

Estudio comparativo de técnicas de caracterización y clasificación automática de emociones a partir de señales del cerebro



**JEFERSON FRANKLIN GOMEZ LARA
OSWALDO ANDRES ORDOÑEZ BOLAÑOS**

**UNIVERSIDAD DE NARIÑO
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELECTRÓNICA
SAN JUAN DE PASTO
2018**

Estudio comparativo de técnicas de caracterización y clasificación automática de emociones a partir de señales del cerebro

**JEFERSON FRANKLIN GOMEZ LARA
OSWALDO ANDRES ORDOÑEZ BOLAÑOS**

**TRABAJO DE GRADO PARA OPTAR POR EL TÍTULO DE INGENIERO
ELECTRÓNICO**

**ASESOR
PhD. DIEGO HERNÁN PELUFFO ORDÓÑEZ
INGENIERO ELECTRÓNICO**

**UNIVERSIDAD DE NARIÑO
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELECTRÓNICA
SAN JUAN DE PASTO
2018**

NOTA DE RESPONSABILIDAD

“La Universidad de Nariño no se hace responsable por las opiniones o resultados obtenidos en el presente trabajo y para su publicación priman las normas sobre el derecho de autor.”

Acuerdo 1. Artículo 324. Octubre 11 de 1966, emanado del honorable Consejo Directivo de la Universidad de Nariño.

NOTA DE ACEPTACIÓN:

Firma del presidente del jurado

Firma del jurado

Firma del jurado

San Juan de Pasto, 19/11/18

AGRADECIMIENTOS

“Agradezco primero que todo a Dios por darme la vida y ponerme en este lugar con una excelente familia y muchos amigos incondicionales, dándome la posibilidad de aprender en el día a día para realizarme como persona, agradezco a mis padres, hermanas, mi hija y a toda mi familia en general por estar siempre acompañándome en los buenos y malos momentos, ayudándome y estando pendientes siempre de mí. A Diego Peluffo y Miguel Becerra por guiarme y ayudarme con este trabajo de la manera más amable y cordial posible.”

Jeferson Franklin Gomez Lara

“Me considero una persona muy afortunada por tener los padres que tengo. Gracias a ellos, que han luchado y trabajado toda su vida por mi bienestar, por ser mis dioses personales y convertirme en lo que soy. Además, aclaro que no creo en la casualidad, encontrarme en el camino de mí vida con Maestros como Diego Peluffo, Miguel Becerra Y Javier Revelo me guiaran a un futuro con mucha ambición de conocimiento, pero sin olvidarme jamás de ser una persona con principios y humiLDAd. Agradezco por ultimo a mi hija Emi, por darme tan grande motivación para ser una persona exitosa, y a mi hermana con Juanita, por ser los motores de mi caótico pero hermoso hogar.”

Oswaldo Andrés Ordóñez Bolaños

DEDICATORIA

“A mis padres y mis hermanas por estar en todo momento acompañándome y dándome fuerzas en todo momento para seguir adelante, a mi hija por ser el motor de todas mis metas y por quien cada día quiero ser mejor tanto en lo personal como en lo profesional, a mi director y amigo Diego Hernán Peluffo Ordóñez por ser mi guía en todo este arduo trabajo.”

Jeferson Franklin Gomez Lara

“Nunca he conocido a nadie con la entrega que tiene mi madre. Ella es la persona más amorosa y luchadora que conozco. Todo lo que soy es gracias a ella y también a mi padre. Los tiempos cambian, el mundo fluye y las metas se cumplen; pero su intervención en mi vida atraviesa todas las posibles teorías del tiempo y el espacio. Su amor es la mayor demostración de ingeniería. Mamá es mi súper héroe favorito, mi inspiración, mi fuerza y sin duda alguna, el gran amor de mi vida”.

Oswaldo Andrés Ordóñez Bolaños

RESUMEN

La electroencefalografía es una técnica exploratoria basada en el registro de la actividad eléctrica del cerebro. Por una parte, hoy en día, su práctica se ha hecho más común en el campo de la ingeniería y su uso ha traído grandes avances en el campo de la neuro-rehabilitación de diferentes extremidades del cuerpo humano. Por otra parte, se ha realizado un gran trabajo en el análisis de esta señal reconociendo actividad cerebral para el desarrollo de interfaces cerebro-computador (BCI).

Diversos estudios han comprobado que las emociones humanas se pueden determinar por medio de señales medidas sobre el cuero cabelludo (EEG), éstas se han utilizado en la realización de diferentes tipos de interfaz cerebro-computador (BCI), diagnóstico de pacientes, reconocimiento de emociones, reconocimiento de acciones, etc. No obstante, aunque se han desarrollado diversos estudios, la determinación de un método que sea óptimo para la identificación de emociones a partir de señales EEG, considerando aspectos como precisión, coste computacional, y aplicaciones en tiempo real, es aún un problema abierto.

Uno de los grandes problemas que se tiene en cuenta en el momento de clasificar este tipo de señales es que las emociones medidas poseen un alto grado de similitud entre ellas, generando una mayor dificultad en el momento de diferenciarlas.

Con este estudio se establece aspectos importantes para la comparación y selección de técnicas de análisis de señales EEG y, además, se propone un método con un buen porcentaje de desempeño para la realización de la ardua tarea del reconocimiento de emociones a través de señales de electroencefalograma.

ABSTRACT

Electroencephalography (EEG) is a scanning technique based on the recording of electrical activity in the brain. Nowadays, on one hand, its practice has become more common in the field of engineering and its use has brought great advances in the field of neuro-rehabilitation of different limbs of the human body. On the other hand, several works have been developed for EEG signal analysis, aimed at recognizing brain activity for the development of brain-computer interfaces (BCI).

As well, studies have shown that human emotions can be determined by means of signals measured on the scalp, which have been used in the design of different types of brain-computer interface (BCI), computer-aided diagnosis systems, recognition of emotions, and automatic interpretation of actions/movements, among others. Nonetheless, despite several studies have been proposed, finding or selecting a method being optimal for the identification of emotions from EEG signals -taking into account aspects such as accuracy, computational cost and applications in real time- remains an open issue.

One of the main problems faced when classifying this type of signals is the nature of the emotions-driven signals, since they may be greatly similar to each other, and therefore the task of differentiating emotions is not trivial but challenging.

This study aims to establish important aspects for the comparison and selection of EEG signal analysis techniques. As well, it is intended to propose a method reaching a good percentage of performance at the task of recognizing emotions through EEG signals.

TABLA DE CONTENIDO

INTRODUCCIÓN	16
Justificación.....	19
Contribuciones de esta tesis.....	19
Organización del documento	20
Objetivos específicos.....	20
Marco teórico	21
Emociones	21
Reconocimiento de emociones camino por explorar	22
Reconocimiento de emociones por medio de señales de electroencefalografía	22
Electroencefalografía (EEG)	23
Recolección de datos.....	27
A Database for Emotion Analysis using Physiological Signals (DEAP)...	27
Mahnob-hci-tagging Database	28
APRENDIZAJE DE MAQUINA: TÉCNICA PARA CLASIFICAR DATOS EEG	28
Reconocimiento de patrones	28
Extracción de características	29
Métodos de extracción de características	30
Selección de características.....	31
Balanceo de datos	32
Smote (Técnicas de sobre muestreo de minorías sintéticas)	33
Clasificación:	33
Clasificación supervisada	33
Clasificación no supervisada	34
Estado del arte en métodos de extracción y clasificación.	34
1. METODOLOGIA	38
1.1. Señales EEG.....	38
1.2. Pre-procesamiento	39
1.3. Descomposición de señales.....	39

1.4. Caracterización	42
Fuente: Creación propia	43
1.5. SELECCIÓN DE CARACTERISTICAS.....	43
1.6. Balanceo de muestras con smote (synthetic minority oversampling.....	44
1.7. Clasificación.....	44
2. MARCO EXPERIMENTAL.....	45
2.1. Medidas de desempeño	45
2.2. Pruebas aplicadas sobre la base de datos.....	45
3. RESULTADOS.....	48
6.1 Interfaz de visualización de resultados	56
4. CONCLUSIONES	62
REFERENCIAS.....	77
ANEXOS.....	82

LISTA DE FIGURAS

Figura 1. Grafica del modelo dimensional de Roussel con Aurosal – Valence y su relación con emociones discretas. Fuente: [24].	23
Figura 2. Sistema de ubicación de electrodos 10 – 20. Fuente: [29].	¡Error! Marcador no definido.
Figura 3. Tipo de onda delta, eje X tiempo en segundos. Fuente: [30].	25
Figura 4. Tipo de onda tetha. Fuente: [30].	25
Figura 5. Tipo de onda alfa. Fuente: [30].	26
Figura 6. Tipo de onda beta. Fuente: [30].	26
Figura 7. Tipo de onda gamma. Fuente: [30].	27
Figura 8. Esquema general de un sistema de reconocimiento de patrones. Fuente: Está investigación.	29
Figura 9. Metodología para el reconocimiento de emociones sobre señales EEG. Fuente: Esta investigación.	38
Figura 10. Ubicación de la media de los estímulos en el plano excitación vs valencia tomando las cuatro clases en las que se etiquetan los 1280 registros (LALV, HALV, LAHV, HAHV). Fuente: Esta investigación	39
Figura 11. Descomposición de una señal EEG en 12 IMFs usando ICEEMD.	41
Figura 12. Medidas de desempeño con la matriz DWT para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.	48
Figura 13. Medidas de desempeño con la matriz MODWT para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.	49
Figura 14. Medidas de desempeño con la matriz ICEEMD para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.	50
Figura 15. Medidas de desempeño con la matriz [DWT MODWT ICEEMD] para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.	50
Figura 16. Medidas de desempeño con la matriz MFCC para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.	51
Figura 17. Medidas de desempeño con la matriz HHT-IMFs para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.	52
Figura 18. Medidas de desempeño para canales EEG con matriz de ICEEMD.	52
Figura 19. Medidas de desempeño para canales EEG con matriz de MODWT.	53
Figura 20. Medidas de desempeño para canales EEG con matriz de DWT.	53
Figura 21. Medidas de desempeño para canales EEG con matriz de HHT-IMFs.	54
Figura 22. Medidas de desempeño para canales EEG con matriz de MFCC.	55
Figura 23. Primera etapa de la interfaz de visualización de resultados con carga de datos y normalización.	57
Figura 24. Segunda etapa de la interfaz de visualización de resultados con selección del método de descomposición – extracción y selección de wavelet madre para el caso de DWT y MODWT.	58

Figura 25. Tercera etapa de la interfaz donde se realiza el proceso de selección, balanceo y clasificación. Se puede modificar el número de iteraciones para el clasificador y el valor de los pesos para la selección.	59
Figura 26. Resultados totales en términos de Se, Sp y Acc para las 4 clases.	59
Figura 27. Mejores resultados del proceso para cada clase en términos de Acc y tiempo (s).....	60
Figura 28. Interfaz general donde podremos observar la ubicación del manual e información de los autores.....	60

LISTA DE TABLAS

Tabla 1. Niveles de descomposición transformada wavelet discreta.....	30
Tabla 2. Estado del arte de métodos de caracterización de señales EEG para detección de emociones. Fuente: Anexo 2.	35
Tabla 3. Estado del arte de métodos de clasificación usados en señales EEG para detectar emociones. Fuente: Anexo 2.	37
Tabla 4. Parámetros del algoritmo ICEEMD.	40
Tabla 5. Formulación matemática de las características representativas para EEG	43
Tabla 6. Tiempo (s) empleado para los diferentes clasificadores en los experimentos del 1-6 teniendo en cuenta el número de características.	55
Tabla 7. Comparación de los resultados obtenidos en este trabajo con respecto al trabajo de Xianf Jie et.	56

LISTA DE ANEXOS

ANEXO 1. Implementación del código de pre-procesamiento y procesamiento de señales EEG para la detección de emociones.....	69
ANEXO 2. Artículo II Jornadas Internacionales de Investigación Científica UTN.	76
ANEXO 3. Certificados de asistencia a ponencia en la UTN.....	89
ANEXO 4. Participación como ponentes en la I feria de tecnología – Universidad Politécnica Estatal del Carchi 16 de abril del 2018.....	90
ANEXO 5. Publicación aceptada en IEEEEXPLORE para el evento: LASCAS 2019 - Latin American Symposium on Circuits and Systems.	92
ANEXO 6. Publicación condicionalmente aceptada en SPRINGER para el evento: 11th Asian Conference on Intelligent Information and Database Systems.....	93
ANEXO 7. Página web.....	94
ANEXO 8. Certificados ponentes en la Zona suroccidental IEEE COLOMBIA 2018	95

GLOSARIO

Frecuencia de muestreo: Se refiere a la cantidad de muestras por unidad de tiempo tomadas de una señal continua para producir una señal discreta.

Inteligencia artificial: Es un área multidisciplinaria que combina diferentes áreas como la computación y la lógica, cuyo objetivo es dar a la maquina la capacidad de resolver problemas o realizar tareas por sí mismos, utilizando algoritmos y paradigmas de comportamiento humano.

Clase: Agrupación de objetos que tiene características comunes.

Características: Se refiere a los atributos que describen las instancias del conjunto de datos.

Algoritmo: Conjunto definido de reglas o procesos que llevan a la solución de un problema en un número determinado de pasos.

Pre-procesamiento: Es un proceso donde se filtra información de las bases de datos usando diferentes mecanismos como el filtraje, normalización, entre otros.

Selección de características: Hace referencia al proceso de elegir información relevante de un conjunto de datos

Big data: Big data, macrodatos o datos masivos es un concepto que hace referencia al almacenamiento de grandes cantidades de datos y a los procedimientos usados para encontrar patrones repetitivos dentro de esos datos.

Dimensión: En términos generales la dimensión de una base de datos es definida como la cantidad de mediciones, características o atributos tiene cada registro.

Interfaz cerebro-computador: Es una tecnología que se basa en la adquisición de ondas cerebrales para luego ser procesadas e interpretadas por una máquina u ordenador.

Interacción persona-computadora: es la disciplina que estudia el intercambio de información mediante software entre las personas y las computadoras.

Electrodos AgCl Activos: El electrodo es un conductor eléctrico utilizado para hacer contacto con una parte no metálica de un circuito, al ser activo puede ser aplicado en un punto determinado para producir estimulación y plata clorada (AgCl) es el material que proporciona señales excelentes, baja polarización y se pueden utilizar para registros de corriente continua si se desea.

INTRODUCCIÓN

Las emociones son estados afectivos que experimentan los seres humanos como respuesta a un hecho específico que puede ser visual, auditivo, físico o psicológico, los cuales han sido denominadas por personajes del ambiente científico como el muro o diferencia que separa a los seres vivos de las máquinas. Según la Real Academia de España (2017), las emociones pueden definirse como una “alteración del ánimo intensa y pasajera, agradable o penosa, que va acompañada de cierta conmoción somática”, de dicha definición se puede extraer que las emociones son estados mentales además de afectivos. El ser humano es capaz de sentir 6 categorías básicas de emociones: Miedo, sorpresa, aversión, ira, alegría o felicidad, y tristeza.

Recientemente, se han mostrado buenos resultados en procesos de interfaces cerebro computadora (BCI) capacitando a las máquinas en temas como el comportamiento del cerebro humano. Para realizar dicha capacitación o aprendizaje de máquina, se han hecho investigaciones en el reconocimiento de expresiones faciales y análisis sobre la voz, teniendo en cuenta que el humano es capaz de reconocer estas emociones con un 70-98% de precisión y las computadoras en especial con el reconocimiento facial (80-90%). Sin embargo, es importante tener en cuenta que estos altos índices de precisión o éxito se encuentran bajo circunstancias muy controladas y será menor en situaciones o ambientes reales.

Desde otro punto de vista, la electroencefalografía o EEG es una exploración de manera segura que posibilita el muestreo en forma de señal de la actividad eléctrica del cerebro medida sobre el cuero cabelludo con electrodos no invasivos, el cual arroja como resultado señales que pueden mostrar tanto anomalías en la salud como también acciones o sentimientos que experimenta el paciente. Desde su creación se ha buscado hacer cada vez una mejor interpretación en estas señales en aspectos como detección de estados emocionales, detección de la voluntad de las personas para realizar acciones con diferentes partes de su cuerpo, o en el reconocimiento de estas señales en pacientes sanos y pacientes con enfermedades neuronales para el respectivo diagnóstico y control de trastornos mentales.

Las señales EEG generalmente son tomadas con rango en escala de micro-voltios y con frecuencias de hasta 300 Hz. En diversos estudios sobre la adquisición de este tipo de señales, se ha reportado que el rango para la detección de emociones en señales EEG se divide de la siguiente manera: Delta (0.5 a 4 Hz) que se asocian con el sueño profundo, Teta (4 a 8 Hz); las cuales normalmente se asocian con las primeras etapas de sueño, Alfa (8 a 13 Hz) que se presentan en estado de reposo y con los ojos cerrados, Beta (13 a 30 Hz) que están presentes

cuando la persona se encuentra en una etapa de sueño nulo; donde se está despierto y consciente, y Gamma (30 a 70 Hz) de las que se ha teorizado que podría

n estar implicadas en el proceso de percepción consciente.

En este orden de ideas, se observa la factibilidad de aplicar aprendizaje automático sobre señales de electroencefalografía para realizar la detección de emociones, por motivo de que estas son consideradas estados mentales a respuesta de estímulos externos e internos que afectan de alguna manera en la vida real del paciente. Diversos autores ya han logrado la detección de estados emociones con señales EEG con precisión que está entre 75% y 90%.

En este trabajo, se realiza un estudio sobre la detección de emociones utilizando la base de datos DEAP, la cual contiene señales de EEG y valores de excitación – valencia que relacionaran estas señales fisiológicas con estados emocionales. Esta base de datos fue tomada con ayuda del Biosemi active II con electrodos activos para la adquisición de señales fisiológicas. Con este equipo, se registraron señales fisiológicas incluyendo ECG, EEG (32 canales), amplitud de respiración y temperatura de la piel mientras se mostraban los estímulos a los participantes.

Línea de investigación: Tratamiento de señales.

Planteamiento del problema

La toma de señales de electroencefalografía es actualmente un procedimiento diagnóstico o comercial muy común, actualmente se realizan diversas investigaciones y aportes tecnológicos en esta área, significando a la tarea de adquisición de señales EEG cada vez más sencilla y accesible. Existen diferentes elementos o mecanismos de toma de datos, cuya diferencia radica en el compromiso entre la exactitud de sus mediciones, su ergonomía y coste, de forma que, dependiendo de los intereses, estas señales se pueden ajustar a diversas aplicaciones y contextos. Respectivamente, es importante mencionar que el trabajo con señales de electroencefalografía no se limita a la toma de este tipo de señales o datos, sino que además trae consigo nuevos retos de investigación o de desarrollo computacional para ingenieros dedicados a este campo, dando la oportunidad de realizar exploraciones más a fondo en aplicaciones de tipo médico, industrial, comercial o científico.

Empresas como Biosemi y Emotiv han puesto sus esfuerzos en realizar cada vez más accesibles y precisas la adquisición de señales cerebrales, las cuales brindan a la comunidad científica la instrumentación necesaria para sus trabajos de investigación, haciendo tomas cada vez más claras y facilitando así el trabajo para sus diferentes aplicaciones.

Ahora partiendo de que el estudio de las emociones, en sí mismo, es uno de los mayores intereses de investigadores de la historia para entender el comportamiento del ser humano, estas también son estados mentales que pueden ser medibles por equipos como el Biosemi Active II en forma de señal eléctrica, concepto clave para el desarrollo de esta investigación.

En el camino de la detección de emociones por medio de señales de electroencefalografía, aún hay retos científicos, tecnológicos y matemáticos a

enfrentar relacionados con la caracterización y clasificación de este tipo de señales; debido a que las emociones son muy diversas y además de poseer un alto grado de similitud entre ellas, éstas necesitan de un arduo proceso de aprendizaje automático al ser un problema multiclase.

