

ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE SISTEMAS

UNIDAD DE TITULACIÓN

**COMPARACIÓN DE MÉTODOS DE EXTRACCIÓN DE
CARACTERÍSTICAS EN EL DOMINIO DEL TIEMPO, LA
FRECUENCIA Y TIEMPO-FRECUENCIA USANDO DATASETS
PÚBLICOS PARA RECONOCIMIENTO DE EMOCIONES USANDO
OPENBCI**

**TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE MAGISTER
DE INVESTIGACIÓN EN COMPUTACIÓN**

MAYRA ISABEL ALVAREZ JIMÉNEZ

mayra.alvarez@epn.edu.ec

Directora: PhD. Myriam Beatriz Hernández Álvarez

myriam.hernandez@epn.edu.ec

Codirectora: PhD. Tania Elizabeth Calle Jiménez

tania.calle@epn.edu.ec

APROBACIÓN DEL DIRECTOR

Como directora del trabajo de titulación COMPARACIÓN DE MÉTODOS DE EXTRACCIÓN DE CARACTERÍSTICAS EN EL DOMINIO DEL TIEMPO, LA FRECUENCIA Y TIEMPO-FRECUENCIA USANDO DATASETS PÚBLICOS PARA RECONOCIMIENTO DE EMOCIONES USANDO OPENBCI, desarrollado por MAYRA ISABEL ALVAREZ JIMÉNEZ, estudiante de la MAESTRÍA DE INVESTIGACIÓN EN COMPUTACIÓN, habiendo supervisado la realización de este trabajo y realizado las correcciones correspondientes, doy por aprobada la redacción final del documento escrito para que prosiga con los trámites correspondientes a la sustentación de la Defensa oral.



PhD. Myriam Beatriz Hernández Álvarez

DIRECTORA

APROBACIÓN DEL CODIRECTOR

Como codirectora del trabajo de titulación COMPARACIÓN DE MÉTODOS DE EXTRACCIÓN DE CARACTERÍSTICAS EN EL DOMINIO DEL TIEMPO, LA FRECUENCIA Y TIEMPO-FRECUENCIA USANDO DATASETS PÚBLICOS PARA RECONOCIMIENTO DE EMOCIONES USANDO OPENBCI, desarrollado por MAYRA ISABEL ALVAREZ JIMÉNEZ, estudiante de la MAESTRÍA DE INVESTIGACIÓN EN COMPUTACIÓN, habiendo supervisado la realización de este trabajo y realizado las correcciones correspondientes, doy por aprobada la redacción final del documento escrito para que prosiga con los trámites correspondientes a la sustentación de la Defensa oral.



PhD. Tania Elizabeth Calle Jiménez

CODIRECTORA

DECLARACIÓN DE AUTORÍA

Yo, MAYRA ISABEL ALVAREZ JIMÉNEZ, declaro bajo juramento que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentada para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

La Escuela Politécnica Nacional puede hacer uso de los derechos correspondientes a este trabajo, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normatividad institucional vigente.



Ing. Mayra Isabel Alvarez Jiménez

DEDICATORIA

Esta tesis está dedicada a:

Mi mamá por su cariño y apoyo incondicional durante todo este proceso, por estar conmigo en todo momento, gracias a sus oraciones, consejos y sobre todo por inculcar en mí el ejemplo de esfuerzo y valentía, de no temer las adversidades porque Dios está conmigo siempre.

A mis hijos Alan y Sebastián quienes son mi fuente de inspiración para cada día dar lo mejor de mí y llegar a cumplir hoy un sueño más.

A mi compañero de vida Gustavo quien con sus palabras de aliento hicieron de mí una mejor persona y de una u otra forma me acompaña en todos mis sueños y metas.

Finalmente quiero dedicar esta tesis a mis compañeros de clase y profesores, por apoyarme cuando los necesite, por extender su mano en momentos difíciles y por la paciencia brindada, de verdad muchas gracias, siempre los llevo presente.

AGRADECIMIENTO

Quiero expresar mi gratitud a Dios, quien con su bendición llena siempre mi vida, y a toda mi familia por estar siempre presente en todo este proceso.

A mi mamá por ser mi pilar y mi apoyo en todas las decisiones importantes en mi vida. A mi compañero de vida por brindarme su apoyo en todo este proceso. Les agradezco infinitamente por su paciencia y comprensión.

También me gustaría agradecer en estas líneas la ayuda que compañeros y docentes me han prestado durante de la carrera, en especial a mi directora de tesis PhD. Myriam Hernández y a mi Codirectora PhD. Tania Calle por guiarme en el proceso de investigación y redacción de este trabajo.

ÍNDICE DE CONTENIDO

APROBACIÓN DEL DIRECTOR.....	II
APROBACIÓN DEL CODIRECTOR.....	III
DECLARACIÓN DE AUTORÍA.....	IV
DEDICATORIA.....	V
AGRADECIMIENTO.....	VI
ÍNDICE DE CONTENIDO.....	VII
LISTA DE FIGURAS.....	I
LISTA DE TABLAS.....	II
RESUMEN.....	III
ABSTRACT.....	IV
1. INTRODUCCIÓN.....	1
1.1 ANTECEDENTES.....	2
1.2 PLANTEAMIENTO DEL PROBLEMA.....	3
1.3 OBJETIVO GENERAL.....	4
1.4 OBJETIVOS ESPECÍFICOS.....	4
1.5 HIPÓTESIS.....	4
1.6 MARCO TEÓRICO.....	5
1.6.1 Interfaz cerebro computador (BCI).....	5
1.6.1.1.1 Tipos de BCI.....	5
1.6.1.1.3 Clasificación por la estrategia de operación.....	6
1.6.1.1.4 Clasificación por el modo de operación.....	7
1.6.2 Electroencefalografía.....	7
1.6.2.1.1 Bandas de frecuencia.....	8
1.6.3 Computación afectiva.....	10
1.6.3.1.1 Emociones.....	10
1.6.3.1.2 Modelos para reconocimiento de emociones.....	11
1.6.3.1.3 Modelo categorial.....	11
1.6.3.1.4 Modelos dimensionales.....	12
1.6.4 Medición de Emociones en Usuarios.....	14
CAPÍTULO 2. REVISIÓN SISTEMÁTICA DE LITERATURA.....	16
2.1 PREGUNTAS DE INVESTIGACIÓN.....	16
2.2 FUENTES Y ESTRATEGIAS DE BÚSQUEDA.....	16
2.3 CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN.....	19
2.4 SELECCIÓN DE ESTUDIOS RELEVANTES.....	19

2.5	ANÁLISIS DE LA RSL	24
2.6	RESULTADOS DE LA RSL	32
	CAPÍTULO 3. MATERIALES Y MÉTODOS	40
3.1	RECONOCIMIENTO DE EMOCIONES	40
3.2	ADQUISICIÓN DE DATOS	41
3.2.1	Dataset DEAP	41
3.2.2	Dataset SEED.....	42
3.3	EXTRACCIÓN DE CARACTERÍSTICAS	43
3.3.1	Dominio del tiempo	44
3.3.2	Dominio de la frecuencia	51
3.3.3	Dominio del tiempo – frecuencia.....	52
3.4	REDUCCIÓN DE DIMENSIONALIDAD	53
3.4.1	Análisis de Componentes Principales (PCA)	53
3.5	CLASIFICACIÓN DE EMOCIONES.....	54
3.5.1	Super Vector Machine (SVM).....	54
3.5.2	K-Nearest-Neighbor (k-NN).....	55
3.5.3	Artificial Neural Networks (ANN).....	56
3.6	MÉTODOS DE EVALUACIÓN DE DESEMPEÑO	56
3.6.1	Matriz de confusión.....	57
3.6.2	Accuracy	57
3.6.3	Precisión	57
3.6.4	Sensitivity (Recall).....	58
3.6.5	F-Score.....	58
3.6.6	Specificity	58
3.7	BALANCEO DE DATOS	58
	CAPÍTULO 4. IMPLEMENTACIÓN Y RESULTADOS.....	60
3.8	PREPARACIÓN DE DATOS.....	60
3.8.1	Base de datos DEAP	61
3.8.2	Base de datos SEED	63
3.9	EXTRACCIÓN DE CARACTERÍSTICAS	64
3.9.1	Dataset DEAP	64
3.9.2	Dataset SEED.....	65
3.9.3	Vectores de extracción de características	66
3.10	REDUCCIÓN DE DIMENSIONES	68
3.11	CLASIFICACIÓN Y EVALUACIÓN DE RENDIMIENTO.....	69
3.11.1	Resultados en dataset DEAP.....	70

3.11.2	Resultados en dataset SEED.....	79
3.11.3	Evaluación de clasificadores Dataset DEAP y SEED.....	81
3.12	DISCUSIÓN.....	83
	CAPÍTULO 5. CONCLUSIONES.....	86
	REFERENCIAS BIBLIOGRÁFICAS.....	88
	ANEXOS	96
A.	Código extracción de características	96
B.	Código de balanceo de datos	96
C.	Código de implementación de PCA	96
D.	Código de clasificación (4 experimentos con distinto vector de entrada) ..	96
E.	Dataset DEAP	96
F.	Dataset SEED.....	96

LISTA DE FIGURAS

Figura 1. Sistemas de electrodos para la recopilación de datos de señales EEG [1].	8
Figura 2. Representación de emociones básicas y avanzadas [38].	12
Figura 3. Representación del modelo bidimensional [41].	13
Figura 4. Modelo tridimensional [43].	14
Figura 5. Medición de emociones: The Self-Assessment Manikin (SAM) [46].	15
Figura 6. Proceso de revisión sistemática de literatura (RSL)	21
Figura 7. Extracción de características en cada dominio	33
Figura 8. Métodos de extracción de características en dominio del tiempo	34
Figura 9. Métodos estadísticos, extracción de características en dominio del tiempo	34
Figura 10. Métodos de extracción de características en dominio de la frecuencia	35
Figura 11. Métodos de extracción de características en dominio tiempo – frecuencia	36
Figura 12. Porcentaje de algoritmos de clasificación en artículos	37
Figura 13. Comparación de rendimiento entre clasificadores	37
Figura 14. Métrica de evaluación	38
Figura 15. Pasos del proceso de reconocimiento de emociones propuesto	40
Figura 16. Porcentajes de clases acorde a criterios de categorización	62
Figura 17. Histograma de emociones dataset SEED	64
Figura 18. Variabilidad de datos con PCA	69
Figura 19. DEAP - Resultados del vector de tiempo sin PCA	71
Figura 20. DEAP - Resultados del vector de tiempo con PCA	71
Figura 21. DEAP - Resultados del vector de tiempo con SMOTETomek	72
Figura 22. DEAP - Resultados del vector de frecuencia	73
Figura 23. DEAP - Resultados del vector de frecuencia con SMOTETomek	74
Figura 24. DEAP - Resultados del vector de tiempo-frecuencia sin PCA	75
Figura 25. DEAP - Resultados del vector de tiempo-frecuencia con PCA	75
Figura 26. DEAP - Resultados del vector de tiempo-frecuencia con SMOTETomek	76
Figura 27. DEAP - Resultados del vector de 29 características sin PCA	77
Figura 28. DEAP - Resultados del vector de 29 características con PCA	77
Figura 29. DEAP - Resultados del vector de 29 características con SMOTETomek	78
Figura 30. SEED - Resultados del vector de tiempo	79
Figura 31. SEED - Resultados del vector de frecuencia	80
Figura 32. SEED - Resultados del vector tiempo – frecuencia	80
Figura 33. SEED - Resultados del vector con 29 características	81

LISTA DE TABLAS

Tabla 1. Frecuencia de bandas.....	9
Tabla 2. Resultados de la búsqueda.....	17
Tabla 3. Criterios de inclusión y exclusión para la RSL.....	19
Tabla 4. Estudios primarios seleccionados	22
Tabla 5. Métodos de extracción de características, clasificadores y métricas de desempeño más comunes en el reconocimiento de emociones en EGG.....	25
Tabla 6. Precisión en la clasificación de emociones	29
Tabla 7. Matriz de confusión	57
Tabla 8. Comparación entre los dataset DEAP y SEED.....	60
Tabla 9. Asignación de etiquetas bajo criterios Median, Mean y Greater than 5	61
Tabla 10. Tiempo de ejecución de extracción de características - usuario 2.....	65
Tabla 11. Tiempo de ejecución de extracción de características - usuario 1.....	66
Tabla 12. Evaluación de clasificadores en DEAP para VA.....	82
Tabla 13. Evaluación de clasificadores en SEED para VA.....	82

RESUMEN

El estudio de señales cerebrales ha ganado gran popularidad en los últimos años ya que resulta improbable fingir la actividad cerebral leída a través de señales EEG. El análisis de las señales EEG implica dos procesos principales: la extracción y clasificación de características. El principal objetivo de este estudio es proponer un modelo utilizando diferentes métodos de extracción de características en los dominios del tiempo, frecuencia y tiempo-frecuencia usando datasets públicos SEED y DEAP para clasificación de emociones en señales EEG. Además, se analizó diferentes características de los tres dominios de tiempo, frecuencia y tiempo-frecuencia, la eficacia de los vectores de entrada de los clasificadores se validó utilizando los algoritmos de clasificación SVM, KNN y ANN seleccionados por ser más utilizados y presentar un mejor rendimiento en el estado del arte. Una vez concluida la etapa de análisis se propuso un modelo capaz de identificar emociones en cuatro cuadrantes del espacio de representación valencia – arousal usando el dataset DEAP, y emociones de acuerdo a su valencia como neutral, triste, miedo y felicidad en el dataset SEED, logrando una precisión de clasificación del 66.20% utilizando características en el dominio del tiempo y el clasificador k-NN y el 66.0% utilizando características en el dominio de la frecuencia y el clasificador SVM para el dataset DEAP, siendo el dominio de la frecuencia el que representa un menor costo computacional. Para el dataset SEED se obtuvo una precisión de 67,40% empleando características en dominio del tiempo y el clasificador SVM.

Palabras clave: Reconocimiento de emociones. Dataset DEAP y SEED. Extracción de características. Dominio del tiempo. Dominio de la Frecuencia. Dominio Tiempo – Frecuencia.

ABSTRACT

The study of brain signals has gained great popularity in recent years as it is unlikely to fake brain activity read through EEG signals. Analysis of EEG signals involves two main processes: feature extraction and classification. The main objective of this is to propose a model using different feature extraction methods in the time domains, frequency and time-frequency study using public SEED and DEAP datasets for emotion classification in EEG signals. In addition, different characteristics of the three domains of time, frequency and time-frequency were analyzed, the efficiency of the input vectors of the classifiers was validated using the SVM, KNN and ANN classification algorithms selected for being more used and presenting a better performance in the state of the art. Once the analysis stage is complete, a model capable of identifying emotions in four quadrants of the valence - arousal representation space will be shown using the DEAP dataset, and emotions according to their valence such as neutral, sad, fear and happiness in the SEED dataset, achieving a classification accuracy of 66.20% using features in the time domain and the k-NN classifier and 66.0% using features in the frequency domain and the SVM classifier for the DEAP dataset, being the domain of the frequency represents the lowest computational cost. For the SEED dataset, an accuracy of 67.40% was obtained using time domain features and the SVM classifier.

Keywords: Recognition of emotions. DEAP and SEED dataset. Feature extraction. Time domain. Frequency domain. Time-Frequency domain.

1. INTRODUCCIÓN

Hoy en día, la Interfaz Cerebro Computador o en inglés Brain Computer Interfaces (BCI) provee una forma de desarrollar la interacción entre persona y computador. La comunicación entre humano y computador resulta de las respuestas neuronales generadas en el cerebro debido a movimientos motores o actividades cognitivas [1]. Dentro de las BCI, se identifican las BCI afectivas (aBCI) cuyo objetivo es detectar el estado emocional de los usuarios y utilizar esa información de modo que los usuarios interactúen con el ordenador [2]. La computación afectiva abarca el estudio y desarrollo de dispositivos que permitan el reconocimiento, análisis e interpretación de las emociones de los usuarios, a través de la captación de sus señales fisiológicas por parte de un ordenador, haciendo posible mediante su estudio, la creación de nuevas tecnologías para mejorar la interacción entre humanos y máquinas [3]–[5].

Los dispositivos BCI registran las respuestas cerebrales mediante diversas técnicas de adquisición invasivas y no invasivas. Las técnicas de BCI no invasivas implican la adquisición de señales cerebrales sin dañar los tejidos cerebrales [1]. En este contexto, el uso de señales electroencefalográficas (EEG) es una de las técnicas preferidas por su rapidez, bajo costo [2], [6] y fuerte conexión con la identificación del estado emocional [5], [7]. La técnica EEG consiste en el registro de la actividad eléctrica generada por las células cerebrales, colocando electrodos metálicos sobre el cuero cabelludo [6]. Generalmente, los electrodos se colocan utilizando el sistema estándar de colocación de electrodos 10-20 [1].

Las señales EEG logran un buen nivel de precisión en la clasificación de rasgos y emociones. Las emociones son una especie de estado fisiológico y psicológico del ser humano, que forman parte de la vida diaria y afecta el desempeño de las personas [8]. Los seres humanos son expertos en ocultar y reprimir emociones [9]. Por tanto, al analizar las emociones desde la autoevaluación, surge la necesidad de desarrollar nuevas técnicas de detección y predicción de emociones.

Las emociones pueden predecirse y reconocerse clasificando la señal de EEG entrante en función de las características y patrones de las bandas de frecuencia que las componen. Las señales EEG se clasifican en función de la frecuencia denominada Brain Rhythmic Activity o EEG Rhythms [10], los rangos de frecuencia de muestra están entre 0,5 Hz a 100 Hz, y se clasifican en cinco bandas: Delta, Theta, Alfa, Beta y Gamma [7]. Las ondas Delta (0,5-4 Hz) suelen estar presentes en los lactantes y durante el sueño profundo. Las ondas Theta (4-8 Hz) se encuentran generalmente durante la meditación, el estado inconsciente

o la somnolencia. Las ondas Alfa (8-13 Hz) se encuentran en un estado relajado con los ojos cerrados. Las ondas Beta (13-30 Hz) están presentes cuando una persona está alerta, atenta o pensando. Las ondas Gamma ($> 30\text{Hz}$) se generan durante los movimientos voluntarios o cuando se da algún estímulo [11].

