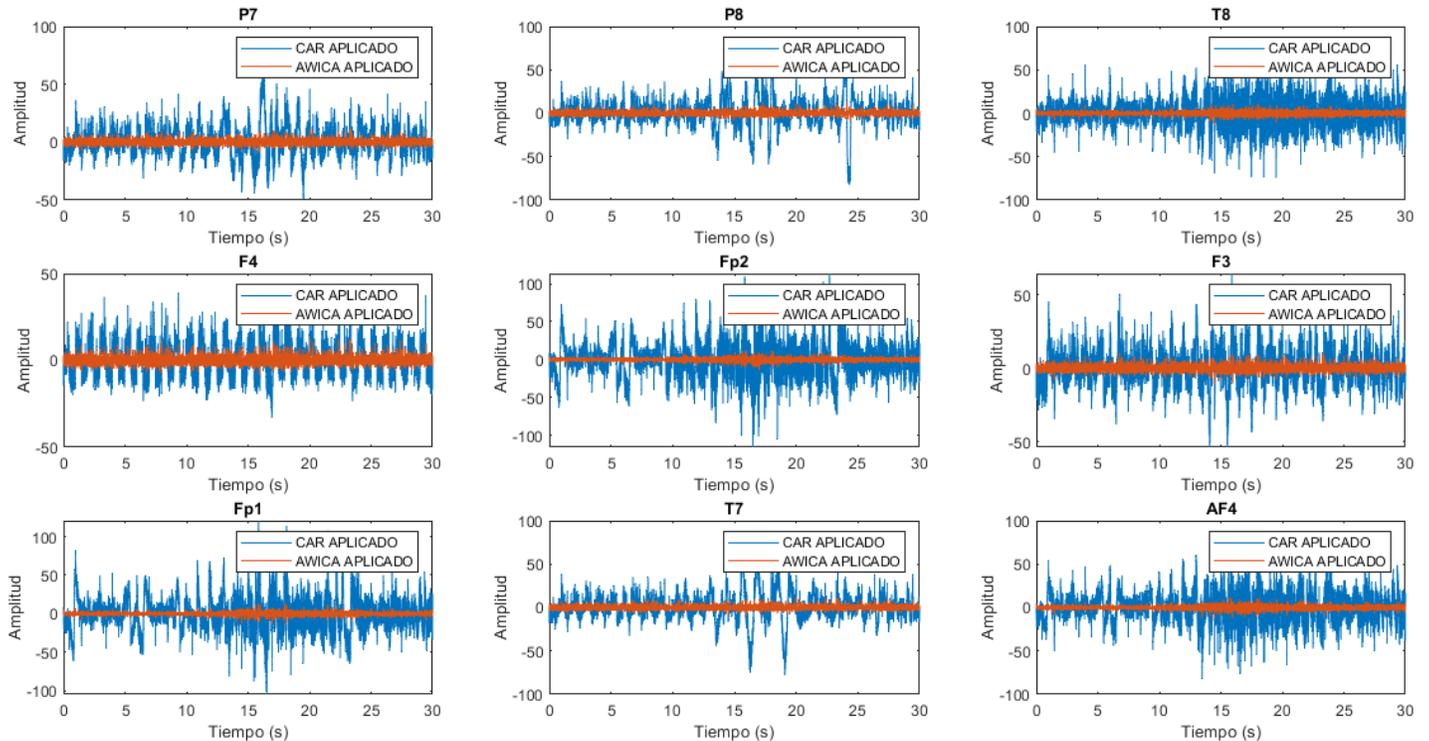


Figura 12. Señal filtrada con CAR y AWICA del participante PM58. Amplitud en microvoltios y tiempo en segundos.

PROCESAMIENTO DE LA SEÑAL

TRANSFORMADA DE WAVELET CONTINUA (CWT)

Esta representa la señal en términos de tiempo y frecuencia, de tal forma que se puede definir como la señal continua multiplicada por una versión desplazada y escalada de la función madre $\Psi(t)$.

$$C(a, b) = \int_{-\infty}^{\infty} f(t) \psi(a, b, t) dt$$

Es un método de transformación que se define como

$$F_{\omega}(a, b) = \frac{1}{a} \int_{-\infty}^{\infty} f(t) \psi^* \left(\frac{t-b}{a} \right) dt$$

Donde a es el escalamiento y b el desplazamiento de la ondícula madre ψ

La función madre genera wavelets hijas al ser escalonada y desplazada, de tal forma que se obtienen coeficientes que permiten conocer la relación entre la señal y la wavelet madre. La wavelet actúa como un tipo de filtro pasabanda que solo deja pasar los componentes de la señal en un rango de frecuencias en específico. Al variar el parámetro de escala a, el ancho de banda y la duración de la wavelet también varían, teniendo wavelets largas en las bajas frecuencias, y wavelets más cortas en las altas frecuencias [53][54][55].

En este caso se utiliza la wavelet madre denominada Morlet que se define como

$$\psi(t) = \pi^{-1/4} \cos(k t) e^{-x^2/2}$$

Donde K es el número de ondas.

Las ondículas de Morlet se utilizan más comúnmente en el análisis de tiempo-frecuencia de la señal de EEG, la extracción de la potencia y la fase instantáneas [56]. La ventaja de utilizarla es que son menos oscilatorias y son mejores para detectar y rastrear frecuencias instantáneas [57]. Otro beneficio de usar esta señal transformada incluye revelar información de frecuencia multiescala en cada punto de tiempo y aislar el ruido; además, el complejo Morlet es eficaz para la reconstrucción de señales.

Al obtener la CWT se determina su magnitud $|F_{\omega}(a, b)|$, luego se genera el escalograma, es decir, la expresión gráfica de los coeficientes de Wavelet en el plano de la frecuencia - tiempo [58]. Este se obtiene en escala de grises porque solo contiene la parte real.

El escalograma de cada canal es concatenado con el fin, de que en la imagen queden los 10 canales y se genere una sola imagen por participante. Esto proporcionó matrices bidimensionales, es decir, imágenes de 770 x 1000. Hay que aclarar que de una sola señal se obtuvieron 15 escalogramas porque se segmentaron con una ventana de 1000, para que se pudiera observar con mayor claridad que ocurría en la señal en un mayor tiempo.

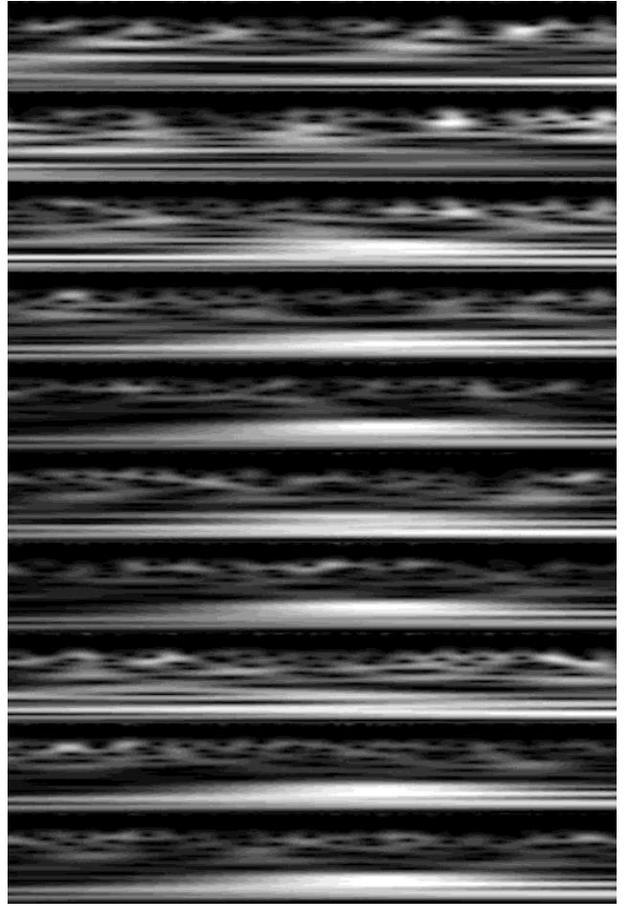
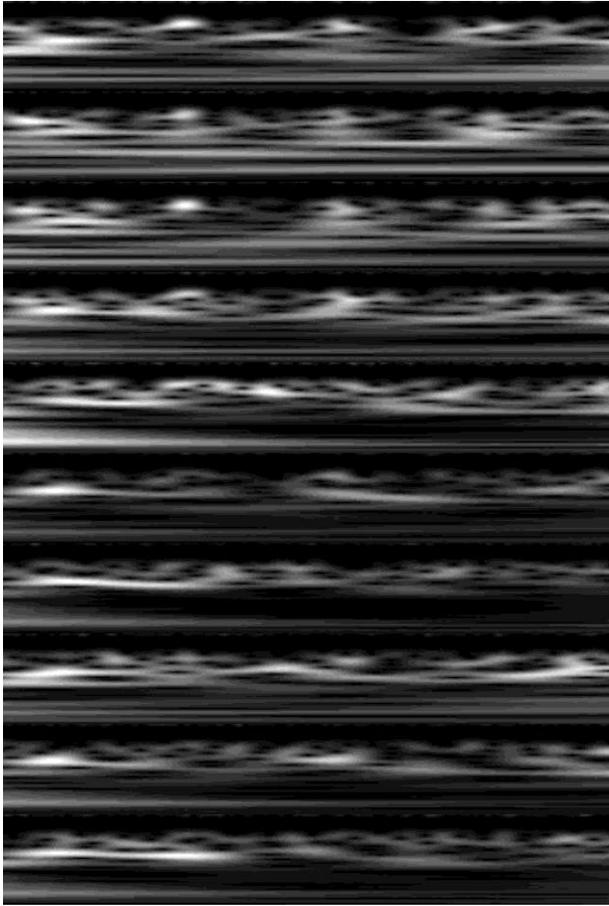


Ilustración 13. Escalogramas pertenecientes a Dimensión de la emoción Arousal, donde el de la izquierda hace referencia a un estímulo activante y el de la derecha, a un estímulo relajante.

