



ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE INGENIERÍA EN SISTEMAS

OBTENCIÓN DE UN DATASET PARA RECONOCIMIENTO DE EMOCIONES USANDO TÉCNICAS DE APRENDIZAJE AUTOMÁTICO.

**Obtención de un dataset para reconocimiento de emociones
usando una interfaz cerebro – computador
(Brain Computer Interface – BCI)**

TIPO DE TRABAJO DE TITULACIÓN: PROYECTO INTEGRADOR

**TRABAJO DE INTEGRACIÓN CURRICULAR PRESENTADO COMO
REQUISITO PARA LA OBTENCIÓN DEL TÍTULO DE INGENIERO EN
CIENCIAS DE LA COMPUTACIÓN**

Edison Daniel Cabrera Pabón

edison.cabrera@epn.edu.ec

DIRECTOR: PHD. Myriam Beatriz Hernández Álvarez

myriam.hernandez@epn.edu.ec

DMQ, septiembre 2022

CERTIFICACIONES

Yo, Edison Daniel Cabrera Pabón, con CI: 172586617-0, declaro que el trabajo de integración curricular aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.



Edison Daniel Cabrera Pabón

Certifico que el presente trabajo de integración curricular fue desarrollado por Edison Daniel Cabrera Pabón, bajo mi supervisión.



PHD. Myriam Hernández
DIRECTOR

DECLARACIÓN DE AUTORÍA

A través de la presente declaración, afirmamos que el trabajo de integración curricular aquí descrito, así como el (los) producto(s) resultante(s) del mismo, son públicos y estarán a disposición de la comunidad a través del repositorio institucional de la Escuela Politécnica Nacional; sin embargo, la titularidad de los derechos patrimoniales nos corresponde a los autores que hemos contribuido en el desarrollo del presente trabajo; observando para el efecto las disposiciones establecidas por el órgano competente en propiedad intelectual, la normativa interna y demás normas.

Edison Daniel Cabrera Pabón

PHD. Myriam Beatriz Hernández Álvarez

DEDICATORIA

El presente trabajo de titulación está dedicado a mi madre, la señora Gladys Cabrera, la razón de mi existir y de estar presente en este mundo, quien ha estado guiándome a lo largo de mi camino estudiantil, brindándome su apoyo, su fortaleza y la sabiduría para poder cumplir esta meta.

Siempre estuvo velando por mi bienestar y educación, depositando toda su confianza en mí y acompañándome en cada reto que a lo largo de mi carrera universitaria se me fue presentando.

Con amor y gratificación.

Edison Cabrera

AGRADECIMIENTO

El presente trabajo, merece expresar un profundo agradecimiento a todas aquellas personas que siempre estuvieron apoyándome y dándome ánimo a lo largo de mi formación universitaria, quienes fueron mi fuerza y mi motivación para conseguir cumplir este sueño.

Mi agradecimiento va dirigido en primer lugar a mi madre, quien siempre estuvo ahí apoyándome, brindándome todo su amor y su comprensión día a día en estos arduos años de formación académica.

A mi familia y amistades en general que siempre me estuvieron brindando su apoyo, para jamás desfallecer y siempre darme energía para poder continuar en mis estudios de tercer nivel.

A mis docentes, quienes me han sabido impartir sus conocimientos y experiencias con mucha paciencia y gran dedicación, para poder formarme como un profesional, habilidades que pondré en práctica tanto en mi vida laboral como personal.

Agradezco a la Dra. Myriam Hernández, quien supo depositar su entera confianza en la realización de este trabajo y me supo guiar durante todo el tiempo que me llevo la realización de este.

Finalmente agradezco a aquellas personas que participaron y colaboraron en este proyecto de investigación, dado que, sin su ayuda, no hubiera sido posible cumplir con este gran objetivo.

Gracias Totales.

Con cariño e infinita gratitud.

Edison Cabrera

ÍNDICE DE CONTENIDO

CERTIFICACIONES.....	I
DECLARACIÓN DE AUTORÍA	II
DEDICATORIA.....	III
AGRADECIMIENTO.....	IV
ÍNDICE DE CONTENIDO.....	V
ÍNDICE DE FIGURAS	VI
ÍNDICE DE TABLAS	VII
RESUMEN.....	VIII
ABSTRACT	IX
Capítulo I: Introducción	1
1.2 Descripción del componente desarrollado	1
1.3 Objetivo General	2
1.4 Objetivos Específicos	2
1.5 Alcance	2
1.6 Marco teórico	3
Capítulo II: Metodología	11
2.2 Justificación Metodológica	11
2.3 Revisión de la literatura	12
2.4 Materiales y métodos	14
Capítulo III: Implementación y Resultados.....	26
3.2 Herramientas	26
3.3 Dataset	28
3.4 Algoritmos de Clasificación	33
3.4.1 Redes Neuronales	33
3.5 Evaluación de Resultados	42
Capítulo IV: Conclusiones y Recomendaciones	45
Referencias	¡Error! Marcador no definido.
Anexos.....	49
ANEXO A: Dataset Inicial	49
ANEXO B: Dataset Balanceado	50
ANEXO C: Código Implementado	52
ANEXO D: Análisis de la Variable Valencia	60
ANEXO E: Análisis de la Variable Excitación	61
ANEXO F: Permiso de los participantes	63

ÍNDICE DE FIGURAS

Figura 1: Ubicación de los Electroodos según la Norma 10-20 [9].	7
Figura 2: Participante en estado de Relajamiento.	14
Figura 3: Participante realizando actividades de Trading.	15
Figura 4: Persona en estado de relajamiento con los ojos cerrados.	17
Figura 5: Persona en estado de relajamiento con los ojos abiertos.	18
Figura 6: Persona en realizando actividades de Trading.	19
Figura 7: Persona en realizando actividades de Trading.	19
Figura 8: Estados Emocionales Valencia-Excitación en el Espacio [13]	21
Figura 9: Estados emocionales en el espacio de dominancia de Valencia-Excitación [13]	21
Figura 10: Diagrama de Fases.	22
Figura 11: Balanceo SMOTE para la variable Valencia.	23
Figura 12: Balanceo SMOTE para la variable Excitación.	24
Figura 13: Aplicación OpenBCI en ejecución.	26
Figura 14: Ultracortex de 8 electrodos.	26
Figura 15: Contenido del dataset Stock-Emotion.	28
Figura 16: Participante realizando actividades de trading.	30
Figura 17: Participante realizando actividades de trading.	30
Figura 18: Distribución clases de valencia antes del balanceo.	31
Figura 19: Distribución clases de excitación antes del balanceo.	31
Figura 20: Distribución clases de valencia después del balanceo.	32
Figura 21: Distribución clases de excitación después del balanceo.	32
Figura 22: Primera Prueba con el Algoritmo de Redes Neuronales.	33
Figura 23: Segunda Prueba con el Algoritmo de Redes Neuronales.	34
Figura 24: Tercera Prueba con el Algoritmo de Redes Neuronales.	34
Figura 25: Cuarta Prueba con el Algoritmo de Redes Neuronales.	35
Figura 26: Resultado Final con el Algoritmo de Redes Neuronales.	35
Figura 27: Algoritmo de redes neuronales implementado.	36
Figura 28: Generación de Curvas K-FOLD para los mejores modelos de redes neuronales que se obtengan.	36
Figura 29: Evaluación de rendimiento para Redes Neuronales.	37
Figura 30: Red Neuronal Implementada.	37
Figura 31: Algoritmo SVM implementado.	39
Figura 32: Evaluación de rendimiento para SVM.	39
Figura 33: Esquema del algoritmo SVM [19].	40
Figura 34: Algoritmo Random Forest implementado.	41
Figura 35: Evaluación de rendimiento para Random Forest.	41
Figura 36: Gráfica de las métricas de evaluación de cada algoritmo al evaluar la variable Valencia.	43
Figura 37: Gráfica de las métricas de evaluación de cada algoritmo al evaluar la variable Excitación.	43
Figura 38: Tiempos ejecución de cada algoritmo en segundos al evaluar la variable Valencia.	44
Figura 39: Tiempos ejecución de cada algoritmo en segundos al evaluar la variable Excitación.	44
Figura 40: Histograma del Dataset Inicial Desbalanceado.	49
Figura 41: Histograma del Dataset Balanceado para la Variable Valencia.	50
Figura 42: Histograma del Dataset Balanceado para la Variable Excitación.	51
Figura 43: Resultados Métricas de Evaluación Redes Neuronales para la variable Valencia.	60
Figura 44: Resultados Métricas de Evaluación Random Forest para la variable Valencia.	60
Figura 45: Curvas ROC aplicado al algoritmo de Redes Neuronales para la variable Valencia.	61
Figura 46: Resultados Métricas de Evaluación Redes Neuronales para la variable Excitación.	61
Figura 47: Resultados Métricas de Evaluación Random Forest para la variable Excitación.	62
Figura 48: Curvas ROC aplicado al algoritmo de Redes Neuronales para la variable Excitación.	62

ÍNDICE DE TABLAS

Tabla 1: Nomenclatura de los Electrodo de OpenBCI acorde a la Norma 10/20.	7
Tabla 2: Nomenclatura de los Sensores.	8
Tabla 3: Estados emocionales en el espacio Valencia-Excitación.	10
Tabla 4: Escala de Evaluación Valencia.	15
Tabla 5: Escala de Evaluación Excitación.	16
Tabla 6: Valores Categorizados Valencia.....	20
Tabla 7: Valores Categorizados Excitación.....	20
Tabla 8: Cuadrantes en el Espacio Valencia-Excitación.....	20
Tabla 9: Matriz de Confusión con los resultados del Algoritmo Redes Neuronales para la variable Valencia.	38
Tabla 10: Matriz de Confusión con los resultados del Algoritmo Redes Neuronales para la variable Excitación.....	38
Tabla 11: Resultados obtenidos por cada algoritmo implementado al evaluar la variable Valencia.	42
Tabla 12: Resultados obtenidos por cada algoritmo implementado al evaluar la variable Excitación.....	42

RESUMEN

El presente trabajo detalla el procedimiento de recopilación de un conjunto de datos para el análisis de los estados emocionales de personas expuestas a realizar actividades específicas. Se registraron señales electroencefalográficas (EEG) correspondientes a 12 participantes mientras cada uno realizaba una sesión. Cada sesión fue de 2 minutos en un estado de relajamiento, para obtener una línea base y de 20 minutos realizando actividades de trading para la detección de emociones.

Para la recopilación de los datos de los participantes se hizo uso de un casco Ultravortex (OPEN BCI) con 8 sensores para la captación de las diferentes señales EEG captadas en distintas ubicaciones alrededor del cráneo.

Los participantes calificaron como se iban sintiendo en términos de niveles de valencia-excitación en el espacio bidimensional formado por estas dos variables. Se tomaron evidencias en video de la cara frontal, tanto para el apartado de relajamiento como para las actividades de trading. Se muestra adicionalmente un extenso análisis de los datos registrados de los participantes y se busca encontrar como correlacionan las señales EEG y los niveles de valencia y excitación registrados por cada uno de los participantes.

El dataset se probó con métodos de aprendizaje automático para la detección de emociones en el espacio valencia-excitación. Se presentan los métodos y los resultados para la clasificación de las emociones de los participantes. El dataset está disponible públicamente y se anima a otros investigadores a que lo utilicen para probar sus propios métodos de estimación de los estados emocionales.

Palabras Clave: clasificación de emociones, señales EEG, procesamiento de señales, valencia, excitación.

ABSTRACT

This paper details the procedure for collecting data for analyzing the emotional states of people exposed to specific activities. Electroencephalographic (EEG) signals corresponding to 12 participants were recorded while each performed a session. Each session lasted 2 minutes in a state of relaxation to obtain a baseline and 20 minutes to perform trading activities to detect emotions.

This work used an Ultravortex helmet (OPEN BCI) with eight sensors to capture the different EEG signals in various areas around the skull to collect the data from the participants.

Participants rated how they felt regarding valence-arousal levels in the two-dimensional space formed by these two variables. Video evidence was taken from the front face, both for the relaxation section and for trading activities. Additionally, an extensive analysis of the registered data of the participants is shown, and it is sought to find how the EEG signals correlate with the levels of valence and arousal recorded by each participant.

The data set was tested with machine learning methods for emotion detection in the valence-arousal space. Methods and results for classifying participants' emotions are presented. The dataset is publicly available, and other researchers are encouraged to use it to test their own methods of estimating emotional states.

Keywords: emotion classification, EEG signals, signal processing, valence, excitation.

Capítulo I: Introducción

1.2 Descripción del componente desarrollado

El uso de señales EEG permite el estudio del reconocimiento de emociones en forma no invasiva. Las señales EEG tienen una resolución temporal alta lo que les hace ideales para correlacionar las emociones humanas y la actividad cerebral registrada a través de las ondas captadas usando una interfaz código abierto cerebro- computadora. Al momento, no se encuentran datasets de fácil acceso que permitan probar distintos métodos para el avance de esta área de computación afectiva. Este es un campo que apunta a detectar automáticamente y cuantificar las emociones humanas [1].