El estudio de las señales cerebrales ha cobrado importancia en los últimos años ya que resulta imposible fingir la actividad cerebral que se puede leer a través de las señales de EEG [12]. Por lo que, el análisis de las señales EEG requiere el estudio de la intensidad, frecuencia y formas de onda de la señal, dando lugar a un proceso de dos pasos fundamentales: la extracción y clasificación de características [13], [14]. Es decir, el reconocimiento de emociones se basa principalmente en la combinación de características y modelos superficiales, estos últimos obtenidos a partir de clasificadores. Por tanto, una evaluación de diferentes tipos de características es importante y necesaria para la realización de sistemas de reconocimiento de emociones más precisos con el objetivo de mejorar la interacción entre humano y computador.

1.1 Antecedentes

Una de las tareas más importantes y desafiantes en la computación afectiva es identificar las características más relevantes que pueden predecir mejor la clase de salida o emoción [15]. La calidad de la extracción de características afecta directamente la precisión de la clasificación de emociones [11], [14]. El rendimiento de la clasificación proporciona información sobre qué tan bien un modelo entrenado puede estimar el estado emocional.

En general, la implementación del reconocimiento de emociones basado en EEG tiene una vasta gama de aplicaciones potenciales, en áreas como el entretenimiento, terapias, seguridad, negocios o educación. El reconocimiento de emociones es un componente clave de la computación afectiva, permite que la experiencia del usuario resulte cada vez más empática y natural con el ordenador [2], [3].

Sin embargo, el problema consiste en seleccionar las características adecuadas para garantizar una precisión aceptable en términos de reconocimiento de la emoción. Aún no está disponible un acuerdo sobre las características de EEG que se utilizarán en la detección de emociones para mejorar la precisión de la clasificación. En consecuencia, el reconocimiento de emociones EEG se ha convertido en un tema activo en las áreas de computación afectiva y de interacción entre humanos y computadoras [16].

1.2 Planteamiento del problema

El reconocimiento de emociones a través de señales EEG permite a los investigadores el estudio del estado emocional de las personas en forma relativamente sencilla y no invasiva. Con el uso de una interfaz cerebro computador se pueden captar estas señales para procesarlas con el fin de detectar y clasificar las emociones humanas.

Sin embargo, las señales EEG son ruidosas y demandan un pre-procesamiento adecuado [17], que requiere un estudio que genere, compare y determine los mejores atributos para realizar el aprendizaje automático con miras a la evaluación de emociones, usando escenarios comparables con distintos vectores entrada. Para lo cual, se puede utilizar diferentes métodos para la extracción de características de señales EEG entre las cuales existen el dominio del tiempo, de la frecuencia y del tiempo-frecuencia para construir vectores de características [18].

En este trabajo se analizó diferentes métodos de extracción de características en el dominio del tiempo, en el dominio de la frecuencia y tiempo-frecuencia para la obtención de vectores de entrada a clasificadores como Super Vector Machine (SVM), K-Nearest-Neighbor (k-NN) y Artificial Neural Networks (ANN). Los datos analizados provienen de las bases de datos DEAP [19] Y SEED [20] que correlacionan estados emocionales con señales EEG usando como estímulos audio e imágenes que adquieren sus datos usando BCI.

DEAP es una base de datos con acceso público que contiene las señales EEG captadas por BCI de 40 participantes que vieron 120 extractos de un minuto de videos musicales y etiquetaron las emociones que sintieron usando parámetros de valencia, excitación, dominancia y gusto para calificar sus sentimientos [19]. SEED es un dataset de acceso público obtenido de la recopilación de señales EEG usando dispositivos BCI de 15 personas cuando vieron 15 clips de películas chinas y etiquetaron los sentimientos que experimentaron usando como parámetro la valencia [20].

Usando los datos EEG de DEAP y SEED se construirán vectores de características en los diversos dominios. Estas características serán la entrada de algoritmos de aprendizaje automático como k-NN, SVM y ANN (para comparar entre métodos shallow y deep). Los modelos obtenidos serán evaluados para definir los atributos en los diferentes dominios, que aporten más información a la clasificación y que por lo tanto producirán mejores rendimientos.

1.3 Objetivo general

Comparación de métodos de extracción de características en el dominio del tiempo, la frecuencia y tiempo-frecuencia usando los datasets públicos SEED y DEAP para clasificación de emociones.

1.4 Objetivos específicos

Realizar una revisión sistemática de la literatura en el área de reconocimiento de emociones asociadas con los cuatro cuadrantes del espacio valencia – excitación, usando señales EEG captadas con BCI. La RSL nos permitirá referenciar literatura relacionada y resultados de trabajos similares que nos servirán para comparar nuestros resultados.

Utilizar las señales EEG de las bases de datos DEAP y SEED vinculadas a emociones etiquetadas para los atributos de valencia y excitación para extraer características en el dominio del tiempo, la frecuencia y tiempo-frecuencia.

Utilizar el vector de características para detectar y clasificar estados emocionales, definidos en los cuatro cuadrantes del espacio valencia – estado (emociones con: baja valencia – baja excitación como, por ejemplo, la tristeza; baja valencia – alta excitación, tal como la ira; alta valencia – baja excitación, como la tranquilidad; alta valencia – alta excitación, como, por ejemplo, la alegría), usando algoritmos de clasificación de shallow y aprendizaje automático con el fin de evaluar qué método de extracción de características aporta más información y produce clasificadores con mejores rendimientos.

Evaluar en forma sistemática el rendimiento de distintos tipos de vectores de características con varios algoritmos de shallow y aprendizaje automático.

Comparar los resultados obtenidos en cuanto a rendimiento de los clasificadores, cuando se los alimenta con vectores de características obtenidos en los distintos dominios del tiempo, la frecuencia o el tiempo – frecuencia. Discutir estos resultados comparando los hallazgos realizados en los distintos cuadrantes del espacio valencia - excitación.

1.5 Hipótesis

Los métodos de extracción de características influyen en la configuración de vectores de entrada para lograr un mejor rendimiento de clasificadores en el reconocimiento de estados emocionales usando señales EEG captadas con dispositivos BCI.

1.6 Marco Teórico

En esta sección se exponen conceptos relacionados a BCI, señales EEG, computación afectiva, modelos emocionales, entre otros, que ayudan a un mejor entendimiento del ámbito de este trabajo.

1.6.1 Interfaz cerebro computador (BCI)

Una interfaz cerebro computador (ICC) o por sus siglas en inglés Brain Computer Interface (BCI), proporciona una forma de desarrollar la interacción entre un cerebro y un computador. Por tanto, la comunicación se desarrolla como resultado de respuestas neuronales generadas en el cerebro debido a movimientos motores o actividades cognitivas. Donde, los medios de comunicación incluyen acciones musculares y no musculares. Estas acciones generan actividades cerebrales u ondas cerebrales que se dirigen a un dispositivo de hardware para realizar una tarea específica.

El dispositivo BCI registra las respuestas cerebrales mediante diversas técnicas de adquisición invasivas y no invasivas, como la electrocorticografía (ECoG), la electroencefalografía (EEG), la magnetoencefalografía (MEG) y la resonancia magnética (MRI).

Los BCI se diferencian de otros dispositivos por las siguientes características:

- Creación de canal de comunicación natural entre usuario y máquina, dado que las respuestas a diferentes estímulos se traducen en comandos directamente, sin previa adaptación al tipo de interfaz.
- Acceso a información mental y afectiva del usuario.

1.6.1.1.1 Tipos de BCI

Actualmente existe una variedad de clasificaciones de los BCIs propuestas por diferentes autores, entre los cuales debido a su fácil entendimiento mencionaremos la siguiente clasificación: Ubicación de los sensores; Estrategia de operación y; Modo de operación [21][22][23].

1.6.1.1.2 Clasificación por ubicación de sensores

En función a la posición de los sensores respecto al cuerpo humano se clasifican en:

- **Invasivas:** Los BCI invasivos se plantean como la implantación y uso de tecnología dentro del cuerpo humano, por tanto, la obtención de datos se realiza a través de electrodos implantados quirúrgicamente en forma intracraneal. Las señales obtenidas mediante este método son de mejor calidad que las obtenidas con métodos no invasivos, sin embargo, conllevan riesgo para los usuarios debido a la intervención quirúrgica que debe realizarse [24]. Un ejemplo, es la electrocorticografía (ECoG), que registra la actividad del cerebro a través de una rejilla de electrodos que se incrusta quirúrgicamente.
- **No invasivas:** Las técnicas de BCI no invasivas implican la adquisición de señales sin dañar los tejidos cerebrales. Estas señales se obtienen a través de sensores/electrodos externos fijados en el cuero cabelludo [24]. Un ejemplo de BCI no invasivo es la Electroencefalografía (EEG), que registra la actividad del cerebro a través de electrodos sin necesidad de intervención quirúrgica.

1.6.1.1.3 Clasificación por la estrategia de operación

En función a la naturaleza de las señales de control empleadas se clasifican en:

- **Endógenas:** Estos dispositivos no necesitan de ningún tipo de estimulación externa para la generación de la actividad cerebral más bien dependen de la habilidad que tengan los usuarios en el control voluntario de sus señales cerebrales en el uso de un fin determinado. El manejo de este tipo de BCI requiere de una fase de entrenamiento intenso por parte del usuario y dependen significativamente del grado de modulación, muchas veces obtenidas a través de la Imaginación Motora (Motor Imaginary, MI) o de los ritmos cerebrales del sujeto [25].
- **Exógenas:** Este tipo de sistemas dependen de la actividad electrofisiológica provocada por estímulos externos para producir respuestas fisiológicas que serán realizadas de forma voluntaria por el sujeto mediante tareas cognitivas, causando distintos patrones de actividad cerebral a ser utilizados en los sistemas BCI. En estos sistemas los usuarios no necesitan de una etapa intensiva de entrenamiento. Dentro de este grupo tenemos a los BCI basados en potenciales evocados P300 y a los BCI basados en potenciales evocados de estado estable SSVEP [13].

1.6.1.1.4 Clasificación por el modo de operación

En función al modo en que son evocadas las señales cerebrales se clasifican en:

- **Activas:** Una BCI activa obtiene sus resultados de la actividad cerebral que el usuario controla de manera consciente, independientemente de los eventos externos [26]. Es decir, la generación de las señales es de forma consiente, por ejemplo, al imaginar el movimiento de uno de sus brazos. Se utilizan principalmente para enviar comandos voluntarios a una aplicación o dispositivo.
- **Reactivas:** Una BCI reactiva deriva sus resultados de la actividad cerebral que surge en reacción a la estimulación externa que es modulada indirectamente por el usuario para controlar una aplicación [26]. Las señales son evocadas a través de estímulos como luces, olores, imágenes, videos, sonidos.
- **Pasivas:** Una BCI pasiva no tiene el propósito de control voluntario de la actividad cerebral, enriquece la interacción humano-computadora con información implícita [26]. Se emplean para monitorear el estado mental de los usuarios como estrés, angustia, atención, etc., y así adaptar la aplicación objetivo de acuerdo con el estado. Dentro del grupo de las BCI pasivas se incluyen las BCI afectivas (aBCI), que monitorean estados afectivos o emociones como alegría o calma.

1.6.2 Electroencefalografía

La electroencefalografía es un método para registrar la actividad cerebral. Las señales de electroencefalografía registran continuamente la actividad eléctrica del cerebro colocando los electrodos metálicos sobre el cuero cabelludo. Las células neuronales se comunican espontáneamente entre sí mediante la generación de corrientes eléctricas y permanecen activas todo el tiempo incluso si una persona está durmiendo o relajándose.

La técnica EEG es no invasiva, flexible, rápida, económica y tiene alta resolución temporal, que utiliza electrodos ubicados sobre el cuero cabelludo para obtener registros de señales cerebrales. Los electrodos son colocados en el cuero cabelludo del cerebro utilizando el sistema estándar de colocación de electrodos 10-20. Además, existen sistemas de colocación de electrodos 10-10 y 10-5 para la adquisición de señales [27]. La diferencia entre los sistemas de electrodos 10-20, 10-10 y 10-5 es la distancia entre cada electrodo de las áreas de la corteza cerebral. El mapa de los sistemas de electrodos 10-20 y 10-10 se muestran en la Figura 1.

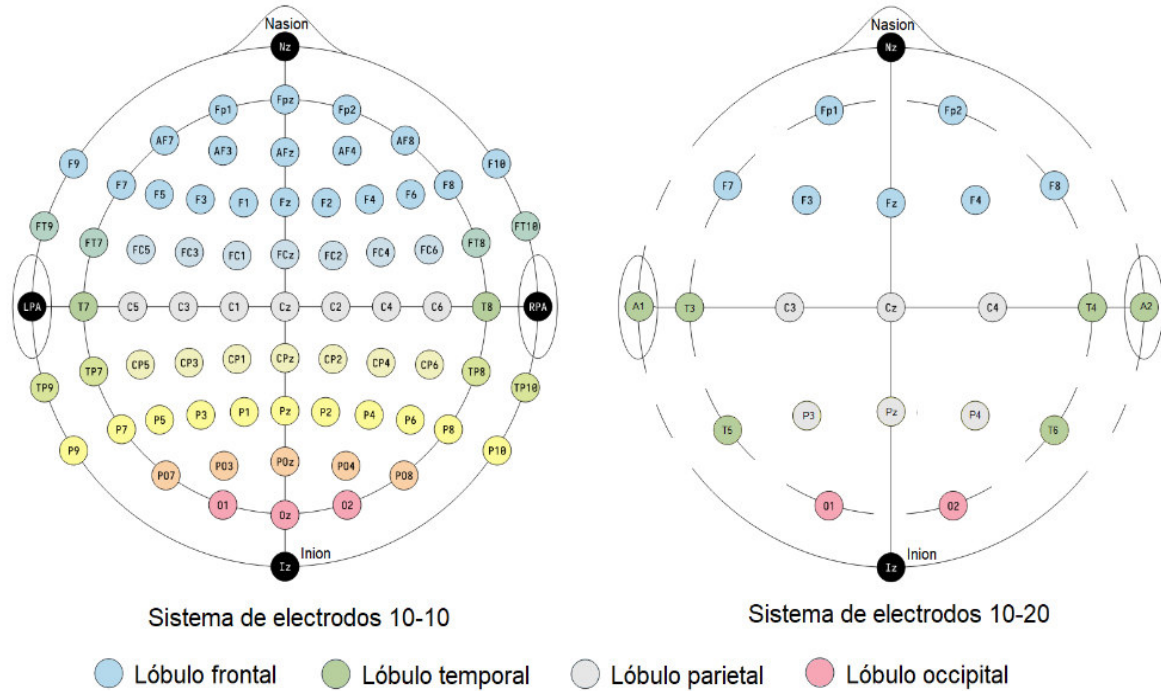


Figura 1. Sistemas de electrodos para la recopilación de datos de señales EEG [1]

1.6.2.1.1 Bandas de frecuencia

El cerebro es el órgano más complejo del cuerpo humano y la corteza cerebral es la parte más pronunciada del cerebro dividiéndose en lóbulo frontal, lóbulo parietal, lóbulo temporal y lóbulo occipital.

La función principal del lóbulo frontal es el pensamiento cognitivo y las necesidades emocionales. El lóbulo parietal responde a la sensación táctil humana y está relacionado con el equilibrio y la coordinación del cuerpo humano. El lóbulo temporal es el principal responsable de la audición y el olfato y está relacionado con las actividades emocionales y mentales. Finalmente, el lóbulo occipital se encarga de procesar la información visual.

Las señales cerebrales registradas a través de los dispositivos de EEG se clasifican en función de la frecuencia, denominada Brain Rhythmic Activity o EEG Rhythms [10]. Los rangos de frecuencia de muestra están entre 1 Hz a 100 Hz, y se clasifican en cinco bandas: Delta, Theta, Alfa, Beta y Gamma [7]. En la Tabla 1, se muestra la clasificación de las bandas de frecuencia con las características más relevantes acorde al rango [2], [11], [13]. Además, se hace mención a la región del cerebro con que se relaciona cada una de las bandas de frecuencia [28].

Tabla 1. Frecuencia de bandas

Banda	Rango de frecuencia	Región	Características
Delta	1 - 4 Hz	Tálamo	<ul style="list-style-type: none"> • Predomina en recién nacidos, raramente presente en adultos con estado normal durante vigilia. • Se observa en la tercera etapa del sueño conocida como sueño de ondas lentas (SWS). • Los artefactos generados por músculos de la mandíbula y el cuello generalmente se confunden con los ritmos delta. • Amplitudes variables superiores a 75 mV.
Tetha	4 - 8 Hz	Línea media frontal (hippocampus)	<ul style="list-style-type: none"> • Anormal en adultos, común en niños menores de 13 años. • Actividad subconsciente o somnolienta del cerebro, también presente en la meditación. • Asociados con estados de meditación, en ocasiones se asocia con estados de estrés, depresión o frustración. • El surgimiento de estas ondas en sujetos normales muestra el cambio de consciente al estado de somnolencia. • Amplitud aproximada de 20 mV.
Alfa	8 - 13 Hz	Occipital, Frontal	<ul style="list-style-type: none"> • Asociadas a la inactividad, se observan en el estado despierto pero relajado. • Muy afectado durante el ciclo menstrual. • La atenuación en esta frecuencia se puede utilizar para evaluar la ansiedad y tensión emocional. • Amplitudes superiores a los 20 mV.
Beta	13 - 30 Hz	Parietal, Frontal	<ul style="list-style-type: none"> • Se observan en el estado completamente despierto, alerta o en la resolución de problemas. • Aumento de la atención y el estado de alerta. • Se pueden obtener niveles crecientes de beta en condición de pánico. • Puede aumentar debido a los defectos óseos o en las regiones con tumores. • Amplitudes generalmente entre los 5 y 30 mV.

Gamma	>30 Hz	Fronto-Central	<ul style="list-style-type: none"> • Conocidas como ondas beta rápidas. • Se generan durante los movimientos voluntarios o al inducir estímulos. • Puede usarse como indicador para diagnosticar ciertos trastornos neurológicos. • Frecuencias más altas con amplitudes más bajas. • Integración funcional de actividades que se producen de forma transitoria. • Obtiene ubicaciones del cerebro responsables de movimientos voluntarios.
-------	--------	----------------	---

1.6.3 Computación afectiva

Computación Afectiva, en inglés Affective Computing, también conocida como Inteligencia Artificial Emocional, estudia cómo crear máquinas que puedan reconocer, interpretar y responder acertadamente a las emociones humanas [29]. La computación afectiva es un campo de la inteligencia artificial (IA) que surge de la necesidad de optimizar la interacción entre personas y computadoras.

Uno de los elementos clave en la Computación Afectiva es el reconocimiento de emociones, que identifica los estados emocionales humanos a partir de sus señales conductuales y fisiológicas [30]. Esta información se puede utilizar para decidir las acciones adecuadas para expresar emociones y diseñar nuevas formas de inteligencia emocional de la máquina y la interacción hombre-máquina.

