

UNIVERSIDAD INTERNACIONAL SEK

DIGITAL SCHOOL

Trabajo de fin de carrera titulado:

Modelo de clasificación de señales EEG usando Random Forest

Realizado por:

Ricardo Fabián Vásquez Mena

Director del proyecto:

PhD. Diego Fernando Riofrío Luzcando

Como requisito para la obtención del título de

MAGISTER EN SISTEMAS DE INFORMACION MENCION EN DATA SCIENCE

Quito, agosto 2021

DECLARACION JURAMENTADA

Yo, **RICARDO FABIAN VASQUEZ MENA**, con cédula de identidad **1803735990**, declaro bajo juramento que el trabajo aquí desarrollado es de mi autoría, que no ha sido previamente presentado para ningún grado a calificación profesional; y, que ha consultado las referencias bibliográficas que se incluyen en este documento.

A través de la presente declaración, cedo mis derechos de propiedad intelectual correspondientes a este trabajo, a la UNIVERSIDAD INTERNACIONAL SEK, según lo establecido por la Ley de Propiedad Intelectual, por su reglamento y por la normativa institucional vigente.

Ricardo Fabián Vásquez Mena

C.C: 1803735990

DECLARATORIA

El presente trabajo de investigación titulado:

“MODELO DE CLASIFICACIÓN DE SEÑALES EEG USANDO RANDOM FOREST”

Realizado por:

RICARDO FABIAN VASQUEZ MENA

Como requisito para la Obtención del Título de:

MASTER EN SISTEMAS DE INFORMACION MENCION EN DATA SCIENCE

Ha sido dirigido por el profesor

PhD. DIEGO FERNANDO RIOFRÍO LUZCANDO

Quien considera que constituye un trabajo original de su autor

PhD. Diego Fernando Riofrío Luzcando,

DIRECTOR

PROFESORES INFORMANTES

Después de revisar el trabajo presentado, lo ha calificado como apto para su defensa oral ante el tribunal examinador.

PhD. Joe Carrión Jumbo

PhD. César Guevara Maldonado

Quito, agosto 2021

DEDICATORIA

Quiero dedicar este trabajo a mi esposa Angeles, a mis padres, Ricardo y Dolly, a mis hermanas, Adriana y Tatiana, a mi sobrino Iker y a mi primo hermano Mateo, quienes permanentemente están incondicionalmente apoyándome en los buenos y malos momentos guiando cada paso que doy. Gracias a ustedes y por ustedes he cumplido muchas metas y se vienen muchas más.

AGRADECIMIENTO

Agradezco a toda mi familia por el apoyo brindado, especialmente a mis padres que han sido inspiración de superación.

Un agradecimiento también a la Universidad Internacional SEK y a mi tutor el PhD. Diego Riofrío que me ha guiado con sus conocimientos durante este año de estudio, a mis docentes y compañeros que han compartido su experiencia que sin duda me ayudarán en mi vida laboral y personal.

Debo agradecer de manera especial a la empresa CTH que me permitió iniciar con esta maestría y a mis amigos que colaboraron en esta época difícil de pandemia para la realización del estudio.

ÍNDICE GENERAL

CAPÍTULO 1 INTRODUCCIÓN	13
1.1 Planteamiento del problema	13
1.2 Justificación.....	13
1.3 Objetivos	14
1.3.1 Objetivo General.....	14
1.3.2 Objetivos Específicos.....	14
1.4 Marco teórico	15
1.4.1 La Neurociencia.....	15
1.4.2 Neurotecnología.....	15
1.4.3 Interfaz Cerebro Computadora (BCI)	16
1.4.4 Electroencefalograma (EEG).....	17
1.4.5 EMOTIV	18
1.4.6 EMOTIV EPOC.....	18
1.4.7 Machine learning	19
1.4.8 Aprendizaje supervisado	20
1.4.9 Modelos de clasificación.....	20
1.4.10 Random Forest.....	21
CAPÍTULO 2 ESTADO DEL ARTE.....	23
2.1 Clasificación de señales EEG	24
2.2 Clasificación de señales EEG con modelos Random Forest	25
2.3 Clasificación de señales EEG utilizando Emotiv headset	25
CAPÍTULO 3 MÉTODO.....	27
3.1 Recopilación de información.....	28
3.2 Análisis de información.....	31
3.3 Validación.....	34
3.4 Clasificación de datos en tiempo real	36
CAPÍTULO 4 RESULTADOS.....	37
4.1 Validación cruzada del modelo completo	37
4.2 Validación cruzada de modelos agrupados	38

4.3 Validación de datos en tiempo real.....	39
CAPÍTULO 5 CONCLUSIONES Y TRABAJOS FUTUROS	43
BIBLIOGRAFÍA	45

ÍNDICE DE FIGURAS

Figura 1 Esquema BCI (Schalk et al., 2004).	16
Figura 2 Sistema Internacional 10-20 (Novo-Olivas et al., 2010).	17
Figura 3 Dispositivo Emotiv Epoc (EMOTIV, 2020).	18
Figura 4 Random Forest (Senthilnathan et al., 2020).	21
Figura 5 Diagrama general del proceso.	27
Figura 6 Resultados Esperados.	27
Figura 7 Proceso de recopilación de información.....	29
Figura 8 Diagrama de base de datos.	30
Figura 9 Modelo en Orange.	33
Figura 10 Análisis número de ramas (Rodrigo, 2020).	34
Figura 11 Señales recopiladas.....	35
Figura 12 Clasificación en tiempo real.	36
Figura 13 Sistema en tiempo real.....	39
Figura 14 Resultado experimento en tiempo real.	40
Figura 15 Resultados se señales en tiempo real.....	41
Figura 16 Comparativo de varianzas.	42

ÍNDICE DE TABLAS

Tabla 1 Señales de sensores.	28
Tabla 2 Datos outliers.	31
Tabla 3 Parámetros de modelos en Orange.....	32
Tabla 4 Matriz de confusión Orange.	33
Tabla 5 Precisión y datos AUC para diseño del modelo.	34
Tabla 6 Detalle de población.	37
Tabla 7 Datos generales del experimento.	37
Tabla 8 Resultados Experimento 1.	38
Tabla 9 Matriz de confusión de validación por clase.	39
Tabla 10 Observaciones en tiempo real.	40
Tabla 11 Comparación de varianzas.	41

RESUMEN

Las emociones son uno de los componentes importantes del ser humano, siendo así una parte valiosa para las actividades diarias como la interacción con las personas, toma de decisiones y aprendizaje. Por este motivo es importante detectar, reconocer e interpretar las emociones utilizando sistemas computacionales para mejorar la comunicación entre personas y máquinas con lo que se facilitaría la capacidad de las computadoras para entender la comunicación entre humanos.

En este estudio se propone la generación de un modelo que permita la clasificación de los sentimientos de las personas a partir de sus señales EEG, para esto se utilizó la interfaz cerebro-computadora EMOTIV EPOC, la cual permitió la recopilación de la información electroencefalográfica de 50 personas, a las cuales se les mostró recursos audiovisuales que ayudaron a provocar el estado de ánimo deseado. La información obtenida fue almacenada en una base de datos para la generación del modelo y el análisis de clasificación respectivo.

Para predecir los tres estados de ánimo (*alegre, triste y relajado*), de las señales de cualquier persona, se generó un modelo utilizando Random Forest, del que se obtuvieron resultados de precisión del 97.21% para alegría, 76% para relajación y 76% tristeza. Finalmente, se utilizó el modelo para la generación de un algoritmo de predicción en tiempo real de las tres emociones, el cual capta las señales EEG de la persona, ejecuta el algoritmo generado y visualiza el resultado en pantalla mediante imágenes representativas de cada emoción.

Palabras clave: Clasificación de sentimientos, Señales electroencefalográficas, Interfaz cerebro computadora, Emotiv epoc, Random forest.

ABSTRACT

Emotions are one of the components of human beings that are essentials in daily activities, like interaction with other people, decision making and learning. Due to what was exposed, it is important to detect, recognize and interpret emotions using computer systems to improve communication between people and machines, which facilitates to computers to understand communication between humans.

This study proposes the generation of a model which allows the classification of people's feelings, from their EEG signals. To accomplish this objective, the “brain-computer interface EMOTIV EPOC” was used, which allowed the collection of electroencephalographic information from 50 persons. The obtained information was stored in a database for the generation of a model with its respective classification analysis.

To predict three moods (happy, sad and relaxed) of the signals of any person, a model was generated using Random Forest, which got accuracies of 97.21% for joy, 76% for relaxation and 76% for sadness. Finally, the model was used to generate a real-time prediction algorithm for the three emotions, which captures the person's EEG signals, then executes the generated algorithm and displays the result on the screen through representative images of each emotion.

Keywords: Classification of feelings, Electroencephalographic signals, Brain-computer interface, Emotiv epoc, Random forest.