Justificación

En los últimos años, los esfuerzos de investigación en Human Computer Interaction (HCI) se centran en los medios para enseñar a las computadoras en reconocer emociones humanas. Las emociones son una de las características más importantes de los seres humanos y más influyentes en el desarrollo laboral de cada persona. Gracias a éstas es que la brecha de la comunicación entre seres humanos y robots inteligentes es aún muy grande. Es decir que, sin la capacidad de procesamiento de las emociones, las computadoras no pueden comunicarse con el usuario de manera natural. En este sentido, se desarrolla este trabajo con el fin de identificar los métodos automáticos que logren a partir de señales fisiológicas provenientes del cerebro, clasificar e identificar emociones, alcanzando un equilibrio entre precisión y costo computacional que abra caminos para nuevos desarrollos científicos en ingeniería computacional. El trabajo se realizó en base a un completo repositorio llamado DEAPdataset, que mide señales EEG de 32 pacientes con el fin de detectar emociones.

En conclusión, este trabajo representa un aporte a la comunidad científica y académica en el área de procesamiento de señales fisiológicas, específicamente, en el análisis de señales EEG para clasificar emociones y, además, se resalta su grado de influencia en aplicaciones médicas, juegos basados en EEG o estudios de mercado. Además, a nivel formal y técnico, las formulaciones matemáticas y los algoritmos explorados y desarrollados, representan una contribución en la investigación básica de la misma área.

Contribuciones de esta tesis

La mayor diferencia que hay entre los seres humanos y los sistemas computacionales actuales, es la capacidad de comunicarse en un lenguaje natural generando una interacción fluida y auto sostenible con el entorno, por esta razón, los proyectos que busquen por medio de aprendizaje automático que las computadoras sean capaces de detectar e identificar emociones, llevaran a la teoría de que es posible lograr computadoras emocionales. La metodología aplicada en este proyecto consiste en realizar diferentes pruebas en el análisis de señales EEG y hacer su relación con las emociones, de forma que se evalúan diversas maneras de pre procesar, caracterizar, extraer y clasificar señales EEG.

Además, la metodología propuesta sirve de base para trazar caminos hacia dónde deben enfocarse futuros estudios sobre clasificación de EEG aplicada a identificación de emociones.

En el campo de investigación de señales EEG, este trabajo representa un aporte importante que puede contribuir para el desarrollo de nuevas investigaciones y el entendimiento de la naturaleza de estas señales, en la detección de diferentes patrones que se asocian a la actividad cerebral como enfermedades, pensamientos o impulsos mentales que sean representables en potenciales eléctricos medibles como señales EEG.

Organización del documento

Este trabajo está dividido en **7 secciones** principales nombradas de la siguiente manera: Introducción, descripción del problema, objetivos, marco teórico, metodología, resultados y conclusiones.

En la **Sección 1**, se presenta el planteamiento del problema, la justificación de este trabajo y las contribuciones científicas de esta investigación.

En la **Sección 2**, se presenta el objetivo general y los objetivos específicos, que fueron planteados al inicio de este trabajo de grado.

En la **Sección 3**, se presenta una revisión bibliográfica donde el lector podrá encontrar la definición de las emociones, y su relación con las señales de electroencefalografía. Además, se explica las implicaciones de trabajar con estas señales por medio de aprendizaje de máquina y reconocimiento de patrones.

En la **Sección 4**, se describe la metodología para la detección de emociones por medio de señales EEG con 11 experimentos. El marco experimental se discute en la **Sección 5**.

Finalmente, después de discutir los resultados en la **Sección 6**, la **Sección 7** presentan las conclusiones que se obtuvieron a partir de este trabajo y trabajos futuros que pueden mejorar la metodología de visualización propuesta.

Objetivo general

Realizar un estudio comparativo de diferentes técnicas de caracterización y clasificación automática en señales de electroencefalografía para reconocer emociones, de forma que se alcance un buen equilibrio entre precisión y costo computacional.

Objetivos específicos

- Establecer un conjunto de características de señales EEG de tipo morfológico, espectral, de representación, basado en teoría de la información y estadístico que representen adecuadamente emociones.

- Implementar clasificadores basados en modelos, densidades y heurísticas en entornos de programación de alto nivel para ser evaluados con características de señales EEG.
- Diseñar una metodología de comparación de técnicas de caracterización y clasificación de señales EEG orientadas a la identificación de emociones con el fin de determinar cuáles de las técnicas alcanzan un buen compromiso entre precisión y costo computacional.

Marco teórico

En el siglo XXI, uno de los más grandes objetivos en la interacción hombre-máquina (HMI) ha sido encontrar una comunicación natural entre los computadores y el ser humano, a través de la computación afectiva. Las nuevas tecnologías han permitido que, más allá de la interacción existente a través de teclado, ratón y hardware informáticos, surjan nuevas modalidades de comunicación entre un ordenador y el usuario que lo maneja. Es por eso que el camino con el que se propone que el computador consiga entender de alguna manera el estado emocional del ser humano con el que interacciona, será una luz para que las interacciones y el intercambio de información con las maquinas cambie definitivamente.

Emociones

¿Qué es la felicidad? ¿Qué es el miedo? ¿Son sólo palabras o hay algo más que entender? Inicialmente se sabe que la ira, felicidad y miedo son emociones. ¿Pero qué son realmente las emociones?

Generalmente, suele creerse que las emociones corresponden a experiencias corporales naturales que luego se expresan a través del lenguaje, y ese lenguaje, a su vez, suele calificarse como irracional y subjetivo. Aun así, históricamente buscarles una definición exacta a las emociones ha sido un problema que ha intrigado a los más antiguos filósofos y científicos. Según Aaron Sloman, investigador de inteligencia artificial, la necesidad de sobrevivir a un mundo que cambia y que es parcialmente impredecible hace necesario que cualquier sistema inteligente (natural o artificial) con motivos múltiples y capacidades limitadas requiera el desarrollo de emociones para sobrevivir. Linda Davidoff, replica que las emociones se constituyen mediante los mismos componentes subjetivos, fisiológicos y conductuales que expresan la percepción del individuo respecto a su estado mental, su cuerpo y la forma en que interactúa con el entorno. Definiciones importantes que infieren que un sistema de inteligencia artificial necesita de las emociones para sobrevivir a un entorno, y que éstas mismas obedecen a

características fisiológicas del ser humano; motivantes importantes para esta investigación.

Sin embargo, uno de los más grandes problemas que hay en la incertidumbre de las emociones es el grado de subjetividad y parecido entre ellas. Una emoción resulta, una experiencia subjetiva, y la capacidad para comunicar este estado emocional está altamente limitada por la fisiología del sujeto, experiencias previas y diferentes factores que definen las emociones de formas diferentes según la manera de hablarlas o expresarlas. Sabiendo eso, esta incertidumbre puede causar en los datos auto informados un gran problema de precisión y generalización debido a la varianza introducida por estas incertidumbres. Pese a eso, la psicología moderna ha dedicado diversos intentos para darle una noción universal a las emociones buscando explicar el comportamiento de algunos datos y así reducir la incertidumbre que genera precisión y efectividades bajas.

Reconocimiento de emociones camino por explorar

En la interacción entre las personas, por las diversas maneras que existen de comunicar las emociones, suele producirse una falsa interpretación en éstas. Este hecho genera pérdida de información o una situación en la cual la relación entre las personas se afecte. Un ejemplo claro de esto puede ser cuando hay comunicación entre el doctor y paciente, empleado y empleador o un caso más natural como el padre e hijo. Por estas razones es que el comprender emociones se ha convertido en una herramienta necesaria para el éxito en la comunicación y desarrollar sistemas que puedan reconocer las emociones minimizando su falsa interpretación uno de los mayores objetivos de grandes investigadores de HMI.

Hay diversos sistemas que lo aplican en diferentes ámbitos como por ejemplo: seguridad, educación, enseñanza, pero en definitiva la aplicación más popular es en Brain Computer-Interface(BCI).

Los sistemas de reconocimiento de emociones son sistemas biométricos que identifican de manera automática mediante el reconocimiento de los caracteres fisiológicos de las personas. Siendo tan valiosos porque son capaces de aprender y predecir a partir de las características de una base de datos que nos entregará resultados retroalimentados.

Reconocimiento de emociones por medio de señales de electroencefalografía

La investigación en human computer-interaction ha ideado diversas maneras de clasificar emociones. En primera instancia están las emociones discretas, las cuales estudian las emociones de manera específica (por ejemplo: Miedo,

felicidad, ira, tristeza, etc.) y a cada una se les asigna un parámetro fisiológico único.

Y está la perspectiva dimensional; inspirada en el modelo de emociones tridimensionales de Schlosberg (1952, 1954), donde se trabaja la tensión del sueño, atención – rechazo y agrado-desagradable, Russell presentó en 1980 un trabajo donde las emociones se caracterizan en dos dimensiones. Según este modelo, las emociones se analizan a partir de su posición bidimensional observada en la **Figura 1**, la cual es compuesta por dos ejes de excitación en el plano vertical y dos ejes de valencia en el horizontal.

Excitación se refiere al nivel de activación cuantitativa que va desde tranquilo a emocionado y **Valencia** representa la calidad de una emoción que va desde desagradable hasta agradable.

Algunos investigadores partiendo de este modelo, proponen un modelo 3D donde se añade la dominancia, la cual se refiere a la medida que tenga una persona para estar en control ante una situación, partiendo desde débil hasta fuerte.

Figura 1. Grafica del modelo dimensional de Roussel con Aurosal – Valence y su relación con emociones discretas.



Fuente: M. M. Bradley y P. J. Lang, «Measuring emotion: The self-assessment manikin and the semantic differential», J. Behav. Ther. Exp. Psychiatry, vol. 25, n.º 1, pp. 49-59, mar. 1994.

Electroencefalografía (EEG)


Siendo las emociones estados mentales, éstas se manifiestan al igual que otras experiencias mentales, como el resultado de una actividad nerviosa en el cerebro,

por esta razón es posible identificar emociones por medio de señales de electroencefalografía.

Las señales de electroencefalografía o también llamadas “La ventana de la mente” permiten la observación cercana de lo que nos sucede dentro del cerebro.

Descubiertas por Hanz Berger en 1924, la Electroencefalografía convencional (EEG) mide la actividad eléctrica generada por el cerebro a través de la lectura de un electrodo de superficie en el cuero cabelludo. Estas señales crean un patrón cognitivo de activación único que hace que la señal oscilante de los electrodos sea la manifestación eléctrica de la actividad cerebral. Estas son medidas por densidad haciendo que la ubicación de los electrodos y su espacio entre ellos sea circunstancial para una lectura coherente. Para reducir la incertidumbre de ubicación se introdujo el estándar llamado “sistema 10 – 20” visualizado en la **Figura 2**, encargado de la colocación de los electrodos basándose en referencia universales del cráneo humano, este método de ubicación consiste en que el primer electrodo debe estar separado del punto de referencia con una distancia de $1/10$ de la distancia total de un punto de referencia a otro mientras que los demás deben estar a $1/5$ de la distancia total. Otra alternativa a la ubicación de los electrodos es el sistema desarrollado por Sociedad Americana de Electroencefalografía (AES) llamado el sistema del 10%, este siguiendo los principios del sistema 10-20 incrementa su resolución con el mismo enfoque y denominación de los electrodos.

Figura 2. Sistema de ubicación de electrodos 10 – 20.




Las señales EEG dependen del grado de actividad de corteza cerebral midiéndose en voltaje en función de tiempo y clasificándose acorde a su frecuencia, magnitud, morfología de onda, distribución espacial y reactividad.

La manera más común de clasificaciones de estas señales es acorde a su frecuencia de banda, descomponiéndose en 5 sub bandas que se asocian a un estado mental descrito a continuación:

Onda delta (δ)

Las ondas delta se encuentran en el rango de frecuencia de 0-4 Hz, teniendo la mayor amplitud de onda y midiéndose en <100 micro volts. Estas señales se detectan durante el sueño profundo y más comúnmente en niños ya que con el tiempo se tiende a producir menos ondas de este tipo.

Por otro lado, este tipo de onda se relaciona sobre todo con actividades corporales de las que no somos conscientes, como la regulación del ritmo cardíaco o la digestión.



Fuente: S. Qureshi, Sohaib, y T. Ahmad, «An empirical study of machine learning techniques for classifying emotional states from EEG data.», 2012.

Ondas theta (θ)

Las ondas theta se encuentran en el rango de frecuencia de 4-8 Hz se relaciona con capacidades imaginativas, reflexión y sueño. Se observan durante tareas de memoria a corto plazo y cuando experimentamos emociones muy profundas.




Fuente: s. qureshi, sohaib, y t. ahmad, «an empirical study of machine learning techniques for classifying emotional states from eeg data.», 2012.

Ondas Alfa (α)

Las ondas alfa se encuentran entre el rango de frecuencia de 8-13 Hz, estas ondas se originan en el lóbulo occipital del cerebro durante el crepúsculo intermedio donde hay calma y relajación, pero no sueño.

Figura 5. Tipo de onda alfa.




Fuente: S. Qureshi, Sohaib, y T. Ahmad, «An empirical study of machine learning techniques for classifying emotional states from EEG data.», 2012.

Onda Beta (β)

Las ondas beta están presentes entre los rangos de frecuencia de 13-30 Hz y se asocian con el pensamiento ansioso y la concentración activa que se originan en el área central del cerebro.

Figura 6. Tipo de onda beta.




Fuente: S. Qureshi, Sohaib, y T. Ahmad, «An empirical study of machine learning techniques for classifying emotional states from EEG data.», 2012.

Onda Gamma (γ)

Las ondas gamma se encuentran entre los rangos de frecuencia de 30-100Hz. Es un tipo de onda que se origina en el tálamo y se mueve desde la parte posterior del cerebro hacia adelante a una velocidad muy alta. El estado mental asociado

con estas ondas es multitarea con un alto procesamiento cognitivo y estado de vigilia.

Figura 7. tipo de onda gamma.



Fuente: S. Qureshi, Sohaib, y T. Ahmad, «An empirical study of machine learning techniques for classifying emotional states from EEG data.», 2012.

Recolección de datos

Aunque el objetivo del presente trabajo no este enfocado a la recolección de las señales de electroencefalografía, es importante en el marco de la investigación dar una breve revisión a las dos bases de datos más relevantes que recolectan señales EEG con el objetivo de reconocimiento de emociones.

A Database for Emotion Analysis using Physiological Signals (DEAP)

Esta base de datos presenta un análisis multimodal para el análisis de estados afectivos por medio de señales EEG y otras señales fisiológicas como presión del volumen sanguíneo (BVP), electromiografía (EMG), electrooculograma (EOG), respuesta galvánica de la piel (GSR), temperatura y respiración.

DEAPdataset contiene un registro de señales fisiológicas usando el equipo Biosemi ActiveTwo system de 32 pacientes, los cuales cada uno observa 40 extractos de videos musicales para después calificarlos en términos de los niveles de excitación, valencia, gusto / disgusto, dominio y familiaridad. Para 22 de los 32 pacientes también se grabó un video frontal.

Las señales EEG en esta base de datos registran un muestreo de 512 Hz usando 32 electrodos AgCl activos y ubicados según el sistema internacional 10-20.

Mahnob-hci-tagging Database

MANHOB-HCI es una base de datos multimodal que tiene como objetivo el reconocimiento de emociones por medio de señales de EEG, medidas fisiológicas como electromiografía (EMG), respuesta galvánica de la piel (GSR), temperatura de la piel, amplitud de la respiración y Eye gaze data de 27 pacientes. 11 hombres y 16 mujeres con diferentes características culturales y raciales participan en dos experimentos para la recolección de datos. En el primer experimento, cada paciente observa 20 videos emocionales para después auto informar sus emociones en función de una palabra clave de emoción sentida, excitación, valencia, dominancia y previsibilidad. El segundo experimento, se mostraron 28 imágenes y 14 videos cortos en primera medida sin ninguna etiqueta y luego con etiquetas correctas o incorrectas. El acuerdo o desacuerdo con las etiquetas mostradas fue la evaluación realizada por los participantes.

Usando el Biosemi active II system con electrodos AgCl activos, se recolectan los 32 canales EEG con un muestreo de 256 Hz ubicándose acorde al sistema de organización de electrodos 10-20.

APRENDIZAJE DE MAQUINA: TÉCNICA PARA CLASIFICAR DATOS EEG

El aprendizaje de máquina es un campo de estudio interdisciplinar y rama de la inteligencia artificial, encargado del desarrollo de programas de computadora y estudio de sistemas, en los cuales se mejoran los desempeños de algunas tareas mediante muestras de datos conocidos que aprenden a través de la experiencia. Aprender en este contexto significa identificar patrones complejos en millones de datos. Además, basa su importancia en la creación de programas que generalicen comportamientos y encuentren reglas de predicción de modo que sea posible identificar patrones y tomar decisiones con mínima intervención humana.

Existen diferentes técnicas de aprendizaje automático para clasificar señales de EEG con sus ventajas y desventajas. En el **Anexo 2**, un estudio extenso del estado del arte muestra como clasificadores más populares con señales de electroencefalografía para detección de emociones a las Máquinas de vectores de soporte (SVM), redes neuronales artificial y k vecinos más próximos (KNN).

Reconocimiento de patrones

Antes de analizar la definición directa de reconocimiento de patrones, necesitamos entender a qué se refiere un patrón. Este según la definición de Watanabe [35] es una entidad a la que se le puede y que está representada por un conjunto de propiedades medidas y las relaciones entre ellas (vector de características). Un

ejemplo claro podría ser una imagen de rostro humano del cual se extrae el vector de características formado por un conjunto de valores numéricos calculados en sus píxeles.

El reconocimiento automático, descripción, clasificación y agrupamiento de patrones es la ciencia que se ocupa de los procesos sobre ingeniería, computación y matemáticas relacionados con objetos físicos y/o abstractos, con el propósito de extraer información que permita establecer propiedades de o entre conjuntos de dichos objetos [36]. El reconocimiento de patrones busca imitar las capacidades cognitivas humanas para diferenciar algún objeto o fenómeno en particular de otro teniendo en cuenta información proveniente de señales del mundo exterior.


Un sistema de reconocimiento de patrones tiene como objetivos, identificar el patrón como parte de una clase ya definida (Clasificación supervisada) o asignar el patrón a una clase todavía no definida alguno de los siguientes objetivos:

- 1) Identificar el patrón como miembro de una clase ya definida (clasificación supervisada).
- 2) Asignar el patrón a una clase todavía no definida (clasificación no supervisada, agrupamiento o clustering).

Para el diseño de un sistema de reconocimiento de patrones se pueden seguir tres fases generalmente descritas a continuación y visualizadas en la Figura 8:

- 1) Adquisición y pre-procesamiento de información.
- 2) Extracción de características
- 3) Toma de decisiones o agrupamiento.

Figura 8. Esquema general de un sistema de reconocimiento de patrones.



Fuente: Creación propia.

Extracción de características

La extracción de características implica en primera instancia el reducir la cantidad de recursos necesarios para describir un gran conjunto de datos (reducción de dimensión). En segunda parte, se define como el proceso de formar un conjunto

de características (de dimensión n) partiendo de los datos de entrada (de dimensión $m > n$). Teniendo como razones principales el proveer conjuntos relevantes de características al clasificador, reducir redundancia, recuperar características latentes significativas, generar mayor comprensión en el proceso de generación de los datos, reducir costos computacionales y mejorar la tasa de generalización.

Métodos de extracción de características

Para el proceso de analizar los datos entregados por la base de datos EEG, se necesita extraer solo información relevante de las señales, por esta razón en esta investigación se trabajaron 3 tipos de descomposición que nombraremos a continuación:

Discrete Wavelet Transform (DWT)

La naturaleza de las señales EEG no son estacionarias ya que estas pueden variar rápidamente en el tiempo. Una técnica que permite modelar estos cambios en tiempo-frecuencia es la transformada wavelet discreta.