La mayoría de datasets reportados en publicaciones científicas utilizan métodos con estímulos audiovisuales que son muy subjetivos y dependientes de los individuos sobre los que se aplican [2].

En este trabajo se proponen un método innovador para provocar emociones a través de la actividad de trading para generar sentimientos en los participantes. Se plantea que el trading en el mercado de valores induce en forma consistente sentimientos relacionados a su componente de "dinero" que representa variables tales como recursos, estilo de vida, probabilidad de sobrevivencia, estatus, entre otras [3]. Generalmente, los participantes tienen emociones intensas relacionadas con estos factores, lo que hace que el trading sea un estímulo emocional de características robustas. En particular, el mercado de valores produce cuatro emociones básicas: miedo, avaricia, esperanza y arrepentimiento [2].

Estas emociones se pueden etiquetar con una medida en dos dimensiones: valencia y excitación (arousal) que se pide a los participantes que valoren y marquen durante las lecturas EEG. Con los experimentos se construirá un dataset de señales eléctricas cerebrales vs las emociones con las que están relacionadas etiquetadas por cada participante. Este dataset será puesto a disposición de la comunidad científica como una contribución para el avance en el campo del reconocimiento de emociones.

Adicionalmente, en este proyecto de titulación se usará este dataset para obtener modelos para realizar reconocimiento de emociones usando algoritmos de aprendizaje automático que se probarán y se evaluará su rendimiento para determinar los que producen mejores resultados.

1.3 Objetivo General

Obtener un dataset para reconocimiento de emociones usando técnicas de aprendizaje automático.

1.4 Objetivos Específicos

1. Realizar experimentos para captar las señales EEG de participantes mientras realizan actividades de trading en el mercado de valores.
2. Obtener una base de datos de señales EEG asociadas a estados emocionales de los participantes en los experimentos.
3. Reconocer las emociones de los participantes utilizando algoritmos de aprendizaje automático (machine learning).
4. Evaluar el rendimiento de los clasificadores, mediante el análisis de la información recopilada de cada uno los participantes.

1.5 Alcance

Obtención de un dataset para reconocimiento de emociones usando una interfaz cerebro –computador (Brain Computer Interface – BCI).

Análisis de emociones relacionadas con los cuadrantes del espacio valencia – arousal para emociones autodefinidas usando técnicas de aprendizaje automático con vector de entrada compuesto por características en el dominio tiempo, frecuencia y tiempo-frecuencia y señales EEG vs solamente señales EEG. Pruebas con distintos algoritmos.

1.6 Marco teórico

1.6.1 BCI – EEG

El reconocimiento de emociones es un problema desafiante en la interacción cerebro-computadora (BCI). El electroencefalograma (EEG) brinda información sobre las actividades cerebrales que se crean debido a los estímulos emocionales. Esta es una de las ventajas más sustanciales de BCI, utilizar señales en comparación con la expresión facial, el tono de voz o el habla en tareas de reconocimiento de emociones. Sin embargo, la falta de datos de EEG y las grabaciones de EEG de alta dimensión conducen a dificultades en la construcción de clasificadores efectivos con alta precisión [4].

En los últimos años, los investigadores suelen utilizar materiales emocionales, como imágenes, sonidos y videos, para inducir a los sujetos a emociones, y analizar sus señales fisiológicas para obtener la regularidad de los cambios emocionales [5]. Las señales fisiológicas, como la electroencefalografía (EEG), la electrocardiografía (ECG), a menudo se utilizan para reflejar estados emocionales.

El más utilizado es el EEG, por su buena resolución temporal, así como una resolución espacial aceptable. Además, EEG se ha utilizado ampliamente en las interfaces cerebro-computadora (BCI), y el estudio del reconocimiento de emociones basado en EEG puede proporcionar un gran valor para mejorar la experiencia del usuario y el rendimiento de las aplicaciones BCI [6].

1.6.2 Formas de Representar Emociones

En la actualidad, existen problemas para el reconocimiento de emociones basado en EEG que requieren una mayor investigación. Un problema es que la precisión de la clasificación de emociones es generalmente baja. Según estudios de evidenció que diferentes sujetos pueden tener diferentes sensibilidades a diferentes características. Estos hallazgos están relacionados con lo que se denomina el problema de alta dimensionalidad en EEG, porque no todas estas características contienen información significativa sobre las emociones [6].

Las emociones se pueden representar utilizando diferentes modelos generales. Los más utilizados son el modelo discreto y los modelos dimensionales.

- **Modelo Discreto**

Identifica emociones básicas, innatas y universales de donde pueden derivarse todas las demás emociones [7]. Algunos autores afirman que estas emociones primarias son la alegría, la tristeza, la ira, la sorpresa, el asco y el miedo. Algunos investigadores consideran que este modelo tiene limitaciones para representar emociones específicas en una gama más amplia de estados afectivos [7].

- **Modelo Dimensional**

Alternativamente, los modelos dimensionales pueden expresar emociones complejas en un espacio continuo bidimensional: valencia-activación (VA), o en tres dimensiones: valencia, activación y dominancia (VAD) [7].

El modelo VA tiene como ejes la valencia y la excitación. La valencia se usa para calificar las emociones positivas y negativas y varía de feliz a infeliz (o triste). La excitación mide las emociones desde la calma hasta la estimulación (o excitación). Los modelos tridimensionales agregan un eje de dominancia para evaluar desde emociones sumisas (sin poder) hasta emociones empoderadas. Esta representación distingue emociones que se representan conjuntamente en el modelo VA. Por ejemplo, el miedo y la ira tienen representaciones de excitación de valencia similares en el plano VA. Así, los modelos tridimensionales mejoran la “resolución emocional” a través de la dimensión de dominancia [7].

1.6.3 Datasets Públicos Disponibles

- **DEAP Dataset**

DEAP (Base de datos para el análisis de emociones mediante señales fisiológicas) es la base de datos recopilada por Koelstra de la Universidad Queen Mary de Londres; la Universidad de Twente; la Universidad de Ginebra, Suiza; y el Instituto Federal Suizo de Tecnología. Los datos multicanal son para estudiar los estados emocionales humanos.

En la actualidad, el conjunto de datos DEAP se ha utilizado ampliamente en la investigación de reconocimiento de emociones. La base de datos se basa en las señales fisiológicas generadas por los estímulos inducidos por los videos musicales. Grabó a 32 sujetos que vieron 40 minutos de videos musicales (1 minuto por cada video musical) de señales fisiológicas y la autoevaluación de los sujetos sobre la valencia y la excitación. Las escalas de excitación y valencia son del 1 al 9 (1 representa tristeza/calma y 9 representa felicidad/emocionada). La frecuencia de muestreo de las señales fisiológicas es de 512 Hz [8].

- **SEED Dataset**

El SJTU Emotion EEG Dataset (SEED), es una colección de conjuntos de datos EEG proporcionados por el laboratorio BCMI, que está dirigido por el Prof. Bao-Liang Lu. El nombre se hereda de la primera versión del conjunto de datos, pero ahora proporciona no solo emoción, sino también un conjunto de datos de vigilancia. El conjunto de datos de SEED contiene datos de EEG y movimiento ocular de 12 sujetos y datos de EEG de otros 3 sujetos. Los datos se recopilaron cuando estaban viendo clips de películas. Los clips de película se seleccionan cuidadosamente para inducir diferentes tipos de emoción, que son positivas, negativas y neutrales [6].

Dificultades de Acceso

No existen muchas dificultades de Acceso para estos dataset, dado que son públicos y de libre acceso, razón por la cual existen múltiples formas de poder descargarlos desde sus páginas oficiales y utilizarlos para fines académicos o de investigación. Sólo es importante leer los términos de licencia y condiciones que cada uno presenta, para no tener problemas de derechos de autor [6].

1.6.4 Número De ElectrodoS o Canales

Muchos de los experimentos de señales EEG, utilizan entre 8 y 32 canales para el reconocimiento de emociones y el marcado implícito, que incluye datos de EEG registrados mediante el uso de un gorro de EEG según el sistema estándar internacional A 10-20 [8]. Para la extracción de características, se usan alguna configuración de 32 electrodos para la recolección de señales, pero usamos solo ocho electrodos de eso; por lo tanto, nuestro método es muy fácil de usar y conveniente para los usuarios. Para evaluar los resultados, comparamos nuestro algoritmo con otros trabajos similares [9].

Las señales de EEG se amplifican y digitalizan a una frecuencia de muestreo de 250 Hz. Se seleccionaron cuarenta videoclips chinos en función de los modelos de emociones positivas y negativas, con 20 clips para cada categoría de emoción (positiva y negativa). En la selección de videos, primero editamos 140 escenas de comedia y tragedia (clips) de películas chinas famosas o programas cruzados, cada uno de los cuales tenía aproximadamente 30 s. Luego, se reclutaron diez voluntarios (que no eran los participantes en el experimento BCI) para ver estos videos y evaluar sus emociones con un nivel (es decir, en absoluto, leve o extremadamente) y una palabra clave (es decir, positiva o negativa) [6].

Norma 10-20 para Ubicación de ElectrodoS

El sistema de 10/20 internacional es un método reconocido internacionalmente al describir la localización de cada uno de los electrodos. Los números 10/20 hacen referencia al porcentaje (10 y 20) de distancia en la que deben estar colocados los electrodos en la parte frontal, occipital, de lado derecho e izquierda del cráneo. Cada sitio tiene una letra para identificar el lóbulo y un número para identificar la ubicación del hemisferio [10].

ELECTRODO	Lóbulo
F	Frontal
T	Temporal
C	Central
P	Parietal
O	Occipital

Tabla 1: Nomenclatura de los Electrodo de OpenBCI acorde a la Norma 10/20.

Como sabemos no existe un lóbulo central únicamente se utiliza para ubicar la parte central del cráneo, la Z (zero) hace referencia a la mitad de la cabeza, los números 2,4,6,8 son los electrodos colocados en el hemisferio derecho y 1,3,5,7,9 los electrodos del hemisferio izquierdo [10].




Figura 1: Ubicación de los Electrodo según la Norma 10-20 [10].

Ubicación De Electrodo En La Herramienta Ultravortex.

A continuación, se presenta una nomenclatura en la Tabla 2.1, de cada uno de los sensores de la herramienta Ultravortex y su respectiva ubicación en el cerebro de una persona.

Área Cerebral	Hemisferio Izquierdo	Línea Media	Hemisferio Derecho
Frontopolar	FP1		FP2
Frontal	F3	Fz	F2
Fronto Temporal	F7, C3	Cz	F8, C4
Temporal Medio y Parietal	T3, P3	Pz	T4, P4
Temporal Posterior y Occipital	T5, O1		T6, O2
Preauriculares	A1		A2

Tabla 2: Nomenclatura de los Sensores.

1.6.5 Formas de Elicitación de Emociones

Este artículo analiza trabajos de investigación que utilizaron diferentes recursos para provocar emociones en sus sujetos. Estos estímulos son videos musicales, fragmentos de películas, pistas musicales, asco autoinducido (producido al recordar un olor desagradable) y situaciones de riesgo en un simulador de vuelo como ejemplo de provocación activa de emociones. Los sistemas BCI basados en EEG utilizan con frecuencia las bases de datos públicas DEAP y SEED que aplican videos musicales y clips de películas como estímulos, respectivamente. Diferentes estímulos provocan emociones que afectan diferentes áreas del cerebro y producen señales EEG que pueden reconocerse en emociones específicas. La figura 5 muestra la frecuencia con la que se aplican diferentes métodos de obtención de emociones a generar conjuntos de datos utilizados en los sistemas revisados [7].

Pocos trabajos de investigación recurren a plataformas interactivas para provocar emociones de la “vida real”. Sin embargo, dichos métodos se han aplicado a otras respuestas fisiológicas (distintas del EEG, como la conductancia de la piel, la respiración, el electrocardiograma (ECG), las expresiones faciales, entre otras) [7]. Algunos autores afirman que los estímulos que provocan emociones de amplio espectro podrían dificultar la exploración de los mecanismos del cerebro activados para la generación de emociones específicas. En este sentido, centrarse en una emoción en particular podría mejorar nuestra comprensión de tales mecanismos. Se destacan trabajos de investigación que estudian las emociones, como la aversión y el asco por separado [7].

1.6.6 Self-Assessment Manikin como forma de Auto etiquetar Emociones.

Se usan las escalas de valencia y excitación SAM, para evaluar emociones. Para la valencia, un continuo de cinco figuras humanas estilizadas (maniqués) representa sentirse muy feliz (puntuación de 1) a muy triste (puntuación de 9). Para la excitación, un segundo continuo de cinco maniqués estilizados representa sentirse muy tranquilo (puntuación de 1) a muy tenso (puntuación de 9). Aunque hay cinco maniqués, las opciones de respuesta intermedia permiten a los participantes elegir un sentimiento a medio camino entre dos maniqués. Así, hay un total de nueve opciones de respuesta para ambas escalas. Los cambios de puntuación pueden oscilar entre -8,0 y 8,0. Los números negativos reflejan sentirse más feliz o tranquilo; los números positivos reflejan sentirse más triste o tenso. El movimiento de un maniquí al siguiente maniquí superior o inferior requiere un cambio de puntuación de 2 [11].