El objetivo de la Computación Afectiva es modelar las interacciones emocionales entre un ser humano y una computadora midiendo el estado emocional de un usuario [31]. El estado emocional interno de una persona puede manifestarse por experiencias subjetivas (cómo se siente la persona), expresiones internas / internas (señales fisiológicas) y expresiones externas / externas (señales audiovisuales) [32].

1.6.3.1.1 Emociones

Las emociones desempeñan un papel vital en nuestras actividades de la vida diaria, incluida la toma de decisiones, la comunicación y el desarrollo personal. Las emociones positivas pueden ayudar a las personas a mejorar la eficiencia laboral y comunicarse mejor

con los demás, mientras que las emociones negativas pueden dañar nuestra salud física y mental [2].

En [28] los autores, demostraron que las computadoras que pueden reconocer y responder a las emociones humanas son fundamentales para el progreso de la interacción humana con la computadora. Sin embargo, el estudio de emociones es un tema complejo dada la dinámica de cambios constante y transformaciones en seres humanos ya sea de manera consciente o inconsciente. Donde, la extracción de características de señales EEG es esencial para la realización de sistemas de reconocimiento de emociones más precisos con el objetivo de mejorar la interacción entre humano y computador, lo que contribuye a campos de atención de la salud, aprendizaje, entretenimiento, negocios, entre otros.

1.6.3.1.2 Modelos para reconocimiento de emociones

Para modelar el estado emocional generalmente los investigadores utilizan una de las dos representaciones: Modelo categorial o discreto y Modelo dimensional o continuo [15],[33],[34].

1.6.3.1.3 Modelo categorial

En el modelo de emociones categorial o discreto se considera la teoría de la emoción básica, la cual sostiene que todas las emociones se pueden representar categóricamente en un conjunto primitivo de emociones básicas, prototípicas e innatas que se activan en respuesta a estímulos ambientales específicos, la combinación de emociones básicas da a lugar emociones avanzadas [35].

El número de emociones básicas en el modelo discreto es un tema de controversia, existe una disputa entre investigadores sobre el número exacto de emociones básicas. Algunos investigadores sostienen que hay ocho emociones básicas consideradas como estados psicológicos separados e independientes [36], mientras que otros cuentan hasta 27 emociones [37].

En la Figura 2, se aprecia la rueda de emociones propuesta por Robert Plutchik, muestra 8 emociones básicas con tres estados diferentes, los más fuertes ubicados al interior del gráfico y los débiles ubicados en el exterior, con una coloración tenue. Donde, la combinación entre emociones básicas genera emociones avanzadas.




Figura 2. Representación de emociones básicas y avanzadas [38]

1.6.3.1.4 Modelos dimensionales

El modelo dimensional o continuo, intenta exponer cómo el individuo experimenta y procesa sus emociones a través de la combinación de las dimensiones de juicio de agrado/desagrado (valencia), de activación (arousal) y de control (dominancia), dando lugar a los modelos bidimensional y tridimensional.

El **modelo bidimensional** describe a las emociones mediante los valores continuos de al menos dos factores: valencia (de negativo a positivo) y arousal (de calmado a emocionante) [39]. Las emociones se pueden dividir en cuatro grupos que son alto arousal - alta valencia (HAHV), alto arousal - baja valencia (HALV), bajo arousal - baja valencia (LALV), bajo arousal - alta valencia (LAHV) [40].

En la Figura 3, se muestran las emociones representativas de los cuatro cuadrantes en base a los componentes valencia - arousal en los ejes (x, y) respectivamente. Así, en el cuadrante superior derecho (HAHV) se ubican emociones como la felicidad, el entusiasmo. En el cuadrante superior izquierdo (HALV) se ubican emociones como la ira, el estrés. En el cuadrante inferior derecho (LAHV) se encuentran emociones como la calma, la satisfacción. En el cuadrante inferior izquierdo (LALV) se ubican emociones como la tristeza, el aburrimiento.

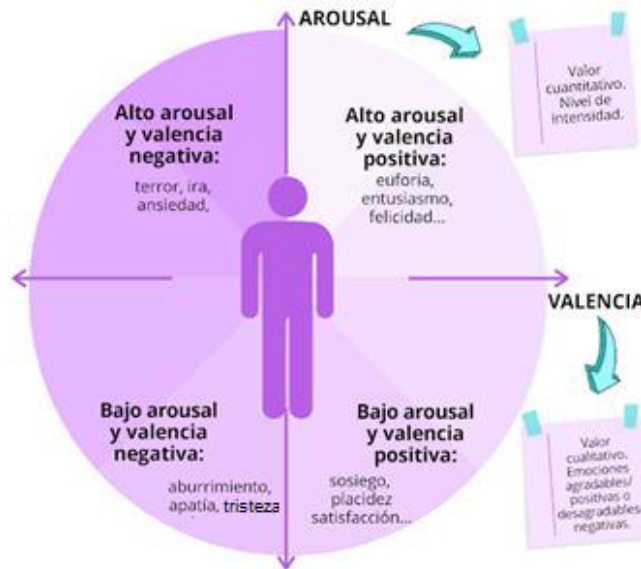


Figura 3. Representación del modelo bidimensional [41]

La utilidad de este modelo es la conceptualización de emociones por parte de personas no expertas en el ámbito de la psicología, facilitando la medición y valoración de la intensidad y tipo de emociones, lo cual es primordial en la elaboración de investigaciones [42].

El **modelo tridimensional** describe a las emociones mediante los valores continuos de tres factores: valencia, arousal y dominancia (continuidad o interrupción de la secuencia conductual). La dominancia se refiere a la percepción individual de control ejercido sobre el ambiente y la emoción misma.

La mayoría de emociones básicas se pueden clasificar a partir del modelo bidimensional. Sin embargo, si incluyen el conjunto de emociones avanzadas las características valencia - arousal se quedan cortas, por este motivo se define el factor dominancia, para diferenciar aquellas emociones que el sujeto es capaz de controlar.

En la Figura 4, se muestra un cubo de emociones cuyo origen de los ejes correspondientes a valencia - arousal – dominancia. Donde, a medida que los valores de los ejes cambian y se combinan entre sí, generan emociones distintas, por ejemplo, altos valores de valencia - arousal, pero con bajo valor de dominancia provocan la emoción de felicidad [43].

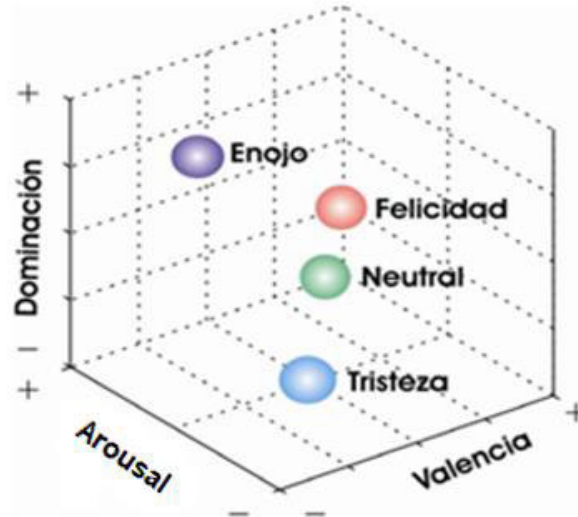


Figura 4. Modelo tridimensional [43]

1.6.4 Medición de Emociones en Usuarios

La medición del estado emocional de un sujeto en distintas situaciones, ha dado a lugar diversas bases de estímulos, siendo las principales emociones a clasificar la tristeza, ira, alegría y miedo. Donde, identificar a la emoción como tal representa un gran desafío.

La Escala SAM Maniquí de Auto Evaluación o en inglés Self-Assessment Manikin SAM, es una escala para medir estados emocionales tales como el placer, la excitación y el control. SAM evalúa el estímulo asociado en respuesta a un evento u objeto [44]. La categoría de evaluación de este método incluye tres dimensiones del modelo de estado emocional PAD: Valencia, Arousal y Dominancia, cada estado emocional se divide en cinco niveles según el grado de diferencia.

En la dimensión de valencia el rango de SAM se extiende desde lo agradable (maniquí sonriente) hasta lo desagradable (maniquí ceñudo) como se muestra en la Figura 5. En la dimensión de arousal el rango de Sam comprende desde la excitación (maniquí de ojos desorbitados) hasta la calma (maniquí somnoliento). La dimensión de dominancia comprende desde lo incontrolable (maniquí sobredimensionado) hasta lo controlable (maniquí diminuto) [45].

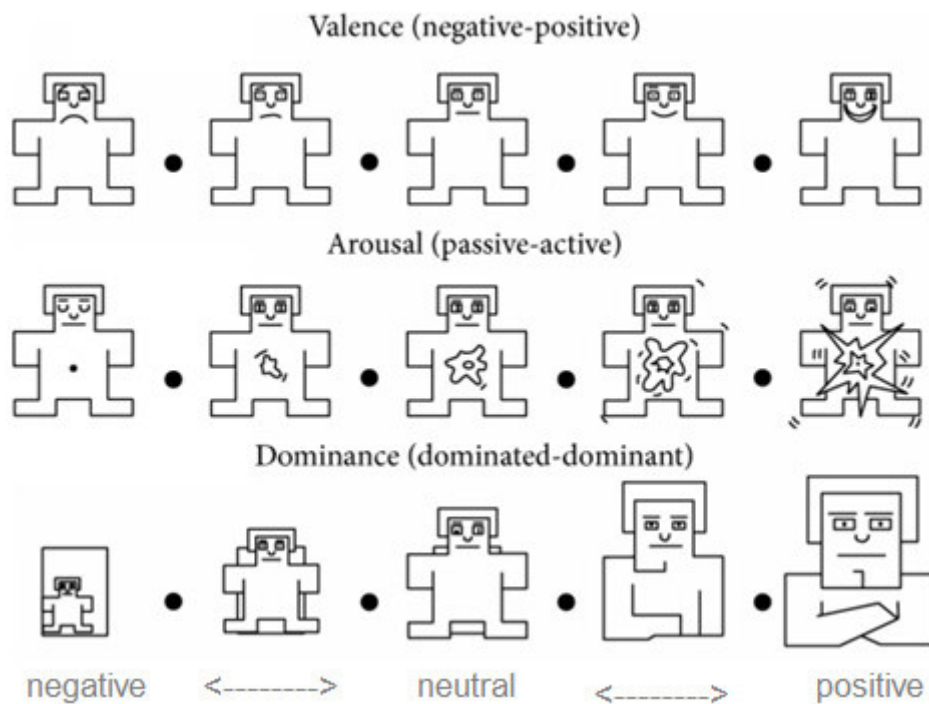


Figura 5. Medición de emociones: The Self-Assessment Manikin (SAM) [46]

En esta versión de SAM el sujeto puede colocar una "X" sobre cualquiera de los cinco maniqués en la escala, o entre dos maniqués, lo que da como resultado una escala de calificación de 9 puntos para cada dimensión. SAM se ha utilizado para medir respuestas emocionales en una variedad de situaciones inducidos por estímulos externos (imágenes, sonidos, anuncios, entre otros).

CAPÍTULO 2. REVISIÓN SISTEMÁTICA DE LITERATURA

Establecidos los fundamentos de reconocimiento de emociones utilizando como vectores de entrada características del dominio del tiempo, frecuencia y tiempo-frecuencia a clasificadores automáticos, se presenta una revisión sistemática de la literatura (RSL) que resume el desarrollo reciente de los modelos de clasificación en el ámbito de reconocimiento de emociones con BCI.

Las fases para la revisión sistemática de literatura acorde a la metodología de Bárbara Kitchenham [47] de forma general son las siguientes: a) Definición de las preguntas de investigación; b) Fuentes y estrategia de búsqueda; c) Criterios de inclusión y exclusión; d) Clasificación de estudios relevantes; e) Síntesis de datos y; f) Resultados y discusión.

2.1 Preguntas de investigación

La revisión de literatura de este trabajo se realiza en base a tres preguntas de investigación, desarrolladas con base en los objetivos de nuestra investigación.

- RQ1: ¿Qué métodos se utilizan para la extracción de características en los dominios del tiempo, la frecuencia o tiempo-frecuencia para el reconocimiento de emociones?
- RQ2: ¿Que algoritmos de clasificación obtienen mejores resultados en la clasificación de emociones?
- RQ3: ¿Qué métricas se utilizan para la evaluación del desempeño de modelos de clasificación de emociones?

2.2 Fuentes y estrategias de búsqueda

Se utilizó ACM Digital Library, IEEEExplore, Springer y Elsevier para búsquedas de revistas utilizadas en esta revisión. Se eligió ACM porque cubre el área de informática y tecnología de la información. IEEEExplore se enfoca exclusivamente en informática, ingeniería y electrónica, es calificada como de las mayores compilaciones de literatura técnica del mundo. Se seleccionó SpringerLink porque contiene journals revisados por pares y proporciona acceso al texto completo.

Finalmente, dadas las características de nuestra investigación se seleccionó Elsevier ya que proporciona información y análisis de investigaciones sobre ciencia y salud en el área de ciencias de la computación.

Con base en las preguntas de investigación mencionadas, se obtuvo las siguientes palabras clave: EEG signals, emotion recognition, machine learning, valence-arousal model, time domain features, frequency domain features, time-frequency domain features, feature extraction, classification, dataset DEAP y dataset SEED.

Posteriormente, se desarrolló una lista de cadenas de búsqueda combinando las palabras clave extraídas con los operadores "Y" y "O". Establecimos seis cadenas de búsqueda (SS01, SS02, SS03, SS04, SS05 y SS06). Todas las cadenas de búsqueda incluyen las palabras clave "EEG signals" y "emotion recognition", donde la diferencia la hacen las primeras palabras. SS01 incluye la palabra clave machine learning. SS02 incluye la palabra clave valence-arousal model. SS03 es más largo porque incluye las palabras clave que involucran los dominios de tiempo, frecuencia y tiempo frecuencia de los cuales se obtendrán las diferentes características. SS04 incluye la palabra clave feature extraction. SS05 incluye la palabra clave classification. Finalmente, SS06 incluye las palabras clave dataset DEAP y SEED. Cabe mencionar que esta estrategia proporciona que los resultados de cada base de datos tengan elementos duplicados.

La Tabla 2, representa las cadenas de búsqueda desarrolladas para este estudio y los resultados de la búsqueda.

Tabla 2. Resultados de la búsqueda

Fuente	ID	Búsqueda	Total
IEEE	SS01	("All Metadata":EEG signals) AND ("All Metadata":emotion recognition) AND ("All Metadata":machine learning)	43
	SS02	("All Metadata":EEG signals) AND ("All Metadata":emotion recognition) AND ("All Metadata":valence-arousal model)	10
	SS03	("All Metadata":EEG signals) AND ("All Metadata":emotion recognition) AND ("All Metadata":time domain features) OR ("All Metadata":frequency domain features) OR ("All Metadata":time - frequency domain features)	16
	SS04	("All Metadata":EEG signals) AND ("All Metadata":emotion recognition) AND ("All Metadata":feature extraction)	97
	SS05	("All Metadata":EEG signals) AND ("All Metadata":emotion recognition) AND ("All Metadata":classification)	91
	SS06	("All Metadata":EEG signals) AND ("All Metadata":emotion recognition) AND ("All Metadata":dataset DEAP) AND ("All Metadata":dataset SEED)	237

		Metadata":dataset DEAP) OR ("All Metadata": dataset SEED)	
			494
Springer	SS01	'ALL EEG signals AND emotion recognition AND machine learning'	93
	SS02	'ALL EEG signals AND emotion recognition AND valence-arousal model'	22
	SS03	'ALL EEG signals AND emotion recognition AND time domain features OR frequency domain features OR time - frequency domain features'	70
	SS04	'ALL EEG signals AND emotion recognition AND feature extraction'	79
	SS05	'ALL EEG signals AND emotion recognition AND classification'	92
	SS06	'ALL EEG signals AND emotion recognition AND dataset DEAP OR dataset SEED'	8
ACM	SS01	[Title: eeg signals] AND [Title: emotion recognition] AND [All: machine learning]	18
	SS02	Title: eeg signals] AND [Title: emotion recognition] AND [All: valence-arousal model]	18
	SS03	[Title: eeg signals] AND [Title: emotion recognition] AND [[All: and time domain features] OR [All: frequency domain features] OR [All: time frequency domain features]]	19
	SS04	[Title: eeg signals] AND [All: emotion recognition] AND [All: feature extraction]	83
	SS05	[Title: eeg signals] AND [Full Text: emotion recognition] AND [Title: classification]	7
	SS06	[Title: eeg signals] AND [All: emotion recognition] AND [All: dataset deap] AND [All: or dataset seed]	56
Elsevier	SS01	EEG signals AND emotion recognition AND machine learning	51
	SS02	EEG signals AND emotion recognition AND valence-arousal model	25
	SS03	EEG signals AND emotion recognition AND time domain features OR frequency domain features OR time - frequency domain features	14
	SS04	EEG signals AND emotion recognition AND feature extraction	49
	SS05	EEG signals AND emotion recognition AND classification	59

SS06	EEG signals AND emotion recognition AND dataset DEAP OR dataset SEED	25
		223
Total de publicaciones		1228

2.3 Criterios de inclusión y exclusión

Luego de identificar las cadenas de búsqueda a utilizar, el siguiente paso fue establecer los siguientes criterios de inclusión y exclusión, mostrados en la Tabla 3.

Tabla 3. Criterios de inclusión y exclusión para la RSL.

Criterios de inclusión	Criterios de exclusión
<ul style="list-style-type: none"> • Publicaciones científicas realizadas en revistas de ciencia y salud, tecnología e informática. • Artículos que utilicen para el reconocimiento de emociones los dataset DEAP o SEED. • Artículos que proponen reconocimiento de emociones a partir de señales EEG y extracción de características en dominio de tiempo, frecuencia o tiempo - frecuencia. 	<ul style="list-style-type: none"> • Artículos que no aportan con métodos de extracción de características en los dominios tiempo, frecuencia o tiempo-frecuencia. • Artículos científicos que no utilicen medidas de rendimiento para los clasificadores. • Artículos científicos con metodología que no sea clara o específica. • Reseñas de literatura, capítulos de libros, tesis, informes técnicos, propuestas de investigación, conferencias o manuales. • Artículos publicados antes del año 2016 o después del 2021. • Artículos duplicados.

2.4 Selección de estudios relevantes

En esta sección se describe el proceso realizado en la RSL, desde la fase de búsqueda inicial, los procesos de filtración y validación hasta la selección de publicaciones para llevar a cabo el presente proyecto.