Este método ha demostrado su eficacia para el análisis de señales de EMG y ECG, pero pese a su excelente respuesta la investigación de esta técnica en señales EEG es aún por explorar. Los coeficientes DWT representan el grado de correlación entre la señal analizada y la wavelet madre en diferentes instancias de tiempo. Por lo tanto, los coeficientes extraídos de realizar la transformada wavelet discreta contienen información temporal útil sobre la actividad transitoria de la señal analizada. Cada banco de filtros es asociado a una familia Wavelet y respectivos niveles de descomposición. En la Tabla 1 podremos observar los niveles de descomposición y el rango de frecuencia de cada nivel.

Tabla 1. Niveles de descomposición transformada wavelet discreta.

Coeficientes wavelet	Rangos de frecuencia (Hz)	Bandas de frecuencia
D1	32 – 64	Gamma
D2	16 – 32	Beta
D3	8 – 16	Alpha
D4	4 – 8	Theta
D5	2 – 4	Delta
A1	0 – 2	Delta

Fuente: Creation propia.

Maximal overlap discrete wavelet transform (MODWT)

La transformada wavelet discreta anteriormente mencionada, tiene algunas limitaciones como por ejemplo el hecho de que el número de coeficientes wavelet y escala N , disminuye por un factor de 2 por cada nivel creciente de la transformada, lo que limita la capacidad de llevar los análisis estadísticos sobre los coeficientes y esto puede presentar ambigüedades en el dominio del tiempo. Ese proceso necesario de disminución de muestreo se puede evitar utilizando Maximal overlap discrete wavelet transform (MODWT) o también conocida undecimated discrete wavelet transform.

Improved Complete Mode Decomposition (ICEEMD)

Empirical Mode Descomposition es un método de extracción de características desarrollado para señales no lineales y no estacionarias, a diferencia de las descomposiciones con wavelets que se desarrollan para señales no lineales pero estacionarias.

Está técnica descompone una señal en múltiples señales llamadas IMFs. Para ser considerado como un IMF, una señal debe cumplir dos condiciones:

- i) El número de extremos (máximos y mínimos) y el número de cruces por cero deben ser iguales o diferir como máximo en uno
- ii) la media local, definida como la media de las envolturas superior e inferior, debe ser cero.

Recientemente, Colomnias propuso un método de análisis de datos asistido por ruido, específicamente ICEEMD, para abordar el problema de la mezcla de modos. Las otras ventajas de esta técnica son: menos ruido residual y mínimo error de reconstrucción en los modos y garantizar la integridad del algoritmo. ICEEMD es adecuado para el procesamiento de señales biomédicas.

Selección de características

Las señales EEG son datos altamente dimensionales que pueden contener muchas características irrelevantes. La selección del subconjunto de características es una técnica para reducir el espacio de atributos de un conjunto de características. En otras palabras, se está identificando un subconjunto de características mediante la eliminación de características irrelevantes o redundantes. Para esta investigación en la selección de características se utiliza el algoritmo de ReliefF.

El algoritmo de ReliefF pondera cada característica de acuerdo con su relevancia para la clase. El peso de cada una de las características se actualiza iterativamente de la siguiente manera:

Este algoritmo selecciona una muestra de los datos e identifican la muestra vecina más cercana que pertenece a la misma clase y la muestra vecina más cercana que pertenece a la clase opuesta. Un cambio en el valor de la característica acompañado de un cambio en la clase conduce a una ponderación del atributo basada en la intuición de que el cambio de atributo podría ser responsable del cambio de clase. Por otro lado, un cambio en el valor del atributo acompañado de ningún cambio en la clase conduce a una ponderación menor del atributo basado en la observación de que el cambio de atributo no tuvo efecto en la clase. Este procedimiento de actualización del peso se realiza para todos los datos. Las actualizaciones de peso se promedian para que el peso final esté en el rango $[-1, 1]$.

Ahora partiendo desde el punto de vista de la minería de datos y machine learning, la realización de selección y/o extracción de características de un conjunto de datos es importante por la presencia de información irrelevante (características que generan problemas de sobre-aprendizaje porque son datos que no aportan información al sistema), información redundante (características relacionadas linealmente que realizan la misma función) y la maldición de la dimensionalidad (El número de características es mayor al de datos, significando que cada característica representa una dimensión)

Balanceo de datos

Una vez se tiene la cantidad de características seleccionadas, en el proceso de la búsqueda de clasificar de manera supervisada para un conjunto de datos con diversas clases, el aprendizaje automático consiste en observar los atributos que componen estas clases y el intento de determinar o “predecir” a cuál de ellas pertenecen. El proceso de aprendizaje se lleva a cabo en dos etapas, el entrenamiento del modelo, y el proceso final de clasificación. Partiendo de datos previos conocidos, en la etapa de clasificación se determina la clase para instancias desconocidas, infiriendo la relevancia de un correcto proceso de entrenamiento. Ahora, si en el conjunto de datos, entre las clases existe una diferencia significativa en la cantidad de elementos, se definen las clases no balanceadas.

El problema de desbalanceo de clases influye significativamente en el desempeño de los clasificadores, un claro ejemplo es en el caso de Random Forest, donde este algoritmo de machine learning no lidia correctamente con conjuntos de datos

de entrenamiento desbalanceados ya que son sensibles a las proporciones de las diferentes clases.

Como alternativa al trabajo de datos desbalanceados, se expone un método de técnicas de sobre muestreo de minorías sintéticas o también llamado SMOTE.

Smote (Técnicas de sobre muestreo de minorías sintéticas)

Este es un método de muestreo, en el cual a la muestra minoritaria se le añade datos, o muestras, mediante la creación de ejemplos sintéticos en vez de usar reemplazos. Basándose en la técnica propuesta por T. M. Ha y H. Bunke para el reconocimiento de caracteres manuscritos; smote se ejecuta sobre un conjunto de instancias minoritarias creando muestras sintéticas de cada instancia del conjunto. La instancia sintética se crea teniendo en cuenta la instancia minoritaria y sus vecinos más cercanos.

Clasificación:

Clasificación supervisada

Después del proceso de extracción de características y el balanceo de clases, el uso de un clasificador es crucial para la asignación de una característica en la clase apropiada. La clasificación supervisada es aquella en la cual a partir de un conjunto de datos conocidos por la maquina (conjunto de entrenamiento), se clasifica un segundo conjunto de datos desconocido. Los algoritmos de clasificación tienen ya un conocimiento del conjunto estudiado, por lo que le es necesario utilizar datos previamente etiquetados con el fin de agrupar en el conjunto o clase que corresponda. Entre algunos ejemplos de clasificadores supervisados están:

- **K vecinos más cercanos (k-NN Nearest Neighbour)** : K-NN se basa en la idea en que los nuevos ejemplos serán clasificados a la clase a la cual pertenezca la mayor cantidad de vecinos más cercanos del conjunto de entrenamiento más cercano a él.
- **Clasificadores lineales (Linear Discriminant Classifiers analysis - LDA):** Este método de clasificación se basa en la regla de probabilidad máxima y principios bayesianos.
- **Máquina de vector soporte (Support Vector Machine – SVM):** Este método puede clasificar datos linealmente separables, es resistente al sobreajuste porque buscan una frontera de decisión específica y es eficiente en el caso no

lineal porque no crea explícitamente el espacio transformado y su transformación no lineal es implícita. Puede procesar gran número de entradas.

- **Bosques aleatorios (Random Forest)** : Este método de clasificación es una combinación de árboles predictores tal que cada árbol depende de los valores de un vector aleatorio probado independientemente y con la misma distribución para cada uno de estos.
- **Redes neuronales (Artificial Neural Networks - ANN)**: Este método se inspira en las redes neuronales biológicas. Sus características principales son la auto-organización y adaptabilidad, su procesamiento no lineal y procesamiento paralelo.

Y como alternativa, en el caso de que no se tenga las etiquetas de los datos, se implementa una clasificación no supervisada descrita a continuación:

Clasificación no supervisada

En contraste al tipo de clasificación antes nombrado, los clasificadores no supervisados son aquellos en los cuales no disponemos de una batería de ejemplos previamente clasificados, sino que únicamente a partir de las propiedades de los ejemplos intentamos dar una agrupación (**clasificación, clustering**) de los ejemplos según su similaridad, es decir, no se necesita un conocimiento a priori sobre los datos que se van a agrupar. Un común ejemplo sobre clasificadores no supervisados es:

- **K-medias**: Este método de clasificación no supervisada tiene como objetivo la partición de un conjunto de n observaciones en k grupos en el que cada observación pertenece al grupo cuyo valor medio es más cercano. La clave de este procedimiento radica en que el centroide o instancia de valor media más cercana, se calcula a partir de los miembros de cluster tras cada asignación y no al final de cada ciclo, como ocurre en otros métodos de clasificación no supervisada como el de Forgy o Jancey.

Estado del arte en métodos de extracción y clasificación.

Conociendo el proceso de aprendizaje automático por el cual las señales de EEG deben ser sometidas para la detección de emociones, se realiza un estudio del arte en búsqueda de cuales han sido los métodos de extracción de características y clasificación más relevantes en este ámbito.

Se expone una investigación exhaustiva de 14 artículos del año 2010 en adelante provenientes de revistas, libros o páginas científicas en los que se abarcan temas relacionados con la extracción de características y su respectiva clasificación para detección de emociones sobre señales EEG. Para la selección de los artículos se tuvieron en cuenta aspectos como: publicación en revista o algún medio de tipo científico, autores locales e internacionales que sean citados considerablemente en campos de ingeniería y que presenten resultados porcentuales que evidencien el grado de clasificación obtenido en sus trabajos.

De la revisión bibliográfica que será soporte para la planeación de una metodología adecuada en la **sección 4**, se expondrá a continuación en la **Figura 2**, el tipo de extracción y caracterización adoptada por los 14 autores, y en la **Figura 3** los métodos de clasificación seguidos por los mismos. En el **Anexo 2** se encontrará los resultados con respecto a precisión que se obtuvieron de cada artículo y una breve descripción de lo que pretendía hacer cada investigador con su trabajo.

Tabla 2. Estado del arte de métodos de caracterización de señales EEG para detección de emociones. **Fuente:** Anexo 2.

Métodos de caracterización																		
AUTOR \ METODO	DTW o ETW	F-score	MSCE	HOC-EC	S-EC	W-EC	LDS	Correlation coefficients	RFE Y MFE (filtros)	mRMR	ES θ	ES f ²	ES λ	Relieff	Entropía Shannon (nuevo)	Correlación cruzada	TTF con ventana hanning	PSD
Sazali et al, 2010	X																	
Lin et al, 2010		X																
Khosrowabadi et al, 2010			X															
Petrantonakis y Hadjileontiadis, 2010				X	X	X												
Sourina y Liu, 2011	PROPONE MODELO DE CARACTERIZACION: FRACTAL-BASED																	
Nie et al, 2011							X	X										
Zhang et al, 2013	X																	
Torres, 2013									X									
Jenke et al, 2014										X	X	X	X	X				
Vijayan et al, 2015															X	X		
Zheng y Lu, 2015																	X	
Montoya y Quintero, 2016	X																	
Atkinson y Campos, 2016	PROPONE MODELO DE CARACTERIZACION: FRACTAL DIMENTION																	
Nafjan et al, 2017																		X

Fuente: Creación propia.

La **Tabla 2** evidencia a DWT como el método de caracterización más popular entre los investigadores de señales EEG para detectar emociones desde el año 2010. Dato con el que trabajará esta investigación proponiendo a DWT como uno de los métodos de caracterización a utilizar.

Tabla 3. Estado del arte de métodos de clasificación usados en señales EEG para detectar emociones.

Métodos de clasificación												
AUTOR \ METODO	KNN	LDA	SVM	QDA	MD	Bayes	Estadísti co. c4.5	MCSVM	DBN	LR	DNN	
Sazali et al, 2010	X	X										
Lin et al, 2010			X									
Khosrowabadi et al, 2010	X											
Petrantonakis y Hadjileontiadis, 2010	X		X	X	X							
Sourina y Liu, 2011						X						
Nie et al, 2011			X									
Zhang et al, 2013							X					
Torres, 2013			X									
Jenke et al, 2014				X								
Vijayan et al, 2015								X				
Zheng y Lu, 2015	X		X						X	X		
Montoya y Quintero, 2016				X								
Atkinson y Campos, 2016			X									
Nafjan et al, 2017											X	

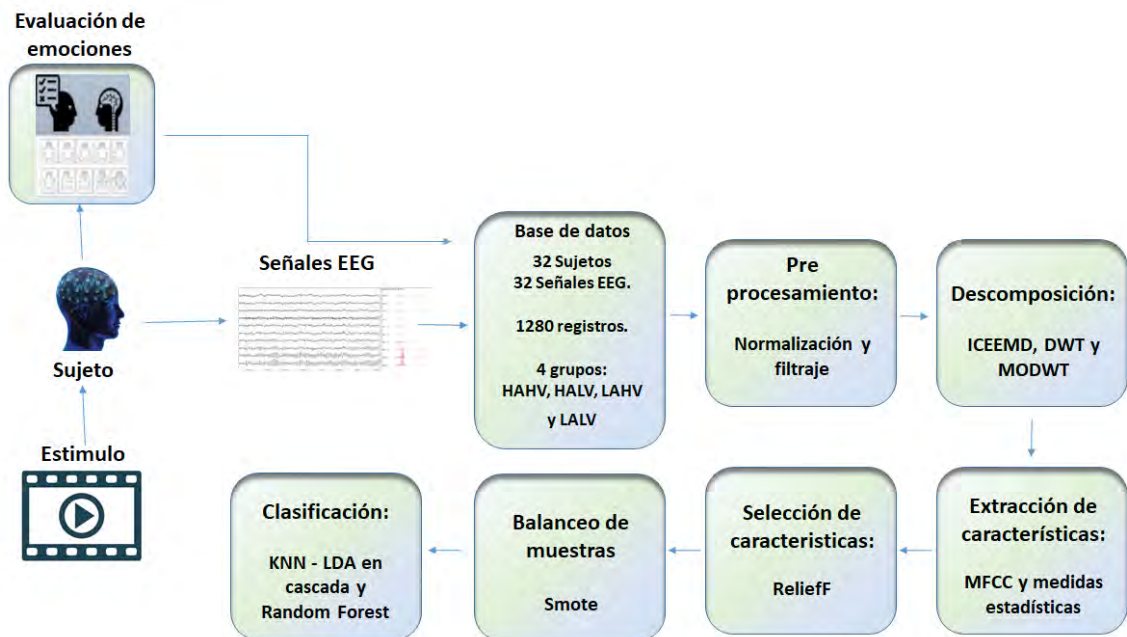
Fuente: Anexo 2.

Respecto a métodos de clasificación, la **Tabla 3** expone a **KNN**, **SVM** y **QDA**, como los clasificadores más utilizados de las investigaciones realizadas.

1. METODOLOGIA

La metodología propuesta para el tratamiento de señales con el fin de clasificar emociones sobre señales de EEG se resume en la Figura 9 y consta de las siguientes etapas: pre-procesamiento, descomposición, extracción de características, selección de características, balanceo de muestras y clasificación.

Figura 9. Metodología para el reconocimiento de emociones sobre señales EEG.

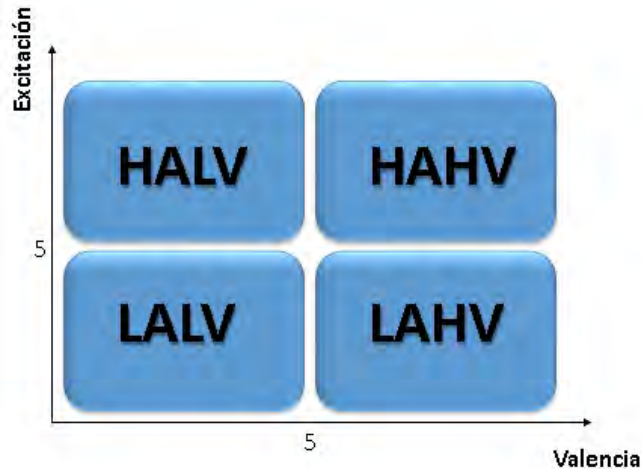


Fuente: Creación propia.

1.1. Señales EEG

Las señales utilizadas fueron extraídas de la base de datos DEAPdataset, que contiene 1280 registros con 32 señales de EEG y 8 periféricas. Los registros fueron etiquetados de la siguiente manera: baja excitación y baja valencia (LALV), alta excitación y baja valencia (HALV), baja excitación y alta valencia (LAHV), y alta excitación y alta valencia (HAHV); como se muestra en la Figura 10.

Figura 10. Ubicación de la media de los estímulos en el plano excitación vs valencia tomando las cuatro clases en las que se etiquetan los 1280 registros (LALV, HALV, LAHV, HAHV).



Fuente: Creación propia

1.2. Pre-procesamiento

Antes de someter las señales de EEG y las periféricas a un procesamiento de señales se normalizan los registros en el rango de $[-1,1]$ quitando niveles de offset con respecto a la Ecuación 1.

$$s = \frac{s - \bar{s}}{\max |S|} \quad (1)$$

Donde S representa la señal, $\max |S|$ el máximo del valor absoluto de la señal y \bar{s} es la media de la señal.

Con lo anterior se asegura que las señales no sobrepasen un cierto rango que esta entre $[-1,1]$, lo que facilita el respectivo procesamiento a seguir para las muestras, además seguido a este proceso se aplica un filtro butterworth pasa bajas de 30 Hz y sexto orden para eliminar frecuencias que no pertenecen a las ondas de EEG, que como se puede observar en la **Sección 3.2.1** son inferiores a los 30 Hz.

1.3. Descomposición de señales

Para la realización de este estudio comparativo se implementaron tres métodos de descomposición de señales que se muestran a continuación:

➤ **Descomposición en modo empírico completo mejorado (ICEEMD)**

El método ICEEMD está desarrollado para señales no lineales y no estacionarias, a diferencia de la descomposición de wavelets que se desarrolla para señales no lineales pero estacionarias. En este trabajo, las señales fisiológicas se descompusieron utilizando el algoritmo ICEEMD presentado en y se configuró con los parámetros mostrados en la **Tabla 2**. En la Figura 11 se muestran los resultados de la descomposición de una señal de EEG en 12 IMFs utilizando ICEEMD. Los tres últimos IMFs tienen muy poca energía.

Tabla 4. Parámetros del algoritmo ICEEMD.

Relación señal ruido (SNR)	Desviación estándar de ruido	Número de realizaciones	Max. iteraciones
Igual SNR para todas las etapas	0.2	50	150

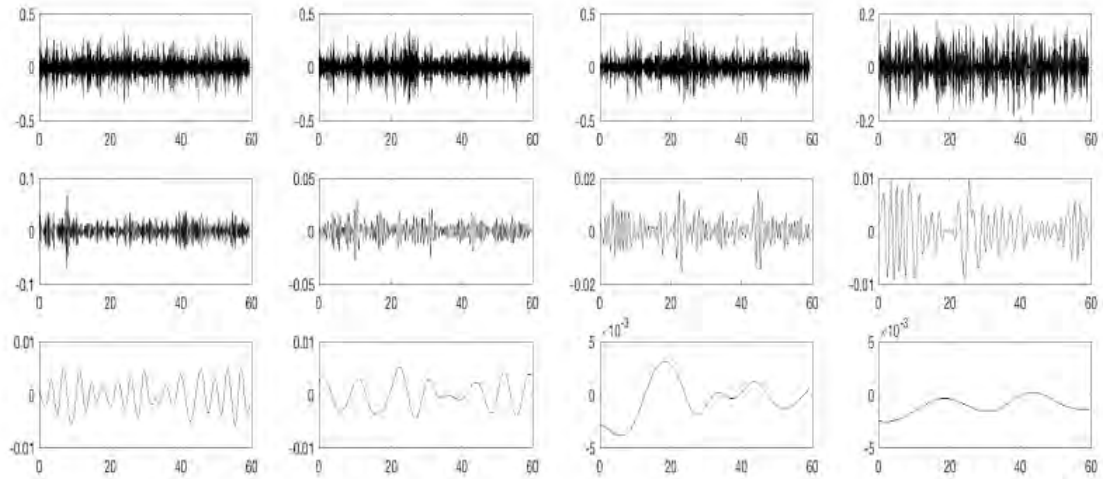
Fuente: Creación propia.