En la tabla 1.3 podemos observar el rango de valores de valencia y excitación equivalente a la emoción de una persona.

Valencia	Excitación	Emoción
-4	7	Ira
-6	6	Asco
-6	4	Temor
-6	3	Tristeza
4	6.5	Alegría
8	5	Sorpresa
-8	1.99	Relajación

Tabla 3: Estados emocionales en el espacio Valencia-Excitación.

Capítulo II: Metodología

2.2 Justificación Metodológica

Se construirá un dataset para el análisis de emociones. Se captarán señales de electroencefalograma (EEG) utilizando OpenBCI con un casco Ultravortex de al menos 12 participantes que serán grabadas en una sesión. Una sesión consta de alrededor de 2 minutos de relajamiento inicial para obtener una baseline y luego 20 minutos en las que se captan señales EEG mientras los participantes realizan transacciones en el mercado de valores y etiquetan sus emociones cada minuto. Como ya se mencionó, el mercado de valores induce consistentemente emociones en los participantes, debido a su componente de riesgo [12].

Para la fase de preprocesamiento, se realizará una verificación y validación de los datos para saber si existen valores nulos o datos incongruentes, posteriormente se analizará los tipos de datos de las diferentes columnas de nuestro dataset correspondiente a los 8 canales que nos reflejará la herramienta ultravortex así como la información de etiquetas de valencia-excitación proporcionada por cada uno de los participantes.

Dado que para las variables de valencia y excitación se tienen que evaluar en 4 tipos de etiquetas que serán HV y LV para valencia y HA y LA para excitación, es necesario un balanceo de estas, para poder establecer una cantidad nivelada y que no exista muchos valores de una misma etiqueta o pocos valores de otra. Para poder realizar este procedimiento se realizará un balance mediante herramientas de balanceo que el lenguaje Python proporciona, entre ellas se usará: Smote, para poder establecer un balanceo óptimo para nuestro dataset, para su posterior uso en modelos de aprendizaje supervisado.

El algoritmo de la técnica de sobre muestreo de minorías sintéticas (SMOTE) crea datos artificiales basados en las similitudes del espacio de características entre la clase minoritaria existente mediante la introducción de una clase minoritaria no replicada.

La introducción de los nuevos ejemplos sirve efectivamente para cambiar el sesgo del alumno, forzando un sesgo más general, pero principalmente para la clase minoritaria. Las nuevas instancias de minorías se extrapolan y crean a partir de los desequilibrios de clases de minorías existentes utilizando el algoritmo k-NN. Los vecinos del k-NN se eligen aleatoriamente en función de la cantidad de sobre muestreo que se requiere. La adición de estas instancias de clase minoritaria generadas sintéticamente hace que las distribuciones de clase sean más equilibradas. [13]

Para la fase de Entrenamiento, se procederá a realizar la clasificación en cada uno de los cuadrantes, con datos numéricos para los valores correspondientes a la etiqueta de excitación y de valencia. Se aplicará cross-validation y separación de muestras para poder realizar la división del dataset en subconjuntos de entrenamiento. En esta fase se obtienen los modelos para la clasificación.

Para la fase de Prueba o Testeo se aplican los modelos en un nuevo set para la clasificación en cada uno de los cuadrantes. Para la evaluación de rendimiento usarán las métricas ya mencionadas: accuracy, precisión y Fmacro o F1.

2.3 Revisión de la literatura

Como punto de partida para la realización de este Trabajo de Titulación, se analizaron algunos artículos científicos referentes a Métodos y provocación de emociones, OPEN BCI, algoritmos de aprendizaje de máquina, reconocimiento de emociones, señales EEG, generación de datasets, protocolos usados para el reconocimiento de emociones, tipos de datasets comúnmente utilizados para el reconocimiento de emociones mediante el uso de señales EEG y BCI, métricas de evaluación para el rendimiento de los algoritmos de aprendizaje de máquina utilizados para las investigaciones, representación emocional, dimensional y analógica.

En esta revisión sistemática de la literatura se analizaron los datasets usados en los diferentes artículos científicos revisados, el número de electrodos que se utilizaron para poder realizar los distintos experimentos para el reconocimiento de emociones, la forma en cómo se representan las emociones, en la cual se pudieron destacar el uso de estados emocionales en el espacio Valencia-Excitación [7], precisión de clasificación promedio para mediciones de un mismo participante mientras expresaba emociones de manera excesiva, estos datos se expresaban en tasas de predicción de 0 a 100 % para cada fase emocional, en otros casos se pudo evidenciar el uso de semidefinición positiva (PSD) [14].

En otros artículos se utilizaron la denominada escala Gabor y SNR o relación señal-ruido que es la relación entre la información deseada o la potencia de una señal y la señal no deseada o la potencia del ruido que existe de fondo [15]. En la mayoría de los artículos relacionados se pudo observar que se usan en promedio entre 32 electrodos dentro del contexto de herramientas BCI, el hecho de usar un número elevado de electrodos siguiendo la Norma 10/20, permite que se pueden alcanzar más zonas del cerebro susceptibles a análisis y con ello arrojar más información sobre los estados emocionales de los pacientes. Los datasets públicos disponibles que se usaron para los análisis de emociones en su mayoría de casos fueron el DEAP dataset y el SEED Dataset.

Otros de los temas que se revisaron a detalle en la revisión sistemática de la literatura fueron los algoritmos de machine learning utilizados, las métricas de evaluación usadas y el rendimiento de los algoritmos. Entre los temas mencionados se encontró que los algoritmos más utilizados son Redes neuronales, Random Forest, KNN, SVM y Native Bayes.

Entre las métricas de evaluación utilizadas, se destacan las siguientes: Precisión Accuracy, Recall, F1 y Matriz de Confusión, con las mismas se pudo evaluar el rendimiento de los algoritmos antes mencionados, en donde se pudo constatar que el uso de KNN tiene un rendimiento de entre el 93% al 94%, Native Bayes: de entre un 915 a un 92%, SVM: de entre un 89% a un 91% y Redes Neuronales: de entre un 94% a un 95%.

2.4 Materiales y métodos

2.4.1 Protocolo para Provocar Emociones

Para lo que concierne la parte de selección de estímulos se decidió trabajar en 2 estados para cada uno de los participantes, referentes a relajamiento y trading.

Relajamiento

Se grabó 2 minutos de sesión a los participantes mientras tenían colocada la herramienta Ultravortex en sus cabezas respectivamente, tal y como puede observarse en la figura 2.



Figura 2: Participante en estado de Relajamiento.

Para este estado de consideró lo siguiente:

- Un minuto en donde el participante estaba con sus ojos cerrados.
- Un minuto en donde el participante estaba con sus ojos abiertos.

Trading

Se grabó 20 minutos de sesión a los participantes mientras tenían colocada la herramienta Ultravortex y adicionalmente realizaban actividades de trading, tal y como puede observarse en la figura 3.

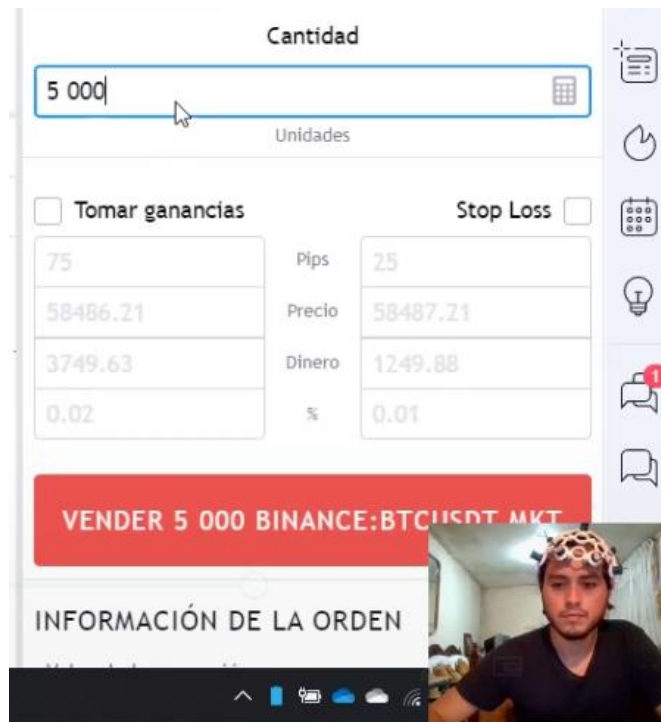


Figura 3: Participante realizando actividades de Trading.

Adicionalmente el participante debía ir registrando en cada minuto de la sesión, como se iba sintiendo, llenando sus niveles de valencia y excitación con la valoración indicada en las tables 1.4 y 1.5 respectivamente.

En la tabla 4 se muestra en una escala del 1 al 10 los valores más destacados en el grado de valencia.


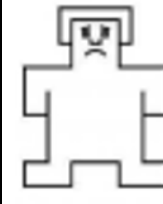
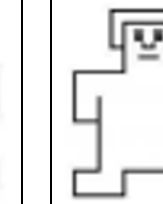
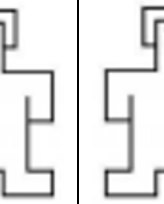
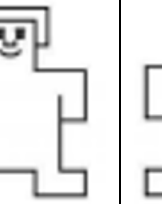
				
1	3	5	7	9

Tabla 4: Escala de Evaluación Valencia.

En la tabla 5 se muestra en una escala del 1 al 10 los valores más destacados en el grado de excitación.






				
1	3	5	7	9

Tabla 5: Escala de Evaluación Excitación.

2.4.2 Configuración del Experimento

Se registrarán las señales cerebrales con las respectivas anotaciones que realice cada individuo en los experimentos para formar la base de datos. Esta información se la hará pública para que sea utilizada por la comunidad científica en el desarrollo del reconocimiento automático de los estados mentales afectivos.

En el presente trabajo, estos datos se los convertirá al dominio de la frecuencia y se pasarán por filtros para eliminar el ruido y separar las señales alfa, beta, gama, theta y delta de las ondas cerebrales en distintos momentos. Con esta información se construirá un vector de características que se ingresará en algoritmos de machine learning supervisados para obtener un modelo. Este modelo se aplicará en datasets de prueba para clasificar el estado mental de los participantes.

2.4.3 Modo de Prueba

Caso 1:

La Persona fue sometida a realizar actividades de relajamiento, abriendo y cerrando los ojos durante 2 minutos y cada minuto registró como se sentía en una encuesta basada en el modelo Self-Assiment.



Figura 4: Persona en estado de relajamiento con los ojos cerrados.

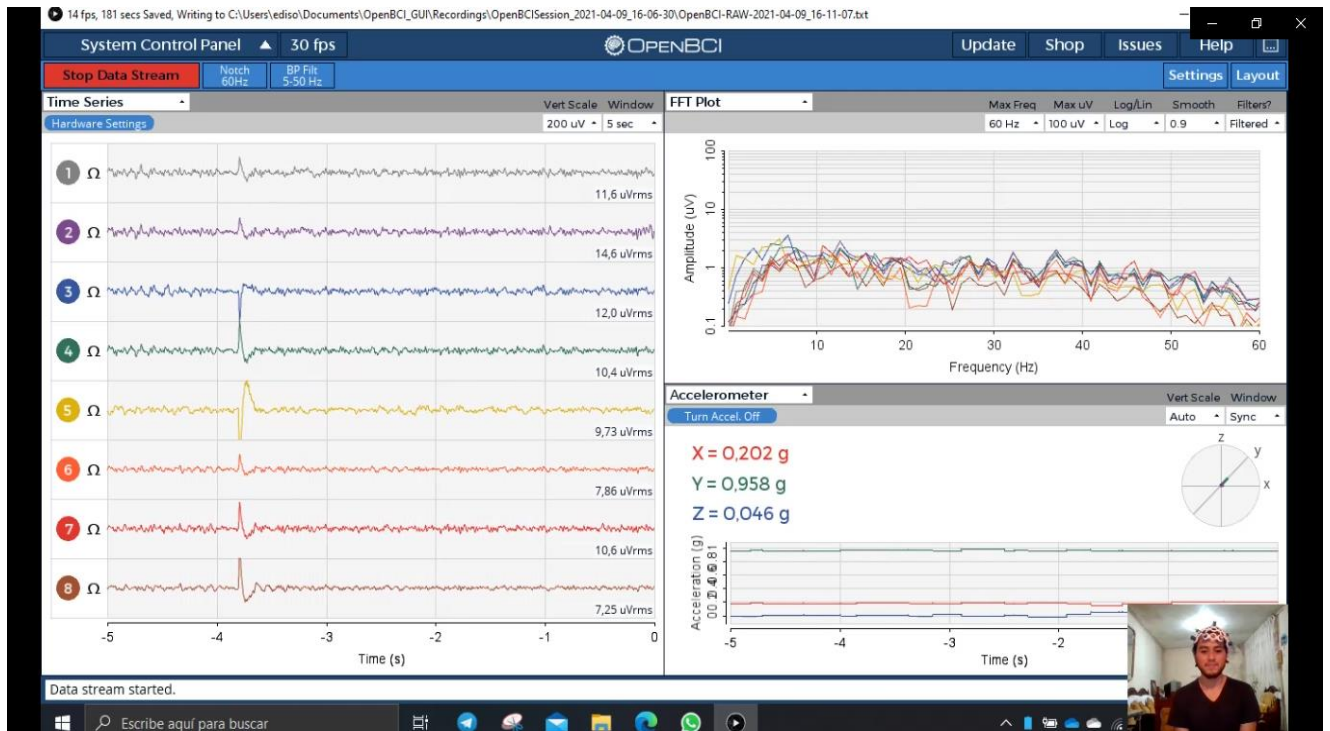


Figura 5: Persona en estado de relajamiento con los ojos abiertos.