La Figura 6, representa las fases que componen la revisión sistemática de literatura. Se encontró 1282 artículos después de realizar la actividad de estrategia de búsqueda. El proceso de filtración se realizó aplicando los criterios de inclusión y exclusión, seleccionando solo aquellos trabajos que aplicaron alguna métrica de evaluación del algoritmo de calificación, se excluyeron 1222 artículos, quedando un total de 60 artículos. La validación de los journals se realizó en base a la lectura de los artículos, seleccionando aquellos más relevantes de acuerdo al contenido del abstract y la descripción de la metodología que tenga un detalle que permita replicación, quedando un total de 23 artículos. Luego de realizar la técnica de snowballing, se agregaron 7 artículos, dando un total de 30 artículos.

Por otro lado, en la Tabla 4, se presenta los estudios primarios que fueron seleccionados luego de los procesos de búsqueda, filtrado y validación. La tabla contiene información del número de referencia bibliográfica, el autor, el título y año de las publicaciones.

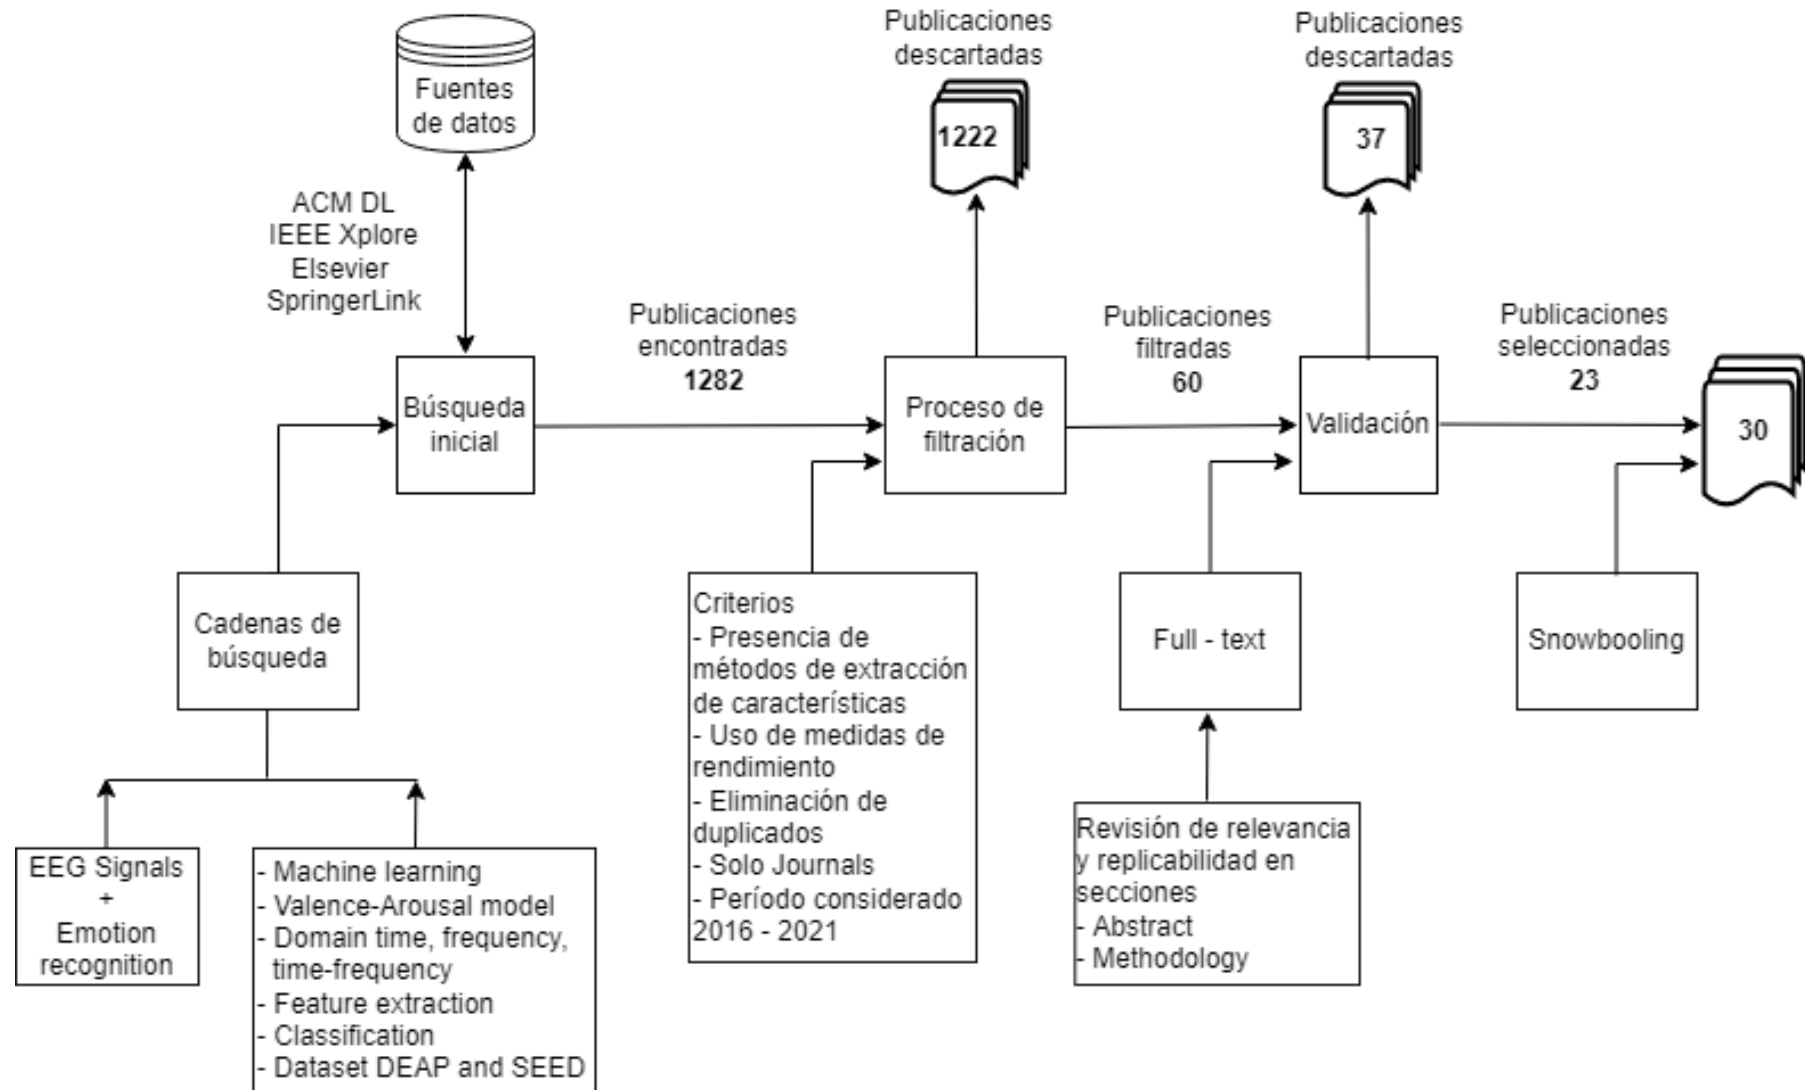


Figura 6. Proceso de revisión sistemática de literatura (RSL)

Tabla 4. Estudios primarios seleccionados

ID	Ref	Autores	Título	Año
PS01	[49]	Garg et al.	Emotion Recognition in Valence-Arousal Space from Multi-channel EEG data and Wavelet based Deep Learning Framework	2020
PS02	[50]	Ozel et al.	Synchrosqueezing transform based feature extraction from EEG signals for emotional state prediction	2019
PS03	[51]	Rahman et al.	Employing PCA and t-statistical approach for feature extraction and classification of emotion from multichannel EEG signal	2019
PS04	[15]	Nawaz et al.	Comparison of different feature extraction methods for EEG-based emotion recognition	2020
PS05	[52]	Wang et al.	Emotion recognition with convolutional neural network and EEG-based EFDMs	2020
PS06	[53]	Yin et al.	Locally robust EEG feature selection for individual-independent emotion recognition	2020
PS07	[54]	Atkinson et al.	Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers	2016
PS08	[33]	Chakladar et al.	EEG based emotion classification using “Correlation Based Subset Selection”	2018
PS09	[55]	Zhang et al.	An approach to EEG-based emotion recognition using combined feature extraction method	2016
PS10	[56]	Gao et al.	EEG based emotion recognition using fusion feature extraction method	2020
PS11	[57]	Khateeb et al.	Multi-Domain Feature Fusion for Emotion Classification Using DEAP Dataset	2021
PS12	[48]	Zheng et al.	Identifying Stable Patterns over Time for Emotion Recognition from EEG	2017
PS13	[58]	Li et al.	Domain Adaptation for EEG Emotion Recognition Based on Latent Representation Similarity	2020
PS14	[59]	Gupta et al.	Cross-Subject Emotion Recognition using Flexible Analytic Wavelet Transform from EEG Signals	2018

PS15	[60]	Luo et al.	EEG-Based Emotion Classification Using Spiking Neural Networks	2020
PS16	[61]	Aras et al.	Two-stepped majority voting for efficient EEG-based emotion classification	2020
PS17	[62]	Ozerdem et al.	Emotion recognition based on EEG features in movie clips with channel selection	2017
PS18	[63]	Mohammadi et al.	Wavelet-based emotion recognition system using EEG signal	2017
PS19	[64]	Verma et al.	Affect representation and recognition in 3D continuous valence–arousal–dominance space	2016
PS20	[65]	Ahirwal et al.	Audio-visual stimulation based emotion classification by correlated EEG channels	2019
PS21	[66]	Pane et al.	Improving the accuracy of EEG emotion recognition by combining valence lateralization and ensemble learning with tuning parameters	2019
PS22	[67]	Zubair et al.	EEG Based Classification of Human Emotions Using Discrete Wavelet Transform	2017
PS23	[67]	Thejaswini et al.	EEG Based Emotion Recognition Using Wavelets and Neural Networks Classifier	2017
PS24	[68]	Chen et al.	Performance Comparison of Machine Learning Algorithms for EEG-Signal-Based Emotion Recognition	2017
PS25	[69]	Piho et al.	A Mutual Information Based Adaptive Windowing of Informative EEG for Emotion Recognition	2020
PS26	[70]	González et al.	Fusing highly dimensional energy and connectivity features to identify affective states from EEG signals	2017
PS27	[71]	Sharma et al.	Automated emotion recognition based on higher order statistics and deep learning algorithm	2020
PS28	[72]	Ali et al.	EEG-Based Emotion Recognition Approach for E-Healthcare Applications	2016
PS29	[73]	Menezes et al.	Towards emotion recognition for virtual environments: an evaluation of EEG features on benchmark dataset	2017

PS30	[74]	Guendil et al.	Computational framework for emotional VAD prediction using regularized Extreme Learning Machine	2017
-------------	------	----------------	---	------

2.5 Análisis de la RSL

A continuación, el análisis de la información obtenida una vez finalizada la fase de Selección de estudios relevantes de la RSL. En esta sección se presentan los métodos de extracción de características, clasificadores, métricas de evaluación de desempeño y porcentajes de clasificación de clases, de las publicaciones seleccionadas en la sección anterior.

La Tabla 5, presenta una síntesis de la información revisada en la literatura y contiene los datos sobre métodos de extracción de características en los dominios de tiempo, frecuencia o tiempo-frecuencia, tipos de clasificadores, clases a categorizar y métricas de evaluación de desempeño.

En la Tabla 6, se muestran los valores de precisión de la clasificación obtenidos en los estudios seleccionados. La métrica de evaluación de desempeño de referencia es Accuracy, dado que la mayor parte de los estudios la utilizan, se presenta una métrica diferente en caso que, el estudio no establezca Accuracy.

El diseño de las tablas se basa en los hallazgos realizados a partir de las preguntas de investigación (RQ1, RQ2 y RQ3). Los datos generados se presentan, analizan e interpretan en la sección "Resultados de la RSL".

Tabla 5. Métodos de extracción de características, clasificadores y métricas de desempeño más comunes en el reconocimiento de emociones en EGG.

ID	Base de datos	Características utilizadas	Dominio	Clasificador(es)	Clases	Métrica
PS01	DEAP	<ul style="list-style-type: none"> DWT 	Tiempo - Frecuencia	CNN	Valencia, Arousal	Acc
PS02	DEAP	<ul style="list-style-type: none"> DWT 	Tiempo - Frecuencia	k-NN, DT, SVM, EC	Valencia, Arousal, Dominancia	Acc
PS03	SEED	<ul style="list-style-type: none"> Stddev, AFD_N, ASD_N, MedAD, Norm L2, Max Norm HFD, SpNorm, SE, PSD 	Tiempo Frecuencia	ANN, SVM, LDA, k-NN	Positivo, Negativo, Neutro	Acc
PS04	DEAP	<ul style="list-style-type: none"> Mean, Stddev, AFD_N, ASD_N, PFD, HFD, KFD PerEn, ApEn, SampEn SE, SVDE, DASM, RASM DWT 	Tiempo Frecuencia Tiempo - Frecuencia	SVM, k-NN, DT	Valencia, Arousal, Dominancia	Acc, Varz
PS05	SEED DEAP	<ul style="list-style-type: none"> STFT 	Frecuencia	CNN	Positivo, Negativo, Neutro	Acc
PS06	DEAP	<ul style="list-style-type: none"> Var, Skewness, Kurtosis, ZeCr, ShEn PR 	Tiempo Frecuencia	NB, LR, k-NN, ANN, SVM	Valencia, Arousal	Acc, F1
PS07	DEAP	<ul style="list-style-type: none"> Median, Stddev, Kurtosis HP, HFD 	Tiempo	SVM	Valencia, Arousal	Acc

PS08	DEAP	<ul style="list-style-type: none"> • Mean, Stddev, Skewness, Kurtosis 	Tiempo	LDA	Positivo, Negativo, Angry, Harmony	Sen, Prc, Spe, F1
PS09	DEAP	<ul style="list-style-type: none"> • SampEn • EMD 	Tiempo Tiempo - Frecuencia	SVM	Valencia, Arousal	Acc
PS10	DEAP	<ul style="list-style-type: none"> • STFT - PSD • DWT 	Frecuencia Tiempo - Frecuencia	SVM	Neutral, Happy, Sad	Acc
PS11	DEAP	<ul style="list-style-type: none"> • HP, ShEn • STFT, RASM, DASM • DWT 	Tiempo Frecuencia Tiempo - Frecuencia	SVM	Valencia, Arousal	Acc, Prc, Rec, F1
PS12	DEAP SEED	<ul style="list-style-type: none"> • ShEn • STFT - PSD 	Tiempo Frecuencia	SVM, ANN - ELM	Valencia, Arousal Positivo, Negativo, Neutro	mAR
PS13	DEAP SEED	<ul style="list-style-type: none"> • ShEn • PSD 	Tiempo Frecuencia	MLP - DNN	Valencia, Arousal Positivo, Negativo, Neutro	Acc, Mean, Std
PS14	DEAP SEED	<ul style="list-style-type: none"> • DWT - FAWT 	Tiempo - Frecuencia	RF, SVM	Valencia, Arousal Positivo, Negativo, Neutro	Acc
PS15	DEAP SEED	<ul style="list-style-type: none"> • Var • FFT • DWT 	Tiempo Frecuencia Tiempo - Frecuencia	ANN - SNN	Valencia, Arousal, Dominancia, Liking	Acc
PS16	DEAP	<ul style="list-style-type: none"> • HFD, KDF, ShEn 	Tiempo	k-NN	HV, LV, HA, LA	Sen, Spe, Acc

		<ul style="list-style-type: none"> • DWT 	Tiempo - Frecuencia			
PS17	DEAP	<ul style="list-style-type: none"> • Max, Mean, Avg, Stddev, Eng • DWT 	Tiempo Tiempo - Frecuencia	k-NN, MLP - MLPNN	Positivo, Negativo	Sen, Spe, Acc
PS18	DEAP	<ul style="list-style-type: none"> • DWT (Ent, Eng) 	Tiempo - Frecuencia	k-NN, SVM	Valencia, Arousal	Acc
PS19	DEAP	<ul style="list-style-type: none"> • DWT 	Tiempo - Frecuencia	k-NN, SVM, MPL	Valencia, Arousal, Dominancia	CR, F1, ROC
PS20	DEAP	<ul style="list-style-type: none"> • LinLen, RMS, AFD_N, ASD_N, SE, ShEn, SampEn • PR, PP, FD, TE 	Tiempo Frecuencia	SVM, NB, ANN	Valencia, Arousal	Acc, Prc, Rec
PS21	DEAP	<ul style="list-style-type: none"> • Avg, Stddev, kurtosis, skewness, ZeCr HP, HFD, Eng, ShEn • PSD, STFT • DWT 	Tiempo Frecuencia Tiempo - Frecuencia	RF, SVM, LDA	Valencia, Arousal	Acc
PS22	DEAP	<ul style="list-style-type: none"> • Mean, Stddev, AFSD_N • DWT 	Tiempo Tiempo - Frecuencia	SVM, QDA	Valencia, Arousal	Acc
PS23	SEED	<ul style="list-style-type: none"> • HP, ShEn, DASM RASM Mean, Stddev, kurtosis AFD_N, ASD_N • DWT 	Tiempo Tiempo - Frecuencia	SVM, ANN	Positivo, Negativo, Neutral	Acc
PS24	DEAP	<ul style="list-style-type: none"> • SampEn, ApEn • DWT (Ent, Eng, energy ratio) 	Tiempo Tiempo - Frecuencia	k-NN, NB, SVM, RF	Valencia, Arousal	Acc

PS25	DEAP	<ul style="list-style-type: none"> Mean, Stddev, AFD_N, ASD_N, PSE, HOC, HOS 	Tiempo	SVN, k-NN, NB	Valencia, Arousal	Acc, Mean, Max
PS26	DEAP	<ul style="list-style-type: none"> RE, SP 	Tiempo	NB, SVM	Valencia, Arousal	Mean, Std, F1
PS27	SEED	<ul style="list-style-type: none"> HOS DWT 	Tiempo Tiempo - Frecuencia	ANN (LSTM)	Valencia, Arousal	Acc, Sen, Spe, rAcc
PS28	DEAP	<ul style="list-style-type: none"> Mean, Stddev, AFD_N, ASD_N DWT (Eng, Ent) 	Tiempo Tiempo - Frecuencia	QDA, k-NN, SVM	Valencia, Arousal	Spe, Prc, Rec, Acc
PS29	DEAP	<ul style="list-style-type: none"> Mean, Stddev, AFD_N, ASD_N HOC PSD 	Tiempo Frecuencia	RF, SVM	Valencia, Arousal	Acc
PS30	DEAP	<ul style="list-style-type: none"> DWT 	Tiempo - Frecuencia	ANN (R-ELM)	Valencia, Arousal, Dominancia	Acc

Siglas utilizadas para denotar los diferentes métodos de extracción de características, clasificadores y métricas de evaluación encontrados en la RSL. **Extracción de características:** Standard Deviation (Stddev), Variance (Var), Maximum (Max), Mean of the normalized absolute values of the first and second (AFD_N), Mean of the normalized absolute values of the first and second (ASD_N), Energy (Eng), Root mean square (RMS), Line Length (LinLen), Average power (Avg), Shannon Entropy (ShEn), Approximate Entropy (ApEn), Sample Entropy (SampEn), Permutation Entropy (PerEn), Higuchi Fractal Dimension (HFD), Katz's Fractal Dimension (KFD), Preprosiian Fractal Dimension (PFD), Hjorth Parameters (HP), Zero Crossing (ZeCr), Higher Order Crossing (HOC), Higher Order Spectral (HOS), Singular Value Decomposition Entropy (SVDE), Empirical mode decomposition (EMD), Spectral entropy (SE), Power Ratio (PR), Power Spectral Density (PSD), Fast Fourier Transform (FFT), Short-Time Fourier Transform (STFT), Spectal Norm (SpNorm), Rational Asymmetry (RASM), Differential Asymmetry (DASM), Frecuencia Dominante (FD), Power Spectral Entropy (PSE), Relative Energy (RE), Spectral Power (SP), Peak Power (PP), Discrete Wavelet Transform (DWT), Wavelet Energy (WEng), Wavelet Entropy (WEnt), Total Wavelet Energy (TE). **Clasificadores:** Convolutional Neural Networks (CNN), Ensemble Classifiers (EC), Decision Tree (DT), Artificial Neural Networks (ANN), Support Vector Machine (SVM), Linear Discriminant Analysis (LDA), k-Nearest Neighbors (k-NN), Naive Bayes (NB), Logistic Regression (LR), Random Forest (RF), Multi-Layer Perceptron (MLP), Quadratic Discriminant Analysis (QDA). **Métricas:** Accuracy (Acc), Variance (Varz), F1-Score (F1), Sensitivity (Sen), Precision (Prc), Specificity (Spe), Recall (Rec), Mean Accuracy Rates (mAR), Standard Deviation (Std), Receiver Operating Characteristics (ROC), Classification Rate (CR), Random Accuracy (rAcc).