La técnica de descomposición empírica en modos descompone una señal en múltiples señales llamadas IMFs, el número de IMFs resultante de cada señal es muy variado por lo que para la extracción de características solo se toman las 7 primeras IMFs obtenidas por el método de ICEEMD. ICEEMD es adecuado para el procesamiento de señales biomédicas. Las IMFs se obtienen como se describe en la ecuación 2 donde $c_k(t)$ representa la k-esima IMF y para la primera iteración se toma $c_k(t) = x(t)$ y se encuentran los máximos y mínimos locales de $x(t)$ para obtener $m_{k,i}(t)$

$$c_k(t) = c_k(t) - m_{k,i}(t) \quad (2)$$

$$m_{k,i}(t) = \frac{1}{2} [s_+(t) + s_-(t)] \quad (3)$$

Figura 11. Descomposición de una señal EEG en 12 IMFs usando ICEEMD.



Fuente: Creación propia.

➤ **Máxima superposición de la transformada wavelet discreta (MODWT) y transformada wavelet discreta (DWT)**

MODWT ha sido considerado como una mejora de DWT. En este trabajo, las señales fisiológicas se descompusieron utilizando el algoritmo MODWT y DWT utilizando un **Daubechies 4** y una descomposición de **5 niveles** para ambas técnicas.

➤ **Transformada Wavelet Discreta (DWT)**

La transformada Wavelet Discreta (DWT) descompone recurrentemente una señal de entrada en dos sub-señales con menor resolución en cuanto a su frecuencia, estas sub-señales son consideradas como de aproximación y detalle. Las señales $S_i(n)$ y $W_i(n)$ son las señales de aproximación y detalle en el nivel i , dependiendo de los niveles en los que se desean descomponer la señal original el proceso se volverá a repetir descomponiendo nuevamente la señal $S_i(n)$ en otras nuevas señales $S_{i+1}(n)$ y $W_{i+1}(n)$ siendo estas las señales de aproximación y detalle en el nivel $i + 1$. La aproximación de la señal se puede calcular como se muestra en la Ecuación 4.

$$S_{i+1} = \sum_k g(k) S_1(2n - k) \quad (4)$$

El detalle de la señal se puede calcular como se muestra en la Ecuación 5.

$$W_{i+1} = \sum_k h(k) S_1(2n - k) \quad (5)$$

1.4. Caracterización

Debido a que las muestras EEG generan un potencial eléctrico que a su vez es extraído como un registro de señales eléctricas es posible tratarlo como un conjunto de datos complejo y dinámico que se puede representar por un conjunto de características. Teniendo en cuenta trabajos anteriores, se extraen las siguientes características que describen las señales EEG desde dos perspectivas: temporal y espectral. Desde el punto de vista espectral se utiliza: valor medio absoluto, desviación estándar, kurtosis, área bajo la curva, raíz media cuadrática (Rms), varianza, covarianza, entropía, integral cuadrática simple y entropía Shannon; y desde el punto de vista temporal se utiliza: frecuencia pico, frecuencia media y energía máxima del poder espectral. Las ecuaciones que representan estas características se encuentran en la Tabla 3.

Por otro lado, se llevaron a cabo técnicas de extracción de características como los coeficientes cepstrales de las frecuencias de Mel (MFCC) y la extracción de características sobre medidas angulares, frecuenciales y de amplitud de la transformada de HILBERT HUANG (HHT).

Se extrajeron cinco conjuntos de características de cada señal para realizar el correspondiente estudio comparativo de la siguiente manera:

- i) 70 características fueron obtenidas de 7 IMFs de cada señal, basadas en las características mostradas en la Tabla 3.
- ii) 40 características fueron obtenidas de múltiples medidas de amplitud, ángulo y frecuencia obtenidos al aplicar HHT a los IMFs.
- iii) 273 coeficientes cepstrales en las frecuencias de Mel fueron obtenidas de cada señal.
- iv) 50 características fueron obtenidas de los 5 niveles de detalle de la descomposición DWT, usando las medidas de la Tabla 3.
- v) 50 características fueron obtenidas de los 5 niveles de detalle de la descomposición MODWT, usando las medidas de la Tabla 3.

Cada vector de características es normalizado por medio de la función zscore que normaliza las señales de acuerdo a la Ecuación 6

$$Z = \frac{X - \bar{X}}{std(X)}, \quad (6)$$

donde Z es la señal resultante, X es la señal original, \bar{X} es la media de la señal y $std(X)$ es la desviación estándar de la señal.

Tabla 5. Formulación matemática de las características representativas para EEG

Característica	Formulación Matemática
Área bajo la curva	$I = \sum_{n=1}^N (X_n) $
Media	$\bar{X} = \frac{1}{N} \sum_{n=0}^N (X_n) $
Raíz media cuadrática	$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N (X_n)^2}$
Varianza	$\frac{\sum_{I=1}^N (X_I - \bar{X})^2}{N - 1}$
Desviación estándar	$\sqrt{\frac{\sum_{I=1}^N (X_I - \bar{X})^2}{N - 1}}$
Entropía energía de registro	$\sum_{X \in A} \log(X^2)$
Integral cuadrada	$I = \sum_{n=1}^N (X_n)^2$
Curtosis	$\frac{\sum_{I=1}^N (X_I - \bar{X})^2}{N}$
Covarianza	$\frac{Std^4 \sum_{I=1}^N (X_I - \bar{X})(Y_I - \bar{Y})}{N - 1}$
Entropía Shannon	$- \sum_{X \in A} p(x) \log_2 p(x)$

Fuente: Creación propia

1.5. Selección de características

Las características obtenidas de las señales EEG forman matrices altamente dimensionales las cuales contienen muchas características que tienen poca relevancia a la hora de representar las clases que se desean clasificar, y por el contrario representan información que hace que el sistema reaccione

negativamente tanto en velocidad como en eficiencia. La toma de un subconjunto más pequeño que el conjunto original se hizo de dos maneras:

- i) Selección de características tomando como criterio los pesos que se encuentran por encima del 70% del máximo peso.
- ii) Tomando las mejores 200, 400, 600 y 1200 características del conjunto original.

1.6. Balanceo de muestras con smote (synthetic minority oversampling)

Después de realizar el etiquetado para cuatro clases de los 1280 registros según los niveles de excitación y valencia obtenidos de la base de datos, es obtenido un desequilibrio en el número de muestras por clase; lo que muestra la necesidad de aplicar una técnica de balanceo en nuestra base de datos. El balanceo de muestras es llevado a cabo con el algoritmo de SMOTE que genera muestras sintéticas en las clases que se desea aumentar el número de muestras, para así equilibrar la matriz de características.

1.7. Clasificación

Como elemento clasificador es aplicado K Vecinos más cercanos (K-NN) y Análisis Discriminante Lineal (LDA) en cascada y Random Forest para los grupos de 200, 400, 600 y 1200 mejores características obtenidas por el algoritmo de ReliefF.

2. MARCO EXPERIMENTAL

En esta sección se realiza la descripción de las medidas de desempeño del clasificador sobre los diferentes conjuntos de características.

2.1. Medidas de desempeño

Para calificar el resultado de la clasificación se utilizaron las siguientes medidas de desempeño: Sensibilidad (Se), Especificidad (Sp) y porcentaje de clasificación (PC); estas medidas son calculadas con las ecuaciones 7, 8 y 9.

$$Se = \frac{Vp}{Vp+Fn} \quad (7)$$

$$Sp = \frac{Vn}{Vn+Fp} \quad (8)$$

$$PC = \frac{Vn \times Vp}{Vn+Fp+Vp+Fn} \quad (9)$$

Y los valores para calcular estas medidas son:

- Vp : Verdaderos positivos o casos de la clase de interés clasificados correctamente.
- Vn : Verdaderos negativos o casos diferentes de la clase de interés clasificados correctamente.
- Fp : Falsos positivos o casos diferentes de la clase de interés clasificados como casos de la clase de interés.
- Fn : Falsos negativos o casos de la clase de interés clasificados como casos diferentes de la clase de interés.

2.2. Pruebas aplicadas sobre la base de datos

En la metodología propuesta se explican diferentes tipos de descomposición que se aplican a las señales EEG y varias características de tipo espectral y temporal; que se combinan entre sí para crear diferentes grupos de características. De esta manera se realizan 11 pruebas para observar la reacción de los clasificadores KNN y LDA en cascada para clasificar las 4 clases propuestas en la Sección 4.1. Para cada prueba se obtienen 4 resultados porcentuales que indican el número de muestras bien clasificadas sobre el total de muestras en el clasificador por cada clase y un resultado general de clasificación que es el número de muestras bien

clasificadas sobre el total de las muestras introducidas al clasificador. Como método de selección de mejores características se aplicó el algoritmo de ReliefF.

- **Experimento 1:** Se realiza utilizando DWT como método de descomposición y se hicieron pruebas con las mejores 200, 300, 600 y 1200 características.
- **Experimento 2:** Se realiza utilizando MODWT como método de descomposición y se hicieron pruebas con las mejores 200, 300, 600 y 1200 características.
- **Experimento 3:** Se realiza utilizando ICEEMD como método de descomposición y se hicieron pruebas con las mejores 200, 300, 600 y 1200 características.
- **Experimento 4:** Se realiza combinando las características de los métodos de descomposición MODWT, DWT e ICEEMD y se hicieron pruebas con las mejores 200, 300, 600 y 1200 características.
- **Experimento 5:** Se realiza utilizando MFCC como método de extracción de características y se hicieron pruebas con las mejores 200, 300, 600 y 1200 características.
- **Experimento 6:** Se realiza utilizando transformada de HILBERT HUANG (HHT) a los IMFs obtenidos del método ICEEMD y se hicieron pruebas con las mejores 200, 300, 600 y 1200 características.
- **Experimento 7:** Se realiza utilizando ICEEMD como método de descomposición y se hicieron pruebas con las mejores características por encima del 80% de la característica con el mayor peso obtenido del análisis de relevancia por ReliefF y se hizo por cada canal.
- **Experimento 8:** Se realiza utilizando MODWT como método de descomposición y se hicieron pruebas con las mejores características por encima del 80% de la característica con el mayor peso obtenido del análisis de relevancia por ReliefF y se hizo por cada canal.
- **Experimento 9:** Se realiza utilizando DWT como método de descomposición y se hicieron pruebas con las mejores características por encima del 80% de la característica con el mayor peso obtenido del análisis de relevancia por ReliefF y se hizo por cada canal.
- **Experimento 10:** Se realiza utilizando transformada de Hilbert Huang a los IMFs obtenidos del método ICEEMD y se hicieron pruebas con las mejores características por encima del 80% de la característica con el mayor peso obtenido del análisis de relevancia por ReliefF y se hizo por cada canal.

- **Experimento 11:** Se realiza utilizando MFCC como método de extracción de características y se hicieron pruebas con las mejores características por encima del 80% de la característica con el mayor peso obtenido del análisis de relevancia por ReliefF y se hizo por cada canal.


Finalmente se realiza una interfaz de usuario que permite recrear los resultados obtenidos, en esta se podrá combinar diferentes grupos de características provenientes de diferentes métodos de descomposición y dos diferentes opciones de clasificación.

3. RESULTADOS

Por medio de tablas y figuras se exponen los resultados obtenidos de las pruebas mencionadas en la sección anterior.

- **Experimento 1:** En la Figura 12 podemos ver los resultados para las medidas de Se y Sp, en los cuatro grupos de características el clasificador KNN y LDA en cascada obtuvieron mejores resultados y en cuanto a la Se que nos indica el número de muestras de la clase de interés correctamente clasificadas el grupo que mejor resultado obtuvo fue el de 200 con un promedio de 0,70. En la Figura 12 también podemos ver el porcentaje de clasificación que indica una relación entre las muestras correctamente clasificadas y el número total de muestras que se introducen al clasificador, obteniendo un resultado muy favorable para el grupo de 200 características.

Figura 12. Medidas de desempeño con la matriz DWT para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.




Fuente: Creación propia.

- **Experimento 2:** Al igual que en el Experimento 1 el clasificador KNN y LDA en cascada fue el que mejores resultados arrojó, teniendo los mejores resultados para el grupo de 600 características mostrado en la parte (b) de la Figura 13, pero a diferencia del experimento anterior este se obtuvo con Random Forest y fue de 0,70; a diferencia de los grupo de 200, 400 y 1200

características que tienen promedios de Se de 0,68, 0,67 y 0,66 respectivamente.

Figura 13. Medidas de desempeño con la matriz MODWT para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.



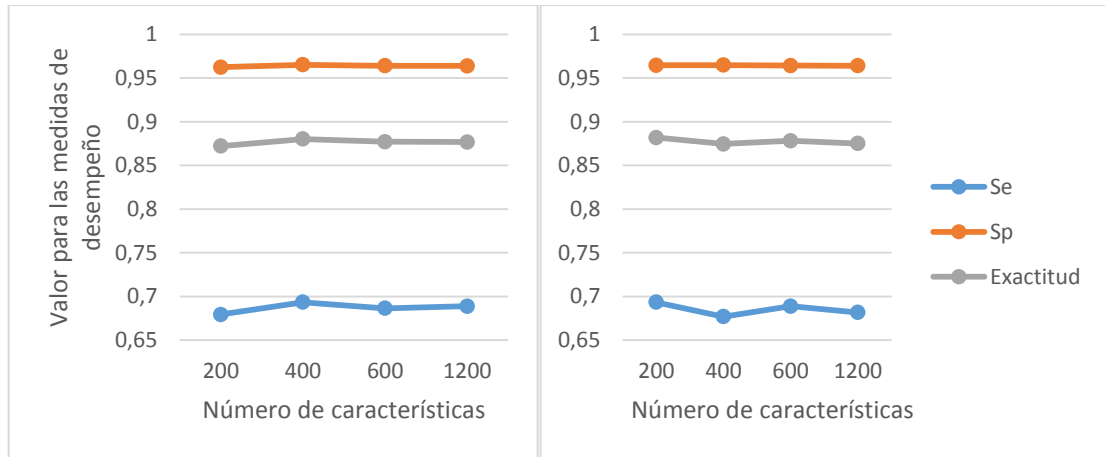
(a)

(b)

Fuente: Creación propia.

- **Experimento 3:** Para este experimento se obtuvieron resultados similares en cuanto Se para ambos clasificadores, arrojando KNN y LDA en cascada 0,6934 para 400 características y Random forest el mismo valor para el grupo de 600 características como se puede ver en las partes (a) y (b) de la Figura 14. Lo que muestra que es un poco más conveniente KNN y LDA teniendo en cuenta el coste computacional.

Figura 14. Medidas de desempeño con la matriz ICEEMD para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.




(a)

(b)

Fuente: Creación propia.

- **Experimento 4:** Para este experimento se obtuvieron los mejores resultados para Se para un clasificador de KNN y LDA en cascada con un grupo de 400 características con un promedio de 0.7052 como se muestra en la parte (a) de la Figura 15.

Figura 15. Medidas de desempeño con la matriz [DWT MODWT ICEEMD] para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.




(a)

(b)

Fuente: Creación propia.

- Experimento 5:** Para los grupos de características de este experimento que fueron extraídos por MFCC, el clasificador KNN y LDA en cascada alcanzo un menor desempeño en los cuatro casos, obteniendo la mejor medida de Se. Además, se evidencia al clasificador de Random Forest con un promedio de 0,6958 para un grupo de 400 características como se puede ver en la parte (b) de la Figura 16.

Figura 16. Medidas de desempeño con la matriz MFCC para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.



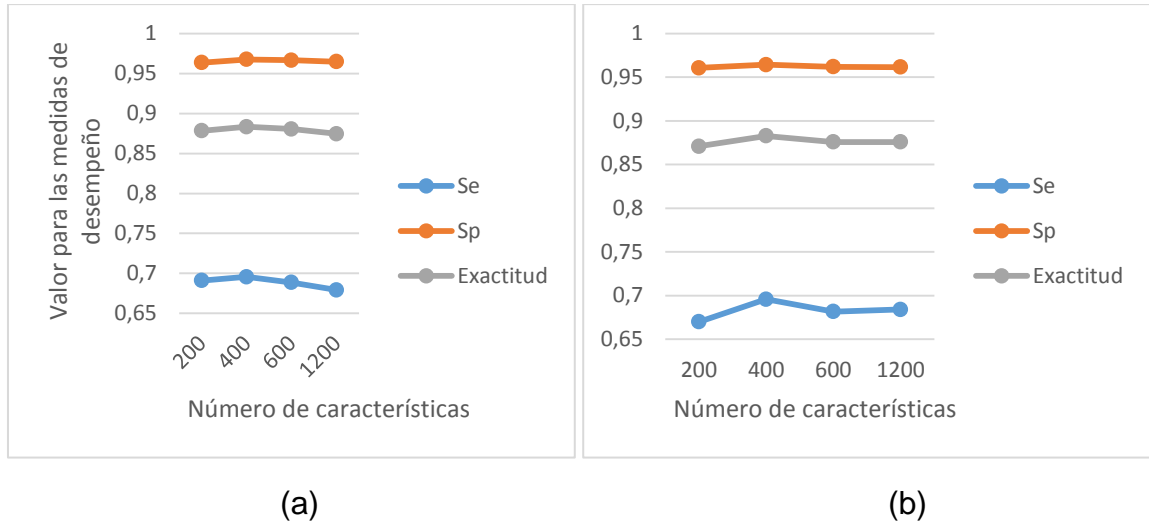
(a)

(b)

Fuente: Creación propia.

- Experimento 6:** En este caso, por parte del clasificador KNN y LDA en cascada se obtuvieron mejores resultados para los cuatro casos, obteniendo el mejor promedio de Se en el grupo de 400 características con un 0,7123 como se muestra en la parte a de la Figura

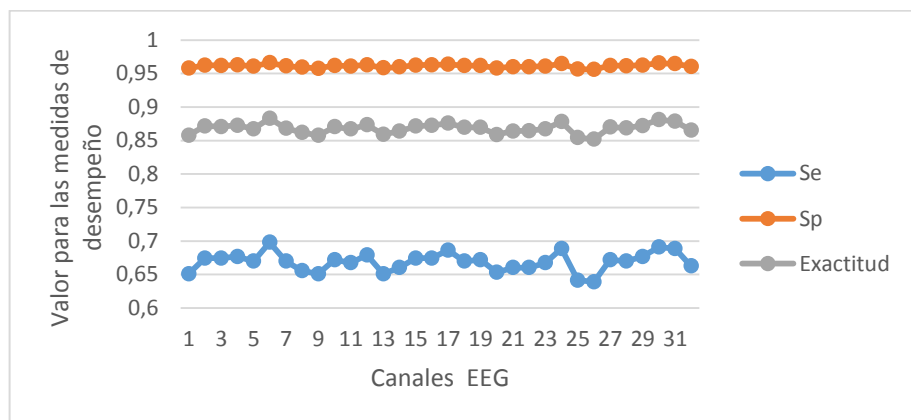
Figura 17. Medidas de desempeño con la matriz HHT-IMFs para los clasificadores (a) KNN y LDA en cascada y (b) Random Forest.



Fuente: Creación propia.

- **Experimento 7:** Con los resultados obtenido gráficamente en la Figura 18 y es posible hacer una especie de filtrado por canales tomando como criterio un umbral igual a un porcentaje de clasificación y escogiendo los canales por debajo de este umbral para poderlos eliminar. En este caso a simple vista podríamos eliminar los canales 14, 25, 32 y 16 por su bajo desempeño.


Figura 18. Medidas de desempeño para canales EEG con matriz de ICEEMD.



Fuente: Creación propia.