Caso 2:

La Persona fue sometida a realizar actividades de Trading Online comprando y vendiendo acciones durante 20 minutos y cada minuto registró como se sentía en una encuesta basada en el modelo Self-Assiment.




Figura 6: Persona en realizando actividades de Trading.

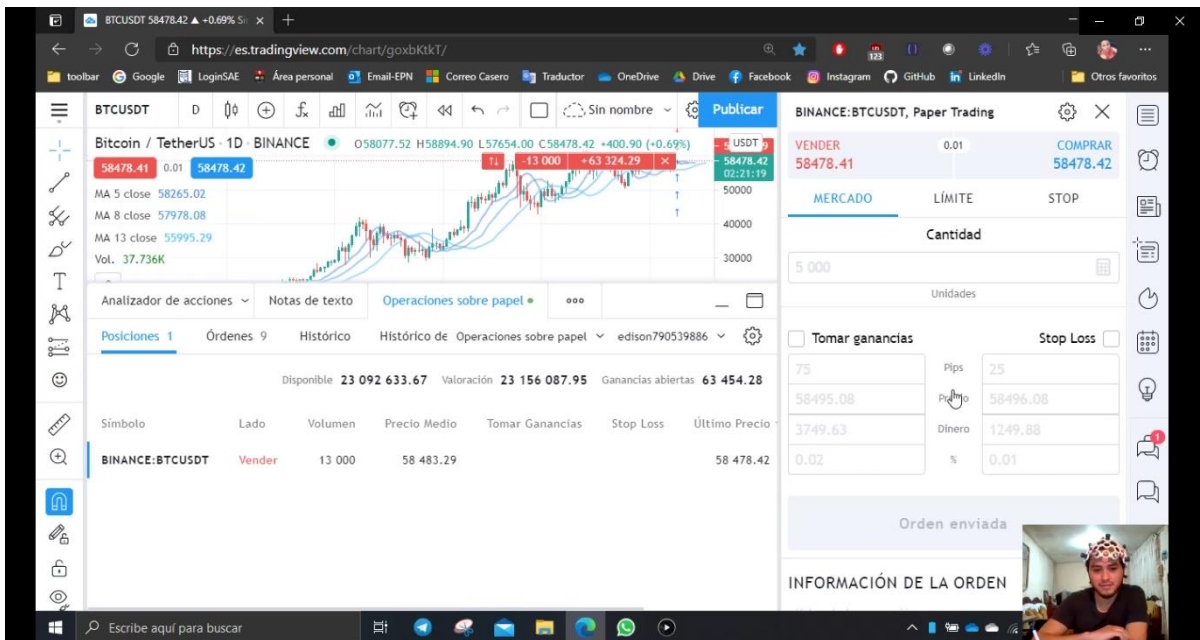


Figura 7: Persona en realizando actividades de Trading.

A continuación, en las tablas 6 y 7 se puede observar una categorización valiéndonos de la escala mostrada en las tablas 4 y 5.

Categorización	Valores
HV	Rango de 1 a 4
LV	Rango de 5 a 10

Tabla 6: Valores Categorizados Valencia.

Categorización	Valores
HA	Rango de 1 a 4
LA	Rango de 5 a 10

Tabla 7: Valores Categorizados Excitación.

En la siguiente tabla podemos observar cómo están divididos los valores de valencia y excitación según lo observado en las tablas 6 y 7 en el espacio.

Valores de V-A	Cuadrantes
HVHA	Primer Cuadrante
HVLA	Segundo Cuadrante
LVLA	Tercer Cuadrante
LVHA	Cuarto Cuadrante

Tabla 8: Cuadrantes en el Espacio Valencia-Excitación.




Figura 8: Estados Emocionales Valencia-Excitación en el Espacio [14]

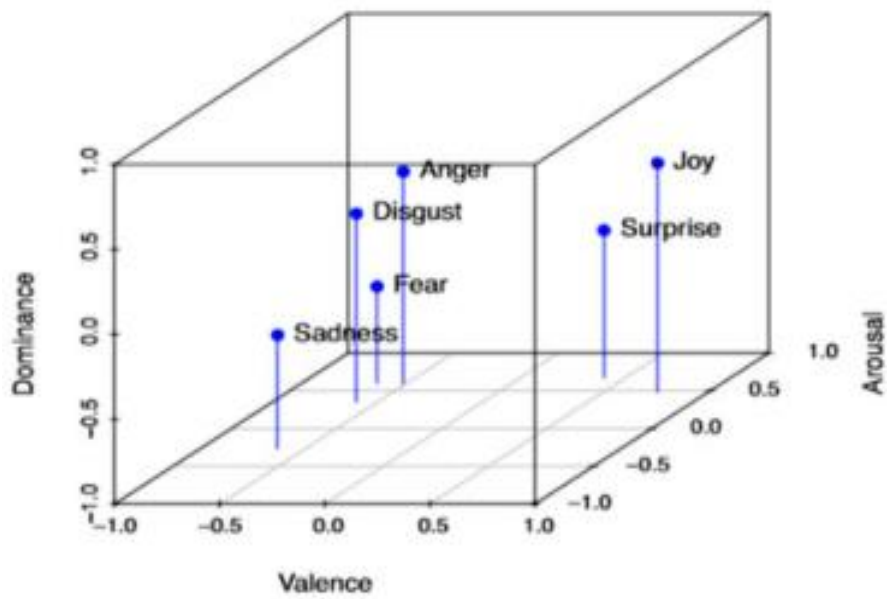


Figura 9: Estados emocionales en el espacio de dominancia de Valencia-Excitación [14]

2.4.4 Pre - Procesamiento

Diagrama con cada fase



Figura 10: Diagrama de Fases

Procesamiento del dataset:

Se realizó una verificación y validación de los datos para saber si existen valores nulos o datos incongruentes, posteriormente se analizará los tipos de datos de las diferentes columnas de nuestro dataset correspondiente a los 8 canales que nos reflejará la herramienta ultravortex así como la información de etiquetas de valencia-excitación proporcionada por cada uno de los participantes.

Dado que para las variables de valencia y excitación se tienen que evaluar en 4 tipos de etiquetas que serán HV y LV para valencia y HA y LA para excitación, fue necesario un balanceo de estas, para poder establecer una cantidad nivelada y que no exista muchos valores de una misma etiqueta o pocos valores de otra. Para poder realizar este procedimiento se realizó un balance mediante herramientas de balanceo que el lenguaje Python proporciona, entre ellas se usó: Smote, para poder establecer un balanceo óptimo para nuestro dataset, para su posterior uso en modelos de aprendizaje supervisado.

El algoritmo de la técnica de sobre muestreo de minorías sintéticas (SMOTE) crea datos artificiales basados en las similitudes del espacio de características entre la clase minoritaria existente mediante la introducción de una clase minoritaria no replicada.

Entrenamiento de los datos:

Se procedió a realizar la clasificación en cada uno de los cuadrantes, con datos numéricos para los valores correspondientes a la etiqueta de excitación y de valencia. Se aplicó cross-validation y separación de muestras para poder realizar la división del dataset en subconjuntos de entrenamiento. En esta fase se obtuvieron los modelos para la clasificación.

Testeo de los datos:

Se aplicó los modelos en un nuevo set para la clasificación en cada uno de los cuadrantes.

Evaluación de rendimiento:

Para poder evaluar como los modelos de machine learning seleccionados se comportan con el conjunto de datos suministrado. Se utilizaron las métricas de: accuracy, precisión y Fmacro o F1.

2.4.5 Balanceo de datos (SMOTE)

```
BALANCEO SMOTE
[ ] sm = SMOTE(random_state=0)
    X_sm, y_sm = sm.fit_resample(X,y)
    pd.Series(y_sm).value_counts()

0    2885801
1    2885801
dtype: int64
```

Figura 11: Balanceo SMOTE para la variable Valencia.

```
BALANCEO SMOTE
[ ] sm = SMOTE(random_state=0)
    X_sm, y_sm = sm.fit_resample(X,y)
    pd.Series(y_sm).value_counts()

1    2373282
0    2373282
dtype: int64
```

Figura 12: Balanceo SMOTE para la variable Excitación.

El algoritmo de la técnica de sobre muestreo de minorías sintéticas (SMOTE) crea datos artificiales basados en las similitudes del espacio de características entre la clase minoritaria existente mediante la introducción de una clase minoritaria no replicada. La introducción de los nuevos ejemplos sirve efectivamente para cambiar el sesgo del alumno, forzando un sesgo más general, pero principalmente para la clase minoritaria.

Las nuevas instancias de minorías se extrapolan y crean a partir de los desequilibrios de clases de minorías existentes utilizando el algoritmo k-NN. Los vecinos del k-NN se eligen aleatoriamente en función de la cantidad de sobre muestreo que se requiere. La adición de estas instancias de clase minoritaria generadas sintéticamente hace que las distribuciones de clase sean más equilibradas [13].

2.4.6 Algoritmos de clasificación:

Algoritmo 1 Redes Neuronales

Las Redes Neuronales (ANN), las redes neuronales comprenden múltiples capas de nodos interconectados. Estos incluyen los nodos de entrada, que se encargan de recibir y ofrecer los datos de entrada a la red; mientras que los nodos de salida representan la predicción final de la red; a su vez existen las denominadas capas ocultas intermedias, que capturan y factorizan las diversas características presentes en el dataset a generar [16].

Algoritmo 2 SVM:

SVM, (Support Vector Machine), son algoritmos de aprendizaje supervisado que tienen como objetivo seleccionar un hiperplano de separación que equidiste de los ejemplos más cercanos de cada clase para, de esta forma, conseguir lo que se denomina un margen máximo a cada lado del hiperplano. Además, a la hora de definir el hiperplano, sólo se consideran los ejemplos de entrenamiento que distan del hiperplano a la distancia margen. Estos ejemplos reciben el nombre de vectores soporte [17].

Algoritmo 3 Random Forest:

Random Forest, es un algoritmo de machine learning que surge como evolución de los árboles de decisión. Los árboles de decisión clasifican los datos de un modelo realizando una serie de particiones binarias, permitiendo realizar predicciones futuras en base a esta clasificación. Los random forests están formados por un gran número de árboles de decisión, creados a partir de la técnica del bagging o bootstrap aggregating. Este algoritmo mejora los árboles de decisión, creando un modelo más fiable y preciso evitando problemas como el overfitting [18].

Capítulo III: Implementación y Resultados

3.2 Herramientas

OpenBCI



Figura 13: Aplicación OpenBCI en ejecución.

La interfaz cerebro-computadora de código abierto (OpenBCI) es un sistema de biodetección asequible que puede tomar muestras de la actividad eléctrica del cuerpo humano, como el cerebro (señales EEG) [19]. Esta aplicación fue utilizada para poder captar la información cerebral de los participantes que fueron seleccionados para realizar esta investigación.

Ultracortex




Figura 14: Ultracortex de 8 electrodos.

El Ultracortex es una herramienta destinada a trabajar con cualquier placa OpenBCI. Es capaz de registrar la actividad cerebral (señales EEG), de grado de investigación [19]. Para para este trabajo de titulación fue utilizado un Ultracortex compuesto de 8 electrodos para captar las señales EEG de los participantes en el experimento realizado.

Active Presenter



Es una aplicación que permite capturar vídeo en tiempo real de la pantalla de nuestro ordenador. Esta herramienta fue utilizada para realizar las grabaciones de pantalla y así como de las personas participantes en la prueba del uso de la herramienta OpenBCI.

Python



Lenguaje de programación utilizado para el análisis y procesamiento de los datos, haciendo uso de sus variadas librerías que ayudan de forma sintetizada a la aplicación de diferentes modelos de aprendizaje supervisado basados en Machine Learning.



Herramienta similar a Jupyter, en donde tenemos un entorno virtualizado para la generaci3n de diferentes notebooks, con los c3digos que deseemos trabajar en lenguaje Python, fue utilizado para el procesamiento de los datos obtenidos y para el desarrollo de modelos de aprendizaje supervisado, tales como SVM, Random Forest y Redes Neuronales.