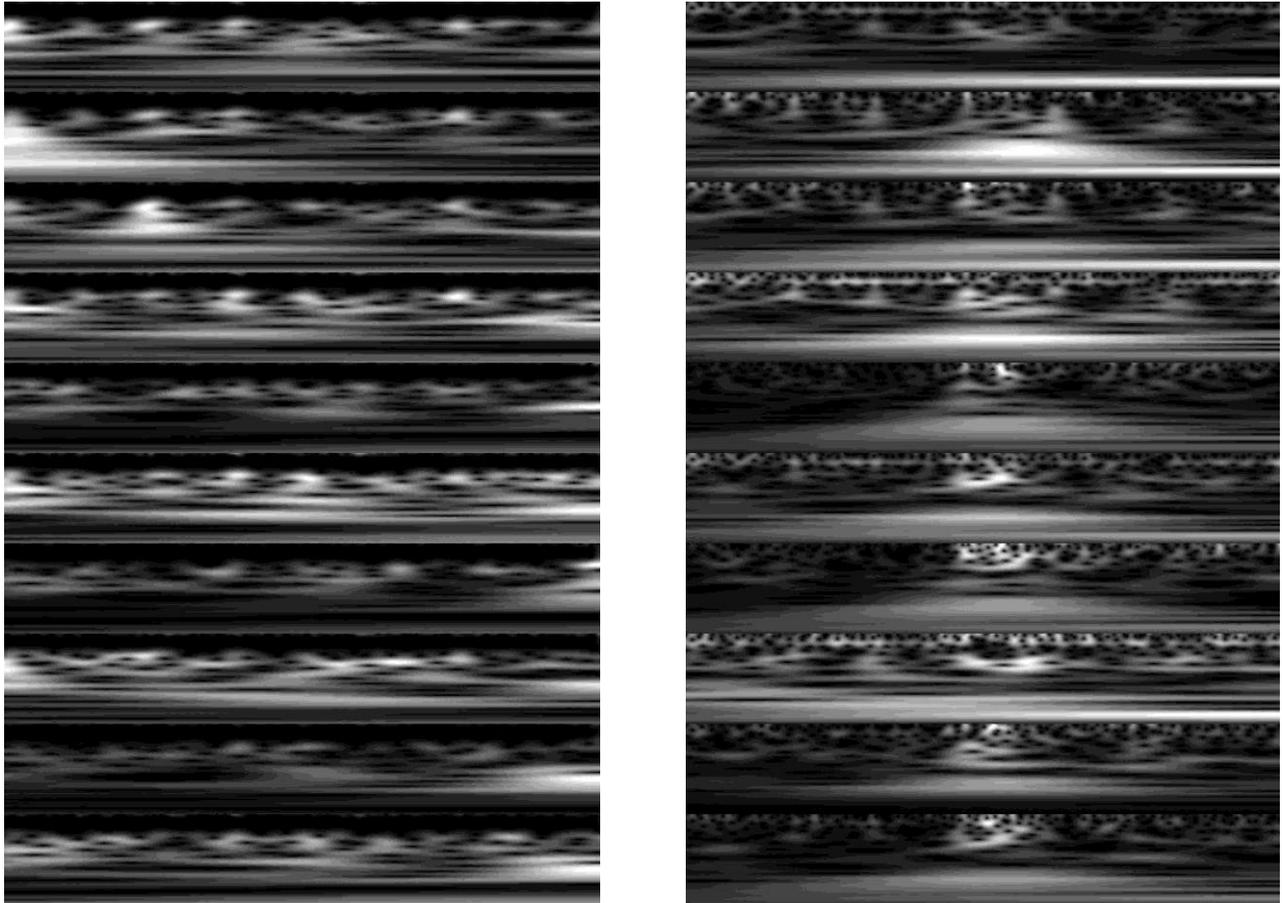


Ilustración 14. Escalogramas pertenecientes a Dimensión de la emoción Valencia, donde el de la izquierda hace referencia a un estímulo desagradable y el de la derecha, a un estímulo agradable

BALANCEO DE CLASES

TÉCNICA DE SOBREMUESTREO MINORITARIO SINTÉTICO (SMOTE)

Usualmente los modelos de aprendizaje automático tienen menor desempeño cuando se tienen datos desbalanceados, es decir, se tiene más información de una clase que de las restantes [59]. Esto implica que haya mejores exactitudes en la clase mayoritaria porque hay mayor cantidad de patrones que el modelo puede aprender, en cambio en la minoritaria apenas si reconocería la información al momento de clasificar.

Así pues, existen métodos que dan solución a dicha problemática, el oversampling que aumenta los datos o el resampling que los disminuye. Lo ideal es no perder información, por ende, se decide utilizar el método SMOTE, el cual cumple con la función de generar nuevas imágenes sintéticas de las clases minoritarias. Esto lo hace mediante la elección de un valor aleatorio de la muestra minoritaria y un número de K vecinos más cercanos, donde se calcula su diferencia, para luego multiplicarlo por 0 o 1, de tal forma que dicho valor sustituye el valor aleatorio tomado anteriormente [60].

Sin embargo, se decide modificar dicho algoritmo bajo la premisa de que ya no se utiliza el k vecino más cercano, sino que se calcula la diferencia absoluta entre imágenes, de tal forma que, se mantiene la idea básica del algoritmo, que es suponer que instancias próximas entre sí, tienen mayor probabilidad de pertenecer a la misma clase [61].

Así pues, el algoritmo lo que hace es tomar una imagen de la clase minoritaria que en este caso fue relajante y las compara con las demás imágenes pertenecientes a esta misma clase, donde se determinan las que tienen una menor diferencia absoluta, es decir, las imágenes más parecidas, de tal forma que, para el caso de Valencia, a partir de las 5 imágenes más cercanas, se generen la cantidad de imágenes que superen el número de la clase mayoritaria.

Esta generación de imágenes se desarrolla bajo el mismo algoritmo de SMOTE, es decir, se determina la distancia, se observa las más parecidas, se multiplican por un escalar (0 o 1) y se suma a la imagen de referencia.

Para el caso de las clases de Activación, se identificó que las clases eran totalmente balanceadas, por ende, no se aplica el algoritmo SMOTE. Sin embargo, para las clases de Valencia se observa un gran desbalanceo, sobre todo con la clase de desagradable como se presenta en la tabla 1, esto es debido a que los investigadores optaron por colocar estímulos musicales que generaran más cambios en la dimensión de la emoción arousal, porque como devolución de resultados para los participante, se espera darles las canciones que son relajantes y activantes para que las escuchen cuando lo necesiten, por ende, no se colocaron piezas que denotan desagrado, por tal motivo, es una clase pobre.

En este caso se tenían 450 imágenes para la dimensión de la emoción arousal y 360 para valencia.

En la tabla 1 se presenta la cantidad de datos específicamente.

	Arousal	SMOTE Arousal		Valencia	SMOTE Valencia
Activante	150	0	Agradable	255	0
Control	150	0	Control	90	165
Relajante	150	0	Desagradable	15	240

Tabla 1. Cantidad de imágenes por cada clase y cantidad de imágenes sintéticas generadas por SMOTE.

En el caso de arousal se tenían todas las clases balanceadas, 150 por clase.

En el caso de valencia se le aplica el SMOTE obteniendo 405 imágenes sintéticas, para obtener 255 imágenes por clase.

A continuación, se presentarán algunos ejemplos de las imágenes sintéticas generadas:

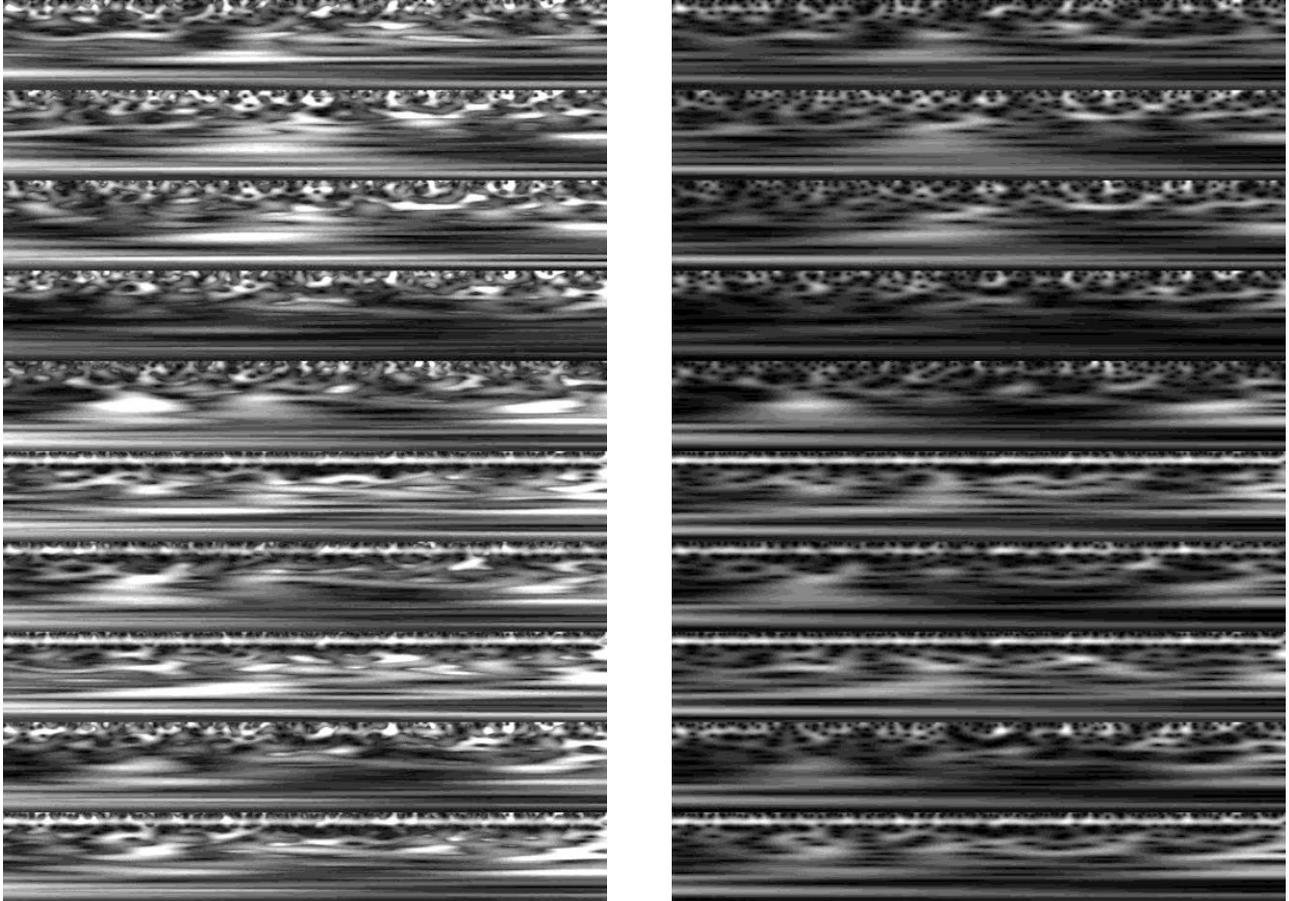


Ilustración 15. Se observan las imágenes sintéticas generadas con SMOTE.

MODELOS DE APRENDIZAJE AUTOMÁTICO

ALEXNET

Esta es considerada como la primera arquitectura CNN profunda que mostró buenos resultados en clasificación y reconocimiento de imágenes en 2012. Esta consta de 5 capas convolucionales 2D, encargadas de extraer características; seguidas de 3 capas totalmente conectadas (fully connected) [62].

La primera capa recibe las imágenes de entrada con dimensión $277 \times 277 \times 3$ y extrae la imagen media del dataset (normalización).

Las siguientes dos capas son una etapa de pooling de 3×3 con solapamiento, que se utilizan para reducir la dimensión de la red y aumenta la profundidad de la capa. Por último, las dos capas siguientes cumplen la función de clasificar, para ellos se usan las fully conectadas donde las neuronas se conectan entre sí. La operación de convolución en cada capa se genera gracias al cambio de tamaño de kernel, obteniendo dimensiones de 11×11 en la primera capa, 5×5 en la segunda, y 3×3 en el resto [63].

Para evitar el sobreajuste (overfitting), el cual hace referencia a que se predigan correctamente los datos de entrenamiento más no datos nuevos, es necesario el uso de

capas dropout, las cuales desactivan un grupo de neuronas de forma aleatoria, con el fin de que cada neurona trabaje de forma independiente, ya que, si lo hacen en conjunto, pueden generar patrones específicos con los datos de entrenamiento, patrones que no se podrán reconocer en datos que nunca ha visto el modelo [62].

Además, se utiliza una función ReLU después de cada capa convolucional y totalmente conectada. Finalmente, el espacio de características resultante se recombina usando tres capas completamente conectadas con 4096 neuronas cada una [64]. El uso de la Unidad Lineal Rectificada (ReLU) como función de activación no lineal de cada capa es una característica importante en AlexNet [65]. La función de activación de ReLU es:

$$R(z) = \text{Max}(0, z)$$

donde z es la función de entrada y $R(z)$ es la función de salida que es igual a la entrada cuando la entrada es positiva e igual a cero en caso contrario.

La capa fully connected de salida tiene un tamaño de 1000, que son el número de clases que se clasifican y que se encuentran con una función softmax para hallar la probabilidad de pertenecer a determinada clase [63].

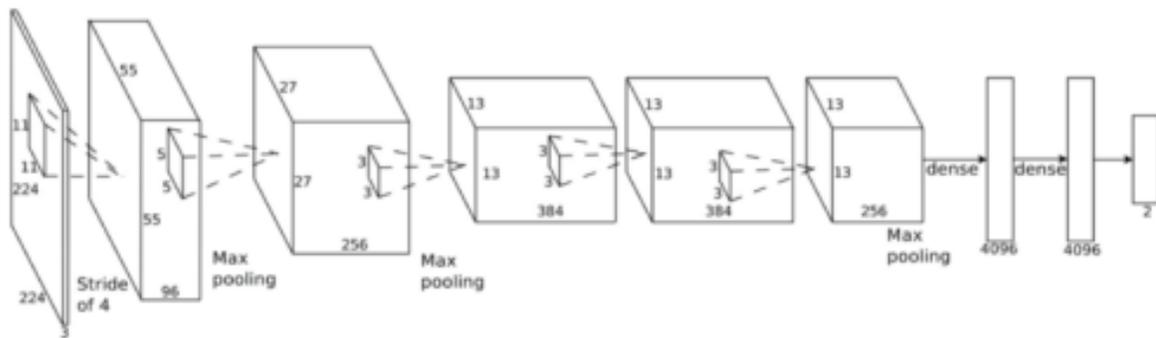


Ilustración 16. Representación de la estructura AlexNet. Tomado de: Sistema para la detección precoz de cáncer de piel basado en tratamiento de imágenes

Toda la estructura se resume en la Ilustración 17.

Capa	Etapas	Dimensionalidad
Capa de entrada	Normalización zerocenter	277x277x3
Capa convolucional	Convolutiva	96 convoluciones de 11x11x3
	ReLU	—
	Normalización entre canales	Normalización con 5 canales
	Pooling	3x3
Capa convolucional	Convolutiva	256 convoluciones de 5x5x48
	ReLU	—
	Normalización entre canales	Normalización con 5 canales
	Pooling	3x3 max pooling
Capa convolucional	Convolutiva	384 convoluciones de 3x3x256
	ReLU	—
Capa convolucional	Convolutiva	384 convoluciones de 3x3x192
	ReLU	—
Capa convolucional	Convolutiva	256 3x3x192
	ReLU	—
	Pooling	3x3
Capa fully-connected	Fully-connected	4096
	ReLU	—
	Dropout 50 %	—
Capa fully-connected	Fully-connected	4096
	ReLU	—
	Dropout 50 %	—
Capa final	Fully-connected	1000
	Softmax	—
	Clasificación	—

Ilustración 17. Estructura detallada de la AlexNet. Tomado de: Sistema para la detección precoz de cáncer de piel basado en tratamiento de imágenes.

El transfer learning es una técnica englobada dentro del deep learning, en la cual se utiliza una red base que haya sido entrenada previamente para una tarea similar, esto es con el fin de ahorrar tiempo al entrenar redes desde cero, ahora solo es cuestión de adaptarla con base a la problemática, de tal forma que el entrenamiento parta de los pesos ya determinados en la red [66].

En este caso se utiliza la red preentrenada AlexNet donde se configura la cantidad de clases a identificar, para ello se debe tener en cuenta que la valencia y la activación son dos modelos diferentes, pero ambos cuentan con 3 clases y los mismos hiperparámetros:

Activación	Valencia
Activado	Agradable.
Control	Control.
Relajado.	Desagradable.

Tabla 2. Clases para identificar en la Red Neuronal Convolucional

Hiperparámetros

Se fijarán los hiperparámetros necesarios para proporcionar el mejor rendimiento posible, estos no varían para la clasificación de valencia y arousal.

- **Optimizador:** Gradiente descendente estocástico con momento. (“SGDM”)
- **Tasa de aprendizaje:** Velocidad a la que el algoritmo alcanza una ponderación optima. (0.001)
- **MaxEpochs:** Determina el número máximo de épocas que se realizará el entrenamiento, es decir, cuantas veces se va a pasar todo el conjunto de datos por la red. (50)
- **MiniBatchSize:** Es la cantidad de datos que se utilizan para cada iteración. (100)

Se utilizaron 80% de los datos para entrenamiento y 20% para la evaluación

En la Ilustración 18. Se presenta la metodología completa del método propuesto.

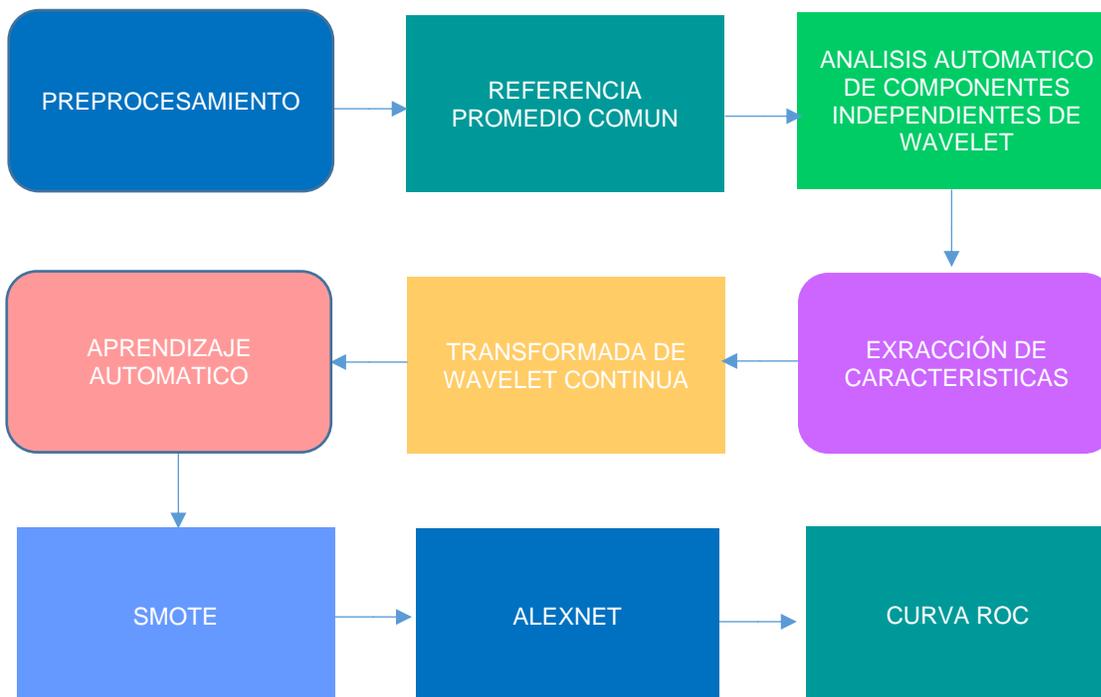


Ilustración 18. Paso a paso de la metodología aplicada en la investigación.