- Experimento 8:** en este apartado observando la Figura 19 es posible notar que los canales 5, 9, 11, 12, 14, 15, 18, 20, 22, 23, 24, 27, 28 y 30 tienen resultados por debajo del 80% en alguno de sus canales, con lo que podríamos eliminar estos canales para realizar un proceso de clasificación con los canales restantes y de esta manera obtener un proceso más óptimo.


Figura 19. Medidas de desempeño para canales EEG con matriz de MODWT.



Fuente: Creación propia.

- Experimento 9:** Como se puede observar en la Figura 20 los canales con resultados porcentuales más bajos en alguno de sus canales son 3, 5, 6, 8, 14, 16, 19, 22, 25 y 27 los cuales de alguna manera representan ruido a la hora de realizar clasificación a un conjunto de características que acoja a los 32 canales en general.


Figura 20. Medidas de desempeño para canales EEG con matriz de DWT.



Fuente: Creación propia.

- Experimento 10:** Los experimentos utilizando la transformada de Hilbert Huang a los IMFs son los que mejores resultados arroja, en este caso como se puede observar en la Figura 21 los canales que tienen alguna clase por debajo del 80% son 7, 8 y 10. Si se desea eliminar más canales debería hacerse utilizando los promedios ya sea del porcentaje de clasificación o de la medida de Se mostrada en la Figura 21.


Figura 21. Medidas de desempeño para canales EEG con matriz de HHT-IMFs.



Fuente: Creación propia.

- Experimento 11:** Como se puede observar en la Figura 22, el porcentaje de clasificación obtenido para los 32 canales en las cuatro clases están por encima del 80 %, pero presenta resultados poco confiables debido a que en canales como 4, 6, 12 y otros, el porcentaje más bajo de clasificación es para la clase 1 lo que nunca había ocurrido en los anteriores experimentos.

Figura 22. Medidas de desempeño para canales EEG con matriz de MFCC.



Fuente: Creación propia.

- **Medida del coste computacional**

Para los experimentos 1, 2, 3, 4, 5 y 6 se midió el tiempo tardado por ambos métodos de clasificación (KNN y LDA en cascada y Random Forest) con el fin de evidenciar, además de la exactitud en clasificación, el coste computacional que estos representan. Anteriormente se observó que KNN y LDA en cascada resulta ser el método de clasificación más conveniente en términos de exactitud, y en la **Tabla 6** se observara como este mismo método resulta mucho más favorable con respecto al tiempo que emplea el algoritmo en la realización de esta etapa.

Tabla 6. Tiempo (s) empleado para los diferentes clasificadores en los experimentos del 1-6 teniendo en cuenta el número de características.

<i>Método \ Clasificador</i>	Tiempo LDA y KNN en cascada (s)				Tiempo Random Forest (s)			
	200	400	600	1200	200	400	600	1200
DWT	1,48	1,63	1,71	2,05	10,12	10,59	10,11	10,13
MODWT	1,48	1,59	1,65	2,07	10,13	10,12	10,12	10,13
ICEEMD	1,43	1,5	1,63	2,1	10,16	10,1	10,13	10,15
DWT, MODWT, ICEEMD	1,53	1,63	1,74	2,08	10,68	10,14	10,08	10,08
MFCC	1,55	1,66	1,8	2,05	10,14	10,13	10,13	10,1
HHT_EMD	1,58	1,64	1,69	2,13	10,01	10,14	10,11	10,12

Fuente: Creación propia.

Debido a estos dos factores (exactitud de clasificación y coste computacional) para los experimentos restantes solo se utilizó KNN y LDA en cascada.

El procesamiento de estas señales se realizó con un procesador Intel(R) Core(TM) i5-6200U CPU @2.30GHz 2.40GHz, con una memoria RAM de 8 GB, un sistema operativo de 64 bits y una tarjeta gráfica NVIDIA GEFORCE 940MX de 4GB.

En la tabla 7 podemos observar una comparación de los mejores resultados obtenidos en este trabajo por cada clase con los resultados de Xianf Jie et. [58]

Tabla 7. Comparación de los resultados obtenidos en este trabajo con respecto al trabajo de Xianf Jie et.

Espacio Valencia-Excitación	LALV	HALV	LAHV	HAHV
Xiang Jie et.	71,16	80,43	71,16	80,43
Este trabajo	99,12	88,10	91,64	90,72

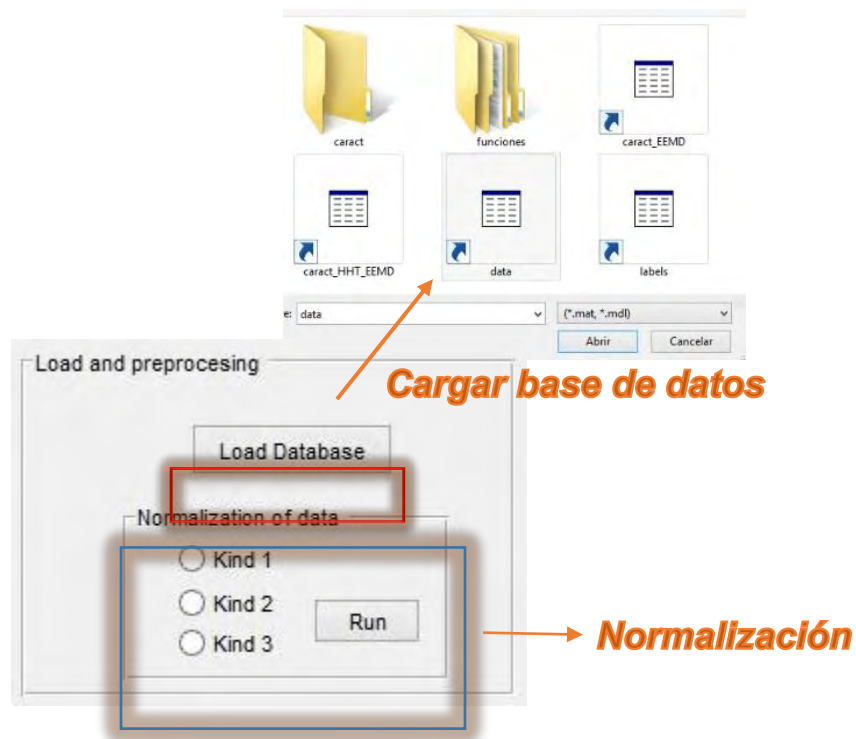
6.1 Interfaz de visualización de resultados

Para el proceso de visualización de resultados, se propuso una interfaz interactiva realizada con la herramienta GUIDE de Matlab. En está el usuario logrará navegar en el proceso de detección de emociones vía señales de electroencefalografía siendo capaz de modificar parámetros de diferentes variables que ayudaran a dar consistencia a los resultados de este estudio comparativo.

La metodología de la interfaz se divide en 3 etapas principales y una etapa de resultados descritos a continuación:

- 1) Etapa de carga de datos y normalización: En esta etapa el usuario podrá seleccionar los datos de la base de datos DEAP en la sección de la **figura 23** para después realizar la etapa de normalización mostrada en la misma sección. La etapa de normalización se puede realizar con 3 métodos diferentes:
 - Kind 1= Normalización dividiendo sobre la desviación estándar.
 - Kind 2 = Normalización entre -1 y 1 y restando mean
 - Kind 3 = Normalización zscore.

Figura 23. Primera etapa de la interfaz de visualización de resultados con carga de datos y normalización.



Fuente: Creación propia.

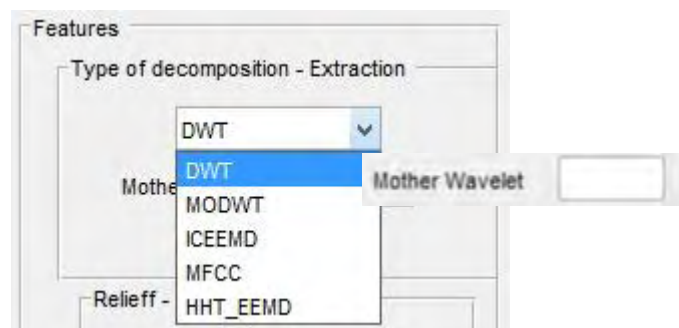
2) Etapa de extracción y descomposición de características: En esta segunda etapa de la interfaz se tendrá la posibilidad de seleccionar entre 5 diferentes tipos de extracción y descomposición de características observados en la **Figura 24**. A cada uno de estos antes se le realiza una etapa de filtraje y normalización descrita a continuación:

- DWT: Se hace un filtro Butterworth de orden 6 pasa bajas de 30 Hz antes de hacer la extracción por medio de DWT con 5 niveles de detalle. La interfaz permite que el usuario digite la wavelet madre en una casilla de la **Figura 24** (El estudio comparativo, en conjunto al estado del arte observado en el **Anexo 2** define que **Db4** es la mejor opción), después se realiza una normalización con zscore.
- MODWT: Se hace un filtro Butterworth de orden 6 pasa bajas de 30 Hz antes de realizar la extracción por medio de MODWT. La interfaz permite que el usuario digite la wavelet madre en una casilla de la **Figura 24** (El estudio comparativo, en conjunto al estado del arte

observado en el **Anexo 2** define que **Db4** es la mejor opción), después se realiza una normalización con zscore.

- MFCC: Se hace un filtro Butterworth de orden 6 pasa bajas de 30 Hz antes de hacer la extracción por medio de MFCC, después de la extracción se hace la caracterización por medio de 10 maneras evidenciadas en la **Tabla 3** y se finaliza con una normalización con zscore.
- ICEEMD: Se implementa el código de ICEEMD simplemente demostrativo cargando una matriz de características antes generada. El motivo de esta decisión es por el alto nivel de consumo computacional en el momento de la extracción de las Imfs necesaria para realizar esta caracterización, generando que no sea posible para el usuario verlo ágilmente en la interfaz.
- HHT EEMD: Se implementa el código de HHT EEMD simplemente demostrativo cargando una matriz de características antes generada. El motivo de esta decisión es porque este método de caracterización se hizo en base a las Imfs generadas por la extracción ICEEMD y esto significa un alto nivel de consumo computacional por el cual no será posible para el usuario verlo ágilmente en la interfaz.

Figura 24. Segunda etapa de la interfaz de visualización de resultados con selección del método de descomposición – extracción y selección de wavelet madre para el caso de DWT y MODWT.



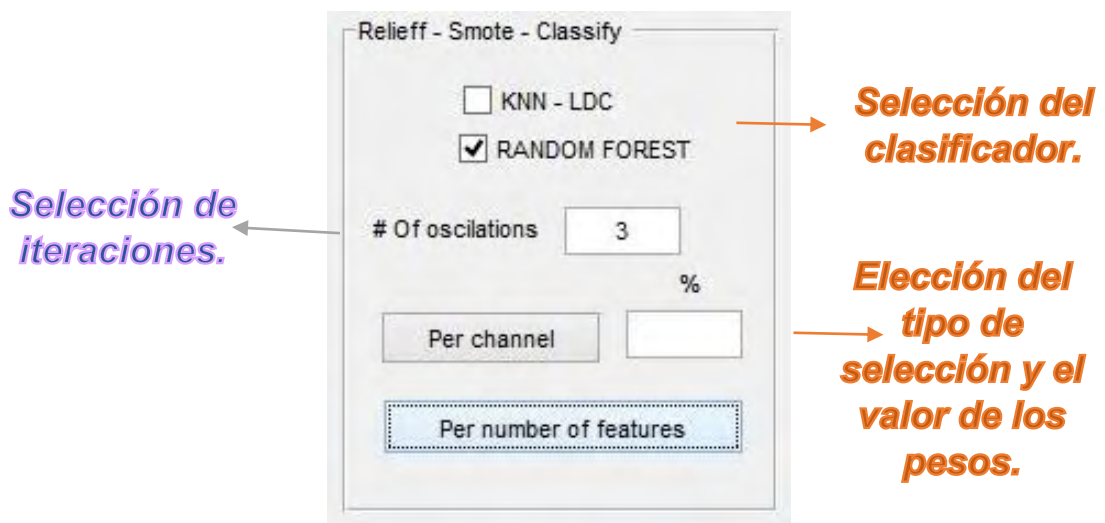
Fuente: Creación propia.

- 3) Etapa de selección, balanceo y clasificación: Está etapa inicialmente se basa en el tipo de selección que quiera hacer el usuario. Como se muestra

en la **Figura 25**, el usuario podrá seleccionar entre realizar un proceso de selección de características por medio de ReliefF por canales, donde además se podrá seleccionar el valor del peso a elegir para la selección, y también se podrá realizar la selección entre las mejores 200, 400, 600 y 1200 características. Una vez realizada el proceso de selección, esta sección generara un balanceo por medio de SMOTE, para finalizar con la etapa de clasificación en la cual tendremos la posibilidad si trabajamos con Knn y Lda en cascada o Random Forest, el usuario podrá elegir el número de iteraciones a realizar.

- 4) Etapa de resultados: Los resultados de en términos de Se, Sp, Acc y tiempo del clasificador, se podrán visualizar de dos maneras diferentes.
- Documento con todos los resultados: Todos los resultados (Se, Sp, Acc y tiempo) de los 32 canales en el caso de selección por canales, y de 200, 400, 600 y 1200 en el caso por número de características, se podrán observar en una tabla en Excel que automáticamente se abre y es evidenciada en la **Figura 26**.
 - Muestra de los mejores resultados: En la parte media derecha de la interfaz, una vez realizada la clasificación, se puede observar los mejores resultados en términos de Acc y tiempo del clasificador en la **Figura 27**.

Figura 25. Tercera etapa de la interfaz donde se realiza el proceso de selección, balanceo y clasificación. Se puede modificar el número de iteraciones para el clasificador y el valor de los pesos para la selección.



Fuente: Creación propia.

Figura 26. Resultados totales en términos de Se, Sp y Acc para las 4 clases.

32 canales

		Clase 1			Clase 2			Clase 3			Clase 4				
A	Channel	Se1	Sp1	Acc1	Se2	Sp2	Acc1	Se3	Sp3	Acc3	Se4	Sp4	Acc4		
1	0,83018868	0,9740634	91,9499106	0	0,53773585	0,94228504	80,7541241	0	0,58490566	0,94660194	82,3717949	0	0,47169811	0,93665158	78,5932722
2	0,78301887	0,96953642	90,2459712	0	0,53773585	0,94463277	81,2834225	0	0,6509434	0,95515152	85,1881505	0	0,53773585	0,94463277	81,2834225
3	0,83018868	0,9764419	92,4874791	0	0,60377358	0,95302013	84,0667678	0	0,64150943	0,95652174	85,3620955	0	0,53773585	0,94725511	81,8920916
4	0,74528302	0,96244784	88,1889764	0	0,48113208	0,93597206	78,558613	0	0,60377358	0,94710327	82,7586207	0	0,54716981	0,94174757	80,7692308
5	0,75471698	0,96533333	88,9267462	0	0,49056604	0,93932584	79,4520548	0	0,67924528	0,95696203	85,9967051	0	0,53773585	0,9433526	80,9930178
6	0,88679245	0,98387097	94,8630137	0	0,55660377	0,94885745	82,5018615	0	0,69811321	0,96208531	87,3817035	0	0,47169811	0,94190871	79,8270893
7	0,87735849	0,98045113	94,0312213	0	0,46226415	0,93559322	78,2276547	0	0,59433962	0,94723926	82,6472962	0	0,48113208	0,93714286	78,8298691
8	0,80188679	0,96987088	90,6333631	0	0,50943396	0,93896714	79,6238245	0	0,62264151	0,94949495	83,5526316	0	0,46226415	0,9350057	78,093774
9	0,83018868	0,9769821	92,5373134	0	0,51886792	0,94614572	81,4004376	0	0,75471698	0,96836983	89,5666132	0	0,52830189	0,94692144	81,6983895
10	0,90566038	0,98542274	95,4954955	0	0,49056604	0,94039735	79,6992481	0	0,63207547	0,95306859	84,4621514	0	0,47169811	0,93886463	79,1044776
11	0,78301887	0,96953642	90,2459712	0	0,49056604	0,94065934	79,7601199	0	0,67924528	0,95802469	86,2236629	0	0,55660377	0,94628571	81,9091609
12	0,88679245	0,98235294	94,5652174	0	0,52830189	0,94252874	80,6800618	0	0,70754717	0,96	87,0725605	0	0,33962264	0,92783505	74,892396
13	0,80188679	0,9707113	90,797546	0	0,51886792	0,94117647	80,2478699	0	0,64150943	0,95261845	84,5024447	0	0,48113208	0,93799324	79,0236461
14	0,71698113	0,96350365	87,9614767	0	0,59433962	0,95152198	83,6003051	0	0,66981132	0,95867769	86,2313139	0	0,60377358	0,95238095	83,9203675
15	0,74528302	0,96498054	88,7029289	0	0,48113208	0,93962678	79,4007491	0	0,68867925	0,9588015	86,5306122	0	0,58490566	0,94859813	82,8125
16	0,83962264	0,97705803	92,7038627	0	0,44339623	0,93796004	78,5454545	0	0,72641509	0,96379526	88,1632653	0	0,53773585	0,94561598	81,509434
17	0,8490566	0,9760479	92,6739927	0	0,39622642	0,92951542	75,975976	0	0,70754717	0,95827725	86,7180805	0	0,43396226	0,93243243	77,1341463
18	0,83018868	0,97329377	91,8032787	0	0,44339623	0,93287827	77,3599386	0	0,69811321	0,95698925	86,3013699	0	0,40566038	0,92992214	76,1904762
19	0,8490566	0,97802198	93,0555556	0	0,44339623	0,93743372	78,4198976	0	0,70754717	0,96139477	87,3675632	0	0,52830189	0,94432071	81,0892587
20	0,80188679	0,97225892	91,1092295	0	0,51886792	0,94377067	80,8414726	0	0,68867925	0,95960832	86,7042707	0	0,52830189	0,94456763	81,1463047
21	0,83018868	0,97662338	92,4623116	0	0,51886792	0,94545455	81,2362031	0	0,67924528	0,96	86,6562009	0	0,5754717	0,95027624	83,0699774
22	0,60377358	0,94865526	83,0917874	0	0,62264151	0,95049505	83,7662338	0	0,68867925	0,95730918	86,2155388	0	0,51886792	0,94093082	80,1864802
23	0,56603774	0,94403893	81,540931	0	0,59433962	0,94671623	82,5345248	0	0,76415094	0,9651325	89,0446976	0	0,47169811	0,93577982	78,3950617
24	0,89622642	0,98558322	95,3664701	0	0,49056604	0,94478528	80,7417974	0	0,67924528	0,96127563	86,9431644	0	0,60377358	0,95424837	84,3517139
25	0,83962264	0,97642164	92,5764192	0	0,51886792	0,94276094	80,608365	0	0,64150943	0,95399516	84,8	0	0,5	0,94117647	80
26	0,8490566	0,97752809	92,9577465	0	0,45283019	0,93709328	78,4546805	0	0,68867925	0,95859473	86,4864865	0	0,5	0,94091416	79,9394398
27	0,86792453	0,98028169	93,8271605	0	0,47169811	0,93913043	79,1666667	0	0,62264151	0,95238095	84,1772152	0	0,54716981	0,94545455	81,595092

Fuente: Creación propia.

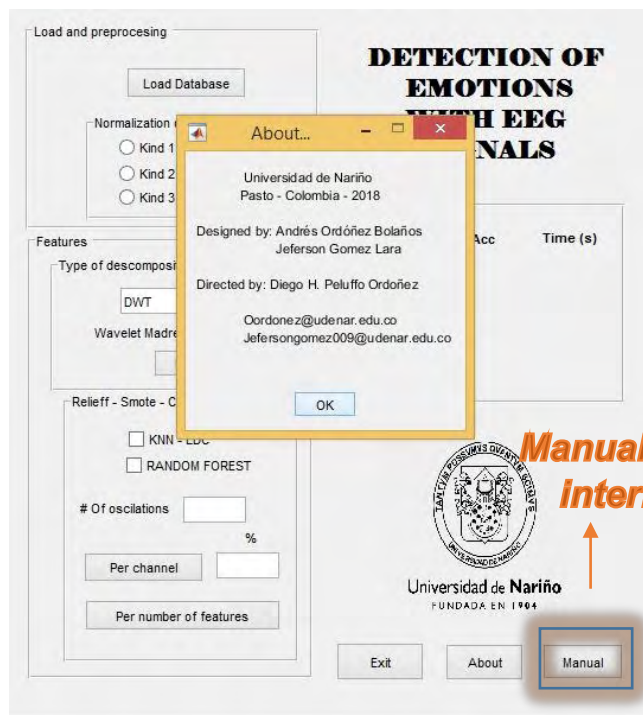
Figura 27. Mejores resultados del proceso para cada clase en términos de Acc y tiempo (s).