3.3 Dataset

indice, channel1, channel2, channel3, channel4, channel5, channel6, channel7, channel8, s1, s2, s3, time, const, valence, arousal, ev, ea
1, 0, 0, 0, 0, 0, 0, -0.138, 0.94, 0.006, " 12:14:00, 111", 1.62E+12, 5, 3, HV, LA
1, -79865.59, -67339.79, -79986.66, -81832.46, -79933.12, -74381.88, -79506.29, -78767.14, 0, 0, 0, " 12:14:00, 111", 1.62E+12, 5, 3, HV, LA
1, -79865.06, -67337.35, -79986.66, -81833.13, -79930.53, -74382.27, -79500.5, -78767.55, 0, 0, 0, " 12:14:00, 113", 1.62E+12, 5, 3, HV, LA
1, -79866.34, -67337.04, -79988.77, -81834.31, -79929.74, -74382.96, -79497.38, -78768.38, 0, 0, 0, " 12:14:00, 113", 1.62E+12, 5, 3, HV, LA
1, -79866.36, -67338.41, -79988.38, -81832.93, -79932.18, -74382.05, -79502.72, -78767.16, -0.102, 0.946, 0.018, " 12:14:00, 114", 1.62E+12, 5, 3, HV, LA
1, -79866.36, -67339.7, -79987.86, -81833.13, -79935.13, -74382.45, -79508.04, -78767.37, 0, 0, 0, " 12:14:00, 114", 1.62E+12, 5, 3, HV, LA
1, -79866.96, -67338.59, -79988.87, -81835.37, -79934.17, -74383.9, -79504.8, -78769.09, 0, 0, 0, " 12:14:00, 114", 1.62E+12, 5, 3, HV, LA
1, -79866.4, -67335.21, -79989.09, -81834.56, -79930.15, -74382.53, -79498.05, -78767.99, 0, 0, 0, " 12:14:00, 114", 1.62E+12, 5, 3, HV, LA
1, -79868.3, -67338.05, -79990.32, -81833.82, -79934.15, -74383.7, -79504.52, -78769.47, 0, 0, 0, " 12:14:00, 115", 1.62E+12, 5, 3, HV, LA
1, -79867.79, -67339.75, -79988.89, -81834.14, -79937.5, -74384.08, -79511.03, -78769.76, 0, 0, 0, " 12:14:00, 115", 1.62E+12, 5, 3, HV, LA
1, -79865.82, -67336.75, -79987.39, -81834.95, -79934.44, -74383.45, -79506.13, -78768.98, 0, 0, 0, " 12:14:00, 115", 1.62E+12, 5, 3, HV, LA
1, -79868.01, -67335.88, -79990.68, -81838.34, -79932.83, -74384.97, -79501.13, -78770.95, 0, 0, 0, " 12:14:00, 115", 1.62E+12, 5, 3, HV, LA
1, -79868.23, -67335.88, -79991.08, -81835.77, -79933.57, -74383.79, -79503.41, -78769.83, 0, 0, 0, " 12:14:00, 115", 1.62E+12, 5, 3, HV, LA
1, -79864.93, -67334.63, -79987.01, -81830.78, -79934.28, -74380.84, -79507.56, -78766.9, 0, 0, 0, " 12:14:00, 115", 1.62E+12, 5, 3, HV, LA
1, -79864.61, -67333.66, -79986.79, -81833.02, -79934.04, -74381.82, -79506.43, -78768.2, -0.102, 0.948, 0.024, " 12:14:00, 115", 1.62E+12, 5, 3, HV, LA
1, -79866.91, -67332.1, -79990.12, -81836.57, -79932.05, -74383.3, -79500.39, -78770.16, 0, 0, 0, " 12:14:00, 115", 1.62E+12, 5, 3, HV, LA
1, -79868.52, -67332.86, -79991.57, -81837.16, -79933.32, -74383.43, -79502.05, -78770.61, 0, 0, 0, " 12:14:00, 117", 1.62E+12, 5, 3, HV, LA
1, -79867.56, -67333.27, -79989.94, -81835.01, -79935.8, -74381.82, -79507.9, -78768.91, 0, 0, 0, " 12:14:00, 117", 1.62E+12, 5, 3, HV, LA
1, -79866.71, -67331.39, -79989, -81835.77, -79935.02, -74381.15, -79506.63, -78768.13, 0, 0, 0, " 12:14:00, 117", 1.62E+12, 5, 3, HV, LA
1, -79869.2, -67330.29, -79992.53, -81839.03, -79933.34, -74382.89, -79500.7, -78770.45, 0, 0, 0, " 12:14:00, 118", 1.62E+12, 5, 3, HV, LA
1, -79871.41, -67331.63, -79995.28, -81838.83, -79934.82, -74384.28, -79501.45, -78772.22, 0, 0, 0, " 12:14:00, 118", 1.62E+12, 5, 3, HV, LA
1, -79870.13, -67332.82, -79993.56, -81836.48, -79937.81, -74383.23, -79507.74, -78771.37, 0, 0, 0, " 12:14:00, 118", 1.62E+12, 5, 3, HV, LA
1, -79869.04, -67332.62, -79992.38, -81835.5, -79938.82, -74383.34, -79509.47, -78771.63, 0, 0, 0, " 12:14:00, 118", 1.62E+12, 5, 3, HV, LA
1, -79866.89, -67328.26, -79990.74, -81834.41, -79933.91, -74381.73, -79500.8, -78770.43, 0, 0, 0, " 12:14:00, 118", 1.62E+12, 5, 3, HV, LA
1, -79865.71, -67325.76, -79989.6, -81832.15, -79931.18, -74379.77, -79496.48, -78768.91, -0.108, 0.946, 0.016, " 12:14:00, 118", 1.62E+12, 5, 3, HV, LA
1, -79864.97, -67327.61, -79988.2, -81829.96, -79934.46, -74379.14, -79503.07, -78768.44, 0, 0, 0, " 12:14:00, 118", 1.62E+12, 5, 3, HV, LA
1, -79864.44, -67329.29, -79987.13, -81828.59, -79937.13, -74380.45, -79507.68, -78769.42, 0, 0, 0, " 12:14:00, 118", 1.62E+12, 5, 3, HV, LA
1, -79863.2, -67326.89, -79986.23, -81828.66, -79934.04, -74380.55, -79501.66, -78769.73, 0, 0, 0, " 12:14:00, 119", 1.62E+12, 5, 3, HV, LA
1, -79863.61, -67325.89, -79986.84, -81828.46, -79932.12, -74380.5, -79497.91, -78769.76, 0, 0, 0, " 12:14:00, 119", 1.62E+12, 5, 3, HV, LA
1, -79864.73, -67329.09, -79986.45, -81827.07, -79936.25, -74381.33, -79505.29, -78770.27, 0, 0, 0, " 12:14:00, 119", 1.62E+12, 5, 3, HV, LA
1, -79862.49, -67329.4, -79983.3, -81825.09, -79937.91, -74380.39, -79509.87, -78769.22, 0, 0, 0, " 12:14:00, 119", 1.62E+12, 5, 3, HV, LA
1, -79862.94, -67329.15, -79984.3, -81828.3, -79937.08, -74382.13, -79507.16, -78771.08, 0, 0, 0, " 12:14:00, 119", 1.62E+12, 5, 3, HV, LA
1, -79867.79, -67332.37, -79990.12, -81832.95, -79938.82, -74386.88, -79506.43, -78775.93, 0, 0, 0, " 12:14:00, 119", 1.62E+12, 5, 3, HV, LA
1, -79868.39, -67334.45, -79989.76, -81830.78, -79941.28, -74386.8, -79511.59, -78775.52, -0.106, 0.952, 0.018, " 12:14:00, 119", 1.62E+12, 5, 3, HV, LA
1, -79864.39, -67333.27, -79985.18, -81827.07, -79941.23, -74383.67, -79515.12, -78772.15, 0, 0, 0, " 12:14:00, 119", 1.62E+12, 5, 3, HV, LA
1, -79864.73, -67332.59, -79985.63, -81830.72, -79940.41, -74384.73, -79512.93, -78773.11, 0, 0, 0, " 12:14:00, 120", 1.62E+12, 5, 3, HV, LA
1, -79866.45, -67331.41, -79988.04, -81834.23, -79937.77, -74385.48, -79507.19, -78773.85, 0, 0, 0, " 12:14:00, 120", 1.62E+12, 5, 3, HV, LA

Figura 15: Contenido del dataset Stock-Emotion.

La herramienta OpenBCI capturó 256 datos por cada segundo, en el primer ambiente de prueba que fue el de relajamiento se tuvo un tiempo de duración de 2 minutos, en donde se recopilaron entre 27 000 a 30 000 muestras por cada participante, mientras que en el segundo ambiente de prueba que fue el de trading que tuvo una duración de 20 minutos, se recopilaron aproximadamente entre 270 000 a 300 000 muestras por cada participante.

Una vez que se finalizó el experimento, se pudo constatar que el dataset completo llegó a tener 3 944 690 de muestras, reflejados en 8 columnas, correspondientes a los 8 electrodos del Ultracortex, una columna para el tiempo, una para el valor de valencia, otra para el valor de excitación, una para la etiqueta de valencia y finalmente una para la etiqueta de excitación.

El dataset mostrado en la figura 13, consta de 18 columnas:

- **índice:** corresponde al número de la muestra, toma valores entre 1 y 256.
- **channel 1 - channel 8:** corresponde a los 8 electrodos que componen la herramienta Ultracortex usada en este experimento.
- **s1 - s2 - s3:** captan información sobre los ejes x, y, z, las cuales suelen estar en 0, debido a que no se está captando dicha información.
- **time:** tiempo real en el que se tomó la muestra.
- **const:** valor constante presente en cada muestra.
- **valence:** valores correspondientes a la variable de valencia.
- **arousal:** valores correspondientes a la variable de excitación.
- **ev:** valores correspondientes a la etiqueta de valencia (HV LV).
- **ea:** valores correspondientes a la etiqueta de excitación (HA LA).




Figura 16: Participante realizando actividades de trading.




Figura 17: Participante realizando actividades de trading.

Datos sobre la distribución de las diferentes clases antes del balanceo.

DISTRIBUCIÓN CLASES DE VALENCIA ANTES DEL BALANCEO




Figura 18: Distribución clases de valencia antes del balanceo.

DISTRIBUCIÓN CLASES DE EXCITACIÓN ANTES DEL BALANCEO

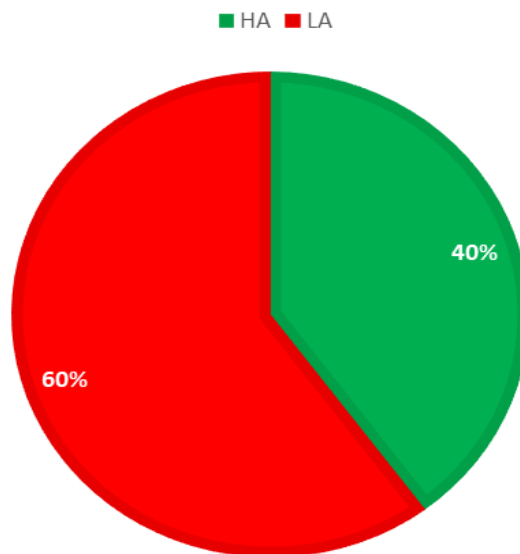


Figura 19: Distribución clases de excitación antes del balanceo.

Datos sobre la distribución de las diferentes clases después del balanceo.

DISTRIBUCIÓN CLASES DE VALENCIA DESPUES DEL BALANCEO




Figura 20: Distribución clases de valencia después del balanceo.

DISTRIBUCIÓN CLASES DE EXCITACIÓN DESPUES DEL BALANCEO




Figura 21: Distribución clases de excitación después del balanceo.

3.4 Algoritmos de Clasificación

3.4.1 Redes Neuronales

Según lo observado en la revisión sistemática de la literatura, se pudo constatar que el uso de redes neuronales para el estudio de emociones es bastante optimo por la gran capacidad y velocidad de análisis que posee este algoritmo de aprendizaje supervisado. Utilizado para poder arrojar resultados óptimos tanto para a variable “valencia” y sus diferentes clases, así como también para la variable “excitación” y sus clases.

Parámetros del Algoritmo:

En primer lugar se creó un modelo vacío de tipo Sequential(), como se muestra en la figura . Este modelo se refiere a que crearemos una serie de capas de neuronas secuenciales, “una delante de otra”.

Pruebas realizadas:

- **Primera Prueba:**
 - Modelo Sequential.
 - Una capa con la función de activación ‘relu’ y 30 entradas.
 - Una capa con la función de activación ‘sigmoid’ y 12 entradas.
 - Una capa con la función de activación ‘sigmoid’ y 7 entradas.
 - Una capa de salida con la función de activación ‘sigmoid’.

```
model = Sequential()
model.add(Dense(30,activation='relu'))
model.add(Dense(12,activation='sigmoid'))
model.add(Dense(7,activation='sigmoid'))
model.add(Dense(1,activation='sigmoid'))
model.compile(optimizer='adam',loss = 'binary_crossentropy',metrics=['accuracy'])
```

Figura: Primera Prueba con el Algoritmo de Redes Neuronales.