1. RESULTADOS

A continuación, se presentan los resultados de la caracterización de la señal de EEG, desde la formación de las imágenes filtradas hasta la clasificación en las dos diferentes dimensiones de la emoción activación y valencia.

CWT- ESCALOGRAMAS

Se obtuvieron como resultados los siguientes escalogramas, los cuales contienen los 10 canales de EEG. Allí, se observa el comportamiento en tiempo y frecuencia de cada señal, de tal forma que, si se analiza detalladamente el escalograma que pertenece a una persona relajada, la energía se concentra en un solo punto, caso contrario, lo que ocurre con una persona que se encuentra activada, ya que la energía se concentra tiempos muy cortos. Bajo esta premisa, la DWT caracteriza la señal a tal punto que la red convolucional se puede aprovechar dichos patrones para poder clasificarlas.

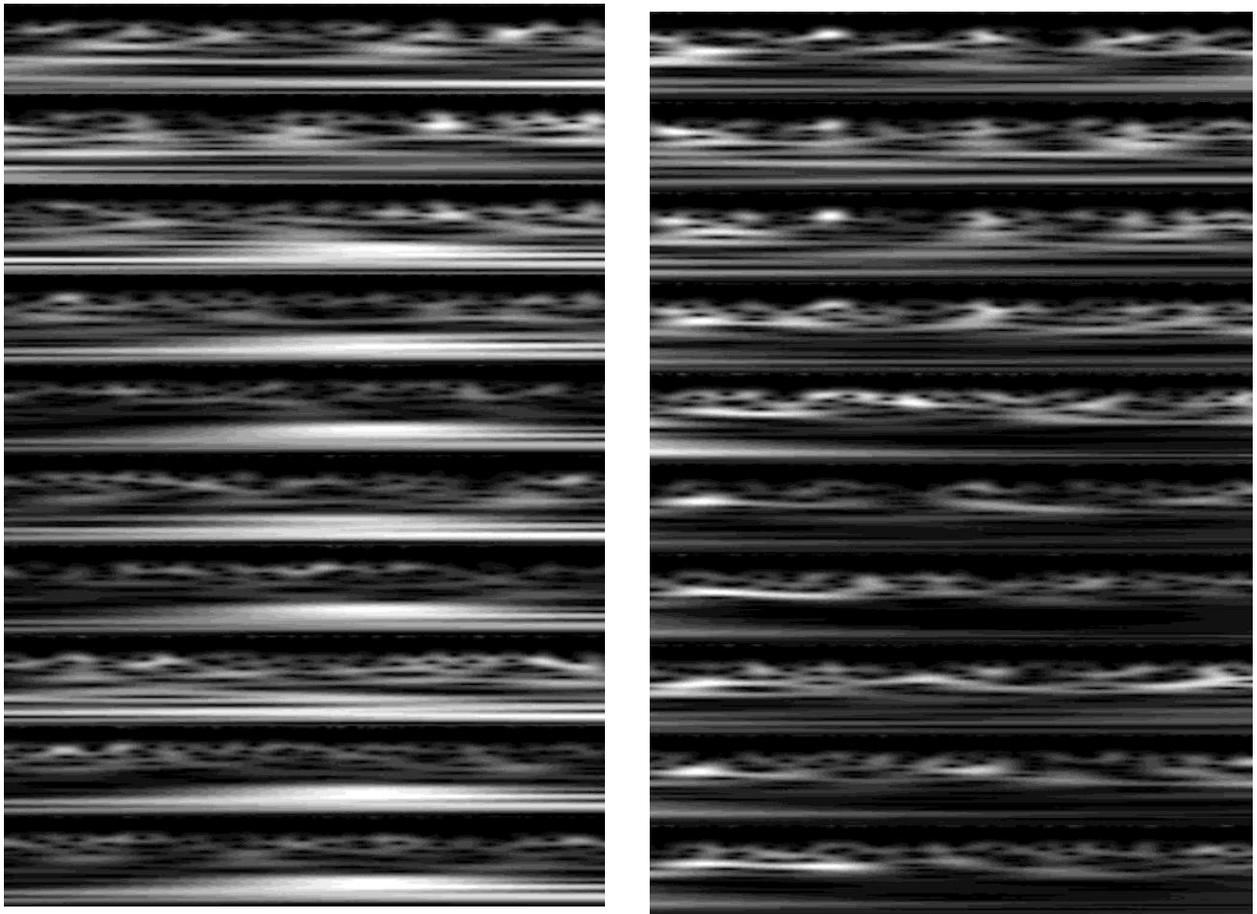


Ilustración 19. Se presentan los escalogramas de la dimensión Arousal del participante PMO6. El del lado derecho hace referencia a relajado y a la izquierda a activación.

En el caso de la dimensión de la valencia, se observa que para una persona que encuentra el estímulo agradable, también la energía busca concentrarse en un punto, sin embargo, para quien lo encuentra desagradable tiende a disminuir la energía, además, se puede observar que en algunos canales la energía es mayor que en otros, demostrando la interacción que tiene cada lóbulo con base a la emoción, es decir, unos se activen más que otros, dependiendo a lo que sienta.

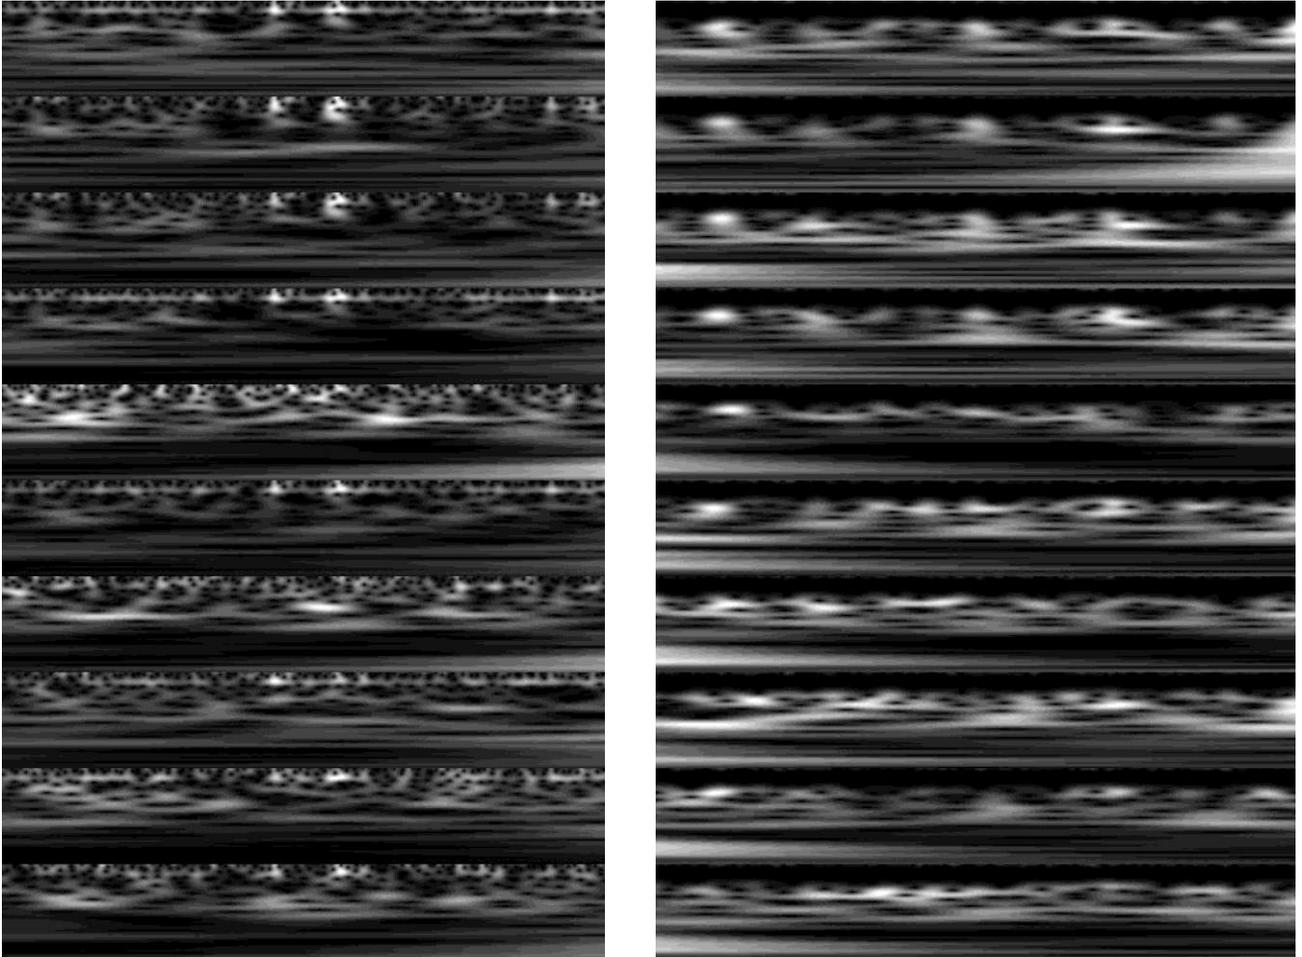


Ilustración 20. Se presentan los escalogramas de la dimensión Valencia del participante PMO6. El lado derecho hace referencia a desagradable y a la izquierda a agradable.