Best results		
V-A	Acc	Time (s)
LALV	95.3665	
HALV	80.7418	1.04387
LAHV	86.9432	
HAHV	84.3517	

Fuente: Creación propia.

Por último se añade una presentación general de la interfaz en la **Figura 28**, donde se puede encontrar un enlace para dirigirse al manual de instrucciones donde se explica el funcionamiento de la interfaz, y un botón donde se puede observar la información de los encargados del trabajo.

Figura 28. Interfaz general donde podremos observar la ubicación del manual e información de los autores.



Fuente: Creación propia.

4. CONCLUSIONES

En términos generales, se verifica la premisa inicial sobre la factibilidad de realizar la tarea de identificación de emociones a partir del análisis de señales EEG. Asimismo, se comprueba la complejidad de esta tarea dada la naturaleza de estas señales, y, en particular, de la interpretación semántica de emociones.

A nivel más técnico y específico:

- ✓ A partir de los resultados mostrados para cada canal, es posible escoger, para casos donde se requiera un buen compromiso entre bajo costo computacional y buena eficiencia, los canales con mejores resultados que a su vez serían los más relevantes. De esta manera, se podría implementar una interfaz donde se utilicen canales con los mejores resultados porcentuales en cuanto a la clasificación.
- ✓ Los mejores resultados obtenidos en esta investigación fueron los obtenidos al clasificar aplicando la transformada de **Hilbert Huang** a los IMFs resultantes de aplicar la técnica de **ICEEMD**, aun así, cabe resaltar que estos resultados no son muy superiores a los que se obtuvieron en tercer lugar, es decir a los obtenidos aplicando **DWT**. Debido al muy elevado costo computacional que es necesario para extraer los IMFs de una señal en cuanto a rapidez se refiere, es mucho más conveniente utilizar la descomposición **DWT** sobre este tipo de señales.
- ✓ En cuanto a los métodos utilizados en el proceso de clasificación el método de cascada de **KNN y LDA** dio muy buenos resultados ya que fue mucho más rápido que **Random Forest** y a su vez fue más eficiente en cuanto a Porcentaje de Clasificación.
- ✓ Para los experimentos 1, 2, 3, 4, 5 y 6 en la mayoría de eventos se obtuvo los mejores resultados para el grupo de **400** características lo que nos indica que es una cantidad óptima para realizar el proceso de clasificación.

Como trabajo futuro, dado que existen muchas otras formas de realizar descomposición de señales EEG para clasificar emociones, se propone el explorar otras alternativas diferentes a las estudiadas aquí, por ejemplo: usando transformada de HILBERT HUANG a los niveles de aproximación y detalle que se obtienen aplicando DWT o MODWT. Subsecuentemente, también será necesario realizar un estudio de clasificación de esas características por paciente y probando otros métodos de selección de características más relevantes.

Adicionalmente, se propone realizar un procedimiento previo que permita evaluar la factibilidad de las muestras, debido a que hay muchas muestras tomadas erróneamente, las cuales hacen que los resultados obtenidos no sean muy altos.

Además, se sugiere aplicar los procesos de pre-procesamiento y procesamiento de señales usados en este trabajo; sobre la base de datos MANHOB y de esta manera poder hacer una comparación sobre la eficiencia de los datos tomados por estos dos bancos de datos EEG.

REFERENCIAS

- [1] K. Takahashi, «Remarks on emotion recognition from bio-potential signals», presentado en 2nd International Conference on Autonomous Robots and Agents, 2004, pp. 186-191.
- [2] S. S. Chambers Jonathon, «EEG Signal Processing», 2007.
- [3] M. Teplan y others, «Fundamentals of EEG measurement», *Meas. Sci. Rev.*, vol. 2, n.º 2, pp. 1–11, 2002.
- [4] Michel Cabanac, «What is emotion? Behavioural processes». pp. 60:69-83, 2002.
- [5] M. Murugappan, N. Ramachandran, y Y. Sazali, «Classification of human emotion from EEG using discrete wavelet transform», *J. Biomed. Sci. Eng.*, vol. 03, n.º 04, pp. 390-396, 2010.
- [6] R. Horlings, D. Datcu, y L. J. Rothkrantz, «Emotion recognition using brain activity», en *Proceedings of the 9th international conference on computer systems and technologies and workshop for PhD students in computing*, 2008, p. 6.
- [7] P. C. Petrantonakis y L. J. Hadjileontiadis, «Emotion Recognition From EEG Using Higher Order Crossings», *IEEE Trans. Inf. Technol. Biomed.*, vol. 14, n.º 2, pp. 186-197, mar. 2010.
- [8] S. Koelstra *et al.*, «DEAP: A Database for Emotion Analysis ;Using Physiological Signals», *IEEE Trans. Affect. Comput.*, vol. 3, n.º 1, pp. 18-31, ene. 2012.
- [9] M. Soleymani, J. Lichtenauer, T. Pun, y M. Pantic, «A Multimodal Database for Affect Recognition and Implicit Tagging», *IEEE Trans. Affect. Comput.*, vol. 3, n.º 1, pp. 42-55, ene. 2012.
- [10] Université de Genève, «HCI Tagging Database». [En línea]. Disponible en: <https://mahnob-db.eu/hci-tagging/>.
- [11] «EMOTIV EPOC+ - 14 Channel Wireless EEG Headset», *Emotiv* .
- [12] «Biosemi EEG ECG EMG BSPM NEURO amplifier electrodes». [En línea]. Disponible en: <https://www.biosemi.com/products.htm>.
- [13] O. Sourina y Y. Liu, «A Fractal-based Algorithm of Emotion Recognition from EEG using Arousal-Valence Model.», en *BIOSIGNALS*, 2011, pp. 209–214.
- [14] D. O. Bos, «EEG-based Emotion Recognition», p. 17.

- [15] «Aaron Sloman», *Wikipedia*. 29-may-2018.
- [16] L. L. Davidoff, *Introduction to Psychology*. McGraw-Hill, 1980.
- [17] M. Owayjan, A. Kashour, N. A. Haddad, M. H. Fadel, y G. A. Souki, «The design and development of a Lie Detection System using facial micro-expressions», *undefined*, 2012. Disponible en: /paper/The-design-and-development-of-a-Lie-Detection-using-Owayjan-Kashour/c786384aedd467d5491699d092d6b34b77c60a9e.
- [18] W. Wang y H. Niu, «Face detection based on improved AdaBoost algorithm in E-Learning», en *2012 IEEE 2nd International Conference on Cloud Computing and Intelligence Systems*, 2012, vol. 02, pp. 924-927.
- [19] Y. Liu, W. Wang, D. Liu, y S. Liu, «The Study of Learners' Emotional Features in the E-learning System», en *2010 Second International Conference on Networks Security, Wireless Communications and Trusted Computing*, 2010, vol. 1, pp. 423-426.
- [20] T. Pun, T. I. Alecu, G. Chanel, J. Kronegg, y S. Voloshynovskiy, «Brain-computer interaction research at the Computer Vision and Multimedia Laboratory, University of Geneva», *IEEE Trans. Neural Syst. Rehabil. Eng. Publ. IEEE Eng. Med. Biol. Soc.*, vol. 14, n.º 2, pp. 210-213, jun. 2006.
- [21] T. Kim, D. Shin, D. Shin, S. Kim, y M. Lee, «Design and development of multimodal analysis system based on biometric signals», en *2010 3rd International Conference on Biomedical Engineering and Informatics*, 2010, vol. 2, pp. 853-857.
- [22] F. Palmero, «Certezas y controversias en el estudio de la emoción», p. 25, 2006.
- [23] J. Posner, J. A. Russell, y B. S. Peterson, «The circumplex model of affect: An integrative approach to affective neuroscience, cognitive development, and psychopathology», *Dev. Psychopathol.*, vol. 17, n.º 3, pp. 715-734, sep. 2005.
- [24] M. M. Bradley y P. J. Lang, «Measuring emotion: The self-assessment manikin and the semantic differential», *J. Behav. Ther. Exp. Psychiatry*, vol. 25, n.º 1, pp. 49-59, mar. 1994.
- [25] *Electric Fields of the Brain: The Neurophysics of EEG*, Second Edition. Oxford, New York: Oxford University Press, 2005.
- [26] J. Malmivuo, P. of B. and H. of the R. G. I. J. Malmivuo, R. Plonsey, y P. of B. E. R. Plonsey, *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*. Oxford University Press, 1995.

- [27] R. Oostenveld y P. Praamstra, «The five percent electrode system for high-resolution EEG and ERP measurements», *Clin. Neurophysiol. Off. J. Int. Fed. Clin. Neurophysiol.*, vol. 112, n.º 4, pp. 713-719, abr. 2001.
- [28] F. Sharbrough, G. E. Chatrian, R. Lesser, H. Luders, M. Nuwer, y T. Picton, «American Electroencephalographic Society guidelines for standard electrode position nomenclature», *Clin. Neurophysiol.*, vol. 8, pp. 200-202, ene. 1991.
- [29] «10–20 system (EEG)», *Wikipedia*. 20-oct-2018.
- [30] S. Qureshi, Sohaib, y T. Ahmad, «An empirical study of machine learning techniques for classifying emotional states from EEG data.», 2012.
- [31] M. Moshfeghi, A. T. Bedasso, y J. P. Bartaula, «Emotion Recognition from EEG Signals using Machine Learning», p. 39.
- [32] E. Ackerman y L. C. Gatewood, *Mathematical Models in the Health Sciences: A Computer-Aided Approach*, NED-New edition. University of Minnesota Press, 1979.
- [33] «Tipos de ondas cerebrales: Delta, Theta, Alfa, Beta y Gamma», *La Mente es Maravillosa*, 03-nov-2017. .
- [34] C. M. Bishop, *Pattern recognition and machine learning*. New York: Springer, 2006.
- [35] S. Watanabe, *Pattern Recognition: Human and Mechanical*. New York: John Wiley & Sons Inc, 1985.
- [36] J. A. C. Ochoa, «Reconocimiento de Patrones», p. 13.
- [37] D. L. A. Romero y D. T. C. Cano, «Capítulo 1.- Redes Neuronales y Reconocimiento de Patrones.», p. 11.
- [38] «Extracción de Características», p. 58.
- [39] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, y B. Arnaldi, «A review of classification algorithms for EEG-based brain–computer interfaces», *J. Neural Eng.*, vol. 4, n.º 2, p. R1, 2007.
- [40] M. A. Colominas, G. Schlotthauer, y M. E. Torres, «Improved complete ensemble EMD: A suitable tool for biomedical signal processing», *Biomed. Signal Process. Control*, vol. 14, pp. 19-29, nov. 2014.
- [41] K. N. V. P. S. Rajesh y R. Dhuli, «Classification of imbalanced ECG beats using re-sampling techniques and AdaBoost ensemble classifier», *Biomed. Signal Process. Control*, vol. 41, pp. 242-254, mar. 2018.

- [42] S. F. Rosario, «RELIEF: Feature Selection Approach», vol. 4, n.º 11, p. 7, 2015.
- [43] «Learning from Imbalanced Data - IEEE Journals & Magazine». Disponible en: <https://ieeexplore.ieee.org/document/5128907>. [Accedido: 22-nov-2018].
- [44] «Off-line, handwritten numeral recognition by perturbation method - IEEE Journals & Magazine». Disponible en: <https://ieeexplore.ieee.org/document/589216>.
- [45] «Clasificación Supervisada y No Supervisada - Fernando Sancho Caparrini». Disponible en: <http://www.cs.us.es/~fsancho/?e=77>.
- [46] C. A. González, «SVM: Máquinas de Vectores Soporte», p. 52.
- [47] L. Breiman, «Random Forests», *Mach. Learn.*, vol. 45, n.º 1, pp. 5-32, oct. 2001.
- [48] J. M. M. Diazaraque, «Introducción a las Redes Neuronales Aplicadas», p. 95.
- [49] «K-means - Wikipedia, la enciclopedia libre». [En línea]. Disponible en: <https://es.wikipedia.org/wiki/K-means>. [Accedido: 23-nov-2018].
- [50] C. A. Rodríguez, J. H. Gallego, I. D. Mora, A. Orozco-Duque, y J. Bustamante, «CLASSIFICATION OF PREMATURE VENTRICULAR CONTRACTION BEATS BASED ON UNSUPERVISED LEARNING METHODS», *Rev. Ing. Bioméd.*, vol. 8, n.º 15, pp. 51-58, jun. 2014.
- [51] «DEAP: A Dataset for Emotion Analysis using Physiological and Audiovisual Signals». [En línea]. Disponible en: <http://www.eecs.qmul.ac.uk/mmv/datasets/deap/index.html>.
- [52] H. Ocak, «Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy», *Expert Syst. Appl.*, vol. 36, n.º 2, Part 1, pp. 2027-2036, mar. 2009.
- [53] R. W. Picard, E. Vyzas, y J. Healey, «Toward Machine Emotional Intelligence: Analysis of A ective Physiological State», p. 24.
- [54] D. G. Manolakis y V. K. Ingle, *Applied Digital Signal Processing: Theory and Practice*. Cambridge University Press, 2011.
- [55] B. Medina Salgado, R. Alvarez López, B. Medina Salgado, y R. Alvarez López, «Characterization of EEG Signals Using Wavelet Packet and Fuzzy Entropy in Motor Imagination Tasks», *Ingeniería*, vol. 22, n.º 2, pp. 226-238, ago. 2017.
- [56] A. Phinyomark, S. Thongpanja, H. Hu, y P. P. and C. Limsakul, «The Usefulness of Mean and Median Frequencies in Electromyography Analysis», *Comput. Intell. Electromyogr. Anal. - Perspect. Curr. Appl. Future Chall.*, 2012.

[57] N. V. Chawla, K. W. Bowyer, L. O. Hall, y W. P. Kegelmeyer, «SMOTE: Synthetic Minority Over-sampling Technique», *J. Artif. Intell. Res.*, vol. 16, pp. 321-357, jun. 2002.

[58] Jie, X., Cao, R., Li, L.: Emotion recognition based on the sample entropy of eeg. *Bio-medical materials and engineering* 24(1), 1185–1192 (2014).

ANEXOS

ANEXO 1. Implementación del código de pre-procesamiento y procesamiento de señales EEG para la detección de emociones.

1. Se carga base de datos data.mat y los archivos valence.mat y arousal.mat.

```
Load(data.mat);
Load(valence.mat);
Load(arousal.mat);
```

2. Se normalizan las 32 señales EEG de los 1280 registros y se extrae el vector de etiquetado de los vectores arousal.mat y valence.mat.

```
for i=1:1280
    data{i,1} = ((data{i,1}-
    mean(data{i,1}')')') ./ repmat(max(abs(data{i,1}')), size(data{i,
    1}',1),1))';
    if valence(i)>5 & arousal(i)>5
        etiquetas2(i,4) = 1;
    end
    if valence(i)<=5 & arousal(i)<=5
        etiquetas2(i,4) = 3;
    end
    if valence(i)>5 & arousal(i)<5
        etiquetas2(i,4) = 4;
    end
    if valence(i)<=5 & arousal(i)>=5
        etiquetas2(i,4) = 2;
    end
end
```

3. Se filtra cada señal, se escoge el método de descomposición y se extraen características.

```
fs = 128; %frecuencia de muestreo
flc = 30;
orden = 6;
[b1,a1] = butter(orden,flc/(fs/2)); %filtro pasa bajas de
30 hz
%% descomposición DWT y extracción de características
for i=1:size(data,1)
for j=1:32
clear A5 D5 D4 D3 D2 D1 x charact %limpia variables
```

```

x = filter(b1,a1,data{i,1}(j,:));           %se aplica filtro a la
señal
[CA,CD]=dwt(x,'db4',5);                     %wavele 5 niveles y
familia db4
    D1 = CD(1,1:length(CD)/5);
    D2 = CD(1,(length(CD)/5)+1:(length(CD)/5)*2);
    D3 = CD(1,((length(CD)/5)*2)+1:((length(CD)/5)*3));
    D4 = CD(1,((length(CD)/5)*3)+1:((length(CD)/5)*4));
    D5 = CD(1,((length(CD)/5)*4)+1:((length(CD)/5)*5));
[character] = características_w(D5,D4,D3,D2,D1); %feature
extraction
caract_dw(i,(size(character,2)*j)-(size(character,2)-
1):size(character,2)*j) = character;
end
    end
caract = zscore(caract_dw);                 %normalizacion de
características

%% descomposicion modwt y extraccion de características
for i=1:size(data,1)
for j=1:32
clear A5 D5 D4 D3 D2 D1 x character
x = filter(b1,a1,data{i,1}(j,:));
signal_modwt = modwt(x,5,'db4');
A5 = signal_modwt(1,:);
D5 = signal_modwt(2,:);
D4 = signal_modwt(3,:);
D3 = signal_modwt(4,:);
D2 = signal_modwt(5,:);
D1 = signal_modwt(6,:);
[character] = características_w(D5,D4,D3,D2,D1);
caract_modwt(i,(size(character,2)*j)-(size(character,2)-
1):size(character,2)*j) = character;
end
    end
    caract = zscore(caract_modwt);          %normalizacion de
características

%% descomposición iceemd y extracción de características
for i=1:size(sg,1)
for j=1:32
clear A5 D5 D4 D3 D2 D1 x character
x = filter(b1,a1,data{i,1}(j,:));

```

```

[modes, its]=iceemdan(x, Nstd, NR, MaxIter, SNRFlag); %function
n1 = modes(1, :); %niveles iceemd
n2 = modes(2, :);
n3 = modes(3, :);
n4 = modes(4, :);
n5 = modes(5, :);
n6 = modes(6, :);
n7 = modes(7, :);
[character] = caracteristicas_iceemd(n1, n2, n3, n4, n5, n6, n7);
caract(i, (size(character, 2)*j)-(size(character, 2)-
1):size(character, 2)*j) =character;
end
end
caract = zscore(caract_modwt); %normalizacion de
características

%% extracción de coeficientes MFCC
for i=1:size(data,1)
for j=1:32
clear x caract
x = filter(b1, a1, data{i, 1}(j, :));
[character] = Caracteristicas_mfcc(x, fs);
caract_mfcc(i, (size(character, 2)*j)-(size(character, 2)-
1):size(character, 2)*j) = caract;
end
end
%normalización de características
%caract = caract_mfcc./(max(abs(caract_mfcc)));
caract = zscore(caract_mfcc);

%% descomposición iceemd y extracción de características
for i=1:size(data,1)
for j=1:32
clear A5 D5 D4 D3 D2 D1 x caract
x = filter(b1, a1, data{i, 1}(j, :));
[modes, its]=iceemdan(x, Nstd, NR, MaxIter, SNRFlag); %function
[character] = caracteristicas_hht(modes, Ts)
Caract_hht(i, (size(character, 2)*j)-(size(character, 2)-
1):size(character, 2)*j) =character;
end
end
caract = zscore(caract_hht); %normalizacion de
características