CAPÍTULO 1

INTRODUCCIÓN

1.1 Planteamiento del problema

En los últimos años las aplicaciones relacionadas con interfaces cerebro-computadora han sido uno de los tópicos más populares en informática, permite la comunicación entre el cerebro humano y una interfaz computacional mediante la captura e interpretación de señales electroencefalográficas EEG.

Este proceso ha ido evolucionando, evitando ser tan invasivo, pero igual de efectivo para la persona, reduciendo los costos de equipos médicos. Cabe mencionar que el uso de este tipo de análisis está limitado en su gran mayoría al área de salud y no se orientan a otras ramas como la educación o al uso de personas naturales (Arboleda et al., 2009; Ghodake & Shelke, 2016; Schalk et al., 2004; Viridi et al., 2017). Es por esto se plantea realizar un modelo Random Forest para la clasificación de señales EEG correspondientes a emociones de las personas.

1.2 Justificación

El creciente avance de la tecnología en los últimos años permite generar un proceso de clasificación de señales EEG mediante dispositivos BCI relativamente barato, no invasivo y amigable con el usuario que permita la recolección y posterior clasificación de las señales EEG del estado de ánimo de las personas mediante modelos Random Forest con el objetivo de reconocer sus emociones (Arboleda et al., 2009; Ghodake & Shelke, 2016; Viridi et al., 2017).

Entre las aplicaciones que se encuentran para la lectura y reconocimiento de señales EEG se puede mencionar la optimización del rendimiento y bienestar del cerebro de la persona, mediante aplicaciones que miden, almacenan y presentan estadísticas de las respuestas neuronales a las actividades diarias, lo que se traduce en el control del estrés y la mejora de concentración.

En el área educativa existen aplicaciones que visualizan en tiempo real la dinámica del cerebro humano lo que resulta de mucha utilidad para aprender sobre las principales áreas del cerebro, su

actividad y lo que representan las bandas de frecuencia para darle sentido a lo visualizado. (EMOTIV, 2020).

El campo de la domótica es otra aplicación importante en la cual se traducen las señales EEG en acciones físicas que permiten accionar dispositivos electrónicos del hogar tales como luces, alarmas, puertas, ventanas, cortinas entre otros (Edla et al., 2018; Ghodake & Shelke, 2016; Roy et al., 2020; Shukla & Chaurasiya, 2018).

1.3 Objetivos

1.3.1 Objetivo General

Desarrollar un modelo de clasificación de señales EEG, mediante un modelo Random Forest, con datos recogidos de personas entre 17 y 71 años, para la identificación automática de emociones de alegría tristeza y relajación.

1.3.2 Objetivos Específicos

- Diseñar un experimento mediante el uso del dispositivo EMOTIV EPOC, un sistema de interpretación de señales EEG y una base de datos, que permita la recolección y almacenamiento de la información.
- Recolectar las señales EEG de 50 personas mediante el experimento antes mencionado, que permita la obtención de datos necesarios para la generación del modelo.
- Realizar la limpieza de los datos recolectados mediante el análisis en herramientas de SQL Server y WEKA que permita el mejoramiento de la calidad de la información.
- Realizar el diseño del modelo, mediante la herramienta ORANGE, con los datos resultantes de los experimentos antes mencionados, que permita la selección del algoritmo que mejor se ajuste al estudio.
- Comprobar la precisión del modelo Random Forest, mediante la experimentación de varios escenarios, que permitan la detección de emociones de las personas.
- Analizar la precisión de cada emoción generando modelos agrupados de dos en dos para la detección de confusiones entre señales.
- Desarrollar un prototipo, utilizando C# y Python, que permita la clasificación de señales EEG en tiempo real.

1.4 Marco teórico

Tratar de comprender el cerebro humano ha generado que múltiples disciplinas converjan para llegar a este objetivo. Colaboraciones entre ramas como Anatomía, Psicología, Neurología, Tecnología o la Bioingeniería han dado como resultado una rama denominada Neurociencia que tiene como reto el entender el sistema nervioso y las conductas del ser humano (Kandel et al., 1996).

1.4.1 La Neurociencia

La Neurociencia consiste en el estudio del funcionamiento del sistema nervioso y su objetivo es entender cómo se genera la conducta e individualidad del ser humano a partir de la actividad celular (Kandel et al., 1996).

El estudio de la neurociencia se ha convertido en una investigación multidisciplinar, incluyendo áreas como la salud, tecnología, ciencias exactas, marketing, educación, entre otras. Esta naturaleza multidisciplinaria ha ido acuñando términos como neuromarketing, neurodidáctica y uno de los más importantes la neurotecnología, este último término proveniente de grandes avances en cuanto a hardware y software que dieron como resultado la neuroimagen, el electroencefalograma o la topografía óptica (Garcia, 2008; Kandel et al., 1996; Kaulino et al., 2008; Purves et al., 2007).

1.4.2 Neurotecnología

La neurotecnología se la puede definir como el conjunto de técnicas, procesos e instrumentos que permiten la comunicación entre un dispositivo tecnológico y el sistema nervioso (Müller & Rotter, 2017).

La Neurotecnología Nace del enfoque multidisciplinario de la neurociencia al combinarlo con hardware y software diseñado por diversos campos de estudio a la salud, la física, la informática, la estadística, entre otras. Esta colaboración entre profesionales ha logrado crear una compleja red de conocimiento con la que se ha creado diversas aplicaciones tecnológicas (Garcia, 2008), entre estas se pueden mencionar:

- Electrónica y párkinson, en el cual se introducen electrodos en el cerebro del paciente para aliviar su sintomatología. Es aplicada en casos en los que la farmacología ha dejado de ser efectiva.
- Resonancia magnética, que consiste en generar imágenes detalladas de la estructura cerebral permitiendo observar el área que se activa ante tareas concretas.
- Interfases cerebro computadora, donde se utilizan las señales eléctricas provenientes del cerebro para comunicarse e interactuar con dispositivos tecnológicos.

Sin duda las posibles aplicaciones de la neurotecnología se centran en mejorar la calidad de vida de las personas, desde implantes para la sordera o párkinson hasta lectores de señales cerebrales para aplicaciones educativas (Oweiss, 2010; Rudolph et al., 2002).

1.4.3 Interfaz Cerebro Computadora (BCI)

Se las puede definir como las interfaces que permiten comunicarse entre el sistema nervioso y un dispositivo tecnológico, esta comunicación se la realiza midiendo la actividad del sistema nervioso central y convirtiéndola en una salida que pueda ser interpretada naturalmente. Esquemáticamente una interfaz cerebro computadora se forma por tres sensores que envían o reciben señales del sistema nervioso, un sistema de procesamiento que interprete estas señales y devuelva una respuesta y un dispositivo capaz de realizar una acción (Figura 1) (Minguez, 2012; Schalk et al., 2004).




Figura 1 Esquema BCI (Schalk et al., 2004).

La intención general de la mayoría de BCI es operar un dispositivo o aplicación detectando pequeñas diferencias en las señales cerebrales, por lo tanto, casi todos los sistemas BCI incluyen un conjunto de tareas o capacidades donde un usuario puede influir cambiando aspectos de señales cerebrales seleccionadas o de respuestas evocadas.

Las BCI se utilizan en tareas del mundo real como la comunicación, el control del medio ambiente, o en el caso de personas con discapacidad, mover prótesis o sillas de ruedas. Estas aplicaciones

generalmente están desarrolladas gracias a técnicas y herramientas como la electromiografía (EMG), electrooculografía (EOG) o la electroencefalografía (EEG) (Arboleda et al., 2009; Moore, 2003).

1.4.4 Electroencefalograma (EEG).

El término “electroencefalograma” (EEG) fue acuñado por el neurólogo alemán Hans Berger en 1929, se lo define como un registro en forma gráfica de la actividad eléctrica en el sistema nervioso. Esta es una de las herramientas más utilizadas para medir actividad cerebral que consiste en colocar sensores en el cuero cabelludo y obtener las señales eléctricas para ser interpretadas. (Martínez & Guardiola, 2006; Novo-Olivas et al., 2010).

Existen varios tipos de EEG de acuerdo con donde están situados los sensores, se puede listar los siguientes:

- EEG de profundidad que se encuentra dentro del cerebro
- EEG cortical cuando se encuentran en la corteza cerebral
- EEG estándar cuando están situados en el cuero cabelludo

El de mayor popularidad es el EEG estándar por ser no invasiva, simple, económica y fácil de implementar. Se realiza colocando electrodos de superficie adheridos al cuero cabelludo por un gel conductor (Ramos-Argüelles et al., 2009), ubicados de acuerdo con el sistema internacional 10-10 -Figura 2 - (Homan et al., 1987; Novo-Olivas et al., 2010).




Figura 2 Sistema Internacional 10-10 Blanco 10-20 Azul (Novo-Olivas et al., 2010).