DATOS DESBALANCEADOS SMOTE

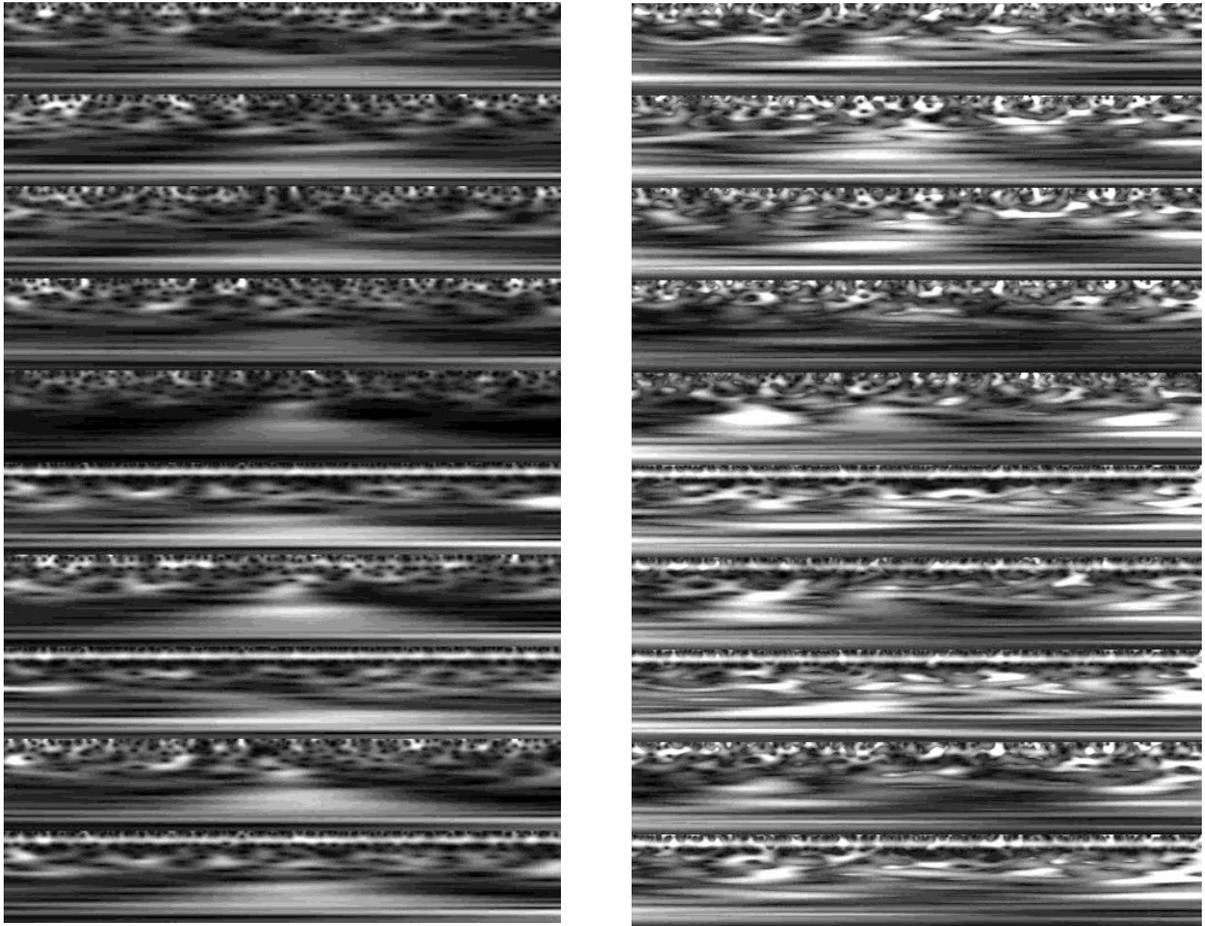


Ilustración 21. Se presentan las imágenes sintéticas, el del lado derecho hace referencia a desagradable y a la izquierda a agradable.

Estas imágenes sintéticas, aunque son muy semejantes con las demás, se observa un cambio notable por los valores aleatorios aplicados, ya que se busca mediante este método un aumento de datos, sin que sea exactamente la misma imagen debido a que tendería al overfitting.

DEEP LEARNING – APRENDIZAJE AUTOMÁTICO - ALEXNET

Una vez entrenados los modelos de las redes neuronales convolucionales, se obtiene la exactitud de cada modelo con respecto a entrenamiento y evaluación.

	Exactitud Valencia	Exactitud Arousal
Evaluación	84 %	84 %
Entrenamiento	87 %	86 %

Tabla 2. Exactitudes de las predicciones en Valencia y Arousal

Se evidencia que el desempeño del clasificador es bueno porque el porcentaje de su exactitud es mayor al 80%, lo que implica que también sobrepasa la exactitud de los estudios comparativos que se mencionarán en el análisis.

Por otro lado, se determinan las matrices de confusión con el fin de analizar con más detalle el desempeño del modelo con respecto a las 3 clases. En este caso se presenta en la ilustración 22, la matriz referente a la dimensión arousal.

Output Class \ Target Class	Activante	Control	Relajante	
Activante	25 27.8%	1 1.1%	5 5.6%	80.6% 19.4%
Control	4 4.4%	28 31.1%	0 0.0%	87.5% 12.5%
Relajante	1 1.1%	1 1.1%	25 27.8%	92.6% 7.4%
	83.3% 16.7%	93.3% 6.7%	83.3% 16.7%	86.7% 13.3%

Ilustración 22. Matriz de confusión para la dimensión de activación

Se debe tener en cuenta, que cada columna hace referencia a los falsos positivos y las filas, los falsos negativos. La diagonal verde de la ilustración 22, hace referencia al verdadero positivo, es decir donde la realidad y la estimación del modelo coinciden.

Se observa que en la dimensión de la emoción arousal, la clase activante es capaz de reconocer por lo menos el 80%, para control un 87% y para relajante un 92.6%.

Se observa que el error de clasificación es mínimo. Sin embargo, para no caer en errores como el overfitting, se ve la necesidad de graficar la curva ROC, ya que es una métrica muy utilizada por diferentes investigadores [67], la cual se encarga de determinar el rendimiento de un modelo de clasificación con base a los parámetros de las tasas de verdaderos positivos y falsos positivos. Así pues, en la ilustración 23, efectivamente se ve una curva cuasi perfecta, es decir, la pendiente de la curva es tan pronunciada, lo que indica que la frecuencia en que se presentan falsos positivos es muy baja [68][69], sin embargo, el ser tan pronunciado, implica que se presenta aparentemente un fenómeno de overfitting, lo que significaría que el modelo aprendió no solo a identificar la imagen, sino también el ruido presente, se aprendió la forma de los datos.

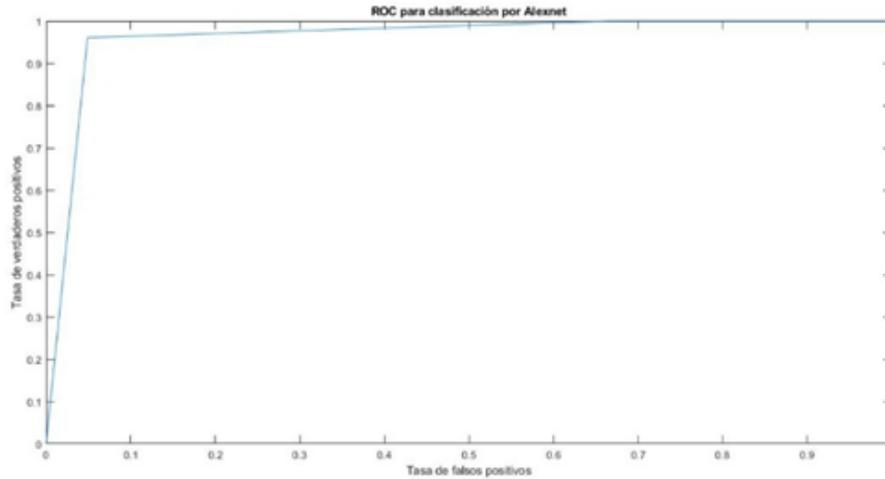


Ilustración 23. Curva ROC para la dimensión de Activación

En la ilustración 24 se presenta la matriz de activación, donde se observa altos niveles de clasificación, por ejemplo, el 100% en desagradable, no obtuvo ningún tipo de error. A pesar de una muy buena exactitud, es bueno calcular la ROC para determinar realmente si no es un sobreajuste.

Confusion Matrix

		Target Class			
		Agradable	Control	Desagradable	
Output Class	Agradable	49 32.0%	5 3.3%	0 0.0%	90.7% 9.3%
	Control	2 1.3%	46 30.1%	17 11.1%	70.8% 29.2%
	Desagradable	0 0.0%	0 0.0%	34 22.2%	100% 0.0%
		96.1% 3.9%	90.2% 9.8%	66.7% 33.3%	84.3% 15.7%

Ilustración 24. Matriz de confusión para la dimensión de Valencia

La curva ROC de la ilustración 25, demuestra que no hay un overfitting porque la curva no es tan definida, es decir, presenta mayor frecuencia de falsos positivos, tampoco es una recta, lo que quiere decir que no clasificará según el azar, por ende, está en el rango de ser tener un buen desempeño [68][69].