Tabla 6. Precisión en la clasificación de emociones

ID	Clasificador	Porcentaje
PS01	CNN	High, Low, Medium <ul style="list-style-type: none"> Valencia: 2 Clases HV y LV 92,19% y 3 Clases HV y LV y MV 83,59% Arousal: 2 Clases HA y LA 61,23% y 3 Clases HA y LA y MA 55,56%
PS02	DT	<ul style="list-style-type: none"> Valencia Arousal Avg.Acc 75.73% HAHV 69.8%, HALV 74.8%, LALV 76.8%, LAHV 77.7%
	SVM	<ul style="list-style-type: none"> Valencia Arousal Avg.Acc 76.30% HAHV 70.8%, HALV 79.1%, LALV 77.1%, LAHV 78.2%
	k-NN	<ul style="list-style-type: none"> Valencia Arousal Avg.Acc 76.28% HAHV 70.7%, HALV 79.1%, LALV 77.1%, LAHV 78.2%
	EC	<ul style="list-style-type: none"> Valencia Arousal Avg.Acc 76.33% HAHV 70.9%, HALV 79.1%, LALV 77.1%, LAHV 78.2%
PS03	SVM	<ul style="list-style-type: none"> Avg.Acc 77.1% Negativo 73.8%, Neutral 77.1%, Positivo 79.7%
	ANN	<ul style="list-style-type: none"> Avg.Acc 84.3% Negativo 86.3%, Neutral 84.4%, Positivo 82.9%
	LDA	<ul style="list-style-type: none"> Avg.Acc 72.9% Negativo 74.6%, Neutral 71.6%, Positivo 72.5%
	k-NN	<ul style="list-style-type: none"> Avg.Acc 66.7% Negativo 72.4%, Neutral 60%, Positivo 69.4%
PS04	k-NN	Valencia (HV y LV)
	SVM	<ul style="list-style-type: none"> Statistical 75.06% FD 63.79%, Entropy 63.36%, Wavelet 61.5%
	DT	<ul style="list-style-type: none"> Statistical 77.62%, FD 66.95%, Entropy 67.68%, Wavelet 66.68% Statistical 71.84%, FD 59.41%, Entropy 60.39%, Wavelet 61.95% Arousal (HA y LA) <ul style="list-style-type: none"> Statistical 74.71%, FD 65.33%, Entropy 66.27%, Wavelet 65.35% Statistical 78.96%, FD 66.56%, Entropy 67.30%, Wavelet 66.89% Statistical 72.93%, FD 61.74%, Entropy 62.03%, Wavelet 62.70%
PS05	CNN	<ul style="list-style-type: none"> DEAP: Negativo 79%, Neutral 84%, Positivo 86% SEED: Negativo 88%, Neutral 90%, Positivo 93%
PS06	NB	Valencia (HV y LV), Arousal (HA y LA)
	LR	<ul style="list-style-type: none"> Valencia 67.32%, Arousal 63.13%
	k-NN	<ul style="list-style-type: none"> Valencia 64.87%, Arousal 60.65%
	ANN	<ul style="list-style-type: none"> Valencia 65.13%, Arousal 60.05%
	SVM	<ul style="list-style-type: none"> Valencia 65.60%, Arousal 61.85% Valencia 67.97%, Arousal 65.10%
PS07	SVM	High, Low, Medium <ul style="list-style-type: none"> Valencia 2 clases HV y LV 73.14% y 63.33% 3 clases HV y LV y MV

		<ul style="list-style-type: none"> • Arousal 2 clases HA y LA 73.06% y 3 clases 60.70% HA y LA y MA
PS08	LDA	<ul style="list-style-type: none"> • Accuracy 82% • Specificity: Positivo 94.61%, negativo 92.54%, enojado 94.06%, en armonía 93.34%
PS09	SVM	<ul style="list-style-type: none"> • HAHV/LAHV 93.92%, LAHV/LALV 93.40%, LALV/HALV 95.63%, HALV/HAHV 96.96%.
PS10	SVM	<ul style="list-style-type: none"> • Avg.Acc Neutral 85.67%, feliz 87.11%, y triste 89.17%,
PS11	SVM	<ul style="list-style-type: none"> • Avg.Acc 9 clases 65.92% (feliz, complacido, relajado, emocionado, neutral, tranquilo, angustiado, miserable y deprimido). • Avg.Acc 7 clases 86.43% (positivas: alegría, diversión, ternura y negativas: ira, asco, miedo, tristeza).
PS12	SVM ANN	DEAP – mAR <ul style="list-style-type: none"> • PSD 36.19%, DE 47.5% (VA) • PSD 61.46%, DE 69.67% (VA) SEED - mAR <ul style="list-style-type: none"> • PSD 72.75%, DE 91.07% (positivo, neutral, negativo). Clasificador ELM.
PS13	MLP	DEAP - 60.38% (VA) SEED - 84.47% (positivo, neutral, negativo).
PS14	RF SVM	DEAP - RF: 2 Clases 79.95% HA y LA, 79.99% HV y LV, 4 Clases 71.43% (VA) SEED <ul style="list-style-type: none"> • 90.48% (positivo, neutral, negativo). • 78.54% (positivo, neutral, negativo).
PS15	ANN	DEAP Valencia Var 78%, FFT 70%, WDT 68% (HV y LV) Arousal Var 74%, FFT 66%, WDT 66% (HA y LA) SEED Valencia Var 100%, FFT 66.67%, WDT 70.5% (positivo, neutral, negativo). Arousal Var 89.99%, FFT 33.33%, WDT 59.5% (positivo, neutral, negativo).
PS16	k-NN	HV y LV 86.25% HA y LA 85%
PS17	k-NN MLP	<ul style="list-style-type: none"> • 72.92% Positivo, negativo • 77.14% Positivo, negativo
PS18	k-NN SVM	<i>Arousal:</i> Emocionado/activo, neutral y calmado. <i>Valencia:</i> Desagradable, neutral y agradable. <ul style="list-style-type: none"> • Valencia 80.68%, Arousal 74.60%

		<ul style="list-style-type: none"> Valencia 73.10%, Arousal 70.17%
PS19	MLP	Medida CR, High, Low, Medium de cada dimensión.
	SVM	<ul style="list-style-type: none"> Valencia 63.47%, Arousal 69.62%, Dominancia 63.57%
	k-NN	<ul style="list-style-type: none"> Valencia 56.34%, Arousal 52.79%, Dominancia 57.71% Valencia 67.51%, Arousal 68.55%, Dominancia 65.10%
PS20	SVM	Emociones feliz, enojado, triste y relajado.
	ANN	<ul style="list-style-type: none"> Tiempo 76.56%, Entropía 83.59%, Frecuencia 78.64%
	NB	<ul style="list-style-type: none"> Tiempo 96.61%, Entropía 98.69%, Frecuencia 97.91% Tiempo 87.50%, Entropía 89.32%, Frecuencia 72.39%
PS21	RF	<ul style="list-style-type: none"> 75.6% (VA)
	SVM	<ul style="list-style-type: none"> 69.8% (VA)
	LDA	<ul style="list-style-type: none"> 60.4% (VA)
PS22	QDA	<ul style="list-style-type: none"> 44.4% HAHV, 47.7% HALV, 45.1% LAHV, 44.6% LALV
	SVM	<ul style="list-style-type: none"> 52.1% HAHV, 49.1% HALV, 49.6% LAHV, 48.3% LALV
PS23	ANN	<ul style="list-style-type: none"> 91.2% (positivo, neutral, negativo)
	SVM	<ul style="list-style-type: none"> 40.4% (positivo, neutral, negativo)
PS24	k-NN	Emociones positivas y negativas.
	NB	<ul style="list-style-type: none"> DWT 76.0%, ApEn y SampEn 91.0%.
	SVM	<ul style="list-style-type: none"> DWT 74.0%, ApEn y SampEn 94.0%.
	RF	<ul style="list-style-type: none"> DWT 76.2%, ApEn y SampEn 92.8%. DWT 76.0%, ApEn y SampEn 92.7%.
PS25	SVM	Valencia (infeliz/triste - feliz/alegre)
	k-NN	<ul style="list-style-type: none"> HOC 79.60%, Statistics 85.85%, PSE 71.01%, HOS 77.19%
	NB	<ul style="list-style-type: none"> HOC 83.74%, Statistics 88.95%, PSE 74.22%, HOS 82.91% HOC 82.70%, Statistics 86.90%, PSE 74.38%, HOS 81.88%
		Arousal (tranquilo/aburrido - estimulado/emocionado)
		<ul style="list-style-type: none"> HOC 77.39%, Statistics 84.08%, PSE 71.39%, HOS 79.01% HOC 81.40%, Statistics 89.45%, PSE 75.39%, HOS 86.95% HOC 77.14%, Statistics 85.98%, PSE 75.25%, HOS 82.11%
PS26	NB	Valencia: HV y LV, Arousal HA y LA
	SVM	<ul style="list-style-type: none"> Arousal 65.6%, Valencia 68.0% Arousal 67.7%, Valencia 69.6%
PS27	ANN	<ul style="list-style-type: none"> HA y LA 85.21%, HV y LV 84.16% 82.01% (VA)

PS28	QDA	<ul style="list-style-type: none"> HAHV 55.33%, LAHV 67.15%, LALV 60.03%, HALV 60.59%
	k-NN	<ul style="list-style-type: none"> HAHV 76.75%, LAHV 72.90%, LALV 76.90%, HALV 75.53%
	SVM	<ul style="list-style-type: none"> HAHV 84.95%, LAHV 84.14%, LALV 83.12%, HALV 82.25%
PS29	SVM	Valencia (Low, Medium, High)
	RF	<ul style="list-style-type: none"> Statistics 61.2%, SPD 88.4%, HOC 62.7% Statistics 61.3%, SPD 86.6%, HOC 64.7% Arousal (Low, Medium, High) <ul style="list-style-type: none"> Statistics 65.0%, SPD 69.2%, HOC 56.8% Statistics 67.1%, SPD 67.9%, HOC 57.4%
PS30	ANN	Valencia 73.43%, Arousal 72.65%, Dominancia 69.53% (VA)

La nomenclatura VA representa los cuatro cuadrantes del modelo emocional 2D (LALV, HALV, LAHV y HAHV).

2.6 Resultados de la RSL

En esta sección se presentan, analizan e interpretan los datos recopilados en la RSL, en función a las preguntas de investigación planteadas en este trabajo, luego de previo análisis de los dominios más utilizados en la literatura.

En la RSL se mencionan varias técnicas de extracción de características para los sistemas BCI basados en señales EEG en el dominio del tiempo (DT), el dominio de la frecuencia (DF) y el dominio del tiempo-frecuencia (DTF).

El porcentaje de artículos que extraen características en cada dominio o la combinación de dominios se muestran en la Figura 7, donde, el 27% de los artículos revisados utilizan la combinación de métodos de extracción de características en dominios DT y DTF. En porcentajes iguales se utilizan los métodos en el dominio DTF y la combinación de los dominios DT y DF, con el 20% cada uno. Con un porcentaje de 14% se encuentra el uso de métodos en dominio DT, seguido por el 13% de la combinación de los 3 dominios DT, DF y DTF. Finalmente, un porcentaje de 3% utilizan métodos del dominio DF, y la combinación de los dominios DF y DTF.

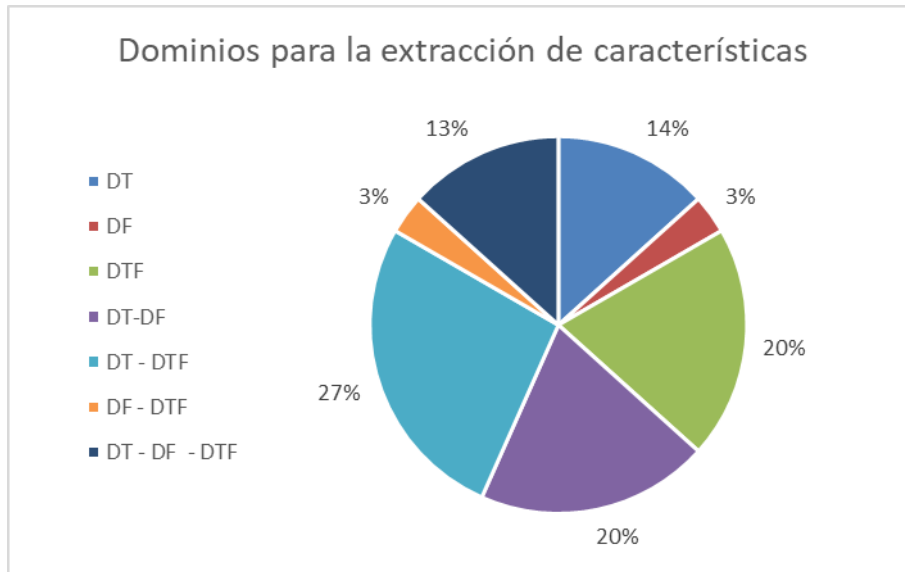


Figura 7. Extracción de características en cada dominio

A continuación, se determinan los métodos para extracción de características, clasificadores y métricas de valuación a utilizar en esta investigación, en base a las tres preguntas de investigación planteadas.

RQ1: ¿Qué métodos se utilizan para la extracción de características en los dominios del tiempo, la frecuencia o tiempo-frecuencia para el reconocimiento de emociones?

El reconocimiento de emociones plantea un desafío para las rutinas computacionales debido a la diferencia no lineal, no estacionaria e individual de las señales EEG. El problema constituye en la decisión de las características adecuadas para garantizar una precisión aceptable en términos de reconocimiento de la emoción. Por tanto, el reconocimiento de emociones podría depender mucho de las características del vector de entrada al clasificador.

En la Figura 8, se muestran los métodos de extracción de características en dominio del tiempo implementados en la literatura. Los métodos estadísticos son los más utilizados, seguidos por los métodos ShEn, HFD, SampEn y HP.



Figura 8. Métodos de extracción de características en dominio del tiempo

En la Figura 9, se muestran los métodos estadísticos encontrados en la RSL. El 26% de artículos emplean como método estadístico Stddev, el 19% utiliza el método mean y seguido por el uso de sus variantes AFSD_N en un 17%. El 12% corresponde al uso del método Kurtosis, el 7% corresponde al uso del método Skewness.




Figura 9. Métodos estadísticos, extracción de características en dominio del tiempo

En base a la periodicidad de uso de métodos en el dominio de tiempo, se seleccionó los métodos más utilizados, siendo estos: Shannon Entropy, Sample Entropy, Higuchi Fractal Dimensión, Parámetros Hjorth y Métodos Estadísticos. Parte de los métodos estadísticos seleccionados están: Standard Deviation, Mean, Mean Absolute Deviation y Kurtosis, que corresponden a los porcentajes mayores al 12%.

Además, se consideraron ciertos métodos en el dominio de tiempo con porcentajes menores, ya que presentan buenos resultados en las métricas de evaluación de los algoritmos de clasificación. Entre los métodos incluidos en el dominio del tiempo están: dos variantes de Entropía (Approximate, Permutación), el método Preprospan Fractal Dimension, Energy, Root mean square, Line Length, Average power, Zero Crossing, Higher Order Crossing, y los métodos estadísticos: Variance, Skewness y Máximo.

En la Figura 10, se muestran los métodos empleados en el dominio de la frecuencia. El 22% de artículos emplean el método PSD para la extracción de características, el 15% de artículos utilizan el método FFT o alguna de sus variaciones, el 11% de artículos utilizan los métodos SE, RASM y DASM, seguido del método PR con el 7%.




Figura 10. Métodos de extracción de características en dominio de la frecuencia

Los métodos seleccionados en el dominio de la frecuencia son: Power Spectral Density, Fast Fourier Transform, Rational Asymmetry, Differential Asymmetry y Spectral entropy, los cuales corresponden a porcentajes mayores o iguales al 11% de periodicidad de uso. Adicional, se seleccionó el método Power Ratio que corresponde al 7%, por presentar buenos resultados en las métricas de evaluación de los algoritmos de clasificación.