1.4.5 EMOTIV

Emotiv Systems nace como una compañía australiana de bioinformática y tecnología dedicada al desarrollo y creación de interfaces cerebro-computadora basado en electroencefalografía portátil (EEG), la compañía fue fundada en el 2003 resultando la primera versión del “EMOTIV EPOC”.

En 2011 la empresa cambia de nombre a Emotiv Inc con su nueva sede en San Francisco, Estados Unidos y con instalaciones en Australia. Sus productos ampliaron su espectro a nuevas versiones del EMOTIV EPOC, EPOC+, Emotiv Insight, kits de desarrollo, productos de datos y aplicaciones móviles (EMOTIV, 2020).

1.4.6 EMOTIV EPOC

Es un dispositivo BCI compuesto por un casco de 14 canales ubicados en los puntos AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 (Figura 2) de acuerdo al estándar determinado por la American Electroencephalographic Society (Lesser & Picton, 1994). La frecuencia de muestreo es de 128 Hz, el ancho de banda es de 0,2 a 45 Hz y cuenta con un dispositivo inalámbrico para la comunicación entre la interfaz BCI y el dispositivo electrónico (EMOTIV, 2020).



Figura 3 Dispositivo Emotiv Epoc (EMOTIV, 2020).

La interfaz se coloca en el cuero cabelludo de la persona y se encarga de captar las señales eléctricas del cerebro por medio de sus electrodos y transmitir las al dispositivo computacional de forma inalámbrica (Figura 3).

El dispositivo cuenta con APIs que permiten el desarrollo de aplicaciones en lenguaje JAVA, C o C#, para mayor información de las APIs de conexión consultar (Vasquez, 2014) página 27 – 36.

1.4.7 Machine learning

El machine learning se define como una rama de la inteligencia artificial con el objetivo de extraer conocimiento de los datos observados. Se produce por medio de algoritmos que establecen sus reglas, aprenden por sí mismos y no dependen de reglas programadas (Huynh-Thu & Geurts, 2019).

Se puede clasificar de acuerdo con el tipo de estrategia y el apoyo de un sistema de aprendizaje de la siguiente manera:

- Supervisados
- No supervisados
- Mediante refuerzos

Existen varias aplicaciones para el machine learning, desde la seguridad de la información mediante prevenciones de fraudes, la salud mediante la predicción de diagnósticos o el análisis de mercado de valores.

Para la generación de proyectos de machine learning existen diversas herramientas entre las cuales podemos nombrar las siguientes:

- Weka¹ es un conjunto de herramientas utilizada para machine learning y minería de datos que se desarrolló originalmente en la Universidad de Waikato en Nueva Zelanda. (Markov & Russell, 2006; Naik & Samant, 2016).
- Orange² es un software de minería de datos y machine learning de código abierto escrito en Python. Tiene un front-end visual de programación para análisis y visualización de datos exploratorios, y también se puede utilizar como una biblioteca de Python. Orange fue utilizado para crear los primeros modelos y comparar los diferentes algoritmos de clasificación para determinar el modelo que mejor se adapta al estudio (Naik & Samant, 2016; Tscherne et al., 2016).

¹ <http://www.cs.waikato.ac.nz/ml/weka/>

² <http://orange.biolab.si/>

- Python³ es un lenguaje de programación orientado a objetos claro y poderoso, utilizado entre otras cosas, para la generación automática de modelos (Fayyad, U., Piatetsky-Shapiro, G., & Smyth, 2007).

1.4.8 Aprendizaje supervisado

El aprendizaje supervisado consiste en realizar predicciones a partir de comportamientos e información histórica. En este método los datos proporcionados como entrada son necesarios para cumplir las metas del aprendizaje (Moreno et al., 2004).

El aprendizaje supervisado se clasifica en modelos de regresión y modelos de clasificación. Los modelos de regresión se basan en predecir valores continuos a partir de la información histórica, por ejemplo, las predicciones meteorológicas. Mientras que en los de clasificación el objetivo es agrupar los datos de acuerdo con los datos históricos previamente etiquetados, por ejemplo, detecciones de fraude de identidad (Gironés et al., 2017).

1.4.9 Modelos de clasificación

Los modelos de clasificación son parte del aprendizaje supervisado y su objetivo consiste en clasificar un atributo de una clase a partir de los atributos de los datos históricos. Estos modelos se clasifican en binaria y multiclase (Lahoz-Beltra, 2010).

La binaria es la clasificación en la que solo se pueden asignar dos clases diferentes. Un ejemplo de este tipo de modelo es la validación del saldo de una tarjeta de crédito, donde 0 sería que no tiene saldo y 1 que si tiene saldo. En cambio, en la clasificación multiclase se pueden asignar varias categorías a las observaciones, por ejemplo, determinar el estado de ánimo de una persona en la que podría ser alegre, triste, relajado, enojado, excitado, enamorado, entre otras.

Entre algunos modelos de clasificación supervisados se pueden nombrar los siguientes (Kotsiantis, 2016; Maglogiannis, 2007):

- Máquina soporte vector (SVM)
- Redes Bayesianas
- Redes neuronales

³ <https://www.python.org/doc/>

- Algoritmos de Árbol de Decisión
- Random Forests

Para seleccionar el algoritmo más adecuado se recomienda probar y comparar los resultados de cada uno tomando en cuenta que el comportamiento estará influido por el conjunto de datos disponible, número de categorías, y si son o no linealmente separables (Gironés et al., 2017; Lahoz-Beltra, 2010).

1.4.10 Random Forest

El algoritmo Random Forest (RF) se utiliza para abordar dos clases principales de problemas: construir una regla de predicción en un problema de aprendizaje supervisado y evaluar y clasificar las variables con respecto a su capacidad para predecir la respuesta. Esto último se hace considerando las llamadas “medidas de importancia variable” que se calculan automáticamente para cada predictor dentro del algoritmo de RF. En particular, se cree que identifican con éxito los predictores implicados en interacciones, es decir, predictores que pueden predecir la respuesta sólo en asociación con uno u otros predictores (Boulesteix et al., 2012; Senthilnathan et al., 2020).

Si se cuenta con un dataset con numerosas características, el algoritmo del árbol de decisión tiende a añadir complejidad al modelo. Se puede solventar este punto seleccionando aleatoriamente cada columna para construir árboles de decisión para cada conjunto de características (Figura 4) (Boulesteix et al., 2012; Gironés et al., 2017; Senthilnathan et al., 2020).




Figura 4 Random Forest (Senthilnathan et al., 2020).

La principal ventaja de este método es que es un modelo resistente al ruido, lo que quiere decir que normalmente no se necesita podar el bosque. Sin embargo, es mucho menos interpretable que el método de árboles de decisión.

Random Forest ofrece características específicas que lo hacen atractivo para aplicaciones bioinformáticas. Puede hacer frente a datos de alta dimensión e incluso se puede aplicar en entornos difíciles con predictores correlacionados. No se basa en un particular modelo estocástico y también puede capturar patrones de asociación no lineal entre predictores y respuesta (Boulesteix et al., 2012).

CAPÍTULO 2

ESTADO DEL ARTE

Para la realización del presente trabajo se consultaron diversos trabajos de dos fuentes principales, Google scholar y Scopus.

La búsqueda se dividió en tres temas principales, la clasificación de emociones, la clasificación de señales EEG y la clasificación utilizando el dispositivo Emotiv headset. Para la clasificación de emociones se consultaron trabajos desde el año 2000, para la clasificación de señales EEG se consultaron trabajos desde el 2006 y para la clasificación utilizando el dispositivo Emotiv headset se consultaron trabajos desde el 2011.

Los principales términos utilizados en la búsqueda fueron “Clasificación emociones”, “Clasificación Random Forest”, “Emotiv epoc”, “dispositivos EEG”, “clasificación EEG”, “Modelos Clasificación”, entre otros.

De acuerdo con estos criterios de búsqueda se encontraron diversos estudios sobre identificación y clasificación de emociones utilizando información de respuestas fisiológicas como rasgos faciales, reconocimiento de voz o señales corporales inducidos por música o videos u otros factores (Bailenson et al., 2008; Daimi & Saha, 2014; Lee et al., 2001; Magdin et al., 2019; Ververidis et al., 2004; Zentner et al., 2008). Magdin et al. (2019) se centran en el análisis de reacciones captando los movimientos faciales, el experimento se realizó con una muestra de 50 personas y consistió en mostrarles imágenes para registrar sus reacciones positivas, negativas o neutrales. Como resultado se obtuvo que los sistemas de análisis facial solo pueden detectar emociones externas y tiene muchas dificultades para detectar emociones internas presentando rangos de aciertos muy bajos.

Por su parte Bailenson et al. (2008) presentaron modelos automatizados en tiempo real creados con algoritmos de aprendizaje automático, utilizando para esto cintas de video para provocar respuestas fisiológicas con el objetivo de predecir la tristeza o la diversión. Para esto, crearon algoritmos basados en puntos extraídos de las caras de los sujetos, así como también sus respuestas fisiológicas tales como, la actividad cardiovascular, actividad somática y respuesta electrodérmica. Los resultados demostraron un mejor rendimiento para calificaciones de diversión que de tristeza.