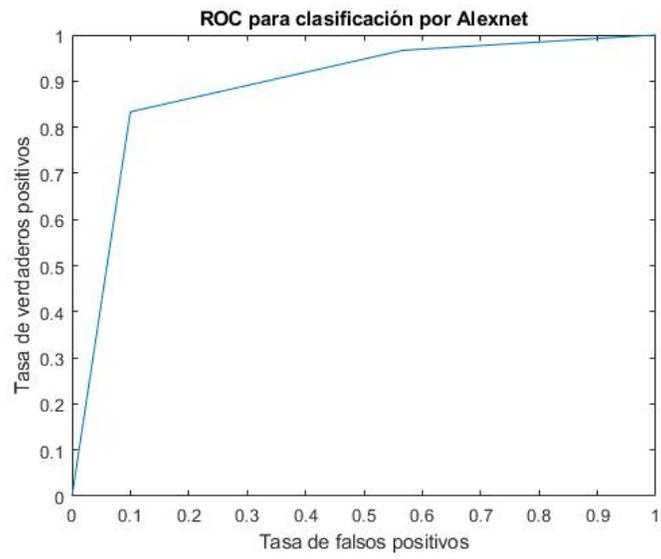


Ilustración 25. Curva ROC para la dimensión de Activación

2. DISCUSIÓN

El objetivo de esta investigación es clasificar la respuesta emocional en términos de valencia y arousal. Para ello se utilizan señales de electroencefalografía que fueron grabadas cuando el participante escuchaba determinado estímulo musical y lo etiquetaba bajo la prueba SAM. Esta señal debe ser caracterizada, pero no hay que olvidar que la señal de EEG viene acompañada con cierto nivel de ruido, por ende, se les aplica el filtro CAR y AWICA para la obtención de señales más limpias; ya que se son más definidas y con menor amplitud como se observa en las ilustraciones 10 y 12, de tal forma que va acorde con la literatura [44][45]. Al obtener una señal limpia, se caracteriza en el dominio tiempo-frecuencia, mediante la Transformada de Wavelet Continua, puesto a que al haber decidido evaluar la clasificación mediante redes neuronales convolucionales, es necesario tener una matriz bidimensional, por tanto, bajo este método, se generan escalogramas con determinados patrones que caracterizan cada dimensión de la emoción como se observan en las ilustraciones 19 y 20. De esta forma, el clasificador utilizado se denomina AlexNet, el cual da la facilidad de ser utilizado en la clasificación de muchas tareas, pero en este caso, permite detectar una determinada emoción. Esta al ser una red que se puede preentrenar, permite un gran ahorro de tiempo, ya que no hay que programarla desde cero, sino que solamente es cuestión de manipular los hiperparámetros necesarios para que desarrolle una tarea en específico. Además, se debe tener en cuenta que estas redes fueron concebidas para clasificar imágenes, por consiguiente, no es sorpresa que se tenga un buen desempeño al utilizar escalogramas como fuente de información.

De lo anteriormente expuesto, es necesario resaltar que se cumple el objetivo, puesto a que se obtuvo una exactitud del 87% para clasificación de valencia y un 86% para la clasificación de arousal, siendo mayor el desempeño en comparación con la literatura, para demostrarlo, se describen tres estudios con el mismo objetivo.

Memarian utilizan la CWT y el cálculo de la entropía, para caracterizar las señal obteniendo como resultados un 73.84% de exactitud para valencia y un 69.82% para arousal. Dando como conclusión que la CWT es poderosa para descomponer, caracterizar y clasificar las señales de EEG mismo objetivo. Q. Li et al., hace una comparativa entre la CWT y la transformada corta de Fourier (FFT) en las mismas dimensiones, donde se obtuvo una exactitud del 63.9% para arousal y 63% para valencia, donde se concluye que es este caso, se obtienen mejores exactitudes de clasificación con la FFT. Por último, en el artículo escrito por Rabiul et al., se clasifica las dimensiones de valencia y arousal, aunque la característica principal es el coeficiente de correlación de Pearson, donde de allí se crea la imagen que se introduce a la CNN para entrenamiento, dando como resultado un 78.22% en valencia y 74,94% en excitación.

En otro orden de ideas, se determina que la CWT es suficiente como característica para poder clasificar una emoción, debido a que se observan comportamientos o determinados patrones dependiendo a cada dimensión de la emoción, por ejemplo, para una persona que se siente relajada y a la vez el sentimiento es de agrado, la energía se concentra en un solo punto como se observa en las ilustraciones 13 y 14, pero para la persona que se encuentra activada y el sentimiento es de desagrado, hay activaciones de energía en tiempos cortos, de tal forma que no tienen un orden.

Por otro lado, se esperaba que Arousal obtuviera un mejor desempeño, ya que en este caso las clases estaban balanceadas y no hubo necesidad de aplicar el SMOTE, allí se comprueba lo que dice la teoría, es decir, si se trabajan con clases balanceadas, mejora la predicción del modelo [59].

También se esperaba que en valencia se diera una menor exactitud, debido a que como se dijo anteriormente, la idea es presentar resultados a los participantes, lo que consiste en darles las canciones relajantes y activantes para que las escuchen cuando quieran sentir este tipo de emociones, por ende, música desagradable no entró como estímulo musical, así pues, al ser clase minoritaria, tuvo que ser aumentada por medio del balanceo de datos (SMOTE), de tal forma que se crean imágenes sintéticas entre las clases desagradable y control, para que hubiera un equilibrio con la clase mayoritaria, sin embargo, este método logró que las imágenes sintéticas fueran tan semejantes que según la curva ROC se podría presentar un modelo aparentemente sobreajustado y para determinar si lo es o no, es necesario entregarle al modelo más datos que no se le hayan presentado antes.

3. RECOMENDACIONES Y TRABAJOS FUTUROS

Las emociones se pueden clasificar bajo numerosos modelos de aprendizaje automático, en este caso se trabajó con un solo modelo ya que el objetivo es ver si puede clasificar la señal del EEG en cualquiera de las tres clases de valencia o activación. Sin embargo, como trabajo futuro, se trabajaría una plantilla de redes neuronales convolucionales con el fin de comparar cuál es el mejor clasificador bajo la misma característica que es la CWT.

4. CONCLUSIONES

- El modelo de aprendizaje automático, Alexnet, es capaz de clasificar entre cada una de las 3 clases referentes a Arousal y Valencia, con una exactitud del 86% y 87%.
- Se logra eliminar el ruido de las señales de EEG, por medio de los métodos CAR y AWICA, ya que la señal se ve más definida y con menor amplitud.
- La DWT es un método lo suficientemente completo para que se pueda caracterizar la señal de EEG, al observar los diferentes patrones que se generan en valencia y activación.
- El algoritmo SMOTE permitió obtener el aumento de datos, al generar escalogramas sintéticos con la suficiente resolución
- Es necesario aplicar métricas como la curva ROC para determinar que el modelo clasifica correctamente y no por sobreajuste.
- Arousal es un modelo aparentemente sobreajustado, por ende, necesita clasificar más datos para determinarlo. Por otro lado, valencia se considera un buen modelo para diferenciar entre las clases agradable, control y desagradable, por su buen desempeño.

REFERENCIAS

- [1] E. G. Fernández Abascal, M. P. Jiménez Sánchez, B. Gracia Rodríguez, M. D. Marín Díaz y F. J. Domínguez Sánchez, *Psicología de la Emoción*, Madrid: Centro de Estudios Ramón Areces. S. A, 2010.
- [2] L. F. Sarmiento Rivera y J. A. Ríos Flórez, «Bases neurales de la toma de decisiones e implicación de las emociones en el proceso» *Neuropsicol.* Vol. 12. Nº 2. P. 33, 2017.
- [3] J. R. Sánchez Tombe «LESIONES EN LA CORTEZA PREFRONTAL VENTROMEDIAL Y SU IMPACTO EN LA COGNICIÓN SOCIAL». *Bibliotecadigital.* 2019. [En línea]. Available: <https://bibliotecadigital.univalle.edu.co/bitstream/handle/10893/14775/CB-0600182.pdf?sequence=1&isAllowed=y#:~:text=Lesiones%20en%20vmPFC%20ocasionan%20varios,conducta%20sexual%20y%20Fo%20moral.> [Último acceso: 2022 5 11].
- [4] F. Morandín Ahuerma, «La hipótesis del marcador somático y la neurobiología de las decisiones» *Escritos de Psicología.* Vol 12. Nº 1. P 21.2019.
- [5] E. E. Benarroch, «La Amígdala. Organización funcional y su participación en trastornos neurológicos», *Neurology*, 2015. [En línea]. Available: https://n.neurology.org/content/neurology/suppl/2015/07/06/WNL.000000000001171.DC1/argentina_benarroch.pdf. [Último acceso: 2022 11 5].
- [6] J. Tirapu Ustárroz, A. García Molina, P. Luna Lario, A. Verdejo García y M. Ríos Lago, «Neuropsicología de la corteza prefrontal y las funciones ejecutivas y Conducta» *Autismodiario.* 2012. [En línea]. Available: <https://autismodiario.com/wp-content/uploads/2013/12/Neuropsicología-de-la-corteza-prefrontal-y-las-funciones-ejecutivas-y-Conducta.pdf>. [Último acceso: 5 11 2022].
- [7] F. Mora Terue, «¿Que es una emoción?» *ARBOR Ciencia, Pensamiento y Cultura*, Vol. 189. Nº 759. P 5. 2013.
- [8] J. S. Saavedra Torres, W. J. Díaz Córdoba, L. F. Zúñiga Cerón, C. A. Navia Amézquita, y T. O. Zamora Bastidas. «Correlación funcional del sistema límbico con la emoción, el aprendizaje y la memoria» *Morfología.* Vol 7. Nº 2. P. 35. 2015.
- [9] C. Belnamonte Martínez, «Emosiones y Cerebro» *Real Academia de Ciencias Exactas, Físicas y Naturales.* Vol. 101, Nº 1. P 59-68. 2007.
- [10] F. Ortiz, "Detección automática de emociones mediante el análisis del electroencefalograma", Máster, Universidad de Sevilla, Sevilla, 2019. Accedido el 22 de noviembre de 2022. [En línea]. Disponible: <https://biblus.us.es/bibing/proyectos/abreproy/71431/fichero/TFM-1431-ORTIZ.pdf>
- [11] X. Xua, M. Caoc, J. Dingc, H. Gub, and W. Lu. «Emotional Recognition of EEG Signals based on Fractal Dimension,» *International Journal of performability Engineering*, Vol. 15, Nº 11, PP. 3072-3080, 2019.
- [12] A. Fernández. "Percepción de Emociones en la Música: Un Estudio de la Influencia del Parámetro Musical "Duración"". (2017). UCLM. 4 [En línea]. Disponible: <https://ruidera.uclm.es/xmlui/bitstream/handle/10578/15271/TESIS%20Fernández%20Sotos.pdf?sequence=1&isAllowed=y> [Último acceso: 2022 12 6]
- [13] A.L. laureano, D.E. hernandez, M. Mora, J. Ramírez, «Aplicacion de un modelo cognitivo de valoracion emotiva a la función de evaluacion de tableros de un programa que juega ajedrez,» *Matemática: Teoría y Aplicaciones*, Vol. 19, Nº 12, PP. 211–237, 2012.
- [14] «Engaging with Music 2021» IFPI. 2021. [En línea]. Disponible: <https://www.ifpi.org/wp-content/uploads/2021/10/IFPI-Engaging-with-Music-report.pdf>. [Último acceso: 2022 11 3].
- [15] L. Lehmborg y V. Fung, «Benefits of Music Participation for Senior Citizens.,» *Music Education Research International*,, vol. 4, pp. 19 - 27, 2010.