```

4. Se utiliza ReliefF para ordenar las características según su nivel de relevancia.

```
Y = etiquetas;
C = size(caract,2)/32;

for i=1:32
    [ranked(i,:),weights(i,:)] = relieff(caract(:,(C*(i-1))+1:C*i),Y,10);
    ran = ranked(i,:);
    wei = weights(i,:);
    desc(i,:) = fliplr(sort(weights(i,:)));
end

cont = 1;
z = max(weights')*0.80;
for j=1:40
    while z(j)<desc(j,cont)
        cont = cont + 1;
    end
    dat(j) = desc(j,cont);
    [u(j,1),u(j,2)] = find(desc(j,)==dat(j));
    cont = 1;
end

cc = 1;
for k=1:40
    for m=1:u(k,2)
        caractr(1:1280,cc) = caract(:,(C*(k-1))+ranked(k,m));
        cc = cc + 1;
    end
end
```

5. Se aplica el método de balanceo por SMOTE

```
clc
Datos = caractR;
Resultado = etiquetas;
Datos = zscore(Datos);
X = Datos;
Y = Resultado;
k = length(unique(Y)); % number of clusters
ind = 1;
for i = 1:length(unique(Y))
    cc = find(Y==i);
```



```

num = length(cc);
Xcc = X(cc(1:num),:);
Ycc = Y(cc(1:num),:);
if i == 1
    Xnew1 = [Xcc];    % tiene 5 if por el # de clases
    Ynew1 = [Ycc];
end
if i == 2
    Xnew2 = [Xcc];
    Ynew2 = [Ycc];
end
if i == 3
    Xnew3 = [Xcc];
    Ynew3 = [Ycc];
end
if i == 4
    Xnew4 = [Xcc];
    Ynew4 = [Ycc];
end
end

tt(1) = size(Ynew1,1); tt(2) = size(Ynew2,1); tt(3) =
size(Ynew3,1); tt(4) = size(Ynew4,1);
ttmax = max(tt);
XX{1,1} = Xnew2; XX{2,1} = Xnew3; XX{3,1} = Xnew4;% XX{4,1} =
Xnew5;
numattrs = size(Datos,2); % Número de atributos
caracteristicas
N(1) = (ttmax-tt(2)) * 100; N(2) = (ttmax-tt(3)) * 100; N(3)
= (ttmax-tt(4)) * 100; %N(4) = (ttmax-tt(4)) * 100;
for j=1:3%4
clear cercaindex newindex kvecinos miu attr dif
nt = size(XX{j,1},1); % Cantidad de muestras
%%%%%%%%%%%%%%

if(N(j) < 100)
nt = floor((N(j)/100)*nt); % Redondeo el numero
N(j) = 100;
end

N(j) = floor(N(j)/100); % Cantidad de SMOTE como multiples de
100

% Vecinos mas cercanos
kvecinos = 5;

```

```

Miu = [];

cercaindex = [];
newindex = 1; % Contador de nuevas muestras generadas

for i = 1:nt
    miu = dist(XX{j,1}(i,:), XX{j,1}');
    [N2,I] = sort(miu);
    cercaindex(i,:) = I(:,2:kvecinos+1);

    while (N(j) ~= 0)
%Selecciono un indice del array aleatoriamente de los vecinos
mas cercanos
        nn = randi(kvecinos);
        for attr = 1:numattrs
            % Diferencia entre un atributo seleccionado
aleatoriamente de
            %los k vecinos mas cercanos y el atributo
            dif = XX{j,1}(cercaindex(nn),attr) -
XX{j,1}(i,attr);
            % Numero aleatorio entre 0 y 1
            gap = rand(1);
            % Se calcula la nueva muestra
            synthetic{j}(newindex, attr) = XX{j,1}(i,attr)
+(gap*dif);
            end

            newindex = newindex +1;
            N(j) = N(j) -1;
            end
        end
    end

caracts = [Datos; synthetic{1}; synthetic{2};
synthetic{3}];%

%%
etiquetasb = [Resultado; 2*ones(ttmax-tt(2),1); 3*ones(ttmax-
tt(3),1); 4*ones(ttmax-tt(4),1)];
b1 = 0; b2 = 0; b3 = 0; b4 = 0; b5 = 0;
for k=1:size(caractt,1)
    if etiquetasb(k,1) == 1
        b1 = b1 + 1;
    end
    if etiquetasb(k,1) == 2

```

```
b2 = b2 + 1;
end
if etiquetasb(k,1) == 3
b3 = b3 + 1;
end
if etiquetasb(k,1) == 4
b4 = b4 + 1;
end
if etiquetasb(k,1) == 5
b5 = b5 + 1;
end
end
b = [round(b1*0.2)-1 round(b2*0.2)-1 round(b3*0.2)-1
round(b4*0.2)-1];
```

ANEXO 2. Artículo II Jornadas Internacionales de Investigación Científica UTN.

En este anexo podremos observar el artículo publicado en el evento organizado por la UTN el 6 - 8 de noviembre de 2017.

Link publicación: <https://issuu.com/utnuniversity/docs/ebook-ii-jornadas-internacionales-u> **ISBN:** 978-9942-984-05-0

Interpretación semántica computarizada de señales cerebrales para identificar emociones: un estado del arte

Jeferson Gomez Lara¹, Andrés Ordóñez Bolaños², Diego Peluffo Ordóñez³

^{1,2}Universidad de Nariño – Colombia, ³Universidad Técnica del Norte - Ecuador

¹Jefersongomez008@gmail.com, ²oordonez@udenar.edu.co, ³diegohpo@gmail.com

RESUMEN

La electroencefalografía es una técnica exploratoria basada en el registro de la actividad eléctrica del cerebro a partir de señales eléctricas medidas sobre el cuero cabelludo –denominadas señales electroencefalograficas (EEG). Hoy en día, su práctica se ha hecho más común en el campo de la ingeniería y su uso ha traído grandes avances en el campo de la neuro-rehabilitación de diferentes extremidades del cuerpo humano, por otra parte, se ha realizado un gran trabajo en el análisis de esta señal reconociendo actividad cerebral para el desarrollo de lo denominado interfaz cerebro-computador o BCI. Diversos estudios han comprobado que las emociones humanas se pueden determinar por medio de señales EEG. Éstas han sido utilizadas para la realización de interfaz cerebro - computador (BCI), diagnóstico de pacientes, reconocimiento de emociones, reconocimiento de acciones, etc. No obstante, aunque se han desarrollado diversos estudios, el desarrollo de un método que sea óptimo para la identificación de emociones a partir de señales EEG, considerando aspectos como precisión, coste computacional, aplicaciones en tiempo real, es aún un problema abierto. Por tanto, es necesario realizar más esfuerzos, a nivel de investigación, en el área de sistemas computarizados de análisis de EEG. En este trabajo se presenta un estado del arte sobre las técnicas de caracterización y clasificación de señales EEG orientadas a la identificación de emociones humanas.

Palabras clave: BCI, Clasificación de patrones, EEG, Reconocimiento de emociones.

ABSTRACT

Electroencephalography is an exploratory technique based on recording electrical activity in the brain through electrical signals measured on the scalp –named, electroencephalographic signals (EEG). Nowadays, its practice has become more common in the field of engineering and its use has brought great advances in the field of neurorehabilitation of different human body limbs. On the other hand, studies have devoted to the EEG signal analysis for recognizing the cerebral activity aimed at developing brain - computer interfaces. Several studies have proved that human emotions can be determined by means of EEG signals. Studies have shown that human emotions can be determined by measured signals on the scalp (EEG). Indeed, such signals have been used for brain-computer interfaces (BCI), diagnosis of patients, recognition of emotions, recognition

of actions, etc. Nonetheless, despite many studies have been made in this regard, the develop of a system able to recognize human emotions -being both accurate and feasible to real time/low computational cost applications- is still an open issue. Therefore, more research efforts must be done in the area of computerized systems for EEG analysis. In this work, a state of the art on EEG signal characterization and classification techniques for human emotion identification is presented.

Keywords: BCI; EEG; Emotion recognition; pattern classification.

1. INTRODUCCIÓN

Las emociones son estados afectivos que experimentan los seres humanos como respuesta a un hecho específico que puede ser visual, auditivo, físico o psicológico, los cuales han sido denominadas por personajes del ambiente científico como el muro o diferencia que separa a los seres vivos de las máquinas. Según la Real Academia de España (2017) [1] las emociones son “alteración del ánimo intensa y pasajera, agradable o penosa, que va acompañada de cierta conmoción somática”, de dicha definición se puede extraer que las emociones son estados mentales además de afectivos. El ser humano es capaz de sentir 6 categorías básicas de emociones: Miedo, sorpresa, aversión, ira, alegría o felicidad y tristeza [2].

Recientemente, se han mostrado buenos resultados en procesos de interfaces cerebro computadora (BCI) capacitando a las máquinas en temas como el comportamiento del cerebro humano, para esta capacitación o aprendizaje de máquina se han hecho investigaciones en el reconocimiento de expresiones faciales y análisis sobre la voz; sobre las que se han realizado numerosos trabajos y se han obtenido porcentajes de acierto sobre la detección de emociones que están en un rango del 30-90% [5], [6], [7], [8], [9]. Sin embargo, es importante tener en cuenta que estos altos índices de precisión o éxito se encuentran bajo circunstancias muy controladas y será menor en situaciones normales.

Desde otro punto de vista, la electroencefalografía o EEG es una exploración de manera segura que posibilita el muestreo en forma de señal de la actividad eléctrica del cerebro medida sobre el cuero cabelludo con electrodos no invasivos, medición que arroja como resultado señales que

pueden mostrar tanto anomalías en la salud como también acciones o sentimientos que experimenta el paciente.

Desde su creación se ha buscado hacer cada vez una mejor interpretación en estas señales en aspectos como detección de estados emocionales, detección de la voluntad de las personas para realizar acciones con diferentes partes de su cuerpo, o en el reconocimiento de estas señales en pacientes sanos y pacientes con enfermedades neuronales como el Alzheimer [10] para el respectivo diagnóstico y tratamiento de trastornos mentales que de la enfermedad se derivan.

Las señales EEG generalmente son tomadas con rango en escala de micro-voltios y con frecuencias de hasta 300 Hz [11]. En diversos estudios sobre la adquisición de este tipo de señales, se ha reportado que el rango para la detección de emociones en señales EEG se divide de la siguiente manera: Delta (0.5 a 3.5 Hz) que se asocian con el sueño profundo, Teta (3 a 7 Hz); las cuales normalmente se asocian con las primeras etapas de sueño, Alfa (8 a 13 Hz) que se presentan en estado de reposo y con los ojos cerrados, Beta (14 a 30 Hz) que están presentes cuando la persona se encuentra en una etapa de sueño nulo; donde se está despierto y consciente, y Gamma (>30 Hz) [12, p. 39] de las que se ha teorizado que podrían estar implicadas en el proceso de percepción consciente [12]. En caso particular respecto a la adquisición y análisis de estas señales, aplicadas en el reconocimiento de emociones, se destaca las 2 bases de datos más utilizadas en el estado del arte: MAHNOB [3] y DEAP [4], las cuales proveen un archivo .BDF donde se exportan las señales EEG en 32 canales.

En este orden de ideas se observa la factibilidad de aplicar control sobre señales de electroencefalografía para realizar la detección de emociones. En este trabajo se plantea un estado del arte acerca de los trabajos realizados sobre métodos de detección de emociones sobre señales EEG que servirán como base para futuros trabajos en temas afines.

2. MATERIALES Y MÉTODOS

Para el desarrollo del presente estado del arte se realizó una investigación exhaustiva de 14 artículos del año 2010 en adelante provenientes de revistas, libros o páginas científicas en los que se abarcan temas relacionados con la extracción de características y su respectiva clasificación para detección de emociones sobre señales EEG, para la selección de los artículos que hacen parte del documento se tuvieron en cuenta aspectos como: publicación en revista o

algún medio de tipo científico, autores locales e internacionales que sean citados considerablemente en campos de ingeniería y que presenten resultados porcentuales que evidencien el grado de clasificación obtenido en sus trabajos. De la revisión bibliográfica realizada se tomaron aspectos significativos de cada artículo que son: el tipo de caracterización y clasificación adoptados por los autores, los resultados que se obtuvieron de cada artículo y una breve descripción de lo que pretendía hacer cada investigador con su trabajo. Aspectos como las bases de datos, el número de electrodos o canales usados, el número de sujetos que se presentaron a los experimentos; no fueron aspectos de relevancia a la hora de la selección de artículos.

3. RESULTADOS Y DISCUSIÓN

En la *Tabla 1* se muestra el resultado de la revisión bibliográfica realizada de tal manera que se puede determinar rápidamente los métodos utilizados por cada autor y compararlos con los otros trabajos, además se encuentran ordenados cronológicamente para mostrar los avances ascendentes o descendentes que se han dado en los últimos 8 años.

Tabla 1. Comparación de métodos de caracterización y clasificación de señales EEG para detectar emociones con sus respectivos resultados porcentuales

Investigador	Caracterización	Clasificador	Resultados
Sazali et al, 2010 [14]	DTW	KNN y LDA	Con KNN: 83.26% Con LDA: 75.21%
Lin et al, 2010 [15]	Método estadístico F-score	SVM	Un promedio de acierto de: 82.28±3.06% en 26 sujetos
Khosrowabadi et al, 2010 [16]	MSCE	KNN	Precisión de detección de un 84%
Petrantonakis y Hadjileontiadis, 2010 [5]	Método propuesto HOC-Based Features, S-EC, W-EC	QDA, KNN, MD, SVM	Con un solo canal: QDA (62.3% con HOC-EC), MD (37.5% con S-EC) Y K-NN (34.6% con W-EC)

Referencia	Método	Algoritmo	Resultados
			Con canales combinados: SVM (83.33% con HOC-EC), MD (44.9% con S-EC) y QDA (32.7% con W-EC)
Sourina y Liu, 2011 [17]	Modelo propuesto	Bayes y Fisher Discriminant Analysis	58% para tres niveles de excitación
Nie et al. 2011 [6]	LDS, correlation coefficients	linear-SVM	Con LDS: 87.53% Con correlation coefficients (100 caracteres): 89.22% Con correlation coefficients (50 caracteres): 84.94%
Zhang et al. 2013 [7]	Wavelet	Tipo estadístico: C4.5	Detección de dos clases por dimensión valencia y excitación: 75.19% (para valencia) y 81.74% (para excitación) 67% Con el 100 % de los datos 80% Con un conjunto menor a la mitad de datos original para ambas bases de datos (después de realizar varias eliminaciones de ruido)
Torres, 2013 [18]	Filtros RFE y MFE	SVM	
Jenke et al. 2014 [19]	Métodos multivariados: rRMR, ES Λ y ES θ . Métodos univariados: ReliefF y ES \mathcal{P}	QDA con estimación de varianza diagonal	Mejor resultado dependiendo de la caracterización sin importar el sujeto: rRMR: 45%, ES Λ : 45%, ES θ : 47.5%, ReliefF: 40%, ES \mathcal{P} : 45%.
Vijayan et al. 2015 [20]	Entropía de Shannon y	MCSVM	Precisión de clasificación: 94.097%

Zheng y Lu, 2015 [21]	correlación cruzada Transformada de Fourier en el tiempo con una ventana Hanning no superpuesta y se aplica sobre las frecuencias obtenidas una entropía diferencial	DBN, SVM, LR, KNN	Resultados de la clasificación: 86.08% (con DBN), 83.99% (con SVM), 82.7% (con LR) y 72.6% (con KNN)
Montoya y Quintero, 2016 [8]	ETW	QDA	Con 150 caracteres: 72% Con 300 caracteres: 74.5% Con 600 caracteres: 87% Con 1680 caracteres: 88%
Atkinson y Campos, 2016 [22]	Statistical features, band power, Hjorth parameters and fractal dimensión	SVM con RBF kernels	Detección de tres clases por dimensión: valencia y excitación se obtuvo: 60.7% (para valencia) y 62.33 (para excitación)
Nafjan et al, 2017 [9]	PSD Frontal Asymmetry	DNN	Detección de dos clases por dimensión: valencia y excitación: 82.5% (para ambas clases)

En las tablas II y III podemos encontrar de manera más clara los métodos de caracterización y clasificación utilizados por cada autor.

Tabla II. Métodos de caracterización usados

Métodos de caracterización																	
AUTOR \ METODO	DTW o ETW	F-score	MSE	HOC-CC	S-CC	WPI	LDL (normalizado)	coeficiente de correlación RTE y MFC (Hrosal)	mSVM	ESB	ESF1	ESF2	Rehef	Entropía Shannon (normal)	Entropía Cruzada	TTC con ventana hamming	PLD
Sarali et al, 2010	X																
Lin et al, 2010		X															
Khosrowabadi et al, 2010			X														
Petrantonakis y Hadjileontiadis, 2010				X	X	X											
Sourina y Liu, 2011								PROPONE MODELO DE CARACTERIZACIÓN: FRACTAL-BASED									
Nie et al, 2011							X	X									
Zhang et al, 2013	X																
Torres, 2013									X								
Jenke et al, 2014										X	X	X	X	X			
Vijayan et al, 2015														X	X		
Zheng y Lu, 2015																	X
Montoya y Quintero, 2016	X																
Atkinson y Campos, 2016																	
Nafjan et al, 2017																	X

Tabla III. Métodos de clasificación utilizados

Métodos de clasificación												
AUTOR \ METODO	KNN	LTA	SVM	CDA	MD	Regres	Redes neuronales	svm	DBM	LR	DNN	
Sarali et al, 2010	X	X										
Lin et al, 2010			X									
Khosrowabadi et al, 2010	X											
Petrantonakis y Hadjileontiadis, 2010	X		X	X	X							
Sourina y Liu, 2011						X						
Nie et al, 2011			X									
Zhang et al, 2013							X					
Torres, 2013			X									
Jenke et al, 2014				X								
Vijayan et al, 2015								X				
Zheng y Lu, 2015	X		X						X	X		
Montoya y Quintero, 2016				X								
Atkinson y Campos, 2016			X									
Nafjan et al, 2017											X	

A continuación, se describen los prefijos mencionados en las *tablas I, II y III*

SVM: Máquina de soporte vectorial

DTW: Wavelet Discreta

ETW: Transformada Wavelet Estacionaria

LDA: Análisis discriminante lineal

MSCE: Estimación coherente de magnitud cuadrada

QDA: Análisis discriminante cuadrático

KNN: k -vecinos más cercanos

MD: Mahalanobis Distance

LDS: Sistema dinámico lineal

Linear-SVM: Máquina de soporte vectorial lineal

RFE: Eliminación de características recursivas

MFE: Eliminación de características basado en el margen

mRMR: Mínima redundancia máxima relevancia

ES Λ : Tamaño del efecto Λ

ES θ : Tamaño del efecto θ

ES φ : Tamaño del efecto φ

MCSVM: Máquina de soporte vectorial de clases múltiples

DNN: DEAP Neural Network

En la *Tabla IV* se encuentra una pequeña descripción de lo que cada autor quiere desarrollar con la elaboración de sus trabajos.