Finalmente, en la Figura 11 se muestran los métodos de extracción de características en el dominio tiempo - frecuencia encontrados en la RSL. El 68% de artículos utilizan el método DWT, seguido por los métodos WEng y WEnt con el 14% cada uno.




Figura 11. Métodos de extracción de características en dominio tiempo – frecuencia

Los métodos en el dominio tiempo-frecuencia seleccionados son: Discrete Wavelet Transform y Wavelet Entropy que corresponden a los mayores porcentajes de periodicidad de uso.

RQ2: ¿Que algoritmos de clasificación obtienen mejores resultados en la clasificación de emociones?

La tarea del clasificador consiste básicamente en identificar patrones o tendencias que se esconden en los datos. El objetivo es crear un modelo que permita resolver la tarea de clasificación de emociones del ser humano.

Los algoritmos de clasificación para el reconocimiento de emociones a partir de señales EEG encontrados en la RSL y porcentaje de uso se muestran en la Figura 12. El 32% de artículos utilizan el clasificador SVM. En porcentajes iguales se encuentran los clasificadores k-NN y ANN, con el 18%. El clasificador NB tiene un 8% de reincidencia en la RSL y el clasificador RF tiene un porcentaje del 6%. En porcentajes menores se encuentran el clasificador LDA con el 3%.




Figura 12. Porcentaje de algoritmos de clasificación en artículos

En la Figura 13, en base a los artículos que utilizan diferentes clasificadores para la comparación de resultados, se muestra que SVM obtiene mejores resultados en el 32% de los artículos. El 23% de los artículos obtiene mejores resultados con ANN, el 18% de los artículos con el clasificador k-NN, seguido por los clasificadores NB y RF con un 13.5%.




Figura 133. Comparación de rendimiento entre clasificadores

Previo al análisis sobre cuáles son los métodos de clasificación utilizados en la RSL, se calculó el porcentaje de periodicidad y rendimiento en base a lo cual se seleccionó para ser implementados en este trabajo los algoritmos SVM, k-NN y ANN cuyo porcentaje es mayor o igual al 18%.

RQ3: ¿Qué métricas se utilizan para la evaluación del desempeño de modelos de clasificación de emociones?

Las métricas de evaluación de un modelo de clasificación explican el rendimiento de un modelo, básicamente se comparan los valores reales del conjunto de pruebas con los valores pronosticados por el modelo, para calcular su precisión. Las métricas de evaluación del modelo de clasificación proporcionan un papel clave en el desarrollo de un modelo, ya que proporcionan pistas de las áreas que pueden mejorarse.

En la Figura 14, se muestra las métricas de evaluación de desempeño de los clasificadores encontradas en la RSL. El 40% de artículos utilizan la métrica Acc o la combinan con el uso de otras métricas, el 9% de artículos utiliza la métrica Spe, seguida de las métricas Mean, F1, Sen y Prc con el 7%, cada métrica. Las métricas Rec y Std las utilizan en un 6%.

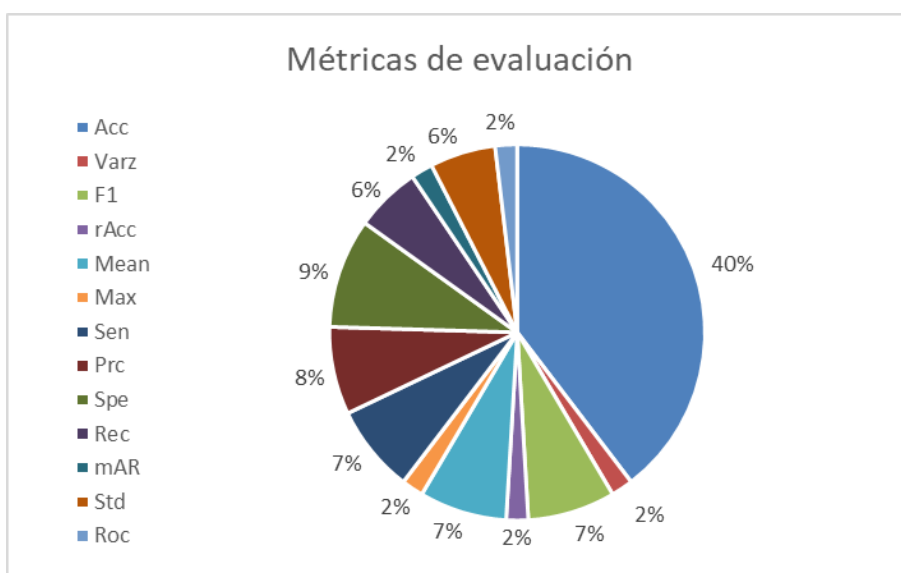


Figura 14. Métrica de evaluación

La métrica a implementar en el presente trabajo fue seleccionada previo al análisis de medidas utilizadas en la RSL y el porcentaje de periodicidad, donde Accuracy representa el 40%.

En resumen, se seleccionó un total de 29 métodos de extracción de características, 21 métodos en el dominio del tiempo incluyendo métodos estadísticos y variantes de entropías, 6 métodos en el dominio de la frecuencia y 2 métodos en dominio tiempo – frecuencia. Los métodos a implementar en el presente trabajo fueron seleccionados en base a la periodicidad de uso en la RSL y a los resultados de las métricas de evaluación de los algoritmos de clasificación.

En base a la RSL realizada podemos concluir que varios trabajos parten de la clasificación de las categorías High/Low Valencia (HV y LV) y High/Low Arousal (HA y LA) para el reconocimiento de emociones. Otros trabajos realizan el reconociendo de emociones en base a los cuatro cuadrantes del modelo bidimensional utilizando el dataset DEAP, incluso hay autores que utilizan ambos dataset DEAP y SEED para la clasificación de emociones utilizando diferentes métodos de extracción de características en dominio de tiempo, frecuencia y tiempo-frecuencia. Sin embargo, aún no está disponible un acuerdo sobre las características EEG que proporcionan mejores resultados para mejorar la precisión de la clasificación. Por tal motivo, se realiza el presente trabajo con el fin de evaluar qué método de extracción de características aporta más información y produce clasificadores con mejores rendimientos.

CAPÍTULO 3. MATERIALES Y MÉTODOS

En este capítulo se mencionan los métodos para extracción de características, algoritmos de clasificación de emociones de las señales EEG y métricas de evaluación de desempeño de los clasificadores utilizados en la implementación del presente trabajo, así como la preparación de datos de los dataset. El estudio se basa en el análisis de los datos de señales EEG de la base DEAP, incluyendo pruebas sobre la base de datos SEED.

3.1 Reconocimiento de emociones

La Figura 15, representa la estructura de un sistema BCI basado en EEG para el reconocimiento de emociones.

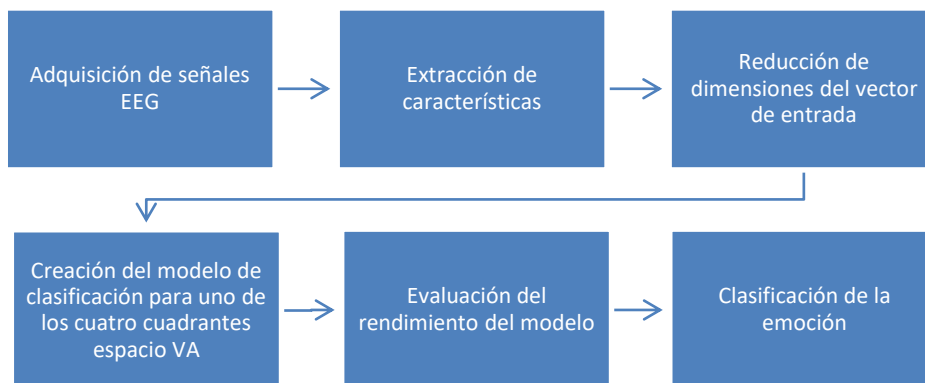


Figura 15. Pasos del proceso de reconocimiento de emociones propuesto

En este trabajo se utilizó los datos pre-procesados de dos conjuntos de datos de EEG previamente marcados con emociones extraídas de sujetos que autoevaluaron sus estados emocionales. Posteriormente, se realiza la extracción de características correspondientes para relacionar las señales EEG con los diferentes estados emocionales, el vector de características obtenido contiene 29 características. Este es un número alto, que provoca un tiempo de procesamiento alto, tomando en consideración que, si se procesan los datos crudos, sin extracción de características. Por lo anterior es necesario implementar técnicas de reducción de dimensiones utilizando PCA. Finalmente se realiza la clasificación del estado emocional mediante el uso de algoritmos de clasificación basados en aprendizaje automático [53], [51].

3.2 Adquisición de datos

En la actualidad, se tienen dos conjuntos de datos públicos de uso común para el análisis de emociones: El conjunto de datos para el análisis de emociones mediante señales fisiológicas DEAP [19] y datos EGG del dataset SEED [20].

Los creadores de los datasets DEAP y SEED ponen a disposición del público en general, páginas web con información a detalle de los experimentos realizados, además, de instrucciones generales y enlaces para obtener los dataset. Por ejemplo, DEAP solicita colocar nuestros nombres, fecha de solicitud y firma en el documento "License Agreement". Una vez enviado el documento solicitado en aproximadamente siete días, nos otorga un usuario y contraseña para la descarga de los archivos, las credenciales proporcionadas por DEAP aún son válidas a la fecha.

Por otro lado, SEED solicita llenar el documento "License Agreement" con nuestra información personal y firma. Luego de enviar la información solicitada, en aproximadamente dos días nos proveen de un enlace y la respectiva contraseña para la descarga de los archivos, cabe mencionar que el acceso al dataset expira.

3.2.1 Dataset DEAP

El conjunto de datos DEAP es de código abierto y contiene múltiples señales fisiológicas con evaluaciones emocionales. DEAP es muy útil para el estudio de señales fisiológicas y análisis emocional que incluye señales EEG recopiladas de 32 sujetos (16 hombres y 16 mujeres) mientras miraban 40 extractos de videos musicales con diferentes tendencias emocionales durante 1 minuto para cada video.

Las señales de EEG son registradas a una frecuencia de muestreo de 512Hz de 32 electrodos activos de acuerdo con el sistema internacional 10-20. Cada participante evalúa sus niveles de valencia, arousal, dominancia y agrado utilizando maniqués de evaluación (SAM) [44], [46]. Los participantes seleccionaron los números del 1 al 9 para el estado emocional de cada clip.

Cada archivo de datos (s01.dat - s32.dat) contiene dos matrices:

1. Matriz de datos: 40 x 40 x 8064, los primeros 40 representan el número total de videos, los segundos 40 representan la colección de señales del número total de canales, 8064 son los datos experimentales en base al video y la secuencia de muestreo (63 x 128), donde, los 3 primeros segundos corresponden a los datos de referencia obtenidos

antes del experimento, y los últimos 60 segundos corresponden a los datos registrados en el proceso del experimento.

2. Matriz de etiquetas: 40 x 4, el número de videos utilizados es representado por 40 y 4 es el número de columnas que representan las dimensiones afectivas: valencia, arousal, dominancia y agrado cuyas puntuaciones van de 1.0 a 9.0 acorde a la escala de maniquí de autoevaluación SAM.

En DEAP utilizan un total de 40 videos de estímulos que comprenden 20 estímulos de alta valencia / arousal y 20 estímulos de baja valencia / arousal. De acuerdo con los valores en el modelo 2D es posible dividir cada video en 4 tipos de emociones, es decir, alto arousal - alta valencia (HAHV), bajo arousal - alta valencia (LAHV), alto arousal - baja valencia (HALV) y bajo arousal - baja valencia (LALV). Donde, las escalas de arousal se extienden de pasivo a activo, y la valencia varía de negativo a positivo.

En este trabajo se evalúa los niveles de valencia y arousal a partir de registros de señales EEG pre-procesadas con extensión .dat para Python, dado que, el pre-procesamiento no es objetivo de este estudio utilizamos los datos ya pre-procesados que se encuentran disponibles para DEAP. Se emplean las señales EEG de los 32 canales a una frecuencia de muestreo descendente de 128Hz. Cada ensayo recopila una señal de 63s, incluida la señal de referencia de los primeros 3s. Por tanto, cada ensayo contiene 8064 puntos de datos para la frecuencia de muestreo, resultando una estructura de 40x32x8064 que corresponde al número de pruebas por participante, número de canales y datos de la señal almacenada para cada canal.

Las emociones a clasificar en este proyecto son: terror, ira, ansiedad / euforia, entusiasmo, felicidad / aburrimiento, apatía, tristeza / sosiego, placidez, satisfacción, que corresponden a cada uno de los cuadrantes del espacio valencia – arousal (VA), como se muestra en la Figura 3 [41]. La clasificación realizada en el presente trabajo se enfoca en los cuatro cuadrantes del espacio VA.

3.2.2 Dataset SEED

El conjunto de datos SEED incluye señales de EEG recolectadas de 15 sujetos (7 hombres y 8 mujeres) que miraban extractos de películas chinas que estimulan emociones positivas, neutrales y negativas. La duración de cada clip de película es de 4 minutos. Las reacciones emocionales del sujeto se registran a través de un cuestionario después de ver cada clip de película.

Hay 15 ensayos para cada experimento, un total de 45 archivos, uno por experimento. Hubo una pista de 5 segundos antes de cada clip, 45 segundos para la autoevaluación y 15 segundos para descansar después de cada clip en una sesión. El orden de presentación está organizado de tal manera que dos fragmentos de película que tienen como objetivo la misma emoción no se muestran consecutivamente.

Cada sujeto realizó el experimento tres veces con un intervalo de aproximadamente una semana. Cada archivo contiene 16 matrices. Quince conjuntos contienen datos de EEG segmentados y preprocesados de 15 intentos en un experimento (eeg_1 a eeg_15, canal x datos). Las matrices restantes contienen las etiquetas emocionales correspondientes a 0: neutral, 1: sad, 2: fear y 3: happy. Las señales de EEG se registraron a una frecuencia de muestreo de 1000Hz de acuerdo con el sistema internacional 10-20 para 62 canales.

El set tiene un total de 45 archivos .mat con los registros de las señales EEG. Los archivos de cada participante constan de un arreglo con una estructura de 15x62x48000, correspondientes al número de pruebas realizadas (15), número de canales (62) y datos de la señal almacenada para cada canal (48000).

En este trabajo se utilizan los datos preprocesados muestreados a 200Hz. Para facilitar la comparación entre datasets, se consideran solo 32 de los 64 canales, ya que representa el número de canales del dataset DEAP para la clasificación de emociones a partir de señales EEG. Las emociones a clasificar se denotan como neutral, sad, fear y happy [20].

3.3 Extracción de características

La etapa de extracción de características es de particular importancia ya que la calidad de datos obtenidos afectará directamente la precisión de la clasificación de emociones. Es decir, encontrar características informativas de las señales EEG puede mejorar la capacidad de discriminación entre emociones con una dimensionalidad limitada [11], [51].

La obtención de información útil a partir de señales EEG implica el uso de métodos de extracción de características para eliminar el ruido de las señales y transformarlas. Algunos métodos de extracción de características de uso común para los sistemas BCI se basan en el análisis de las señales en el dominio del tiempo, el dominio de la frecuencia y el dominio del tiempo - frecuencia [28].

Las expresiones matemáticas de algunos métodos de extracción de características junto con sus parámetros se mencionan en las siguientes secciones.

3.3.1 Dominio del tiempo

La mayoría de equipos de adquisición de EEG existentes recoge señales de EEG en el dominio del tiempo, como series en este dominio. Este tipo de método comienza principalmente con las características geométricas de las señales de EEG, y el investigador puede realizar análisis estadísticos de manera precisa e intuitiva sobre sus características. Sus características incluyen las señales de EEG con menor pérdida de información. Sin embargo, debido a la forma de onda compleja de las señales de EEG, no existe un estándar unificado para el análisis de las características en el dominio del tiempo de EEG.

- Métodos estadísticos

En el presente estudio se extraen ocho características estadísticas de la señal EEG de serie temporal para el reconocimiento de emociones. Los métodos implementados son aquellos utilizados en más de 5 artículos considerados en la RSL. Además, se implementaron métodos con menor uso (2 y 3 artículos) para obtener un vector de características más amplio y poder comparar los resultados obtenidos.

En las ecuaciones de la 1 a la 7, tenemos las denotaciones X_i que es el conjunto de datos (señal EEG), donde $i = 1, \dots, N$ y N es el número total de muestras (experimentos).

- Maximum: Se realiza la búsqueda del elemento con el valor más alto de la señal analizada. Es decir, teniendo un conjunto C y un elemento X_i que pertenece a él ($X_i \in C$), X_i es el elemento máximo de C si cualquier otro elemento de dicho conjunto es menor o igual a X_i .
- Mean: La media calcula el valor de amplitud promedio de las muestras de datos de EEG recopiladas dentro del área seleccionada. Se la puede entender como el centro geométrico de la señal analizada. Se calcula usando la ecuación 1.

$$mean = \frac{1}{N} \sum_{i=1}^N X_i \quad (1)$$

- Standard Deviation: Esta característica cuantifica la desviación de los puntos de la señal con respecto a su valor medio. Matemáticamente se puede denotar como se muestra en la ecuación 2.

$$stddev = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - mean)^2} \quad (2)$$

- Variance: La varianza es una medida de dispersión, puede ser definida como la media de los cuadrados de las desviaciones sobre la media. Si existen datos muy por encima y muy por debajo de la media, esta será menos representativa y se reflejará como elevada varianza. Matemáticamente se calcula con la ecuación 3.

$$var = \frac{1}{N} \sum_{i=1}^N (X_i - mean)^2 \quad (3)$$

- Skewness: Es una medida que muestra el grado de asimetría en una distribución de datos. Una distribución es simétrica si se ve igual desde ambos extremos (izquierdo y derecho) con respecto al punto medio. Donde “N” es el número total de puntos de muestra. Matemáticamente se mide usando la ecuación 4.

$$skewness = \frac{\sum_{i=1}^N (X_i - mean)^3 / N}{(stddev)^3} \quad (4)$$

- Kurtosis: Informa sobre el grado de homogeneidad de la distribución de datos de la señal. El valor del canal con kurtosis alto significa la presencia de ruido en los datos, cuando el valor es bajo se refiere a la falta de valores atípicos. Matemáticamente se mide usando la ecuación 5.

$$kurtosis = \frac{\sum_{i=1}^N (X_i - mean)^4 / N}{(stddev)^4} \quad (5)$$

- Mean of absolute values of first difference of normalized: La primera diferencia de la señal se calcula como la suma de la diferencia entre un par de N-1 muestras sobre el número de muestras -1. Matemáticamente se calcula con la ecuación 6.

$$AFD_N = \frac{1}{N-1} \sum_{i=1}^{N-1} |X(i+1) - X(i)| \quad (6)$$

- Mean of absolute values of second difference of normalized: La segunda diferencia de la señal se calcula como la suma de la diferencia entre un par de N-2 muestras sobre el número de muestras -2. La segunda diferencia de una señal se calcula con la ecuación 7.

$$ASD_N = \frac{1}{N-2} \sum_{i=1}^{N-2} |X(i+2) - X(i)| \quad (7)$$

- Entropías

La entropía es un método desarrollado para el análisis no lineal de señales EEG. En este estudio, extrajimos cuatro variantes de entropía de cada canal de EEG. Las variantes de entropía implementadas son las encontradas en la RSL, independientemente del porcentaje de periodicidad de uso, debido a que este tipo de características presentan buenos resultados en las métricas de evaluación de los clasificadores, a pesar de tener un alto costo computacional, como se muestra en la Tabla 9.