- **Segunda Prueba:**

- Modelo Sequential.
- Una capa con la función de activación 'sigmoid' y 30 entradas.
- Una capa con la función de activación 'sigmoid' y 12 entradas.
- Una capa con la función de activación 'sigmoid' y 7 entradas.
- Una capa de salida con la función de activación 'sigmoid'.

```
model = Sequential()  
model.add(Dense(30,activation='sigmoid'))  
model.add(Dense(12,activation='sigmoid'))  
model.add(Dense(7,activation='sigmoid'))  
model.add(Dense(1,activation='sigmoid'))  
model.compile(optimizer='adam',loss = 'binary_crossentropy',metrics=['accuracy'])
```

Figura 22: Segunda Prueba con el Algoritmo de Redes Neuronales.

- **Tercera Prueba:**

- Modelo Sequential.
- Una capa con la función de activación 'sigmoid' y 50 entradas.
- Una capa con la función de activación 'sigmoid' y 30 entradas.
- Una capa con la función de activación 'sigmoid' y 12 entradas.
- Una capa con la función de activación 'sigmoid' y 7 entradas.
- Una capa de salida con la función de activación 'sigmoid'.

```
model = Sequential()  
model.add(Dense(50,activation='sigmoid'))  
model.add(Dense(30,activation='sigmoid'))  
model.add(Dense(12,activation='sigmoid'))  
model.add(Dense(7,activation='sigmoid'))  
model.add(Dense(1,activation='sigmoid'))  
model.compile(optimizer='adam',loss = 'binary_crossentropy',metrics=['accuracy'])
```

Figura 23: Tercera Prueba con el Algoritmo de Redes Neuronales.

- **Cuarta Prueba:**

- Modelo Sequential.
- Una capa con la función de activación 'sigmoid' y 50 entradas.
- Una capa con la función de activación 'sigmoid' y 40 entradas.
- Una capa con la función de activación 'sigmoid' y 30 entradas.
- Una capa con la función de activación 'sigmoid' y 17 entradas.
- Una capa de salida con la función de activación 'sigmoid'.

```
model = Sequential()  
model.add(Dense(50,activation='sigmoid'))  
model.add(Dense(40,activation='sigmoid'))  
model.add(Dense(30,activation='sigmoid'))  
model.add(Dense(17,activation='sigmoid'))  
model.add(Dense(1,activation='sigmoid'))  
model.compile(optimizer='adam',loss = 'binary_crossentropy',metrics=['accuracy'])
```

Figura 24: Cuarta Prueba con el Algoritmo de Redes Neuronales.

- **Algoritmo Final:**

- Modelo Sequential.
- Una capa con la función de activación 'sigmoid' y 70 entradas.
- Una capa con la función de activación 'sigmoid' y 50 entradas.
- Una capa con la función de activación 'sigmoid' y 40 entradas.
- Una capa con la función de activación 'sigmoid' y 20 entradas.
- Una capa de salida con la función de activación 'sigmoid'.

```
model = Sequential()  
model.add(Dense(70,activation='sigmoid'))  
model.add(Dense(50,activation='sigmoid'))  
model.add(Dense(40,activation='sigmoid'))  
model.add(Dense(20,activation='sigmoid'))  
model.add(Dense(1,activation='sigmoid'))  
model.compile(optimizer='adam',loss = 'binary_crossentropy',metrics=['accuracy'])
```

Figura 25: Resultado Final con el Algoritmo de Redes Neuronales.

Implementación del Algoritmo:

```
import time
inicio = time.time()
inputs = np.concatenate((X_train1, X_test1), axis=0)
targets = np.concatenate((y_train1, y_test1), axis=0)
kf = KFold(n_splits=5, shuffle=True)
fold_no = 1
acc_per_fold=[]
loss_per_fold=[]
best_acc=[]
aux=90

for train_index, test_index in kf.split(inputs,targets):
    model = Sequential()
    model.add(Dense(70,activation='sigmoid'))
    model.add(Dense(50,activation='sigmoid'))
    model.add(Dense(40,activation='sigmoid'))
    model.add(Dense(20,activation='sigmoid'))
    model.add(Dense(1,activation='sigmoid'))
    model.compile(optimizer='adam',loss = 'binary_crossentropy',metrics=['accuracy'])
```

Figura 26: Algoritmo de redes neuronales implementado.

```
modeloann=model.fit(inputs[train_index], targets[train_index],validation_data=(inputs[test_index],targets[test_index]),batch_size=250,epochs=25,verbose=1)
scores = model.evaluate(inputs[test_index], targets[test_index], verbose=0)
print(f'Score for fold {fold_no}: {model.metrics_names[0]} of {scores[0]}; {model.metrics_names[1]} of {scores[1]*100}%')
acc_per_fold.append(scores[1] * 100)
loss_per_fold.append(scores[0])
fold_no=fold_no+1

for i in acc_per_fold:
    ba=max(acc_per_fold)
    if(ba>aux):
        model_json = model.to_json()
        with open("model.json", "w") as json_file:
            json_file.write(model_json)
        model.save_weights(f"model{ba}.h5")
        print(f"Modelo Guardado for ACC: {ba} ")
        aux=ba
    else:
        print("Modelo no apto")

time.sleep(1)
fin = time.time()
print("Tiempo de Ejecución:", fin-inicio)
```

Figura 27: Generación de Curvas K-FOLD para los mejores modelos de redes neuronales que se obtengan.

```

# accuracy: (tp + tn) / (p + n)
accuracy = accuracy_score(targets[test_index],vd_preds)
print('Accuracy: %f' % accuracy)
# precision tp / (tp + fp)
precision = precision_score(targets[test_index],vd_preds)
print('Precision: %f' % precision)
# f1: 2 tp / (2 tp + fp + fn)
f1 = f1_score(targets[test_index],vd_preds)
print('F1 score: %f' % f1)
#matriz de confusión
print('Matriz de Confusión:')
confusion_matrix(targets[test_index],vd_preds)

```

Figura 28: Evaluación de rendimiento para Redes Neuronales.

Dibujo de la red neuronal implementada:



Figura 29: Red Neuronal Implementada.

Matriz de confusión Valencia:

473825	103128
228538	348829

Tabla 9: Matriz de Confusión con los resultados del Algoritmo Redes Neuronales para la variable Valencia.

Matriz de confusión Excitación:

287464	186941
93583	381324

Tabla 10: Matriz de Confusión con los resultados del Algoritmo Redes Neuronales para la variable Excitación.

3.4.2 SVM

Se utilizó los denominados SVC (Support Vector Classifier), que son algoritmos clasificadores de vectores de soporte, este tipo de SVM fue implementado para el análisis de valencia-excitación, porque su objetivo principal es seleccionar un hiperplano de separación que equidiste de los ejemplos más cercanos de cada clase, para conseguir un margen máximo a cada lado del hiperplano propuesto, lo cual fue necesario para las diferentes clases que se tienen por cada una de las variables de análisis: HV, LV, HA, LA respectivamente.

Características del algoritmo:

- Kernel sigmoid.

Implementación del Algoritmo:

```
import time
inicio = time.time()

svm = SVC(kernel='sigmoid', verbose=True)
svm.fit(X_train1,y_train1)

time.sleep(1)
fin = time.time()
print("Tiempo de Ejecución:", fin-inicio)

svmPredict=svm.predict(X_test1)
```

Figura 30: Algoritmo SVC implementado.

```
# accuracy: (tp + tn) / (p + n)
accuracy = accuracy_score(y_test1,svmPredict)
print('Accuracy: %f' % accuracy)
# precision tp / (tp + fp)
precision = precision_score(y_test1,svmPredict)
print('Precision: %f' % precision)
# f1: 2 tp / (2 tp + fp + fn)
f1 = f1_score(y_test1,svmPredict)
print('F1 score: %f' % f1)
#matriz de confusión
print('Matriz de Confusión:')
confusion_matrix(y_test1,svmPredict)
```

Figura 31: Evaluación de rendimiento para SVM.

Esquema del Algoritmo:




Figura 32: Esquema del algoritmo SVM [20].

3.4.3 Random Forest

Random Forest, es un algoritmo de machine learning que trabaja como lo hacen los denominados árboles de decisión, los cuales clasifican los datos de un modelo realizando una serie de particiones binarias, permitiendo realizar predicciones en base a esta clasificación, fue implementado para el análisis de nuestras variables de valencia y excitación porque permite plantear modelo más fiable y preciso evitando problemas como el overfitting que se tuvieron con el algoritmo de redes neuronales.

Características del algoritmo:

- El número de árboles de decisión: 100
- random_state: 0

Implementación del algoritmo:

```
import time
inicio = time.time()

rR = RandomForestRegressor(n_estimators=100,random_state=0)
rR.fit(X_train1,y_train1)

time.sleep(1)
fin = time.time()
print("Tiempo de Ejecución:", fin-inicio)
```

Figura 33: Algoritmo Random Forest implementado.

```
# accuracy: (tp + tn) / (p + n)
accuracy = accuracy_score(y_test1,y_pred)
print('Accuracy: %f' % accuracy)
# precision tp / (tp + fp)
precision = precision_score(y_test1,y_pred,average='micro')
print('Precision: %f' % precision)
# f1: 2 tp / (2 tp + fp + fn)
f1 = f1_score(y_test1,y_pred,average='micro')
print('F1 score: %f' % f1)
#matriz de confusión
print('Matriz de Confusión:')
confusion_matrix(y_test1,y_pred)
```

Figura 34: Evaluación de rendimiento para Random Forest.

3.5 Evaluación de Resultados

Algoritmo	Accuracy	Precision	F1	Tiempo de ejecución
Redes Neuronales	71%	77%	67%	7948.48 segundos
SVM	indeterminado	indeterminado	indeterminado	36000.04 segundos
Random Forest	ambiguo	ambiguo	Ambiguo	447.57 segundos

Tabla 11: Resultados obtenidos por cada algoritmo implementado al evaluar la variable Valencia.

Algoritmo	Accuracy	Precision	F1	Tiempo de ejecución
Redes neuronales	70%	67%	73%	6708.33 segundos
SVM	indeterminado	indeterminado	indeterminado	36500 segundos
Random Forest	ambiguo	ambiguo	Ambiguo	371.04 segundos

Tabla 12: Resultados obtenidos por cada algoritmo implementado al evaluar la variable Excitación.

Definiciones:

Indeterminado: el algoritmo no pudo retornar un resultado cuantitativo, dado que luego de un procesamiento de 10 horas, no se pudo completar el análisis en tiempo real y finalizó forzosamente su ejecución.

Ambiguo: existe falta de información en los resultados del algoritmo para producir una clasificación específica.




Figura 35: Gráfica de las métricas de evaluación de cada algoritmo al evaluar la variable Valencia.




Figura 36: Gráfica de las métricas de evaluación de cada algoritmo al evaluar la variable Excitación.




Figura 37: Tiempos ejecución de cada algoritmo en segundos al evaluar la variable Valencia.




Figura 38: Tiempos ejecución de cada algoritmo en segundos al evaluar la variable Excitación.

Capítulo IV: Conclusiones y Recomendaciones

- La generación de un dataset con millones de datos tiene la ventaja de poder predecir variables de una forma óptima, dado que los algoritmos pueden procesar mejor la información evitando errores y mejorando los resultados de las métricas de evaluación.
- El aporte principal de la realización de este trabajo es la generación de un dataset que va a ser de disponibilidad pública para que se pueda experimentar y avanzar en el campo del análisis de señales EEG y su interacción con interfaces Cerebro-Computador. Se adjunta el enlace de acceso al mismo: https://epnecuador-my.sharepoint.com/:f/g/personal/edison_cabrera_epn_edu_ec/EpynDafgRvVBoXHNRAfyE-4BLppzgHVFB0Z18DXvLUb75g?e=D7AWVg
- Fue necesario realizar un preprocesamiento previo de los datos, dado que la herramienta OpenBCI, devuelve resultados en formato de texto plano y se hizo la conversión respectiva de los mismos a formato Excel y CSV, respectivamente, para poder analizarlos con algoritmos de aprendizaje de máquina.
- Se aplicaron 3 modelos para este proyecto: ANN, SVM y Random Forest, para poder hacer comparativas asertivas, debido a que estos algoritmos son los más utilizados en investigaciones relacionadas con análisis de señales EEG, así como para realizar predicción de emociones.
- Al aplicar Redes Neuronales, obtuvimos resultados de entre 70 % y 80 % en las métricas de evaluación implementadas: Accuracy , Precision y F1 siendo así el mejor modelo que se adaptó a este trabajo.
- Con Curvas ROC, incluidas en los anexos (D.3) y (E.3), fue posible la comprobación del modelo ANN y donde se observan resultados alentadores del 70 % y 80 % acercándose bastante a los resultados observados en ANN, con lo cual se concluye que ANN es la mejor alternativa para la predicción del nivel de valencia y excitación de una persona.

- Los algoritmos menos eficientes en el presente trabajo fueron SVM y Random Forest, dado que no se adaptaron correctamente al dataset implementado, a pesar de las múltiples pruebas realizadas no fue posible su correcta ejecución.
- SVM, es un algoritmo eficiente para datasets con pocos datos, pero cuando se tienen dataset con una cantidad de información bastante considerable, se demora demasiado su ejecución a tal punto de que no es posible que logre ejecutarse completa y necesita de un tiempo de procesamiento bastante largo.
- Se recomienda siempre revisar que el funcionamiento de los algoritmos, así como sus parámetros sean los adecuados, para evitar errores en los resultados de las métricas de evaluación.
- Es importante que se realiza un previo procesamiento de los datos, antes de disponer del dataset para su uso con algoritmos de aprendizaje de máquina, dado que esto ayuda a que los datos estén debidamente depurados, con lo cual ahorramos tiempo en el apartado práctico del trabajo.