Ververidis (2004) en su artículo propone el diseño de una herramienta que clasifique automáticamente cinco expresiones emocionales, la ira, la felicidad, la neutralidad, la tristeza y la sorpresa. Para esto se basaron en una herramienta de software de análisis del habla desarrollado en MATLAB el cual graba el habla y la muestra en pantalla en forma de onda. El resultado es una tasa de clasificación correcta del $51,6\% \pm 3\%$ con un intervalo de confianza del 95% para las cinco emociones, mientras que una clasificación aleatoria daría una tasa correcta de clasificación del 20%.

Otra forma de clasificación, considerada una de las más importantes, es la realizada mediante señales electroencefalográficas EEG utilizando interfaces cerebro computadora con el que se han realizado diversas aplicaciones de domótica, aplicaciones médicas o relacionadas a la detección de emociones, estos estudios se han realizado utilizando diferentes interfaces para la recolección de información.

2.1 Clasificación de señales EEG con distintos modelos

Existen varios artículos que hablan sobre la clasificación de señales EEG utilizando interfaces cerebro computadora, entre los principales se pueden mencionar a los relacionados con la domótica y el reconocimiento de estados emocionales (Bos, 2006; Ghodake & Shelke, 2016; Li et al., 2019; Lin et al., 2010; Nugraha et al., 2016; Roy et al., 2020; Shukla & Chaurasiya, 2018; Virdi et al., 2017). Por ejemplo, Roy et al. (2020) utilizan el dispositivo Emotiv Epoc+ de 14 canales para obtener las señales EEG de las personas con el objetivo de controlar un foco. Esto lo lograron clasificando las señales EEG con redes neuronales para ser enviadas a un circuito que interpretaba la acción y la ejecutaba.

Por su parte Lin et al. (2010) realizaron un estudio en el cual se aplicaron algoritmos de machine learning para categorizar señales EEG, pertenecientes al estado de ánimo de las personas, estos estados fueron la alegría, la ira, la tristeza y el placer. El estudio contó con una población de 26 personas y utilizó el algoritmo de clasificación máquina de vectores de soporte el cual arrojó una precisión promedio de $82,29\% \pm 3,06\%$.

Mientras que Li et al. (2009) tuvieron como objetivo presentar un sistema de reconocimiento de emociones mediante técnicas de clasificación y reconocimiento de patrones. Se utilizaron videos

como estímulo para cada emoción y las emociones estudiadas fueron alegría relajación y tristeza. Para el estudio se utilizó el algoritmo de clasificación de máquina de vectores de relevancia (RVM) en una población de 5 personas. El resultado fue una precisión en alegría de 70.70%, relajación 73.30% y tristeza 72.30%.

Por su parte Nugraha et al. (2016) realizaron un estudio para determinar si una persona está fatigada al manejar, utilizando como datos de entrada las señales EEG de 30 personas. Para la clasificación de los datos utilizaron los algoritmos kNN y SVM. Con el algoritmo kNN obtuvieron una precisión de 96% y con el algoritmo SVM lograron una precisión del 81%.

En los estudios mencionados anteriormente, se utilizan diferentes dispositivos para la recopilación de información. Lin et al. (2010) utilizaron un dispositivo de 32-channel EEG de Neuroscan, Inc, Li et al. (2009) utilizaron el dispositivo de Microelements headgear mientras que Nugraha et al. (2016) utilizaron el dispositivo Emotiv EPOC+.

2.2 Clasificación de señales EEG con modelos Random Forest

Existen varios artículos que tratan sobre la clasificación de señales EEG con modelos Random Forest para varias aplicaciones, entre las más importantes se encuentran las aplicaciones médicas (Chen et al., 2014; Donos et al., 2015; Edla et al., 2018; Shen et al., 2007). Por ejemplo, Chen et al. (2014) realizaron la clasificación de señales EEG para detectar los trastornos cerebrales en los recién nacidos. Mientras que Donos et al. (2015) desarrollaron un algoritmo de detección temprana de convulsiones basado en señales EEG intracraneales utilizando Random Forest.

Por su parte Edla et al. (2018) realizaron la clasificación de datos EEG para el análisis del estado mental humano usando Random Forest donde los estados analizados fueron la concentración y a meditación. La recopilación de información se realizó mediante el dispositivo Neurosky Mindwave Mobile de 8 valores y contó con una muestra de 40 sujetos obteniendo como resultado una predicción correcta del 75%.

2.3 Clasificación de señales EEG utilizando Emotiv headset

Existen artículos de clasificación de señales EEG utilizando el dispositivo Emotiv headset para la recolección de información (Liu et al., 2011; Nugraha et al., 2016; Yu & Sim, 2016).

Por ejemplo, Liu et al. (2011) propusieron un algoritmo de clasificación de emociones en tiempo real, a partir de las señales del electroencefalograma EEG, para analizar el estado de miedo, frustración, tristeza, alegría y satisfecho. Estas emociones fueron provocadas con la ayuda de sonidos digitales, reproducción de piezas musicales y cuestionarios.

El estudio de Liu et al. (2011) recolectó información de 22 personas mediante el dispositivo Emotiv headset de 14 canales de los cuales se utilizaron tres para el estudio AF3, F4 y FC6. Se obtuvo como resultado un sistema prototipo de reconocimiento de emociones en tiempo real que permite la visualización de emociones en forma de expresiones faciales de avatares personalizados en entornos 3D.

CAPÍTULO 3

MÉTODO

El proceso realizado para lograr la clasificación de emociones se divide en forma general en seis pasos: la generación de emociones en las personas, la lectura de las señales EEG mediante el dispositivo, la captura de señales enviadas por medio de un software desarrollado a la medida, el almacenamiento en una base de datos, el análisis de la información almacenada, la presentación de resultados del estudio y la visualización de resultados en vivo (Figura 5).




Figura 5 Diagrama general del proceso.

Con estos pasos se realizó un análisis que obtuvo como datos de entrada las señales EEG de las personas y, por medio de un proceso de clasificación, permitir predecir el estado de ánimo de estas señales (Figura 6).




Figura 6 Resultados Esperados.

Para cumplir este objetivo se formó el presente proyecto con los siguientes procesos:

- Recopilación de información.
- Análisis de información.
- Validación.

- Clasificación en tiempo real.

3.1 Recopilación de información

La recopilación de información consistió en la adquisición, procesamiento y almacenamiento de los datos necesarios para la generación del modelo de clasificación. Esta información estuvo formada por señales EEG de diferentes personas pertenecientes a tres emociones, la alegría, la tristeza y la relajación. Estas señales fueron extraídas con el dispositivo EMOTIV EPOC, que es una interfaz para la interacción cerebro computadora de 14 canales que permitió la comunicación entre el cerebro y el sistema de recolección de datos (Revisarlo en el numeral 1.4.6). Este sistema fue desarrollado en tecnología .Net C# y cumplió con la función de interpretar, visualizar y almacenar los datos EEG enviados por el dispositivo.

Para recopilar la información necesaria, se realizó un pequeño experimento con una muestra de 50 voluntarios de entre 17 y 71 años, de los cuales 27 pertenecen al género masculino y 23 al género femenino, todos de nacionalidad ecuatoriana. A cada una de las personas se le aplicaron una serie de tareas detalladas a continuación:

- Preparación del dispositivo EMOTIV EPOC. Donde se verificó que cada esponja esté hidratada con solución salina.
- Colocación del dispositivo a la persona. Fase donde se ajustaron los respectivos indicadores plásticos del dispositivo por detrás de las orejas.
- Inicio y parametrización del software de recolección de información. Consistió en la inicialización del sistema mediante el ingreso de un código para la persona y la acción que va a ser almacenada. Luego de ingresar estos datos el sistema visualizaba el estado de la conexión de los sensores por medio de los colores negro, rojo, naranja y verde, donde negro significa que no se registra señal y verde significa excelente señal. Se debe procurar que la señal permanezca en color verde. En la Tabla 1 se puede observar el significado de los colores.

Tabla 1 Señales de sensores.

Color	Descripción
Negro	Sin señal
Rojo	Señal pobre
Naranja	Señal mediana
Verde	Excelente señal

- Calibración del sistema. Donde se realizó la toma de datos de la persona tales como edad, género, estado civil, nivel de educación entre otros, con el objetivo de que todos los sensores tengan excelente señal y para almacenar la información general de la persona en la base de datos.
- Finalmente se recolectaron los datos del estado de ánimo de las personas para lo cual se utilizaron recursos audiovisuales. Una vez iniciado el video se inicia la grabación de información en el sistema durante cinco minutos, tiempo en el cual se almacenan aproximadamente 2000 registros por minuto, es decir, cada persona registró un promedio de 8000 registros por acción (Figura 7).