- [16] M. Miranda, S. Hazard y P. Mirand, «La música como una herramienta terapéutica,» *Chil Neuro-Psiquiat*, Vol. 55, Nº 4, P. 266-277, 2017.
- [17] V. Chaturvedi, A. Beer Kaur, V. Varshney, A. Garg, G. Singh Chhabra y M. Kumar, «Music mood and human emotion recognition based on physiological signals: a systematic review,» 2021. [En línea]. Disponible: <https://link.springer.com/article/10.1007/s00530-021-00786-6>. [Último acceso: 2022 5 11].
- [18] F. Galvão, M. J. Fonseca y . S. M. Alarcão, «Predicting Exact Valence and Arousal Values from EEG,» *Sensors (Basel)*, Vol. 21, Nº 20, P. 1 - 21, 2021.
- [19] A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto y E. E. Ponce de León Sentí, «Contrastación de algoritmos de aprendizaje automático,» *Research in Computing Science*, Nol. 149, Nº 8, P. 515–525, 2020.
- [20] R. Islam, M. Islam, M. Rahman, C. Mondal, S. K. Singha, M. Ahmad, A. Awal y S. Islam, «EEG Channel Correlation Based Model for Emotion Recognition,» *Computers in Biology and Medicine*, Vol. 132, 2021.
- [21] Y. Yang, Q. Wu, M. Qiu, Y. Wang y X. Chen, «Emotion Recognition from Multi-Channel EEG» *8 International Joint Conference on Neural Networks*, 2018.
- [22] Nater, U. (2003). Cuestionario sobre la preferencia musical (MPQ-R). *Music and Health Lab*. [En línea]. Disponible: <https://www.musicandhealthlab.com/publications>. [Último acceso: 2022 5 11]
- [23]. Angulo, R., y Albarracín, A. P. Validez y confiabilidad de la escala rasgo de metaconocimiento emocional (TMMS-24) en profesores universitarios. *Revista Lebre*. Nº 10, P. 61-72. 2018.
- [24]. GONZALEZ, Rocío; CUSTODIO, Jesica Brenda and ABAL, Facundo Juan Pablo. Propiedades psicométricas del Trait Meta-Mood Scale-24 en estudiantes universitarios argentinos. *Psicogente*. Vol.23, Nº.44 P.1-26. 2020.
- [25]. CARDONA-ARANGO, Doris et al. LA FELICIDAD COMO PREDICTOR DE FUNCIONALIDAD FAMILIAR DEL ADULTO MAYOR EN TRES CIUDADES DE COLOMBIA. *Hacia promoc. Salud*, Vol.24, Nº.1, P.97-111, 2019
- [26]. "Depresión". *World Health Organization (WHO)*. [En línea]. Disponible: <https://www.who.int/es/news-room/fact-sheets/detail/depression> Último acceso: 2022 9 20]
- [27]. BORDA PEREZ, Mariela et al. Depresión en adultos mayores de cuatro hogares geriátricos de Barranquilla (Colombia): prevalencia y factores de riesgo. *Salud, Barranquilla*, Vol.29, Nº.1, P.64-73. 2013
- [28]. MARTINEZ DE LA IGLESIA, J. et al. Versión española del cuestionario de Yesavage abreviado (GDS) para el despistaje de depresión en mayores de 65 años: adaptación y validación. *Medifam*. Vol.12, Nº.10, P.26-40. 2002
- [29]. M. Gutiérrez y L. Bohórquez. "Ansiedad Rasgo – Estado en el Adulto Mayor Institucionalizado y no Institucionalizado en la Ciudad de Villavicencio, Meta: Un estudio comparativo". *repository.uniminuto*. https://repository.uniminuto.edu/bitstream/10656/13480/1/UVDT.P_BohorquezLina-GutierrezMaria_2018.pdf [Último acceso: 2022 9 20]
- [30]. M, González & Martín, Marta & A, Lorenzo & JA, Grau. (2007). *Extractos del capítulo: Instrumentos de evaluación psicológica para el estudio de la ansiedad y la depresión*.
- [31]. Z. Nasreddine. "Montreal Cognitive Assessment [Evaluación Cognitiva Montreal] (MoCA) Versión 8.1 Instrucciones para la administración y puntuación de los resultados". *Home Page - Champions for Health*. <https://championsforhealth.org/wp-content/uploads/2018/12/MOCA-8.1-Spanish.pdf>. [Último acceso: 2022 9 20]
- [32] Gantiva, Carlos & Barrera Valencia, Mauricio & Cadavid, Natalia & Calderón, Liliana & Gelves Ospina, Melissa & Herrera, Eduar & Mejía-Orduz, Manuel & Montoya Arenas, David & Suárez-Pico, Paola. (2019). Inducción de estados afectivos a través de imágenes. Segunda validación colombiana del Sistema Internacional de Imágenes Afectivas (IAPS). *Revista Latinoamericana de Psicología*. Vol 51. Nº2. P- 5. 2019
- [33] Sanchez, R. and Ledesma, R., 2007. Los Cinco Grandes Factores: cómo entender la personalidad y cómo evaluarla. *Academia.edu*. [En línea]. Disponible: <

https://d1wqtxts1xzle7.cloudfront.net/56725801/cap.LosCincoGrandesFactores-comoente-with-cover-page-v2.pdf?Expires=1665683990&Signature=g2Lf6o2pqSixd3zs8HUsVPAA~8QeMNNBul551aauhoTgCoPD9qV47XS42I-GZCveS9XRQVn2Q1rFFMQKJsKbFJyMuCQQ4UivHaa-7Ut-AHl5ab4PLEbdtA80B~YwWH7fkjL9FdDK4zpJxyd3NTf031X385wuGMPpC2t5H9B4iD0KigjqM3stvKuqleE0IF~ZxWVKWMMWIdAsA8-vRh4bDp0zJ41GPLig~vCZdjzfrPF779Us1ARKnsgSN2tC52UMuYJ-5XjHxJN57Ups33nh33E4de8wryXBs3Oo2gE-X-8QvfbFR6vskGWiPFZsXIVWdjuch~7V6sBfTbfw2YV~A__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA [Ultimo acceso: 2022 10 13]

[34] SANCHEZ, Roberto Oscar; MONTES, Silvana Andrea y SOMERSTEIN, Luis Daniel. *Inventario de Personalidad para el DSM-5: propiedades psicométricas en población argentina. Estudio preliminar. Interdisciplinaria ., Vol.37, N°.1], P.7-8. 2020*

[35] *Neuroelectrics User Manual – P2. Electrodes –. (2018). Neuroelectrics, Vol 1. N° 4, P. 8–9.*

[36] Santos, E.J. and McMullen, K. (2020). *The Design of an Algorithmic Modal Music Platform for Eliciting and Detecting Emotion. Proceedings of 2020 8th International Winter Conference on Brain-Computer Interface (BCI), Gangwon.*

[37] Alarcão, S.M. and Fonseca, M.J.. *Emotions Recognition Using EEG Signals: A Survey.IEEE Transactions on Affective Computing, Vol. 10, No. 3. 2019*

[38] J. López, "Análisis y clasificación de emociones en personas con discapacidad visual usando señales EEG y aprendizaje automático", resumen extendido de Doctoral, Universidad Carlos III de Madrid, 2021.