Referencias

- [1] E. A. T. M. H.-Á. a. S. G. Y. Edgar P. Torres, «EEG-Based BCI Emotion Recognition: A Survey,» Quito, 2020.
- [2] M. R. B. M. MSc. Carlos Barros Bastida, «LOS MEDIOS AUDIOVISUALES Y SU INFLUENCIA EN LA EDUCACIÓN DESDE ALTERNATIVAS DE ANÁLISIS,» Guayaquil, 2015.
- [3] M. d. R. R. Sanclemente, 18 diciembre 2015. [En línea]. Available: https://e-archivo.uc3m.es/bitstream/handle/10016/22498/rosario_rivera_tesis.pdf. [Último acceso: 25 mayo 2022].
- [4] M. P. M. & S. H. Kalashami, «EEG Feature Extraction and Data Augmentation in Emotion Recognition. Computational Intelligence and Neuroscience,» Tehran, 2022.
- [5] M. Hossain y G. Muhammad, «Emotion recognition using deep learning approach from audio–visual emotional big data,» 2019.
- [6] L. Q. R. L. Z. H. J. X. Y. L. F. W. a. J. P. Zina Li, «Enhancing BCI-Based Emotion Recognition Using an Improved Particle Swarm Optimization for Feature Selection,» 2020.
- [7] E. A. T. M. H.-Á. a. S. G. Y. Edgar P. Torres, «EEG-Based BCI Emotion Recognition: A Survey,» Quito, 2020.
- [8] B. P. a. W. Zheng, «Emotion Recognition Based on EEG Using Generative Adversarial Nets and Convolutional Neural Network,» 2021.
- [9] A. Momenzhad, «Matching pursuit algorithm for enhancing EEG signal quality and increasing the accuracy and efficiency of emotion recognition,» 2019.
- [10] «MANUAL SISTEMA 10/20 INTERNACIONAL».
- [11] M. R. P. D. V. a. S. M. K.-F. Maureen Murdoch, «The Psychological Risk of Minimal Risk Activities: A Pre- and Posttest Study Using the Self-Assessment Manikin,» 2019.
- [12] W. R. K. T. X. Sari Pekkala Kerr, «Personality Traits of Entrepreneurs: A Review of Recent Literature,» 2017.
- [13] S. J. Dattagupta, «A PERFORMANCE COMPARISON OF OVERSAMPLING METHODS FOR DATA GENERATION IN IMBALANCED LEARNING TASKS,» Lisboa, 2017.
- [14] B. & Z. W. Pan, « Emotion Recognition Based on EEG Using Generative,» 2021.
- [15] M. A, «Matching pursuit algorithm for enhancing EEG signal quality and increasing the accuracy and efficiency of emotion recognition. Biomedical Engineering / Biomedizinische Technik,» 2020.

- [16] I. B. a. K. J. Kontoleon, «Performance Evaluation of Artificial Neural Networks (ANN) Predicting Heat Transfer through Masonry Walls Exposed to Fire,» Francesco Salamone, Thessaloniki, 2021.
- [17] D. R. B. B. y. D. E. C. Priego, «SUPPORT VECTOR REGRESSION: PROPIEDADES Y APLICACIONES,» Sevilla, 2016.
- [18] M. G. R. d. León, «Análisis de Sensibilidad Mediante Random Forest,» Madrid, 2018.
- [19] OpenBCI, «OpenBCI,» OpenBCI, [En línea]. Available: <https://openbci.com/>. [Último acceso: 20 enero 2022].
- [20] 16 diciembre 2020. [En línea]. Available: <https://dataaspirant.com/svm-kernels/>. [Último acceso: 2 julio 2022].
- [21] L. Carvajal, Metodología de la Investigación Científica. Curso general y aplicado, 28 ed., Santiago de Cali: U.S.C., 2006, p. 139.

Anexos

ANEXO A: Dataset Inicial.




Figura 39: Histograma del Dataset Inicial Desbalanceado.

ANEXO B: Dataset Balanceado.




Figura 40: Histograma del Dataset Balanceado para la Variable Valencia.




Figura 41: Histograma del Dataset Balanceado para la Variable Excitación.

ANEXO C: Código Implementado.

```
import pandas as pd
import seaborn as sns
import matplotlib.pyplot as plt
from matplotlib import pyplot
import numpy as np
import seaborn as sns
from sklearn.model_selection import train_test_split
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from sklearn.metrics import
mean_squared_error, mean_absolute_error, explained_variance_score
from sklearn.metrics import classification_report, confusion_matrix
from imblearn.over_sampling import SMOTE
from sklearn.metrics import accuracy_score
from sklearn.model_selection import cross_validate
from sklearn.preprocessing import StandardScaler, LabelEncoder
from sklearn.metrics import roc_curve
from sklearn.metrics import roc_auc_score
from sklearn.model_selection import KFold
from sklearn.model_selection import StratifiedKFold
from sklearn.model_selection import GroupKFold
from sklearn.svm import SVC
from sklearn.neural_network import MLPClassifier
from sklearn.svm import LinearSVC
from sklearn.impute import SimpleImputer
from sklearn.ensemble import RandomForestRegressor
from sklearn.neighbors import KNeighborsClassifier
from sklearn.linear_model import LinearRegression
from sklearn.metrics import r2_score
from sklearn.metrics import precision_score
from sklearn.metrics import recall_score
from sklearn.metrics import f1_score

"""Importamos el dataset a ser utilizado en el proyecto"""

df=pd.read_csv('/content/drive/MyDrive/Colab
Notebooks/Tesis/Dataset_Completo.csv')

""" Hacemos uso de las funciones head y tail saber si los datos están
ordenados por algún criterio en específico"""

df.head()
```

```

df.tail()

"""Verificamos si existen valores nulos
"""

df.isnull().sum()

"""Mostramos la información de nuestro dataset"""

df.info()

"""Utilizamos Pearson para observar el índice de coorelación que existe
entre las variables de nuestro dataset"""

sns.set(style='whitegrid', font_scale=1)
plt.figure(figsize=(15,15))
plt.title('Pearson')
sns.heatmap(df.corr(), vmax=0.85,
square=True,cmap='GnBu',linecolor='b',annot=True,annot_kws={"size":9})

df.hist(figsize=(15,15))

"""Eliminamos las variables que no nos están aportando nada, basándonos en
la correlación de Pearson antes mostrada"""

x_aux = df.iloc[:,0:18]
x_aux = x_aux.drop(['indice'],axis=1)
x_aux = x_aux.drop(['s1'],axis=1)
x_aux = x_aux.drop(['s2'],axis=1)
x_aux = x_aux.drop(['s3'],axis=1)
x_aux = x_aux.drop(['const'],axis=1)
X =x_aux

"""RESUMEN"""

valence = df.iloc[:,14]

valence

valence.value_counts()

arousal = df.iloc[:,15]

arousal

arousal.value_counts()

```

```

y = df.iloc[:,16]

y

y.value_counts()

y.isnull().sum()

"""Eliminamos la variable ea correspondiendo a la categorización de
exitación, dado que es la que queremos predecir"""

#X = X.drop(['ea'],axis=1)

"""Eliminamos la variable ev correspondiendo a la categorización de
valencia, dado que es la que queremos predecir"""

X = X.drop(['ev'],axis=1)

X.info()

"""Obtenemos el tiempo de muestro para el dataset"""

X["time"] = X["time"].astype("str")
print(X["time"])

X['minutos'] = X['time'].str.extract(r'(:\d+)').astype('str')

X['minutos'] = X['minutos'].str.extract(r'(\d+)').astype('float')

X['minutos']

freq = X.groupby(['minutos']).size()
print(freq)

X['time_muestreo']=freq

X = X.drop(['time'],axis=1)
X = X.drop(['minutos'],axis=1)

X.info()

"""Eliminamos el Tiempo de Muestreo"""

X = X.drop(['time_muestreo'],axis=1)

X.isnull().sum()

"""Aplicamos get_dummies para los valores ev"""

```



```

X = pd.get_dummies(X)

X

"""Preparación de la Variable Valence
"""

y

y.shape

y.value_counts()

"""Realizamos un labelencoder para los valores de y"""

lenc = LabelEncoder()
y = lenc.fit_transform(y)

y

"""Balanceamos los Datos que tenemos para este proyecto

BALANCEO SMOTE
"""

sm = SMOTE(random_state=0)
X_sm, y_sm = sm.fit_resample(X,y)
pd.Series(y_sm).value_counts()

X_sm.hist(figsize=(15,15))

"""Definimos nuestros Test y Train para nuestros modelos"""

def trainTestSplit(X,y):
    X_train,X_test,y_train,y_test=train_test_split(X,y,test_size=0.3)
    return X_train,X_test,y_train,y_test

"""Desbalanceado"""

#X_train1,X_test1,y_train1,y_test1 = trainTestSplit(X_imputer,y)

"""Balanceado"""

X_train1,X_test1,y_train1,y_test1 = trainTestSplit(X_sm,y_sm)

"""Aplicación de Modelos

```

ANN

5 Capas de redes neuronales

5 sigmode 70 50 40 20 1

"""

```
import time
inicio = time.time()
inputs = np.concatenate((X_train1, X_test1), axis=0)
targets = np.concatenate((y_train1, y_test1), axis=0)
kf = KFold(n_splits=5, shuffle=True)
fold_no = 1
acc_per_fold=[]
loss_per_fold=[]
best_acc=[]
aux=90

for train_index, test_index in kf.split(inputs,targets):
    model = Sequential()
    model.add(Dense(70,activation='sigmoid'))
    model.add(Dense(50,activation='sigmoid'))
    model.add(Dense(40,activation='sigmoid'))
    model.add(Dense(20,activation='sigmoid'))
    model.add(Dense(1,activation='sigmoid'))
    model.compile(optimizer='adam',loss =
'binary_crossentropy',metrics=['accuracy'])

    modeloann=model.fit(inputs[train_index],
targets[train_index],validation_data=(inputs[test_index],targets[test_index]
),batch_size=250,epochs=25,verbose=1)
    scores = model.evaluate(inputs[test_index], targets[test_index],
verbose=0)
    print(f'Score for fold {fold_no}: {model.metrics_names[0]} of {scores[0]};
{model.metrics_names[1]} of {scores[1]*100}%')
    acc_per_fold.append(scores[1] * 100)
    loss_per_fold.append(scores[0])
    fold_no=fold_no+1

for i in acc_per_fold:
    ba=max(acc_per_fold)
    if(ba>aux):
        model_json = model.to_json()
        with open("model.json", "w") as json_file:
            json_file.write(model_json)
        model.save_weights(f"model{ba}.h5")
        print(f"Modelo Guardado for ACC: {ba} ")
        aux=ba
```

```

else:
    print("Modelo no apto")

time.sleep(1)
fin = time.time()
print("Tiempo de Ejecución:", fin-inicio)

prediccion = model.predict(inputs[test_index])
vd_preds = (prediccion > 0.5)

prediccion

vd_preds

# accuracy: (tp + tn) / (p + n)
accuracy = accuracy_score(targets[test_index],vd_preds)
print('Accuracy: %f' % accuracy)
# precision tp / (tp + fp)
precision = precision_score(targets[test_index],vd_preds)
print('Precision: %f' % precision)
# f1: 2 tp / (2 tp + fp + fn)
f1 = f1_score(targets[test_index],vd_preds)
print('F1 score: %f' % f1)
#matriz de confusión
print('Matriz de Confusión:')
confusion_matrix(targets[test_index],vd_preds)

"""CURVAS ROC

Seleccionamos el Modelo que mejor que se adaptó a las características del
proyecto y a su objetivo

ANN
"""

ns_probs = [0 for _ in range(len(targets[test_index]))]

predict_prob = model.predict(inputs[test_index])

lr_probs = predict_prob[:,0]

ns_auc = roc_auc_score(targets[test_index], ns_probs)
lr_auc = roc_auc_score(targets[test_index], lr_probs)

print('Sin entrenar: ROC AUC=%.3f' % (ns_auc))
print('ANN: ROC AUC=%.3f' % (lr_auc))

ns_fpr, ns_tpr, _ = roc_curve(targets[test_index], ns_probs)