Figura 7 Proceso de recopilación de información.

Como resultado de este experimento se obtuvieron 1'106.752 datos pertenecientes a las 3 acciones de las 50 personas, los cuales fueron almacenados en varias tablas dentro del motor de base de datos SQL Server Express para su posterior tabulación y análisis. El diagrama de la base de datos se lo puede observar en la Figura 8 y las principales tablas utilizadas fueron las siguientes:

- Personas: Almacena los datos generales de cada voluntario.
- DatosPersonas: Estructura principal que almacena las señales del estado de ánimo de cada persona. Los campos AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 son de tipo numérico con seis decimales. El campo CLASS almacena el tipo de estado de ánimo, *ALEGRE*, *TRISTE*, *RELAJADO*. Por último, el campo CODIGO guarda el código de la persona que realizó el análisis.

- **Modelo:** Descripción de los modelos generado en el proceso de análisis de datos y validación cruzada. Contiene el nombre del modelo, la fecha de generación y una descripción del modelo generado.
- **Predicciones:** Almacena datos de las predicciones que se usaron para los resultados y la validación cruzada. Contiene el código secuencial de la tabla DatosPersonas, el código secuencial de la tabla de Modelos, la clase original del dato y la clase predicha que fué actualizada en el proceso de generación del modelo.
- **DatosOutliers:** Información de datos de tipo outlier generados en el análisis de información. Contiene el secuencial de relación con la tabla de datosPersonas, un campo que indica si el registro es outlier o no y un campo que muestra si el dato es un valor extremo. Estos datos se obtienen utilizando Weka en la fase de análisis de información.
- **MatrizConfusion:** Almacenó el resultado de cada modelo y su respectiva matriz de confusión. Contiene el nombre del modelo, la clase analizada, el porcentaje clasificado como *ALEGRE*, *RELAJADO* y *TRISTE* y el porcentaje de acierto general. Esta información se la genera en el proceso de análisis de información.




Figura 8 Diagrama de base de datos.

3.2 Análisis de información.

Una vez recopilados los datos se ejecutaron los procesos de limpieza y diseño del modelo, lo que permitió la clasificación de la información. Para el proceso de análisis de los datos se utilizaron las herramientas:

- Weka⁴ (Versión 3.8.4): fue utilizado para la limpieza de información, generación de outliers y datos repetidos (Markov & Russell, 2006; Naik & Samant, 2016).
- Orange⁵ (Versión 3.26.0): fue utilizado para crear los primeros modelos y comparar los diferentes algoritmos de clasificación para determinar el modelo que mejor se adapta al estudio (Naik & Samant, 2016; Tscherne et al., 2016).
- Python⁶ (Versión 3.6.5): fue utilizado para crear un programa para la generación automática de modelos (Fayyad, U., Piatetsky-Shapiro, G., & Smyth, 2007).

Para la limpieza de información se utilizó la herramienta WEKA en la identificación y eliminación de datos outliers y datos repetidos. Para la marcación de estos registros se aplicó el filtro InterquartileRange es una técnica que para detectar valores atípicos y extremos basados en rangos intercuartílicos y ayuda a encontrar y etiquetar valores atípicos en los datos que se distribuyen continuamente, en este método, el conjunto de datos se divide en cuartiles y ordena el conjunto de datos en cuatro partes iguales (Hall et al., 2009; Vinutha et al., 2018). El factor para determinar los umbrales para valores extremos fue seis y el factor para umbrales atípicos fue tres. El detalle de los datos outliers se pueden observar en la Tabla 2.

Tabla 2 Datos outliers.

Clase	Recolectados	Outliers	Total
RELAJADO	395281	41009	354272
ALEGRE	355852	13442	342410
TRISTE	355619	34043	321576
TOTAL	1106752	88494	1018258

Una vez que se marcaron y excluyeron los datos outliers se realizó un análisis entre cinco modelos de clasificación utilizando el programa Orange con el objetivo de seleccionar el que mejor resultados dé al experimento. Para la selección de estos modelos se tomó en cuenta el número de variables, la dispersión de los datos y la cantidad de resultados que podía arrojar el modelo

⁴ <http://www.cs.waikato.ac.nz/ml/weka/>

⁵ <http://orange.biolab.si/>

⁶ <https://www.python.org/doc/>

(alegría, tristeza y relajación), es así como se seleccionaron los modelos de árboles de decisión, SVM, Random Forest, kNN y Redes Neuronales. Luego de seleccionar los procesos a utilizar se graficó en Orange mediante su interfaz gráfica con los siguientes objetos.

- La entrada de datos que contenía la información requerida para el experimento en formato csv con el siguiente detalle:
 - o 14 columnas de tipo numérico que representaron cada uno de los sensores del dispositivo detallados en el numeral **¡Error! No se encuentra el origen de la referencia..**
 - o Una columna que contiene la clase (*alegre, triste, relajado*).
- Los cinco modelos de análisis de datos, con sus parámetros respectivos (Tabla 3).

Tabla 3 Parámetros de modelos en Orange.

	Parámetro	Valor
Árbol de decisión	Número mínimo de instancias en hojas	2
	No dividir conjuntos más pequeños que	5
	Límite de profundidad máxima del árbol	100
	Parámetro	Valor
Random Forest	Número de árboles	25
	No dividir conjuntos más pequeños que	5
	Límite de profundidad de cada árbol	NA
	Parámetro	Valor
Red neuronal	Número de árboles	25
	No dividir conjuntos más pequeños que	5
	Límite de profundidad de cada árbol	NA
	Parámetro	Valor
Random	Neuronas en capas ocultas	100
	Número máximo de iteraciones	200
	Entrenamiento replicable	Sí
	Parámetro	Valor
SVM	Tipo SVM	SVM
	Tipo de kernel	RBF
	Límite de iteración	100
	Parámetro	Valor
kNN	Número de vecinos	5
	Métrica	Euclidiana
	Peso	Uniforme

- Las salidas representadas en los objetos de matriz de confusión (Tabla 4), de prueba y resultados y predicciones (Figura 9).




Figura 9 Modelo en Orange.

- Al finalizar el análisis de los datos y modelos, Orange arrojó automáticamente la información de la matriz de confusión de cada uno de los cinco procesos.

Tabla 4 Matriz de confusión Orange.

Árbol de decisión				
CLASE	ALEGRE	RELAJADO	TRISTE	Sumatoria
ALEGRE	228233	17550	25557	271340
RELAJADO	16065	341808	24387	382260
TRISTE	24684	27674	409162	461520
SVM				
CLASE	ALEGRE	RELAJADO	TRISTE	Sumatoria
ALEGRE	159463	10345	101532	271340
RELAJADO	126450	18228	237582	382260
TRISTE	152042	18782	290996	461820
kNN				
CLASE	ALEGRE	RELAJADO	TRISTE	Sumatoria
ALEGRE	251308	7096	12936	271340
RELAJADO	2865	370091	9304	382260
TRISTE	4119	8355	449346	461820
Redes Neuronales				
CLASE	ALEGRE	RELAJADO	TRISTE	Sumatoria
ALEGRE	218427	17528	35385	271340
RELAJADO	12004	346307	23949	382260
TRISTE	22665	22743	416412	461820
Random Forest				
CLASE	ALEGRE	RELAJADO	TRISTE	Sumatoria
ALEGRE	255381	5343	10616	271340
RELAJADO	1576	373782	6902	382260
TRISTE	1902	5083	454835	461820

Es así como se obtuvo la información de la Tabla 5 en la que se pudo observar el valor de la precisión y el valor del área bajo la curva (AUC) de cada clase, con estos datos se determinó que

el mejor nivel de precisión se presentó en el modelo Random Forest con un 97.20% de clasificación correcta.

Tabla 5 Precisión y datos AUC para diseño del modelo.

Color	Precisión	AUC Alegre	AUC Relajado	AUC Triste
kNN	0.960	0.994	0.996	0.996
Neural Network	0.879	0.959	0.979	0.967
Random Forest	0.972	0.997	0.998	0.998
SVM	0.412	0.344	0.437	0.422
Tree	0.878	0.893	0.914	0.908

Finalmente, con este resultado, se generó el proceso de clasificación utilizando Python, el proceso utilizó la librería Pandas para el manejo de la información, la librería numpy para el manejo estructuras y la librería Scikit-learn para la generación del modelo Random Forest y la predicción de los datos.

El primer paso del proceso consistió en determinar el valor óptimo de ramas del modelo, para identificar este valor se realizó un proceso de validación cruzada modificando este parámetro desde uno hasta que la diferencia de precisión entre los dos últimos modelos analizados se acerque a cero. Como se observa en la Figura 10 al llegar a las 25 ramas el porcentaje de confianza de la predicción llega a un punto en que la curva empieza a aplanarse. Con este valor se generó el modelo en Python que será consumido en el experimento.




Figura 10 Análisis número de ramas (Rodrigo, 2020).