- Shannon Entropy: Es un índice de la medida de la complejidad de un sistema incierto, se obtiene aplicando la estimación del histograma de la función de densidad de probabilidad, $P_i(X)$. Matemáticamente se calcula con la ecuación 8.

$$ShEn = - \sum_{i=1}^N P_i(X) \log P_i(X) \quad (8)$$

Donde X representa la señal EEG, P_i es la probabilidad de que ocurra cada uno de los valores en X y N es el número total de experimentos.

- Approximate Entropy: Es una técnica utilizada para cuantificar la cantidad de regularidad y la imprevisibilidad de las fluctuaciones en los datos de series temporales. El vector plantilla de tamaño m se define como una señal de ventana: $u[i] = [x[i]x[i+1] \dots x[i+m-1]]^T$, primero se considera la autosimilitud del vector plantilla $u[i]$ con una tolerancia r , definido por la ecuación 9.1.

$$C_i^m(r) = \frac{1}{N-m+1} \sum_{j=0}^{N-m} \theta(r - \|u[i] - u[j]\|_\infty) \quad (9.1)$$

Donde $\theta(x)$ es uno cuando $x \geq 0$, y cero en caso contrario. Cuando X es en su mayoría autosimilar, entonces las secuencias $u[i]$ y $u[j]$ son muy cercanas y, por lo tanto, C_i es alto. ApEn agrega los índices de autosimilitud sobre todas las posibilidades desplazadas de los vectores de plantilla dada la tolerancia y la longitud de la plantilla. ApEn se define con la ecuación 9.2.

$$ApEn(X, m, r) = \frac{1}{N-m+1} \sum_{i=0}^{N-m} \log C_i^m(r) - \frac{1}{N-m} \sum_{i=0}^{N-m-1} \log C_i^{m+1}(r) \quad (9.2)$$

Donde X representa la señal EEG, m el tamaño del vector, r es el valor de tolerancia, N es el número total experimentos, C_i^m es la autosimilitud del vector.

- Sample Entropy: Es la modificación de la entropía de aproximación utilizada para evaluar la complejidad de la señal fisiológica de series temporales. En SampEn la autosimilitud de todos los pares de vectores plantilla $u[i]$ y $u[j]$ con una tolerancia r se calcula con la ecuación 10.1.

$$\phi^m(r) = \sum_{j=0, j \neq i}^{N-m} \sum_{i=0}^{N-m} \theta(r - \|u[i] - u[j]\|_{\infty}) \quad (10.1)$$

Si las señales son autosimilares, $\phi^m(r)$ es alto. La SampEn está definida por la ecuación 10.2.

$$SampEn(X, m, r) = \log \phi^m(r) - \phi^{m+1}(r) \quad (10.2)$$

- Permutacion Entropy: Es una medida de la complejidad local en una señal. Con el vector plantilla $u[i]$ y un patrón de permutación π_k de orden m que consiste en $m!$ patrones, la probabilidad del patrón de permutación para todos los $k = 1, 2, \dots, m!$ se define como la probabilidad de que un vector plantilla tenga el mismo patrón que el de permutación como se muestra en la ecuación 11.1.

$$p(\pi_k) = \frac{1}{N - m + 1} \sum_{i=0}^{N-m} f(u[i], \pi_k) \quad (11.1)$$

Donde $f(u[i], \pi_k) = 1$ cuando $u[i]$ y π_k son el mismo patrón, y cero en caso contrario. En este caso, el patrón se define por el orden de $u[i]$ correspondiente a su elemento, la probabilidad de ocurrencia de cada categoría del patrón de permutación se calcula y denota por $p(\pi_k)$. Permutacion Entropy se define con la ecuación 11.2.

$$PE(X) = \sum_{k=1}^{m!} p(\pi_k) \log p(\pi_k) \quad (11.2)$$

- Energy: Se hace referencia a una señal de energía si y solo si su energía total E es finita, es decir, $0 < E < \infty$. Por tanto, la amplitud de la señal debe aproximarse a cero a medida que el tiempo se aproxima a más o menos infinito, es decir, $X(n) \rightarrow 0$ como $n \rightarrow \pm\infty$, donde, $X(n)$ es la señal EEG. La energía se calcula con la ecuación 12.

$$Eng = \sum_{n=-\infty}^{\infty} |X(n)|^2 \quad (12)$$

- Average power: Se hace referencia a una señal de potencia si y solo si la potencia media de la señal es finita, es decir, $0 < P < \infty$. Una señal de energía tiene una potencia promedio cero, mientras que una señal de potencia tiene una energía infinita. La potencia de una señal se calcula con la ecuación 13.

$$Avg = \lim_{N \rightarrow \infty} \frac{1}{2N} \sum_{n=-N}^N |X(n)|^2 \quad (13)$$

Donde, N es el número de muestras tomadas para el cálculo, $X(n)$ es la señal EEG.

- Root mean square: Se calcula como la raíz cuadrada del promedio de muestras al cuadrado de una señal de EEG. El valor RMS se calcula con la ecuación 14.

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N X^2(n)} \quad (14)$$

Donde, N es el número de muestras tomadas para el cálculo y $X(n)$ es la señal EEG.

- Line Length: a veces llamada longitud de la curva, es la longitud vertical total de la señal definida. Line Length está definida por la ecuación 15.

$$LL = \sum_{i=1}^N |X[i-1] - X[i]| \quad (15)$$

Donde, X es la señal EEG de entrada y N es el número de muestras en la señal, i es el índice del punto de datos.

- Higuchi Fractal Dimension: La dimensión fractal es un índice matemático para medir la complejidad de la señal. El algoritmo de Higuchi se basa en la medición de la longitud de las señales $L(k)$. Tomando k puntos de muestreo como unidad, HDF satisface la ecuación 16.1.

$$\langle L(k) \rangle \propto k^{-HDF} \quad (16.1)$$

La longitud parcial denotada como $L_m(k)$, se calcula a partir de una serie de tiempo parcial con un intervalo de tiempo k y un tiempo inicial de $m = 0,1,2, \dots, k$ como se muestra en la ecuación 16.2. Donde m es el punto inicial, k es el intervalo, $\langle \cdot \rangle$ denota la notación de Gauss y tanto m como k son números enteros. Para k nuevas

secuencias reconstruidas, se calcula la longitud de cada secuencia representada por $L_m(k)$.

$$L_m(k) = \frac{1}{\tau} \left(\sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |x[m + i \cdot k] - x[m + (i-1)k]| \right) \frac{N-1}{\lfloor \frac{N-m}{k} \rfloor k} \quad (16.2)$$

Aquí, N es el número total de señales, y $\frac{N-1}{\lfloor \frac{N-m}{k} \rfloor k}$ es el factor de corrección de normalización. La longitud promedio de k secuencias con el mismo intervalo que la longitud de la señal $L(k)$ correspondiente al intervalo k , según la ecuación 16.3.

$$L(k) = \frac{1}{k} \sum_{m=1}^k L_m(k) \quad (16.3)$$

Finalmente, HDF de la ecuación 16.1 es el valor de la dimensión fractal de los datos de la serie temporal y se puede calcular con la ecuación 16.4.

$$HDF = - \lim_{k \rightarrow \infty} \frac{\log(L(k))}{\log(k)} \quad (16.4)$$

- Preprospan Fractal Dimension: Calcula de forma rápida la dimensión fractal, debido a que transforma los datos de la señal analizada a datos binarios. La PFD se calcula mediante la ecuación 17.

$$PFD = \frac{\log(m)}{\log(m) + \log\left(\frac{m}{m + 0.4N_\Delta}\right)} \quad (17)$$

Donde, m es la longitud de la señal analizada y N_Δ es el número de pares de segmentos que no son similares en la secuencia binaria.

- Hjorth Parameters: Los parámetros de Hjorth incluyen actividad, movilidad y complejidad. La actividad se define como la varianza de la señal de entrada representada por $x(t)$, $var(x'(t))$ representa la varianza de la primera derivada de la señal de entrada, $var(x(t))$ representa la varianza de la señal y $mobility(x(t))$ es la movilidad de la primera derivada de la señal de entrada. Los parámetros de Hjorth se pueden calcular mediante las ecuaciones 18.1, 18.2 y 18.3.

$$Activity = var(x(t)) \quad (18.1)$$

$$Mobility = \sqrt{\frac{var(x'(t))}{var(x(t))}} \quad (18.2)$$

$$Complexity = \frac{Mobility(x'(t))}{Mobility(x(t))} \quad (18.3)$$

- Zero Crossing: Es el número de veces que la señal cambia de valor, de positivo a negativo y viceversa. El *ZCR* se define de acuerdo a la ecuación 19.1.

$$ZeCr(i) = \frac{1}{2W_L} \sum_{n=1}^{W_L} |sgn[x_i(n)] - sgn[x_i(n-1)]| \quad (19.1)$$

Donde, W_L es el recuento total de muestras presentes en un bloque de la señal EEG, $x(n)$, sgn es la función de signo, por ejemplo

$$sgn[x_i(n)] = \begin{cases} 1, & x_i(n) \geq 0 \\ -1, & x_i(n) < 0 \end{cases} \quad i = 1, \dots, N \quad (19.2)$$

- Higher Order Crossing: El cruce de orden superior consiste en el número de cruces por cero de un cero finito que significa datos de series temporales. ¿Cuántas veces cruza una señal el nivel cero? esto debe calcularse para extraer HOC. El vector de características HOC se puede calcular mediante la ecuación 20.1, para un valor específico de k .

$$HOC_k = ZeCr\{S_k(Z_t)\} \quad (20.1)$$

Donde, *ZeCr* es para la estimación del Número de Pasos por Cero.

$$\nabla Z_t \equiv Z_t - Z_{t-1} \quad (20.2)$$

$$S_k = \nabla^{k-1}, k = 1, 2, 3, \dots \quad (20.3)$$

Aquí, Z_t representa datos de series de medios cero finitos, ∇ es el filtro de paso alto y S_k es la secuencia del filtro de paso alto.

3.3.2 Dominio de la frecuencia

Los métodos de análisis en el dominio de la frecuencia transforman las señales EEG de dominio del tiempo en el dominio de la frecuencia para analizarlas. Por lo general, el espectro adquirido se descompone en múltiples sub-bandas para la extracción de características y posterior análisis de las señales de EEG. Los análisis de las señales de EEG en el dominio de la frecuencia no perderán la información del dominio del tiempo de la señal original, y se puede garantizar una mayor resolución durante el proceso de análisis.

- Spectral Entropy: Es una medida de la incertidumbre del proceso aleatorio a partir de la distribución de frecuencias. Un valor bajo de SE significa que la distribución de frecuencias es intensa en algunas bandas de frecuencia. Su cálculo se realiza con la ecuación 21.1.

$$SE(x) = - \sum_{i=1}^m p(s_i) \log_2 p(s_i) \quad (21.1)$$

Donde, m es el número de valores para la señal EEG. El denominador, \log_2 , representa el ruido máximo uniformemente distribuido y $S = \{S_1, \dots, S_m\}$ en función de la probabilidad de ocurrencia $P = \{p(S_1), \dots, p(S_m)\}$ dada por la ecuación 21.2.

$$P(m) = \frac{S(m)}{\sum_i S(i)} \quad (21.2)$$

- Power Ratio: Determina la relación de potencia de las épocas actual y de fondo en el mismo rango de frecuencia para comparar las potencias. El poder de un período de incautación es relativamente más alto que el de fondo. Se calcula con la ecuación 22.

$$PR = \frac{\text{Potencia Delta} + \text{Potencia Theta}}{\text{Potencia Alpha} + \text{Potencia Beta}} \quad (22)$$

- Power Spectral Density: Describe la potencia de la señal analizada en función de la frecuencia e informa sobre el nivel de dispersión de la potencia de la señal. Se calcula con la ecuación 23.

$$PSD = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T |x(t)|^2 dt \quad (23)$$

Aquí, $x(t)$ representa la señal EEG que durante todo el tiempo está dada por el siguiente promedio de tiempo, donde, T está centrado en algún punto arbitrario $t = t_0$.

- Fast Fourier Transform: Toda señal periódica puede ser representada por la suma de series de Fourier, con un análisis adecuado es posible obtener una representación de Fourier para señales de duración finita. Esta representación es la que se conoce como la Transformada de Fourier Discreta (TFD). La TFD se calcula con la ecuación 24.

$$FFT[k] = \sum_{n=0}^{N-1} x[n] \cdot W_N^{kn} \quad k = 0, 1, \dots, N - 1 \quad (24)$$

Donde $W_N^{kn} = e^{-j\frac{2\pi}{N}}$, N es el número de muestras en la señal y $x(n)$ representa la señal EEG de entrada.

- Asymmetry: Las proporciones de asimetría incorporan características de señal del hemisferio izquierdo y el derecho del cerebro. En particular, algunas emociones están dedicadas al hemisferio derecho, mientras que otras al hemisferio izquierdo del cerebro [75]. Las características de asimetría racional (RASM) y asimetría diferencial (DASM) se calculan con las ecuaciones 25 y 26.

$$RASM = \frac{P_{left}}{P_{right}} \quad (25)$$

$$DASM = P_{left} - P_{right} \quad (26)$$

Donde P_{left} y P_{right} representan la potencia (para las bandas alfa, beta y gamma) de los electrodos en los hemisferios izquierdo y derecho del cerebro.

3.3.3 Dominio del tiempo – frecuencia

El método de análisis en el dominio del tiempo-frecuencia integra el dominio del tiempo y la información del dominio de la frecuencia y tiene capacidades de análisis localizado en el dominio del tiempo-frecuencia simultáneamente.

- Discrete Wavelet Transform: La transformada wavelet proporciona información de frecuencia más precisa en frecuencias bajas e información de tiempo más precisa en frecuencias altas. La Transformada Wavelet Discreta (DWT) es utilizada para eliminar el ruido y descomponer la señal de EEG en señales de subbandas como delta, theta, alfa, beta y gamma. Se calculan con la ecuación 27.

$$\gamma(t) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{2^a}} \psi\left(\frac{t - b * 2^a}{2^a}\right) dt \quad (27)$$

Donde, $\gamma(t) = DWT$ de cualquier señal en el dominio del tiempo $x(t)$; $\psi(t) =$ wavelet madre, a y b son el parámetro de escala y el parámetro de desplazamiento respectivamente.

- Wavelet entropy: La entropía es el indicador de la medida de la asimetría, el desequilibrio y la incertidumbre. Esta técnica combina la descomposición de wavelets y la entropía para estimar el grado de orden/desorden de una señal con una alta resolución de frecuencia de tiempo. Se calcula a partir de la ecuación 28.

$$T(l) = -\frac{E(l)}{\sum_{m=1}^M E(m)} \log\left(\frac{E(l)}{\sum_{m=1}^M E(m)}\right) \quad (28)$$

Donde, E es la energía de la wavelet en base a un valor l , l es el nivel de la entropía wavelet, $E(l)$ es el cuadrado de los elementos que componen el vector y m el número de descomposición wavelet.

3.4 Reducción de dimensionalidad

Se realizó la extracción de características EEG iniciales en los diferentes dominios del tiempo, frecuencia y tiempo - frecuencia. Sin embargo, las características extraídas pueden no estar correlacionadas con los estados emocionales y conducir a la degradación del rendimiento de los clasificadores. La reducción de la dimensionalidad podría ayudar a aumentar la velocidad y la estabilidad del clasificador. Por tanto, en este estudio utilizamos el enfoque de Análisis de Componentes Principales (PCA) para reducir las dimensiones.

3.4.1 Análisis de Componentes Principales (PCA)

PCA también llamado transformada de Karhunen-Loève, es una técnica estadística para el tratamiento de datos de forma compacta, que elimina la redundancia de los datos originales. El objetivo de PCA es conseguir una representación de los datos lo mejor posible para re expresar un conjunto de datos dado. Se espera que esta nueva base revele la estructura oculta en el conjunto de datos y filtre el ruido [76].

Generalmente, se podrán obtener tantas componentes principales distintas como variables disponibles. La elección se realiza de manera que la primera componente principal sea la

que mayor varianza recoja; la segunda debe recoger la máxima variabilidad no recogida por la primera, y así sucesivamente, eligiendo un número que recoja un porcentaje suficiente de varianza total.

El objetivo es identificar las combinaciones lineales que mejor representan las variables X_1, \dots, X_p . Sean (Z_1, Z_2, \dots, Z_M) $M < p$ combinaciones lineales de las p variables originales como se muestra en la ecuación 29.

$$Z_m = \sum_{j=1}^p \phi_{jm} X_j \quad (29)$$

Donde, ϕ_{jm} son las cargas o loadings de los componentes principales. Cada vector de loadings de longitud igual a p , define la dirección en el espacio sobre el cual la varianza de los datos es mayor. X_j representa los datos de la señal EEG.

3.5 Clasificación de emociones

Una vez extraídos los vectores de características y realizada la reducción de dimensiones, procedimos a clasificar las emociones de acuerdo a las clases previamente establecidas. Existen varios clasificadores para la identificación automática de emociones, a continuación, mencionaremos algunos de los más utilizados en la RSL.

3.5.1 Super Vector Machine (SVM)

Este algoritmo utiliza el enfoque de proyectar el espacio de entrada a un espacio de más alta dimensión, de modo que los datos no lineales también puedan separarse fácilmente. La característica fundamental de los SVM es que el margen de separación de los datos llega a ser lo más amplio posible [77].

Los SVM utilizan métodos kernel, los cuales pueden ser de varios tipos, entre ellos tenemos: lineal, polinómico, gaussiano, entre otros. El objetivo de SVM es elegir un hiperplano de separación óptimo de modo que maximice la distancia entre dos puntos de datos de diferentes clases [78].