```

```

lr_fpr, lr_tpr, _ = roc_curve(targets[test_index], lr_probs)

pyplot.plot(ns_fpr, ns_tpr, linestyle='--', label='Sin entrenar')
pyplot.plot(lr_fpr, lr_tpr, marker='.', label='ANN')
pyplot.xlabel('Tasa de Falsos Positivos')
pyplot.ylabel('Tasa de Verdaderos Positivos')
pyplot.legend()
pyplot.show()

"""SVM

Kernel: sigmoid
"""

import time
inicio = time.time()

svm = SVC(kernel='sigmoid', verbose=True)
svm.fit(X_train1,y_train1)

time.sleep(1)
fin = time.time()
print("Tiempo de Ejecución:", fin-inicio)

svmPredict=svm.predict(X_test1)

# accuracy: (tp + tn) / (p + n)
accuracy = accuracy_score(y_test1,svmPredict)
print('Accuracy: %f' % accuracy)
# precision tp / (tp + fp)
precision = precision_score(y_test1,svmPredict)
print('Precision: %f' % precision)
# f1: 2 tp / (2 tp + fp + fn)
f1 = f1_score(y_test1,svmPredict)
print('F1 score: %f' % f1)
#matriz de confusión
print('Matriz de Confusión:')
confusion_matrix(y_test1,svmPredict)

"""Random Forest"""

import time
inicio = time.time()

rR = RandomForestRegressor(n_estimators=100,random_state=0)
rR.fit(X_train1,y_train1)
time.sleep(1)
fin = time.time()

```

```

print("Tiempo de Ejecución:", fin-inicio)

y_pred = rR.predict(X_test1)

y_pred

# accuracy: (tp + tn) / (p + n)
accuracy = accuracy_score(y_test1,y_pred)
print('Accuracy: %f' % accuracy)
# precision tp / (tp + fp)
precision = precision_score(y_test1,y_pred,average='micro')
print('Precision: %f' % precision)
# f1: 2 tp / (2 tp + fp + fn)
f1 = f1_score(y_test1,y_pred,average='micro')
print('F1 score: %f' % f1)
#matriz de confusión
print('Matriz de Confusión:')
confusion_matrix(y_test1,y_pred)

"""Árboles de Decisión"""

from sklearn import tree
import time
inicio = time.time()

clftree = tree.DecisionTreeClassifier(max_depth = 1000)
clftree.fit(X_train1, y_train1)

time.sleep(1)
fin = time.time()
print("Tiempo de Ejecución:", fin-inicio)

y_prd = clftree.predict(X_test1)

y_prd

# accuracy: (tp + tn) / (p + n)
accuracy = accuracy_score(y_test1,y_prd)
print('Accuracy: %f' % accuracy)
# precision tp / (tp + fp)
precision = precision_score(y_test1,y_prd)
print('Precision: %f' % precision)
# f1: 2 tp / (2 tp + fp + fn)
f1 = f1_score(y_test1,y_prd)
print('F1 score: %f' % f1)
#matriz de confusión
print('Matriz de Confusión:')
confusion_matrix(y_test1,y_prd)

```

ANEXO D: Análisis de la Variable Valencia.

Anexo D.1 Algoritmo 1 Redes Neuronales:

```
Accuracy: 0.712674
Precision: 0.771819
F1 score: 0.677783
Matriz de Confusión:
array([[473825, 103128],
       [228538, 348829]])
```

Figura 42: Resultados Métricas de Evaluación Redes Neuronales para la variable Valencia.

Anexo D.2 Algoritmo 3 Random Forest:

```
Accuracy: 1.000000
Precision: 1.000000
F1 score: 1.000000
Matriz de Confusión:
array([[866465,    0],
       [    0, 865016]])
```

Figura 43: Resultados Métricas de Evaluación Random Forest para la variable Valencia.

Anexo D.3 Redes Neuronales usando Curvas ROC:




Figura 44: Curvas ROC aplicado al algoritmo de Redes Neuronales para la variable Valencia.

ANEXO E: Análisis de la Variable Excitación.

Anexo E.1 Algoritmo 1 Redes Neuronales:

```
Accuracy: 0.704498
Precision: 0.671032
F1 score: 0.731086
Matriz de Confusión:
array([[287464, 186941],
       [ 93583, 381324]])
```

Figura 45: Resultados Métricas de Evaluación Redes Neuronales para la variable Excitación.

Anexo E.2 Algoritmo 3 Random Forest:

```
Accuracy: 1.000000  
Precision: 1.000000  
F1 score: 1.000000  
Matriz de Confusión:  
array([[712463,    0],  
       [    0, 711507]])
```

Figura 46: Resultados Métricas de Evaluación Random Forest para la variable Excitación.

Anexo E.3 Redes Neuronales usando Curvas ROC:

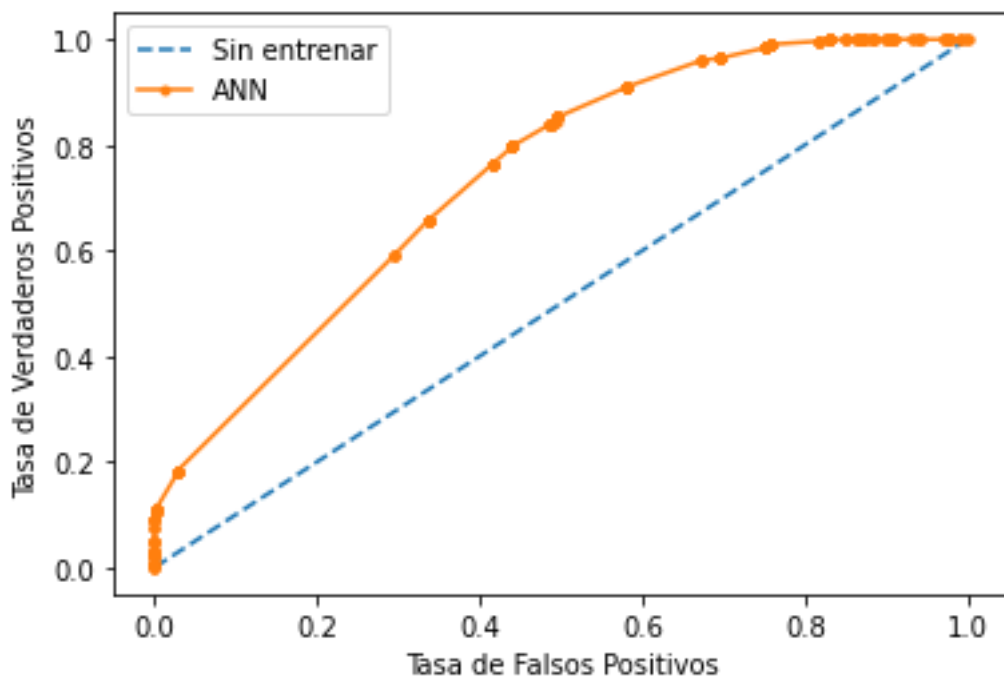


Figura 47: Curvas ROC aplicado al algoritmo de Redes Neuronales para la variable Excitación.

ANEXO F: Permiso de los participantes.



ESCUELA POLITÉCNICA NACIONAL
FACULTAD DE INGENIERÍA EN SISTEMAS
INGENIERÍA EN COMPUTACIÓN



TRABAJO DE INVESTIGACIÓN ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Edad: Género:

Confirmo:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / resultados de señales cerebrales obtenidas con dispositivo BCI, serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad aplicable.

Doy mi consentimiento para participar en este experimento:

Firma:

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de

El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SI / NO / no aplica

Es posible que se me acerquen para un futuro estudio neurocientífico.

SI / NO



TRABAJO DE INVESTIGACIÓN
ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Luis Ernesto Almeida Zambrano Edad: 23 Género: M

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / resultados de señales cerebrales obtenidas con dispositivo BCI, serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad aplicable.

Doy mi consentimiento para participar en este experimento:

Firma: 

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de
El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SI / NO / no aplica

Es posible que se me acerquen para un futuro estudio neurocientífico.

SI / NO



ESCUELA POLITÉCNICA NACIONAL
FACULTAD DE INGENIERÍA EN SISTEMAS
INGENIERÍA EN COMPUTACIÓN



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Jenny Verdezoto Edad: 44 Género: Femenino

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / resultados de señales cerebrales obtenidas con dispositivo BCI, serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad aplicable.

Doy mi consentimiento para participar en este experimento:

Firma: Jenny Verdezoto

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de
El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SI / NO / no aplica

Es posible que se me acerquen para un futuro estudio neurocientífico.

SI / NO



ESCUELA POLITÉCNICA NACIONAL
FACULTAD DE INGENIERÍA EN SISTEMAS
INGENIERÍA EN COMPUTACIÓN



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: César Cabrera Edad: 38 Género: Masculino

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / resultados de señales cerebrales obtenidas con dispositivo BCI, serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad aplicable.

Doy mi consentimiento para participar en este experimento:

Firma: César Cabrera

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de
El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SI / NO / no aplica

Es posible que se me acerquen para un futuro estudio neurocientífico.

SI / NO



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Paulo Vinicio Cabrera Altamirano Edad: 36 Género: M

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / resultados de señales cerebrales obtenidas con dispositivo BCI, serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad aplicable.

Doy mi consentimiento para participar en este experimento:

Firma: 

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SI / NO / no aplica

Es posible que se me acerquen para un futuro estudio neurocientífico.

SI / NO



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Martha Gladys Cruz Godoy Edad: 40 Género: F

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / resultados de señales cerebrales obtenidas con dispositivo BCI, serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad aplicable.

Doy mi consentimiento para participar en este experimento:

Firma: 

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SI / NO / no aplica

Es posible que se me acerquen para un futuro estudio neurocientífico.

SI / NO



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Gabriela Coetz Edad: 38 Género: Femenino

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / material corporal serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad europea aplicable.
- Se solicitará mi consentimiento cada vez que participe en un nuevo experimento.

Doy mi consentimiento para participar en este experimento:

Firma: [Firma]

Fecha y lugar: Quito, 9/04/2021

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SÍ NO / no aplica *

Es posible que se me acerquen para un futuro estudio neurocientífico.

SÍ NO*



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Luis David Suárez Vinueza Edad: 22 Género: Masculino

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / resultados de señales cerebrales obtenidas con dispositivo BCI, serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad aplicable.

Doy mi consentimiento para participar en este experimento:

Firma:

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SI / NO / no aplica

Es posible que se me acerquen para un futuro estudio neurocientífico.

SI / NO



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Paola Morales Espinosa Edad: 50 Género: Femenino

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / material corporal serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad europea aplicable.
- Se solicitará mi consentimiento cada vez que participe en un nuevo experimento.

Doy mi consentimiento para participar en este experimento:

Firma: Paola de Vique

Fecha y lugar: Quito, 09 Abril / 2021

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SÍ NO / no aplica *

Es posible que se me acerquen para un futuro estudio neurocientífico.

SÍ NO*



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: EDWIN R. VINOZZA ALVAREZ Edad: 51 años Género: MASCULINO

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / material corporal serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad europea aplicable.
- Se solicitará mi consentimiento cada vez que participe en un nuevo experimento.

Doy mi consentimiento para participar en este experimento:

Firma: 

Fecha y lugar: Quito A 09/08/2021

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

NO / no aplica *

Es posible que se me acerquen para un futuro estudio neurocientífico.

SÍ NO*



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Eric K. Andres Meza Cancino..... Edad: 23..... Género: Masculino

Confirmo:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / material corporal serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad europea aplicable.
- Se solicitará mi consentimiento cada vez que participe en un nuevo experimento.

Doy mi consentimiento para participar en este experimento:

Firma: .....

Fecha y lugar: Quito, 09/04/21.....

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SÍ NO / no aplica *

Es posible que se me acerquen para un futuro estudio neurocientífico.

SÍ NO*



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Jesús César Calero Córdova Edad: 57 Género: Masculino

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / resultados de señales cerebrales obtenidas con dispositivo BCI, serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad aplicable.

Doy mi consentimiento para participar en este experimento:

Firma: Jesús C. Calero P.

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SI / NO / no aplica

Es posible que se me acerquen para un futuro estudio neurocientífico.

SI / NO



TRABAJO DE INVESTIGACIÓN

ANÁLISIS DE SEÑALES EEG

Autorización Para Obtener y Usar Datos EEG

Nombre: Glady Páez Cabezas Pabón Edad: 53 Género: F

Confirmando:

- Fui informado satisfactoriamente sobre el estudio en cuestión.
- He tenido la oportunidad de plantear preguntas sobre el estudio y que estas preguntas han sido respondidas satisfactoriamente.
- He considerado cuidadosamente mi participación en el experimento.
- Participo por mi propia voluntad.

Estoy de acuerdo que:

- Mis datos / resultados de señales cerebrales obtenidas con dispositivo BCI, serán recopilados y utilizados con fines de investigación.
- Para fines de estudio se pueden realizar grabaciones de audio y / o video.
- Más allá del alcance de este estudio: mis datos experimentales anónimos se compartirán con otros investigadores o grupos de investigación.

Entiendo que:

- Tengo derecho a retirarme del experimento en cualquier momento sin tener que dar una razón.
- Tengo derecho a solicitar la eliminación de mis datos experimentales hasta 1 mes después de la participación.
- Mis datos estarán protegidos de acuerdo con la ley de privacidad aplicable.

Doy mi consentimiento para participar en este experimento:

Firma: Glady Páez Cabezas Pabón

Acepto que, con fines científicos, recopilamos posibles grabaciones de foto / video / audios identificables más allá de El alcance de este estudio se compartirá con otros investigadores o grupos de investigación.

SI / NO / no aplica

Es posible que se me acerquen para un futuro estudio neurocientífico.

SI / NO