3.3 Validación

El proceso de validación cruzada se lo automatizó en Python y consistió en cargar los modelos generados, tomar los datos de la tabla de predicciones, generar el valor de predicción de cada registro para finalmente almacenarlo en la base de datos.

Para la realización de la validación se siguieron los siguientes pasos:

- Generación del modelo completo: Para lo cual se realizaron 30 modelos de pruebas de validación cruzada, iniciando con un análisis que tomó en cuenta el 90% de datos aleatorios para la generación del modelo y el 10% de datos aleatorios para la generación de la validación. Para obtener la cantidad de 30 modelos se realizó la prueba de normalidad de los porcentajes de acierto, dando como resultado un p-valor de 0.6982 por lo que no hizo falta agregar más modelos al análisis.
- Graficación de los datos: Consistió en tomar los datos de las señales EEG y graficarlos como muestra la Figura 11. En esta gráfica se pudo observar una similitud entre la relajación y la tristeza, razón por la cual se realizó un segundo modelo agrupando los sentimientos de dos en dos.
- Generación de modelos agrupados: Consistió en generar modelos agrupados entre alegría – tristeza, alegría – relajación y relajación - tristeza. Para esta validación se tomó aleatoriamente 250.000 registros de los cuales el 90% se utilizó para la generación de cada modelo y el 10% para la validación cruzada. Este estudio se lo realizó para determinar si los estados de relajación y tristeza se confunden entre sí.



Figura 11 Señales recopiladas.

3.4 Clasificación de datos en tiempo real

La segunda fase del estudio consistió en la generación de un prototipo que clasifique las señales en tiempo real. Este prototipo fue desarrollado con tecnología Microsoft .Net C# y Python.

En la Figura 12 se visualizan los procesos para la interpretación de las señales. Este proceso se lo realizó mediante las siguientes acciones:

- Se colocó del dispositivo a la persona y se inició el recurso audiovisual.
- Se esperó alrededor de 30 segundos de calibración para iniciar la recolección de información.
- Se realizó la recolección, lectura e interpretación de señales mediante el sistema desarrollado en C# durante diez segundos.
- Las señales interpretadas fueron enviadas a los scripts de Python, los cuales cargaban los modelos de clasificación y respondían con la predicción respectiva nuevamente a C#.
- Finalmente, el sistema mostraba visualmente el resultado en tiempo real en pantalla.
- El proceso de recolección, interpretación y respuesta se repite cada diez segundos.
- La duración del experimento fue de cinco minutos por cada sentimiento, desde el primer paso hasta el último.




Figura 12 Clasificación en tiempo real.

CAPÍTULO 4

RESULTADOS

En esta sección se visualizan y discuten los resultados obtenidos mediante la aplicación del modelo Random Forest a los datos recolectados de la población que consistió en un total de 50 personas de entre 17 y 71 años (Tabla 6).

Tabla 6 Detalle de población.

Ítem	Detalle
Población total	50
Población masculina	27
Población femenina	23
Rango de edad	17-71 años
Nacionalidad	Ecuatoriana

Como se mencionó anteriormente se realizaron tres experimentos, el primero generando un modelo con todos los datos, el segundo agrupando los datos por alegría – tristeza, alegría relajación y relajación – tristeza y el tercer experimento utilizando el modelo con todos los datos para predecir en tiempo real. La información utilizada en los experimentos se la puede observar en la Tabla 7.

Tabla 7 Datos generales del experimento.

Detalle	Cantidad
Total recolectados	1,106,752
Datos outliers	88,494
Datos para trabajar	1,018,258
Datos Relajado	354,272
Datos Alegre	342,410
Datos Triste	321,576
Generación modelo experimento 1	900,000
Datos para predicciones 1	100,000
Generación modelo experimento 2	225,000
Datos para predicciones 2	25,000

4.1 Validación cruzada del modelo completo

Para la primera validación se realizaron 30 modelos generados con todas las emociones, donde cada uno de ellos contenía 900.000 registros para la creación y 100.000 registros para ser validados. El resultado promedio de precisión de los experimentos fue 97.69%.

Tabla 8 Resultados Experimento 1.

N°	Correctas	Fallidas	Precisión
1	97704	2296	97.70%
2	97613	2387	97.61%
3	97569	2431	97.57%
4	97772	2228	97.77%
5	97741	2259	97.74%
6	97686	2314	97.69%
7	97654	2346	97.65%
8	97692	2308	97.69%
9	97695	2305	97.70%
10	97644	2356	97.64%
11	97697	2303	97.70%
12	97681	2319	97.68%
13	97656	2344	97.66%
14	97716	2284	97.72%
15	97782	2218	97.78%
16	97676	2324	97.68%
17	97760	2240	97.76%
18	97626	2374	97.63%
19	97718	2282	97.72%
20	97643	2357	97.64%
21	97760	2240	97.76%
22	97625	2375	97.63%
23	97616	2384	97.62%
24	97658	2342	97.66%
25	97778	2222	97.78%
26	97827	2173	97.83%
27	97640	2360	97.64%
28	97663	2337	97.66%
29	97720	2280	97.72%
30	97641	2359	97.64%

Como se puede observar en la Tabla 8 existe una precisión muy alta en todos los resultados, sin embargo, como ya se mencionó anteriormente en el apartado 3.3, se intuyó que el modelo puede estar sobreentrenado con la clase de alegría. En la Figura 11 se pudo observar que entre la relajación y tristeza no tienen mucha diferencia por lo cual se vio necesario realizar una validación por clase, es decir, tomando para el grupo de predicción solo una clase.

4.2 Validación cruzada de modelos agrupados

Para esta validación se realizaron 30 modelos por cada estado de ánimo lo que arrojó como resultados en alegría 97.21%, relajado un 76.53% y triste un 76.04%. En la Tabla 9 se puede observar la matriz de confusión promedio de las 30 validaciones realizadas por clase.

Tabla 9 Matriz de confusión de validación por clase.

CLASE	ALEGRE	RELAJADO	TRISTE	Precisión
ALEGRE	24303	206	491	97.21%
RELAJADO	5000	17610	400	76.53%
TRISTE	5766	224	19011	76.04%

Por medio de estos datos se puede decir que la alegría es la clase con mayor facilidad de predicción mientras que la tristeza y la relajación tienen una mayor dificultad de predicción. Esto puede deberse a que las señales de relajación y tristeza son parecidas de acuerdo con lo que se puede observar en la Figura 11.

4.3 Validación de datos en tiempo real

La validación en tiempo real se la realizó con dos voluntarios a los cuales se les colocó el dispositivo y con ayuda de recursos audiovisuales llegaban a los estados de ánimo (*alegre, relajado o triste*). El resultado se presentó en tiempo real en el monitor del computador mostrando valores de precisión de entre 35% y 90% (Tabla 10). La pantalla que observaron los voluntarios la podemos observar en la Figura 13.



Figura 13 Sistema en tiempo real.

La Tabla 10 muestra los datos de las observaciones en tiempo real tomadas a uno de los voluntarios durante cinco minutos con un lapso entre cada observación de 20 segundos.

Tabla 10 Observaciones en tiempo real.

Observación	Clase	Precisión	Tiempo
1	ALEGRÍA	39%	0:20
3	ALEGRÍA	35%	0:40
4	ALEGRÍA	45%	1:00
5	ALEGRÍA	62%	1:20
6	ALEGRÍA	52%	1:40
7	ALEGRÍA	71%	2:00
8	ALEGRÍA	64%	2:20
9	ALEGRÍA	75%	2:40
10	ALEGRÍA	78%	3:00
11	ALEGRÍA	85%	3:20
12	ALEGRÍA	88%	3:40
13	ALEGRÍA	90%	4:00
14	ALEGRÍA	59%	4:20
15	ALEGRÍA	86%	4:40
16	ALEGRÍA	78%	5:00

El resultado del experimento arrojó un promedio de precisión del 67%, pero a medida que pasa el tiempo el porcentaje de acierto sube (Figura 14 Resultado experimento en tiempo real).




Figura 14 Resultado experimento en tiempo real.

Finalmente, se almacenaron y graficaron los datos generados en línea para la comparación con las señales utilizadas en el modelo (Figura 15).



Figura 15 Resultados se señales en tiempo real.

Como se puede observar en la Figura 15, las gráficas tienen el mismo patrón entre las generadas por una persona en tiempo real y las almacenadas en el modelo. De la misma manera se puede determinar que existe mucha similitud entre las gráficas de relajación y tristeza mientras que la alegría se diferencia bastante de las otras dos. Para comprobar esta similitud se procedió a calcular la varianza general del modelo por sensor y la varianza de las señales obtenidas en tiempo real. En la Tabla 11 se observan los datos de las varianzas del modelo separado por cada sensor y la varianza de los datos en tiempo real.

Tabla 11 Comparación de varianzas.