Tabla IV. Breve descripción de los artículos citados en el presente texto

Título de la investigación	Tema de la investigación
<p>Classification of human emotion from EEG using discrete wavelet transform [14]</p>	<p>Se propone un protocolo audiovisual basado en inducción con contenido emocional más dinámico para incluir emociones discretas (disgusto, felicidad, sorpresa, miedo y neutral)</p>
<p>EEG-Based Emotion Recognition in Music Listening [15]</p>	<p>Se propone una metodología para detección de emociones en la que se busca características de señales EEG específicas de las emociones y se explora a su vez la posibilidad de usar menos electrodos para la caracterización dinámica del EEG</p>
<p>EEG-based emotion recognition using self-organizing map for boundary Detection [16]</p>	<p>se plantea un mapa de auto organización para detectar emociones por medio de límites que las separan en diferentes grupos</p>
<p>Emotion Recognition From EEG Using Higher Order Crossings [5]</p>	<p>Implementación un método de extracción de características denominado HOC-Emotion (HOC-EM) con el objetivo de aplicarse exclusivamente sobre emociones</p>
<p>A fractal-based algorithm of emotion recognition from EEG using arousal-valence model [17]</p>	<p>Se propone un algoritmo de extracción de características en el cual se usa el menor número de electrodos posible para luego ser probado por diferentes tipos de clasificadores</p>
<p>EEG-based Emotion Recognition during Watching Movies [6]</p>	<p>Su objetivo es encontrar la relación entre las señales EEG y las emociones humanas</p>
<p>Ontology-based context modeling for emotion recognition in an intelligent web [7]</p>	<p>Se presenta la detección de emociones con ayuda de la base de datos DEAP [1] para probar el modelo ontológico Bio-Emotion que actúa como un puente entre los estados emocionales de los usuarios y las características de bioseñal de bajo nivel.</p>

<p>from Electroencephalogram (EEG) Signal using Deep Neural Network</p> <p>[9]</p>	<p>posibilidad de detectar mediante un clasificador las emociones de excitación, meditación, aburrimiento y frustración sobre señales de EEG por medio de la adquisición de una red neuronal.</p>
---	---

En los resultados obtenidos se puede ver el tipo de rutinas de programación utilizadas para el procesamiento de las señales para detectar este tipo de patrones, dando una idea clara al comparar los resultados porcentuales obtenidos al clasificar las características de cada modelo. Teniendo en cuenta estos resultados se puede escoger diferentes tipos de caracterizador o clasificador de los propuestos por los autores citados en la *Tabla I* por ejemplo: si lo que se desea es un alto grado de seguridad podemos revisar los artículos [20] o [6] con caracterización de correlación cruzada y un clasificador SVM sobre 50 características que fueron los artículos en los que se muestra el mayor grado de acierto en la detección de emociones; también podemos elegir artículos en los que se compara el tipo de caracterizador con un solo clasificador como es el caso de [6], [18], [19], [20]; o por el contrario artículos donde se comparó diferentes clasificadores con un tipo de caracterizador como en [14], [21]; también encontramos un artículo donde se varía tanto el método de caracterización como el de clasificación [5]; teniendo en cuenta lo mostrado en la *Tabla I* en conjunto con lo mostrado en la *Tabla III* podemos revisar artículos en los que se pretende reducir el coste computacional ya sea eliminando canales de adquisición de datos o por medio de extracción de características como es el caso de [6], [18], [8]; en la revisión bibliográfica también encontramos autores que proponen su métodos de extracción de características como [17] y [22] y también encontramos artículos se centran en la clasificación de valencia y excitación como [7], [22], [9]

4. CONCLUSIONES

El avance que se ha obtenido del procesamiento en general para la detección de emociones sobre señales cerebrales ha sido muy *significante* en estos últimos años llegando a obtener resultados mayores al 90%, y más recientemente se ha empezado a buscar nuevos métodos que realicen la caracterización y clasificación de los datos de manera que se utilice el menor coste computacional posible y a su vez se han hecho comparaciones con diversos métodos de

caracterización y clasificadores de patrones variando el número de caracteres utilizado para encontrar así el mínimo número de datos de los que se puede hacer una clasificación confiable.

5. REFERENCIAS BIBLIOGRÁFICAS

- [1] R.- ASALE, «emoción», *Diccionario de la lengua española*. Disponible en: <http://dle.rae.es/?id=EjXP0mU>.
- [2] «2_Emociones_basicas.pdf».
- [3] S. Koelstra *et al.*, «DEAP: A Database for Emotion Analysis Using Physiological Signals», *IEEE Trans. Affect. Comput.*, vol. 3, n.º 1, pp. 18-31, ene. 2012.
- [4] «taffcsi-2010-11-0112-2.pdf», *HCI Tagging Database*. Disponible en: <https://mahnob-db.eu/hci-tagging/media/uploads/taffcsi-2010-11-0112-2.pdf>.
- [5] P. C. Petrantonakis y L. J. Hadjileontiadis, «Emotion Recognition From EEG Using Higher Order Crossings», *IEEE Trans. Inf. Technol. Biomed.*, vol. 14, n.º 2, pp. 186-197, mar. 2010.
- [6] D. Nie, X. W. Wang, L. C. Shi, y B. L. Lu, «EEG-based emotion recognition during watching movies», en *2011 5th International IEEE/EMBS Conference on Neural Engineering*, 2011, pp. 667-670.
- [7] X. Zhang, B. Hu, J. Chen, y P. Moore, «Ontology-based context modeling for emotion recognition in an intelligent web», *World Wide Web*, vol. 16, n.º 4, pp. 497-513, jul. 2013.
- [8] G. Mejia, A. Gómez Montoya, y O. Quintero, «Reconocimiento de Emociones utilizando la Transformada Wavelet Estacionaria en Señales EEG Multicanal», presentado en VII Congreso Latinoamericano de Ingeniería Biomédica CLAIB, At Bucaramanga, Colombia, 2016.
- [9] A. Al-Naffjan, A. Al-Wabil, M. Hosny, y Y. Al-Ohali, «Classification of Human Emotions from Electroencephalogram (EEG) Signal using Deep Neural Network», *International Journal of Advanced Computer Science and Applications (IJACSA)*, 2017. Disponible en: <https://pdfs.semanticscholar.org/bb87/1941973c600ade787e20ee9a5b87a57b8a73.pdf>.
- [10] J. Poza, D. Abásolo, C. Gómez, C. I Sánchez, y M. Lopez-Coronaño, *Análisis de Electroencefalogramas con la Transformada Wavelet Discreta. Aplicación a la Enfermedad de Alzheimer*. 2017.
- [11] J. A. Chambers y S. Sanei, «Wiley: EEG Signal Processing», sep-2007. Disponible en: <http://www.wiley.com/WileyCDA/WileyTitle/productCd-0470025816.html>.
- [12] C. Valderrama y G. Ulloa, «Análisis espectral de parámetros fisiológicos para la detección de emociones», *Análisis Espectral Parámetros Fisiológicos Para Detección Emociones Rev. ST 1020 27-49*, vol. 10, mar. 2012.
- [13] S. S. Chambers Jonathon, «EEG Signal Processing», 2007.

- [14] M. Murugappan, N. Ramachandran, y Y. Sazali, «download;jsessionid=AB11873969EB557C0814BCD45D2DE5AD.pdf», feb-2010. Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=AB11873969EB557C0814BCD45D2DE5AD?doi=10.1.1.473.5514&rep=rep1&type=pdf>.
- [15] Y. P. Lin *et al.*, «EEG-Based Emotion Recognition in Music Listening», *IEEE Trans. Biomed. Eng.*, vol. 57, n.º 7, pp. 1798-1806, jul. 2010.
- [16] R. Khosrowabadi, H. C. Quck, A. Wahab, y K. K. Ang, «EEG-based Emotion Recognition Using Self-Organizing Map for Boundary Detection», en *2010 20th International Conference on Pattern Recognition*, 2010, pp. 4242-4245.
- [17] O. Sourina, y Y. Liu, «OSBIOSIGNALS_66_CR.pdf», 2011. Disponible en: http://www3.ntu.edu.sg/home/EOSourina/Papers/OSBIOSIGNALS_66_CR.pdf.
- [18] C. Torres, «6213822T693.pdf», 2013. Disponible en: <http://repositorio.utp.edu.co/dspace/bitstream/handle/11059/3820/6213822T693.pdf?sequence=1>.
- [19] R. Jenke, A. Peer, y M. Buss, «Feature Extraction and Selection for Emotion Recognition from EEG», *IEEE Trans. Affect. Comput.*, vol. 5, n.º 3, pp. 327-339, jul. 2014.
- [20] A. E. Vijayan, D. Sen, y A. P. Sudheer, «EEG-Based Emotion Recognition Using Statistical Measures and Auto-Regressive Modeling», en *2015 IEEE International Conference on Computational Intelligence Communication Technology*, 2015, pp. 587-591.
- [21] W. L. Zheng y B. L. Lu, «Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks», *IEEE Trans. Auton. Ment. Dev.*, vol. 7, n.º 3, pp. 162-175, sep. 2015.
- [22] J. Atkinson y D. Campos, «Improving BCI-based Emotion Recognition by Combining EEG Feature Selection and Kernel Classifiers», *Expert Syst Appl*, vol. 47, n.º C, pp. 35-41, abr. 2016.

ANEXO 3. Certificados de asistencia a ponencia en la UTN



UNIVERSIDAD TÉCNICA DEL NORTE

Confiere (n) el presente

CERTIFICADO

JEFERSON FRANKLIN GÓMEZ LARA

A
Por Su aporte a la investigación científica al haber presentado la ponencia
"INTERPRETACIÓN SEMÁNTICA COMPUTARIZADA DE SEÑALES CEREBRALES PARA
IDENTIFICAR EMOCIONES: UN ESTADO DEL ARTE", en el marco de las II Jornadas
Internacionales de Investigación Científica y I Foro de Investigación "Desafíos Actuales de la
Sociedad del Conocimiento

noviembre 2017

Ciencia y Técnica al Servicio del Pueblo

Dr. Miguel Posso
DIRECTOR CUICYT



UNIVERSIDAD TÉCNICA DEL NORTE

Confiere (n) el presente

CERTIFICADO

ANDRÉS ORDÓÑEZ BOLAÑOS

A
Por Su aporte a la investigación científica al haber presentado la ponencia
"INTERPRETACIÓN SEMÁNTICA COMPUTARIZADA DE SEÑALES CEREBRALES PARA
IDENTIFICAR EMOCIONES: UN ESTADO DEL ARTE", en el marco de las II Jornadas
Internacionales de Investigación Científica y I Foro de Investigación "Desafíos Actuales de la
Sociedad del Conocimiento

noviembre 2017

Ciencia y Técnica al Servicio del Pueblo

Dr. Miguel Posso
DIRECTOR CUICYT



ANEXO 4. Participación como ponentes en la I feria de tecnología – Universidad Politécnica Estatal del Carchi 16 de abril del 2018.





UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI

Ley No. 2006-36 · Publicada en el Segundo Suplemento del Registro Oficial No. 244 del 5 de abril del 2006

Tulcán, 16 de abril del 2018

El suscrito Msc. Luis Patiño, Director de la Carrera de Ingeniería y en Informática y Computación de la Universidad Politécnica Estatal del Carchi UPEC, a petición del interesado, en forma legal:

CERTIFICA

Que el Sr. Jefferson Gómez Lara, portador de la C.I. 1085311057, estudiante de la Universidad de Nariño participó con el Proyecto denominado "Aplicaciones de machine learning para detección de emociones con señales EEG", en la I **FERIA TECNOLÓGICA**", realizada el 09 y 10 de abril del presente año en la ciudad de Tulcán - Ecuador.

Es todo cuanto puedo certificar en honor a la verdad, pudiendo el interesado hacer uso del presente para los trámites pertinentes.

Atentamente,



Msc. Luis Patiño

DIRECTOR DE INGENIERÍA EN INFORMÁTICA
"EDUCACIÓN PARA EL DESARROLLO Y LA INTEGRACIÓN"

Recognition of emotions using ICEEMD-based characterization of multimodal physiological signals

O. A. Ordóñez-Bolaños¹, J. F. Gómez-Lara¹, M. A. Becerra², D. H. Peluffo-Ordóñez³,
C. M. Duque-Mejía², D. Medrano-David⁴ and C. Mejía-Arboleda⁴

Abstract— Physiological-signal-analysis-based approaches are typically used for automatic emotion identification. Given the complex nature of signals-related emotions, their right identification often results in a non-trivial and exhaustive process -especially because such signals suffer from high dependence upon multiple external variables. Some emotional criteria of interest are arousal, valence, and dominance. Several research works have addressed this issue, mainly through creating prediction systems, notwithstanding, due to aspects such as accuracy, in-context interpretation and computational cost, it is still considered a great-of-interest, open research eld. This paper is aimed at verifying the usefulness of the so-called improved complete empirical mode decomposition (ICEEMD) as a physiological-signal-characterization building block within an emotion-predicting system. To this purpose, some physiological signals along with patients' metadata from the DEAP database are considered. The experiments are set-up as follows: Signals are pre-processed by amplitude adjusting and simple filtering. Then, a feature set is built using HC, and multiple statistic measures from information given by the three considered decompositions, namely: ICEEMD, discrete wavelet transform (DWT), and Maximal overlap DWT. Subsequently, Relief F selection algorithm was applied for reducing the dimensionality of the feature space. Finally, classifiers (LDC and K-NN cascade architectures) are used to assess the class-separability given by the feature set. The different decomposition techniques were compared, and the relevant signals and measures were established. Experimental results evidence the suitability of ICEEMD decomposition for physiological-signal-driven emotions analysis.

The affective process of the emotions can be carried outside of the visual perception [9], since, this can be verbally raised or by non-verbally signs. Besides, the emotional states are systematically interrelated: therefore, these are not independently among them and different methods evaluate them. Russell proposed a three-dimensional model in which emotions were denoted by coordinates (valence, arousal, and dominance) expressed by degrees [12]. However, other studies added variables such as the pleasure [11] and the unpredictability [5] but the most commonly used model is the Circumplex Model of Affect(CMA), which only uses valence and arousal [12]. The emotion recognition have been studied using unimodal and multimodal approaches [14], nonetheless, this is an open research field.

In this study, it is presented emotion prediction system based on a multimodal analysis of physiological signals using improved complete empirical mode decomposition (ICEEMD), which improves some problems of EEMD Colominas2014. DEAP database [8] is used as a benchmark, and the results of ICEEMD are compared with discrete wavelet transform (DWT) and Maximal overlap DWT (MODWT). This work was developed as follows. First, the signals were preprocessed, then three different decompositions were carried out using ICEEMD, DWT, and MODWT. Feature extraction was carried out using Hermite coefficients (HC), Mel frequency cepstral coefficients, Hilbert Huang transform, and multiple statistic measures calculated from intrinsic mode functions (IMFs). MODWT and DWT coef

I. INTRODUCTION

L2 LASCAS 2019 <lascas2019@easychair.org>
Tue 8/11/2018, 5:58 AM
Usted ▾

↩ ⏪ → ⋮

Dear Andrés Ordóñez Bolaños,

[Congratulations!](#)

Your paper number 33 entitled Feature extraction analysis for emotion recognition from ICEEMD of multimodal physiological signals, has been ACCEPTED for ORAL presentation at the 10th IEEE LASCAS - Latin American Symposium on Circuits and Systems - LASCAS 2019 - to be held in the city of Armenia, Colombia from 24th to 27th February, 2019.

ANEXO 6. Publicación condicionalmente aceptada en **SPRINGER** para el evento: 11th Asian Conference on Intelligent Information and Database Systems.

Feature extraction analysis for emotion recognition from ICEEMD of multimodal physiological signals

No Author Given

No Institute Given

Abstract. The emotions identification is a very complex task due to depending on multiple variables individually and as a group. They are evaluated by different criteria such as arousal, valence, and dominance mainly. Several investigations have been focused on building prediction systems. Nevertheless, this is still an open research field. The main objective of this paper is the analysis of the Improved Complementary Ensemble Empirical Mode Decomposition (ICEEMD) for feature extraction from physiological signals for emotions prediction. Physiological signals and metadata of the DEAP database were used. First, the signals were preprocessed, then three decompositions were carried out using ICEEMD, Discrete Wavelet Transform (DWT), and Maximal overlap DWT. Feature extraction was carried out using Hermite coefficients, and multiple statistic measures from IMFs, coefficients DWT, and MODWT, and signals. Then, Relief F selection algorithms were applied to reducing the dimensionality of the feature space. Finally, Linear Discriminant Classifier (LDC) and K-NN cascade classifiers were tested. The different decomposition techniques were compared, and the relevant signals and measures were established. The results demonstrated the capability of ICEEMD decomposition for emotions analysis from physiological signals.

Keywords: Emotion recognition · Improved Complementary Ensemble Empirical Mode Decomposition · multimodal · physiological signals · Signal processing

ACIIDS 2019 submission 155 update



ACIIDS 2019<aciids2019@easychair.org>

Ayer, 5:48 p.m.

Usted ↕

Responder | ▾

Dear authors,

we acknowledge that we received new files for your ACIIDS 2019 submission. The information about this update is shown below.

Number: 155

Authors: Diego Hernán Peluffo-Ordoñez, Miguel Alberto Becerra Botero, Jose Luis Rodriguez, Andres Ordoñez Bolaños, Jeferson Gómez Lara, Daniela Medrano, Carolina Duque and Andrés Eduardo Castro Ospina

Title: Feature extraction analysis for emotion recognition from ICEEMD of multimodal physiological signals

Uploaded by: Miguel Alberto Becerra Botero <migb2b@gmail.com>

Updates:

paper, version 4 (868143 bytes)

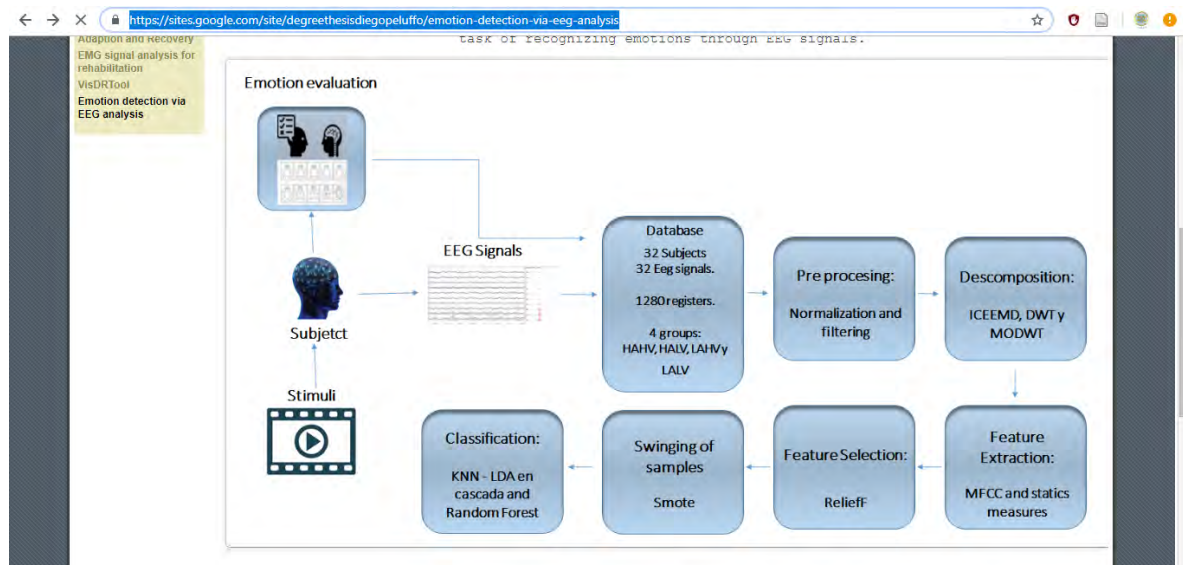
To access the new version of your submission you should log in to the ACIIDS 2019 EasyChair page.

ANEXO 7. Página web

Dentro del desarrollo de este proyecto, uno de los productos esperados era el diseño una página web en la que se pueda subir información relacionada a la interfaz, algoritmos, ejecutables, datos y otros productos adicionales como los artículos y videos. La página web fue creada en google sites y se puede acceder mediante el siguiente vínculo:

<https://sites.google.com/site/degreethesisdiegopeluffo/emotion-detection-via-eeg-analysis>

The screenshot shows a web browser displaying a page titled "Emotion detection via EEG analysis" on a site named "Degree theses". The page header includes a search bar and navigation links. The main content area features the title "Emotion detection via EEG analysis" in green, followed by the author information: "Jeferson Gomez Lara and Andrés Ordóñez Bolaños, Universidad de Narño, San Juan de Pasto - Colombia, 2018". The text describes Electroencephalography (EEG) as a scanning technique based on recording electrical activity in the brain. It mentions that EEG is now more common in engineering and neuro-rehabilitation. The text also discusses the challenges of EEG signal analysis, such as accuracy, computational cost, and real-time applications. The page includes a sidebar with a list of other theses topics like "Interactive Interface for Data-Vis", "Weighted inverse model for source localization", and "EMG signal analysis for".



ANEXO 8. Certificados ponentes en la Zona suroccidental IEEE COLOMBIA 2018