[39] C. Q. Lai, H. Ibrahim, M. Z. Abdullah, J. M. Abdullah, S. A. Suandi and A. Azman, "Artifacts and noise removal for electroencephalogram (EEG): A literature review," *IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE), P. 326-332. 2018*

[40] Y. Rodríguez, T. González, E. Marañón, A. Montoya y F. Sanabria, «Aplicación de la corrección de artefactos en el,» *Rev Cubana Neurol Neurocir, Vol. 5, N° 1, P. S9–S14, 2015.*

[41] *INFORMÁTICA XI-CUATRIMESTRE. (6 de 2017). SNR (Signal To Noise Ratio). Weebly. [En línea]. Disponible: <https://recursoinformatico.weebly.com/uploads/1/0/7/3/107381475/snr.pdf>. [Ultimo acceso: 2022 9 20]*

[42] D. Zea, J. Arévalo. "Sistema de detección de la intención de dos movimientos de la mano a través del procesamiento de señales EEG", *Pregrado, Universidad de Cuenca, Cuenca, 2020.*

[43] A. Torres, C. Reyes, L. Villaseñor, J. Ramírez. *Análisis de señales electroencefalográficas para la clasificación de habla imaginada. Revista mexicana de ingeniería biomédica, Vol .34, N° 1, P 23-39. 2013*

[44] E. Hernández, "Clasificación de señales EEG basada en representaciones bidimensionales y redes neuronales convolucionales", *Máster, Instituto Nacional de Astrofísica Óptica y Electrónica, Puebla, 2020.*

[45] N. Mammone, F. La Foresta and F. C. Morabito, "Automatic Artifact Rejection From Multichannel Scalp EEG by Wavelet ICA," *in IEEE Sensors Journal, Vol. 12, No. 3, P. 533-542, 2012.*

[46] *Introducción a la Transformada Wavelet. (2006). Obtenido de Unicen.edu: <https://users.exa.unicen.edu.ar/catedras/escuelapav/cursos/wavelets/apunte.pdf>*

[47] Castillo, M., & Meneses, G. (s.f.). *COMPRESIÓN Y DESCOMPRESIÓN DE VOZ MEDIANTE TÉCNICAS DE PROCESAMIENTO DIGITAL DE IMÁGENES UTILIZANDO WAVELETS. Obtenido de Repositorio.unicauca.edu: http://repositorio.unicauca.edu.co:8080/bitstream/handle/123456789/2040/Anexo_A.pdf?sequence=2&isAllowed=y*

[48] I. E. Gareis, G. Gentiletti, R. C. Acevedo & H. L. Rufiner; "Extracción de características en interfaces cerebro computadoras mediante transformada wavelet discreta: Resultados preliminares" *Memorias del XVII Congreso Argentino de Bioingeniería (SABI 2009), No. 167, P. 58-62, 2009.*

- [49] MEDIN, B., Sierra, J., & Barrios, A. Técnicas de extracción de características de señales EEG en la imaginación de movimiento para sistemas BCI. *ESPACIOS*, Vol. 39, N°22, PP 36. 2018
- [50] J. Xiang, E. Maue, Y. Fan, L. Qi, F. Mangano, H. Greiner, J. Tenney. La curtosis y la asimetría de las señales cerebrales de alta frecuencia se alteran en la epilepsia pediátrica, *Brain Communications*. Vol 2, N° 1, 2020
- [51] A. Delorme, T. Sejnowski, and S. Makeig, "Enhanced detection of artifacts in EEG data using higher-order statistics and independent component analysis" *Neuroimage*, Vol. 34, P. 1443–1449, 2007.
- [52] J.-R. Bouveresse, «Independent Components Analysis with the JADE algorithm» *TrAC Trends in Analytical Chemistry*, Vol. 50, P. 22-32, 2013.
- [53] Anubhav, D. Nath, M. Singh, D. Sethia, D. Kalra and S. Indu, "An Efficient Approach to EEG-Based Emotion Recognition using LSTM Network," 2020 16th IEEE International Colloquium on Signal Processing & Its Applications (CSPA), 2020, P. 88-92, 2020
- [54] Pardo, E., Talmant, M., Laugier, P. y San Emeterio, J. (2006). la transformada wavelet como herramienta para el estudio de señales ultrasónicas transmitidas en hueso cortical. *Digital.csic.es/*. [Y] <https://www.scopus-com.ez.urosario.edu.co/record/display.uri?eid=2-s2.0-84879788862&origin=inward&txGid=7116af2dc76170f9a2aedc9551fb8bce>
- [55] Z. Gao, R. Li, C. Ma, L. Rui and X. Sun, "Core-Brain-Network-Based Multilayer Convolutional Neural Network for Emotion Recognition," in *IEEE Transactions on Instrumentation and Measurement*, Vol. 70, P. 1-9, 2021.
- [56] Thangarajoo RG, Reaz MBI, Srivastava G, Haque F, Ali SHM, Bakar AAA, Bhuiyan MAS. Machine Learning-Based Epileptic Seizure Detection Methods Using Wavelet and EMD-Based Decomposition Techniques: A Review. *Sensors (Basel)*. Vol 21, N° 24, P 84-85. 2021
- [57] Wang, Hao & Chen, Zihua & Zou, Safeng & Zhao, Li.. [The continuous analysis of EEG's alpha wave by morlet wavelet transform]. *Journal of biomedical engineering*. Vol. 27. 746-8, 752.2010
- [58] Medina, L. (2017). Análisis de técnicas Wavelet para el desarrollo de compresores de audio (Publicación N.º 100) [Master, UNIVERSIDAD EAFIT]. Eafit. https://repository.eafit.edu.co/bitstream/handle/10784/11744/MedinaSanchez_LauraVictoria_2017.pdf?isAllowed=y&sequence=1
- [59] V. B. Deepa, P. Thangaraj and S. Chitra, "Mining rare event classes in noisy EEG by over sampling techniques," 2010 International Conference on Innovative Computing Technologies (ICICT), 2010, P. 1-6
- [60] D. Romaisa, M. E. Habib and M. A. Chikh, "Epileptic Seizure Detection from Imbalanced EEG signal," 2019 International Conference on Advanced Electrical Engineering (ICAEE), 2019, P.1-6
- [61] Moreno, J & Rodriguez, Daniel & Sicilia, M. & Riquelme, José & Ruiz, Y. (2009). SMOTE-I: mejora del algoritmo SMOTE para balanceo de clases minoritarias. *Actas de los Talleres de las Jornadas de Ingeniería del Software y Bases de Datos*, Vol. 3, N°. 1, P- 200.
- [62] Montoya, ó. (2018). Redes neuronales convolucionales profundas para el reconocimiento de emociones en imágenes [Máster, universidad politécnica de Madrid]. https://oa.upm.es/51441/1/TFM_OSCAR_PICAZO_MONTOYA.pdf
- [63] Thalagala, Shiron & Walgampaya, Chamila. (2021). Application of AlexNet convolutional neural network architecture-based transfer learning for automated recognition of casting surface defects. *Smart Computing and Systems Engineering* .P . 129-136.
- [64] Martínez-Rodrigo A, García-Martínez B, Huerta Á, Alcaraz R. Detection of Negative Stress through Spectral Features of Electroencephalographic Recordings and a Convolutional Neural Network. *Sensors (Basel)*.;Vol. 21,N° 9 ,P – 3050. 2021

[65] Asghar MA, Khan MJ, Fawad, Amin Y, Rizwan M, Rahman M, Badnava S, Mirjavadi SS. EEG-Based Multi-Modal Emotion Recognition using Bag of Deep Features: An Optimal Feature Selection Approach. Sensors (Basel). Vol. 19, N° 23, P 5218. 2019

[66] Serrano, C. (2018). Sistema para la detección precoz de cáncer de piel basado en tratamiento de imágenes [Pregrado, UNIVERSIDAD AUTÓNOMA DE MADRID]. Uam. https://repositorio.uam.es/bitstream/handle/10486/688455/serrano_moreno_cecilia_tfg.pdf?sequence=1

[67] Borja-Robalino, Ricardo & Monleon-Getino, Antonio & Rodellar, José. Estandarización de métricas de rendimiento para clasificadores Machine y Deep Learning. RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao. N° 30. P 184-196. 2020

[68] P. Sanahuja. "Entendiendo la curva ROC y el AUC: Dos medidas del rendimiento de un clasificador binario que van de la mano. – Pol Martí Sanahuja". Data Scientist | PhD in Physics. <https://polmartisanahuja.com/entendiendo-la-curva-roc-y-el-auc-dos-medidas-del-rendimiento-de-un-clasificador-binario-que-van-de-la-mano/>. > [Ultimo acceso: 2022 12 12]

[69] Bouza, Carlos. (2021). LAS CURVAS ROC TEORÍA Y HERRAMIENTAS PARA SU USO.

[70] Memarian Sorkhabi, Majid. (2014). Emotion Detection from EEG signals with Continuous Wavelet Analyzing. American Journal of Computing Research Repository, 2014, Vol. 2, No. 4, 66-7

[71] Q. Li et al., "EEG signal processing and emotion recognition using Convolutional Neural Network," 2021 International Conference on Electronic Information Engineering and Computer Science (EIECS), P. 81-84, 2021

[72] Md. Rabiul islam, Md. Milon islam, Md. Mustafizur Rahman, Chayan Mondal, Suvojit Kumar Singha, Mohiuddin Ahmad, Abdul Awal, Md. Saiful Islam, Mohammad Ali Moni, EEG Channel Correlation Based Model for Emotion Recognition, Computers in Biology and Medicine, Volume 136, 2021.

[73] "CIE-11 para estadísticas de mortalidad y morbilidad". ICD-11. <https://icd.who.int/browse11/l-m/es> > [Ultimo acceso: 2022 12 11]

[74] "Clasificación Internacional del Funcionamiento de la Discapacidad y la Salud". 2011. Organización Mundial de la Salud. https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&cad=rja&uact=8&ved=2ahUKEwjY-bi9wPL7AhXsSDABHUQBvoQFnoECCsQAQ&url=https://aspace.org/assets/uploads/publicaciones/e74e4-cif_2001.pdf&usg=AOvVaw3x4zwwj6O1phRunS7qKMAHm > [Ultimo acceso: 2022 12 12]

ANEXOS

Apartado para los anexos del trabajo realizado. Máximo 10 hojas. Se consideran anexos: Códigos de programación, tablas, formatos, instrumentos, guías, etc.

[Consentimiento Informado](#)

[Entrevista Sociodemográfica](#)

[Cuestionario sobre preferencia musical \(MPQ-R\)](#)

[Montreal Cognitive Assessment Basic \(MOCA-B\)](#)

[Montreal Cognitive Assessment Basic \(MOCA-A\)](#)

[CODIGOS](#)