Varianza general del modelo														
CLASE	AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
Alegre	226269	367334	316039	243316	374687	201619	233778	326195	516709	396714	399771	238290	428539	388021
Relajado	14656	20666	11107	5281	21369	8124	16317	10495	65718	21795	38527	9494	32443	22022
Triste	12786	22248	18374	12880	28033	13029	16854	20878	45938	27366	30777	12233	31046	23377
Varianza datos usuario en línea														
CLASE	AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
Alegre	170481	252178	172178	67411	200134	93142	191941	161406	244196	164116	144113	136779	161727	157409
Relajado	2457	2306	2455	3255	2535	1446	1969	2464	3056	3121	2891	3128	2818	2662
Triste	8312	4059	7498	1386	5990	3852	6427	6649	7525	7501	8445	6606	7989	6823

En la Figura 16 se muestra la gráfica de las varianzas, tanto en la figura como en los datos podemos observar que la varianza en el caso de alegría tiene valores altos de seis cifras bajas mientras que para relajación y tristeza se obtienen valores bajos en el rango de hasta cinco cifras bajas.




Figura 16 Comparativo de varianzas.

CAPÍTULO 5

CONCLUSIONES Y TRABAJOS FUTUROS

En este estudio se propuso un proceso de clasificación de las señales electroencefalográficas de las personas utilizando el modelo Random Forest logrando el reconocimiento de tres emociones: alegría, tristeza y relajación.

Para esto, se diseñó un proceso que permitió la recolección de información EEG de forma rápida y simple, esto se lo logró gracias al desarrollo de un sistema automatizado de adquisición y almacenamiento de la información, permitiendo que el proceso tome solo entre 15 y 20 minutos por persona.

A pesar de la pandemia fue posible recolectar información a 50 personas lo que dio como resultado la recopilación de 1.1 Millones de registros. Esto se logró gracias al sistema mencionado anteriormente ya que permitió tomar los datos en corto tiempo y sin contacto alguno.

La limpieza de la información se la realizó con la ayuda de la herramienta WEKA la cual generó 88.494 datos outliers para ser registrados y eliminados del proceso, que correspondieron al 8% del total de registros. De ese total el 46% pertenecieron a *relajado*, el 39% a *triste* y el 15% a *alegre* (Tabla 2). Este resultado se presentó ya que la varianza de relajado y triste es menor y fue más fácil identificar los datos outliers (Figura 11).

Se seleccionó el algoritmo que mejor se ajustó al conjunto de datos, para esto se generaron cinco modelos en la herramienta Orange con los algoritmos de árboles de decisión, kNN, Random Forest, SVM y redes neuronales. El resultado fue que Random Forest tuvo el mayor porcentaje de acierto (para este conjunto de datos) por encima del resto de algoritmos (Tabla 5).

El primer análisis realizado con la totalidad de los datos de las 50 personas arrojó una precisión del 97.06%, mientras que el segundo análisis arrojó un porcentaje de acierto de 97.21% para alegría y 76% para relajación y tristeza, lo que permite concluir que la relajación y la tristeza presentan un porcentaje menor de precisión, esto pudo deberse a que las señales de estas emociones se parecen entre sí, lo que pudo haber sido ocasionado por el sesgo hacia la alegría provocado por la mayor cantidad de datos de esa clase, que se obtuvieron luego de la limpieza de la información.

En el tercer análisis se logró desarrollar un prototipo que clasifica las señales electroencefalográficas de una persona en tiempo real y permite visualizar mediante gráficos el estado de ánimo en el que se encuentra la persona en ese momento. Según el resultado de este análisis se pudo concluir que fue posible determinar en tiempo real el estado de ánimo de una persona con un porcentaje de acierto del 67% en promedio. Se pudo observar que mientras pasa el tiempo el voluntario se concentra más en el experimento obteniendo mejores resultados.

En general se logró implementar el reconocimiento de las tres emociones, sin embargo, se podrían crear modelos con mayor cantidad de emociones, como la meditación, la ira, la angustia. Estas emociones no se las tomó en cuenta ya que para llegar a ellas es necesaria la ayuda de un profesional de la salud.

Como otro trabajo futuro se puede mejorar la clasificación de la tristeza y la relajación tanto en los modelos como en el sistema de reconocimiento en tiempo real, esto se lo podría lograr mejorando el proceso de toma de señales con ayuda de profesionales de la salud. Mejorando este aspecto también mejorará el sistema de clasificación en tiempo real.

El modelo también podría ser aplicado en el hogar para que, de acuerdo con determinado estado de ánimo, se activen diferentes dispositivos como luces, música o videos controlados por domótica.

En el ámbito de la salud, se podría controlar a personas con problemas de ansiedad o depresión determinando en tiempo real su estado de ánimo visibilizando así problemas que no pueden ser detectados con facilidad.

Otra aplicación que se lo podría tener el modelo es en el ámbito laboral, en donde se aplique el análisis a los trabajadores de las empresas para determinar su estado de ánimo y medir su nivel de estrés.

BIBLIOGRAFÍA

- Arboleda, C., García, E., Posada, A., & Torres, R. (2009). Diseño Y Construcción De Un Prototipo De Interfaz Cerebro-Computador Para Facilitar La Comunicación De Personas Con Discapacidad Motora. *Revista EIA*, 11, 105–115.
- Bailenson, J. N., Pontikakis, E. D., Mauss, I. B., Gross, J. J., Jabon, M. E., Hutcherson, C. A. C., Nass, C., & John, O. (2008). Real-time classification of evoked emotions using facial feature tracking and physiological responses. *International Journal of Human Computer Studies*, 66(5), 303–317. <https://doi.org/10.1016/j.ijhcs.2007.10.011>
- Bos, D. O. (2006). EEG-based emotion recognition. *The Influence of Visual and Auditory Stimuli*, 1–17. <https://doi.org/10.1109/TBME.2010.2048568>
- Boulesteix, A. L., Janitza, S., Kruppa, J., & König, I. R. (2012). Overview of random forest methodology and practical guidance with emphasis on computational biology and bioinformatics. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2(6), 493–507. <https://doi.org/10.1002/widm.1072>
- Chen, W., Wang, Y., Cao, G., Chen, G., & Gu, Q. (2014). A random forest model based classification scheme for neonatal amplitude-integrated EEG. *BioMedical Engineering Online*, 13(Suppl 2), 1–13. <https://doi.org/10.1186/1475-925X-13-S2-S4>
- Daimi, S. N., & Saha, G. (2014). Classification of emotions induced by music videos and correlation with participants' rating. *Expert Systems with Applications*, 41(13), 6057–6065. <https://doi.org/10.1016/j.eswa.2014.03.050>
- Donos, C., Dümpelmann, M., & Schulze-Bonhage, A. (2015). Early Seizure Detection Algorithm Based on Intracranial EEG and Random Forest Classification. *International Journal of Neural Systems*, 25(5), 1–11. <https://doi.org/10.1142/S0129065715500239>
- Edla, D. R., Mangalorekar, K., Dhavalikar, G., & Dodia, S. (2018). Classification of EEG data for human mental state analysis using Random Forest Classifier. *Procedia Computer Science*, 132(Iccids), 1523–1532. <https://doi.org/10.1016/j.procs.2018.05.116>
- EMOTIV. (2020). EPOC X User manual. *Emotiv*. <https://www.emotiv.com/epoc-x/>
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (2007). Python for Scientific Computing Python Overview. *Computing in Science and Engineering*, 10–20.
- Garcia, L. (2008). Neurotecnología para el ciudadano. *Inventum*, 14–15.

- Ghodake, A. A., & Shelke, S. D. (2016). Brain controlled home automation system. *Proceedings of the 10th International Conference on Intelligent Systems and Control, ISCO 2016*.
<https://doi.org/10.1109/ISCO.2016.7727050>
- Gironés, J., Casas, J., Minguillón, J., & Caihuelas, R. (2017). Minería de datos: Modelos y Algoritmos. In *Editorial UOC* (Issue 1).
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. H. (2009). The WEKA data mining software. *ACM SIGKDD Explorations Newsletter*, 11(1), 10–18.
<https://doi.org/10.1145/1656274.1656278>
- Homan, R. W., Herman, J., & Purdy, P. (1987). Cerebral location of international 10-20 system electrode placement. *Electroencephalography and Clinical Neurophysiology*, 66(4), 376–382. [https://doi.org/10.1016/0013-4694\(87\)90206-9](https://doi.org/10.1016/0013-4694(87)90206-9)
- Huynh-Thu, V. A., & Geurts, P. (2019). Unsupervised Gene Network Inference with Decision Trees and Random Forests. *Methods in Molecular Biology*, 1883, 195–215.
https://doi.org/10.1007/978-1-4939-8882-2_8
- Kandel, E. R., Schwartz, J. H., & Jessell, T. M. (1996). *Neurociencia y conducta*. Pearson Educación. <https://books.google.com.ec/books?id=YawMPAAACAAJ>
- Kaulino, A., Stecher, A., & Diaz, E. M. (2008). *Cartografía de la psicología contemporánea: pluralismo y modernidad*. LOM Ediciones. <https://books.google.com.ec/books?id=uxyzeT-1bKoC>
- Kotsiantis, S. (2016). Mössbauer study of Fe-Re alloys prepared by mechanical alloying. *Supervised Machine Learning: A Review of Classification Techniques*, 237(1), 1–8.
<https://doi.org/10.1007/s10751-016-1232-6>
- Lahoz-Beltra, R. (2010). *Bioinformática: Simulación, vida artificial e inteligencia artificial*. Editorial Diaz de Santos, S.A. <https://books.google.com.ec/books?id=U4pwetEPmpQC>
- Lee, C. M., Narayanan, S., & Pieraccini, R. (2001). Recognition of negative emotions from the speech signal. *2001 IEEE Workshop on Automatic Speech Recognition and Understanding, ASRU 2001 - Conference Proceedings*, 240–243.
<https://doi.org/10.1109/ASRU.2001.1034632>
- Lesser, R., & Picton, T. W. (1994). Guideline thirteen: Guidelines for standard electrode position nomenclature. *Journal of Clinical Neurophysiology*, 11(1), 111–113.
<https://doi.org/10.1097/00004691-199401000-00014>

- Li, P., Liu, H., Si, Y., Li, C., Li, F., Zhu, X., Huang, X., Zeng, Y., Yao, D., Zhang, Y., & Xu, P. (2019). EEG Based Emotion Recognition by Combining Functional Connectivity Network and Local Activations. *IEEE Transactions on Biomedical Engineering*, 66(10), 2869–2881. <https://doi.org/10.1109/TBME.2019.2897651>
- Lin, Y. P., Wang, C. H., Jung, T. P., Wu, T. L., Jeng, S. K., Duann, J. R., & Chen, J. H. (2010). EEG-based emotion recognition in music listening. *IEEE Transactions on Biomedical Engineering*, 57(7), 1798–1806. <https://doi.org/10.1109/TBME.2010.2048568>
- Liu, Y., Sourina, O., & Nguyen, M. K. (2011). Real-Time EEG-Based Emotion Recognition and. *Transancations on Computer Science*, 12, 256–277.
- Magdin, M., Benko, L., & Koprda, Š. (2019). A case study of facial emotion classification using affdex. *Sensors (Switzerland)*, 19(9). <https://doi.org/10.3390/s19092140>
- Maglogiannis, I. G. (2007). *Emerging Artificial Intelligence Applications in Computer Engineering: Real Word AI Systems with Applications in EHealth, HCI, Information Retrieval and Pervasive Technologies*. IOS Press. https://books.google.com.ec/books?id=vLiTXDHR%5C_sYC
- Markov, Z., & Russell, I. (2006). An introduction to the WEKA data mining system. *Working Group Reports on ITiCSE on Innovation and Technology in Computer Science Education 2006*, 367–368. <https://doi.org/10.1145/1140124.1140127>
- Martínez, M., & Guardiola, G. T. (2006). Conceptos Básicos de Electroencefalografía. *Duazary*, 3(1), 18–23.
- Microsoft. (2021). *Creación de informes y paneles en Power BI*. <https://docs.microsoft.com/es-es/power-bi/create-reports/>
- Minguez, J. (2012). Tecnología de Interfaz Cerebro - Computador. *Departamento de Informatica e Ingeniería de SistemasUniversidad de Zaragoza*, 1–12.
- Moore, M. M. (2003). Real-world applications for brain-computer interface technology. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(2), 162–165. <https://doi.org/10.1109/TNSRE.2003.814433>
- Moreno, A., Armengol, E., Bejar, E., Belanche, L., Cortez, U., Gavaldà, R., Lopez, B., & Sanchez, M. (2004). *Aprendizaje automático*. <https://upcommons.upc.edu/handle/2099.3/36157>
- Müller, O., & Rotter, S. (2017). Neurotechnology: Current Developments and Ethical Issues.

- Frontiers in Systems Neuroscience*, 11(December), 1–5.
<https://doi.org/10.3389/fnsys.2017.00093>
- Naik, A., & Samant, L. (2016). Correlation Review of Classification Algorithm Using Data Mining Tool: WEKA, Rapidminer, Tanagra, Orange and Knime. *Procedia Computer Science*, 85(Cms), 662–668. <https://doi.org/10.1016/j.procs.2016.05.251>
- Novo-Olivas, C., Chacón Guitiérrez, L., & Alberto Barradas Bribiesca, J. (2010). *Mapeo Electroencefalográfico y Neurofeedback*. September, 371–412.
- Nugraha, B. T., Sarno, R., Asfani, D. A., Igasaki, T., & Nadzeri Munawar, M. (2016). Classification of driver fatigue state based on EEG using Emotiv EPOC+. *Journal of Theoretical and Applied Information Technology*, 86(3), 347–359.
- Oweiss, K. G. (2010). *Statistical Signal Processing for Neuroscience and Neurotechnology*. Elsevier Science. https://books.google.com.ec/books?id=YqIo8%5C_fsG0kC
- Purves, D., Augustine, G., Fitzpatrick, D., Hall, W., LaMantia, A.-S., McNamara, J., & Wililams, S. M. (2007). *Neurociencia* (p. 918).
- Ramos-Argüelles, F., Morales, G., Egozcue, S., Pabón, R. M., & Alonso, M. T. (2009). Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas. *Anales Del Sistema Sanitario de Navarra*, 32 Suppl 3, 69–82. <https://doi.org/10.4321/s1137-66272009000600006>
- Rodrigo, J. A. (2020). *Ciencia de Datos, Estadística, Machine Learning y Programación*. https://www.cienciadedatos.net/documentos/py08_random_forest_python.html
- Roy, P. P., Kumar, P., & Chang, V. (2020). A hybrid classifier combination for home automation using EEG signals. *Neural Computing and Applications*, 32(20), 16135–16147.
- Rudolph, A., Ayers, J., & Davis, J. (2002). *Neurotechnology for biomimetic robots*. MIT press.
- Schalk, G., Mcfarland, D. J., Hinterberger, T., Birbaumer, N., Wolpaw, J. R., & Technology, A. B. I. B. C. I. (2004). *BCI2000 : A General-Purpose Brain-Computer Interface (BCI) System*. 51(6), 1034–1043.
- Senthilnathan, K., Shanmugam, B., Goyal, D., Annapoorani, I., & Samikannu, R. (2020). *Deep Learning Applications and Intelligent Decision Making in Engineering*. IGI Global. <https://books.google.com.ec/books?id=OrgIEAAAQBAJ>
- Shen, K. Q., Ong, C. J., Li, X. P., Hui, Z., & Wilder-Smith, E. P. V. (2007). A feature selection method for multilevel mental fatigue EEG classification. *IEEE Transactions on Biomedical*

- Engineering*, 54(7), 1231–1237. <https://doi.org/10.1109/TBME.2007.890733>
- Shukla, P. K., & Chaurasiya, R. K. (2018). A Review on Classification Methods Used in EEG-Based Home Control Systems. *2018 3rd International Conference and Workshops on Recent Advances and Innovations in Engineering (ICRAIE)*, 1–5.
- Tscherne, F., Wilke, N., Schachenhofer, B., Roux, K., & Tavlaridis, G. (2016). Orange: Data Mining Toolbox in Python. *International Journal of Conservation Science*, 7(SpecialIssue1), 295–300.
- Vasquez, F. (2014). *Sistematización de la empresa “FAVAS TECH” dedicada a la generación de soluciones neurotecnológicas utilizando el dispositivo EMOTIV EPOC*. <https://repositorio.pucesa.edu.ec/bitstream/123456789/978/1/85148.pdf>
- Ververidis, D., Kotropoulos, C., & Pitas, I. (2004). Automatic emotional speech classification. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, 1(January 2015). <https://doi.org/10.1109/icassp.2004.1326055>
- Vinutha, H. P., Poornima, B., & Sagar, B. M. (2018). Detection of outliers using interquartile range technique from intrusion dataset. In *Advances in Intelligent Systems and Computing* (Vol. 701). Springer Singapore. https://doi.org/10.1007/978-981-10-7563-6_53
- Virdi, P., Syal, P., & Kumari, P. (2017). Home automation control system implementation using SSVEP based brain computer interface. *2017 International Conference on Inventive Computing and Informatics (ICICI)*, 1068–1073.
- Yu, J. H., & Sim, K. B. (2016). Classification of color imagination using Emotiv EPOC and event-related potential in electroencephalogram. *Optik*, 127(20), 9711–9718. <https://doi.org/10.1016/j.ijleo.2016.07.074>
- Zentner, M., Grandjean, D., & Scherer, K. R. (2008). Emotions Evoked by the Sound of Music: Characterization, Classification, and Measurement. *Emotion*, 8(4), 494–521. <https://doi.org/10.1037/1528-3542.8.4.494>