SVM se elige debido a su alta capacidad de generalización y clasificación. Considere un conjunto de entrenamiento $(x_j, y_j), 1 \leq j \leq N$, donde x_j denota los vectores de características extraídos de las señales de EEG, y_j denota las etiquetas de emoción correspondientes y N es el número de datos. La función de decisión SVM se puede escribir con la ecuación 30.

$$f(x) = \sum_i^N \alpha_i y_i k(S_i, x) + b \quad (30)$$

Donde x es el vector de entrada (en este caso, el vector de características extraído de las señales EEG), k es la función kernel, S_i denota vectores de soporte, α_i son los pesos y b es el sesgo.

3.5.2 K-Nearest-Neighbor (k-NN)

k-NN es un método de estimación no paramétrico que implementa un refinamiento donde el entorno de características es de alta resolución en regiones con entrenamiento denso y baja resolución en la varianza. Este algoritmo asigna etiquetas a puntos previamente no muestreados, generalmente tiene una menor eficiencia a medida que aumenta el tamaño de los datos [77].

La clasificación con k-NN se basa en la constante k definida por el usuario, donde el nuevo caso se asignará a la clase más común entre sus k vecinos más cercanos medidos por una métrica de distancia como la Euclidiana, Manhattan, Minkowski y Hamming. La mayoría de los clasificadores k-NN utilizan la métrica euclidiana para medir las diferencias entre los ejemplos representados como entradas vectoriales expectativa [79]. La distancia euclidiana se define con la ecuación 31.

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n W_r (a_r(x_i) - a_r(x_j))^2} \quad (31)$$

Donde, se define un ejemplo al vector $x = (a_1, a_2, a_3, \dots, a_n)$, n es la dimensionalidad del vector de entrada (número de atributos de un ejemplo), a_r es el atributo r th del ejemplo, W_r es el peso del atributo r th, r es de 1 a n y $d(x_i, x_j)$ representa al menor de los dos ejemplos más similares [80]. La etiqueta de clase asignada a un ejemplo de prueba está determinada por el voto mayoritario de sus k vecinos más cercanos a partir de la ecuación 32.

$$y(d_i) = \arg \max_k \sum_{x_j \in kNN} y(x_j, C_k) \quad (32)$$

Donde, d_i es un ejemplo de prueba, x_j es uno de sus k vecinos más cercanos en el conjunto de entrenamiento, $y(x_j, C_k)$ indica si x_j pertenece a la clase C_k .

3.5.3 Artificial Neural Networks (ANN)

Las ANN se basan en sistemas neuronales biológicos que tienen características como no linealidad, adaptabilidad, capacidad de respuesta y tolerancia a fallas. Las entradas en ANN se denominan neuronas, las cuales están interconectadas entre sí y trabajan en conjunto con el objetivo de buscar la mejor configuración mediante la modificación de los pesos de la red para la resolución de un problema.

Una red neuronal recibe como entrada un conjunto de $i = 1, \dots, n$ patrones en forma de vectores de dimensión p , cada vector de entrada es procesado a través de las neuronas de las I capas ocultas de acuerdo a las conexiones entre los nodos de estas. Cada nodo contiene un función de activación f , la cual mediante una suma ponderada de las entradas de los nodos y un valor de sesgo adicional obtiene el valor de salida del nodo [78].

En una ANN feedforward, hay tres tipos de capa: capa de entrada, capa de salida y capa oculta. La capa de entrada amortigua la distribución de las señales de entrada x_n ($n = 1, 2, 3, \dots$) y las envía a las neuronas de la capa oculta. Las neuronas de la capa oculta agregan las señales de entrada, x_n después de pesarlas con las fuerzas de conectividad respectivas, W_{nl} son las entradas de la capa. Finalmente, la salida y se calcula con la ecuación 35.

$$y_l = f \left(\sum_{n=1}^n W_{nl} x_n \right) \quad (35)$$

El número de neuronas es I . La función puede tener diferentes formas funcionales como sigmoideal, radial, lineal, tangente hiperbólica, etc. Con un enfoque similar, se calculan las salidas de las neuronas.

3.6 Métodos de evaluación de desempeño

El desempeño de un clasificador se puede evaluar calculando el número de ejemplos de clase reconocidos correctamente (TP), el número de ejemplos reconocidos correctamente que no pertenecen a la clase (TN), los ejemplos que fueron asignados a la clase incorrectamente (FP) y los fueron reconocidos como ejemplos de clase incorrectamente (FN) [81].

Las métricas de evaluación de desempeño más comunes en la RSL son Accuracy, Precision, Sensitivity, F1-Score y Specificity, las cuales, se obtienen a partir de la matriz de confusión.

3.6.1 Matriz de confusión

La matriz de confusión se utiliza para medir el rendimiento del problema de clases para un conjunto de datos. En la Tabla 6, se muestra un ejemplo de la matriz de confusión.

Tabla 7. Matriz de confusión

Etiquetas	Predicción	
	Negativo (0)	Positivo (1)
Negativo (0)	TN	FP
Positivo (1)	FN	TP

Nomenclatura: Verdaderos positivos (TP), verdaderos negativos (TN), falsos positivos (FP), falsos negativos (FN).

Los elementos de la diagonal derecha TP y TN clasifican las instancias correctamente, así como FP y FN clasifican las instancias incorrectamente. Donde:

- Total de instancias = Instancias correctas + Instancias incorrectas
- Instancia clasificada correctamente = TP + TN
- Instancia clasificada incorrectamente = FP + FN

3.6.2 Accuracy

Accuracy es la medida de efectividad por clase de un clasificador, se define como la relación entre las instancias correctamente clasificadas y el número total de instancias, como se muestra en la ecuación 36. Donde, N es el número de etiquetas de clase.

$$Accuracy = \frac{\sum_{i=1}^N \frac{TP + TN}{TP + FN + FP + TN}}{N} \quad (36)$$

3.6.3 Precisión

Precisión es la relación entre los módulos correctamente clasificados y el número de módulos completos clasificados como propensos a fallas. Se calcula como la relación entre la suma de la precisión de cada clase y el número de clases, empleando la ecuación 37.

$$Precision = \frac{\sum_{i=1}^N \frac{TP}{TP + FP}}{N} \quad (37)$$

3.6.4 Sensitivity (Recall)

Recall es la relación entre los módulos correctamente clasificados como propensos a fallas y el número de módulos defectuosos completos, es decir, se usa para encontrar cuántas clases están realmente clasificadas, se calcula con la ecuación 38.

$$Recall = \frac{\sum_{i=1}^N \frac{TP}{TP + FN}}{N} \quad (38)$$

3.6.5 F-Score

F-Score es una combinación de recall y precision. Representa la relación entre las etiquetas positivas de los datos y las dadas por un clasificador basado en sumas de decisiones, se calcula con la ecuación 39.

$$FScore = \frac{(\beta^2 + 1) Precision * Recall}{\beta^2 Precision + Recall} \quad (39)$$

3.6.6 Specificity

Specificity mide con que eficacia un clasificador identifica etiquetas negativas. La especificidad responde a la pregunta: De las clases a clasificar, ¿cuántas de ellas se predijo correctamente?, se calcula con la ecuación 40.

$$Specificity = \frac{\sum_{i=1}^N \frac{TN}{TN + FP}}{N} \quad (40)$$

3.7 Balanceo de datos

En un caso ideal todos los datos pertenecientes a cada clase se encuentran agrupados entre ellos y claramente diferenciables del resto de clases. Sin embargo, con frecuencia los datos presentan diferentes problemas que dificultan el trabajo de los clasificadores y disminuyen la calidad de la clasificación realizada.

En estas situaciones, los clasificadores presentan una tendencia de clasificación hacia la clase mayoritaria, minimizando de ésta manera el error de clasificación y clasificando correctamente instancias de clase mayoritaria término conocido como "Distribución de datos desequilibrada". El sesgo que se produce en la clasificación de datasets que tienen una distribución desigual de registros en las diferentes clases genera la necesidad de utilizar técnicas de balanceo de datos.

Existen varias opciones para el tratamiento de desbalanceo de datos, en este trabajo se utiliza el algoritmo SMOTE-Tomek con el objetivo de modificar la distribución de los datos incrementando el número de casos de la clase minoritaria para que se compare con el número de registros de la clase mayoritaria. Para ello se requiere generar datos en forma sintética, basándose en la distribución estadística del dataset.

SMOTE-Tomek (técnica de sobremuestreo de minorías sintéticas) es un algoritmo cuyo objetivo es equilibrar la distribución de clases aumentando aleatoriamente los ejemplos de clases minoritarias al replicarlos. Este método combina la capacidad de SMOTE para generar datos sintéticos para la clase minoritaria y la capacidad de Tomek Links para eliminar los datos identificados como enlaces Tomek de la clase mayoritaria, es decir, muestras de datos de la clase mayoritaria más cercana a los datos de la clase minoritaria [82].

El algoritmo consiste en crear individuos sintéticos a partir de individuos de la clase minoritaria, determinando como primera instancia una vecindad entre los individuos cercanos. Luego se procede a crear un nuevo individuo tomando como referencia la distancia entre los individuos de la misma vecindad y esta distancia se multiplica por un valor aleatorio entre 0 y 1.

Como resultado se obtiene una clase minoritaria aumentada dependiendo del número de individuos sintéticos que se escoja aumentar por cada individuo observado. Además, es posible aplicar otra estrategia que es la de sub muestrear a la clase mayoritaria de forma que se escoge una muestra aleatoria menor de esta clase lo que a la final equilibra las proporciones de las diferentes clases eliminando distorsiones por el no balanceo de las clases.

CAPÍTULO 4. IMPLEMENTACIÓN Y RESULTADOS

En este capítulo se expone la aplicación de los métodos para la extracción de características y para la clasificación de emociones de las señales EEG de los dataset DEAP y SEED con los respectivos parámetros de entrada. Además, se mencionan las herramientas y librerías utilizadas para la ejecución de este trabajo, así como la preparación de datos previo a su análisis.

El procesamiento de datos, extracción de características y clasificación de emociones a partir de los dataset DEAP y SEED se ejecutaron en un computador con procesador Intel Core i7 8th Generación de 64 bits (2,8 GHz) con 16 GB de RAM, 4 núcleos físicos y 4 núcleos virtuales generando aproximadamente 18GB en datos. Cabe mencionar, que el cálculo de las features del dataset SEED representó un costo computacional más alto, por tanto, se pagó por el servidor de la nube de Azure con 16 núcleos y 256 GB de RAM, generando aproximadamente 20GB en datos.

3.8 Preparación de datos

Como se muestra en la Tabla 8, los conjuntos de datos DEAP Y SEED son bastante dispares en cada aspecto técnico: número de canales, número de sujetos, frecuencia de muestreo, clasificación de emociones en el espacio VA o solamente usando Valencia y tipo de estímulo. Por tanto, se tomaron en cuenta diferentes consideraciones en la preparación de datos previa a la extracción de características y clasificación de emociones.

Tabla 8. Comparación entre los dataset DEAP y SEED

Características	Dataset DEAP	Dataset SEED
Dispositivo EEG	Biosemi ActiveTwo	ESI NeuroScan
# de canales	32 para EEG, 8 para señales fisiológicas periféricas	64 para EEG
Muestreo	Original 512 Hz, muestras descendentes de 128 Hz	Original 1000 Hz, muestras descendentes de 200 Hz
# de sujetos	32	15
Estímulo	Videos musicales	Extracto de películas chinas
Emociones	Valence, liking, arousal, dominance (Escala de 1 a 9) y familiaridad de 1 a 5.	Positivas, negativas y neutrales.

3.8.1 Base de datos DEAP

Como ya lo mencionamos en la sección anterior el dataset DEAP consta de dos partes: los datos y la etiqueta de las emociones clasificadas en escalas numéricas de 1 a 9. En cuanto a las etiquetas nos interesa solo dos variables de las cuatro disponibles, estas son las dos primeras correspondientes a Valence y Arousal.

One hot encoding

One hot encoding es un proceso de conversión de variables a datos categóricos para que puedan proporcionarse a los algoritmos de aprendizaje automático y mejorar las predicciones. Para este proceso se propuso tres criterios mediana, promedio y valor fijo.

El primer criterio “Median” consiste en buscar el valor medio entre las etiquetas valencia-arousal (VA) de forma independiente y acorde a esto categorizar dichas etiquetas con valores de 0 y 1. Del valor de la media hacia arriba se otorga la etiqueta 1 y a los valores inferiores la etiqueta 0. El segundo criterio “Mean” como paso inicial busca el valor promedio entre los datos VA de forma independiente. Una vez identificado el valor promedio se estandarizan las etiquetas de modo que los valores iguales y mayores se etiquetan con 1 y los valores menores al promedio se etiquetan con 0. Finalmente, el tercer criterio “Greater than 5” propone colocar todo los datos mayores o iguales a 5 la etiqueta 1 y los datos menores a 5 la etiqueta 0.

Los criterios propuestos son en base al modelo emocional 2D (HAHV, LAHV, HALV, LALV) una vez normalizadas las etiquetas se procede a asignar dichos valores como se muestra en la Tabla 9, donde se observa el número de usuario, número de ensayo, las etiquetas asignadas a valencia y arousal (0 y 1) y el cuadrante correspondiente, para cada uno de experimentos en base a los 3 criterios propuestos. Las celdas marcadas representan la variación de las etiquetas según el criterio de categorización aplicado.

Tabla 9. Asignación de etiquetas bajo criterios Median, Mean y Greater than 5

Usuario	Ensayo	Median			Mean			Etiqueta > 5		
		V	A	C	V	A	C	V	A	C
1	39	0	1	LALV	0	1	LALV	0	1	LALV
1	40	1	1	HAHV	0	1	LALV	1	1	HAHV
2	1	1	0	LAHV	1	0	LAHV	1	1	HAHV
2	2	1	1	HAHV	1	1	HAHV	1	1	HAHV
2	3	1	1	HAHV	1	1	HAHV	1	1	HAHV
2	4	1	0	LAHV	1	0	LAHV	1	0	LAHV
2	5	1	0	LAHV	0	0	HALV	1	0	LAHV

2	6	0	0	HALV	0	0	HALV	1	0	LALV
2	7	0	0	HALV	0	0	HALV	0	0	HALV
2	8	1	1	HAHV	1	1	HAHV	1	1	HAHV
2	9	1	1	HAHV	1	1	HAHV	1	1	HAHV
2	10	0	0	HALV	0	0	HALV	0	0	HALV
2	11	1	0	LALV	1	0	LALV	1	0	LALV
2	12	1	1	HAHV	1	1	HAHV	1	1	HAHV
2	13	1	0	LALV	1	0	LALV	1	0	LALV
2	14	1	1	HAHV	1	1	HAHV	1	1	HAHV
2	15	1	1	HAHV	1	1	HAHV	1	1	HAHV
2	16	1	0	LALV	1	0	LALV	1	1	HAHV
2	17	1	0	LALV	1	0	LALV	1	0	LALV
2	18	1	1	HAHV	1	1	HAHV	1	1	HAHV

Muestra de asignación de etiquetas 0 y 1 para valencia y arousal según criterios propuestos. V: Valencia, A: Arousal y C: Cuadrante.

En la Figura 16, se muestran los porcentajes de cada categorización acorde a los criterios propuestos. El criterio "Median" tiene el 28% de clases etiquetadas como HAHV, 22% como LALV, 25.2 como HALV y 24.8 como LALV, En el criterio "Mean" el 26.6% de clases corresponden a la etiqueta HAHV, el 23.7% a LALV, el 20% a HALV y el 29.6% a LALV. Entre los criterios "Median" y "Mean" la diferencia es entre 1.7% y 5.2%. Sin embargo, al comparar los resultados con el tercer criterio "Greater than 5" tenemos el 35.8% en HAHV, 23.1% en LALV, 20.8% en HALV y 20.3% en LALV, existiendo una amplia diferencia de 7.8% y 9.2% en la etiqueta HAHV.

Criterios para categorizar los cuadrantes emocionales




Figura 16. Porcentajes de clases acorde a criterios de categorización

A partir de estos resultados, se realizaron pruebas iniciales para el proceso One hot encoding asignando el 80% y 20% a train y test [83]. Tomando en cuenta los criterios “Median” y “Mean”, se identificó que la mejor opción para realizar el proceso One hot encoding es el uso el criterio “Median”, ya que separa los datos de modo que hay muestras de emociones de cada cuadrante VA, tanto en train como en test.

3.8.2 Base de datos SEED

El dataset SEED consta de 45 archivos .mat con los registros de las señales EEG identificados con el nombre del participante. Además, existen dos archivos denominados “seed-iv-stimulation.xlsx” y “Channel Order. xlsx”. El primer archivo contiene las etiquetas de las emociones asignadas a cada experimento, etiquetas que corresponden a 0, 1, 2 y 3 las mismas que denotan las emociones básicas neutral, triste, miedo y felicidad, respectivamente. El segundo archivo contiene el orden de los 62 canales de acuerdo con el sistema de electrodos internacional 10-20.

Los archivos .mat de cada participante para nuestro propósito constan de un arreglo de estructura 15x32x48000, correspondientes al número de pruebas realizadas (15), número de canales (32) a ser considerados y datos de la señal almacenada para cada canal (48000). En este trabajo se utilizan los datos preprocesados muestreados a 200Hz y las emociones a clasificar de denotan como neutral, sad, fear y happy [20].

A diferencia del dataset DEAP, no fue necesario realizar procesos adicionales en la preparación de datos, cada uno de los usuarios en el dataset SEED tiene dos partes: datos y su etiqueta.

En la Figura 17, se muestra que los datos se encuentran distribuidos en un mismo porcentaje en las cuatro emociones denotadas como neutral, sad, fear y happy, por tanto, no hubo necesidad de balancear los datos ya que las clases están ya balanceadas.




Figura 17. Histograma de emociones dataset SEED

3.9 Extracción de características

Para dar una idea del tiempo de ejecución que toma generar las características por usuario se procedió a calcular el tiempo de ejecución de los features para un "único dato", es decir, generar los features de una señal de un usuario específico, de un único ensayo, con un único canal y 32 canales. Este resultado se presenta como referencia para poder comparar los procesos entre datasets.

3.9.1 Dataset DEAP

En el dataset DEAP se toma como ejemplo los datos del usuario 2, ensayo 0 y canal 0, obteniendo un total de 8064 datos que representan una señal a procesar. Por tanto, se procede a promediar 3 ejecuciones de nuestro propio paquete que calcula las características para una señal dada.

En la Tabla 10, se resume el tiempo aproximado en segundos, que toma la extracción de características de los diferentes dominios en el dataset DEAP. Las agrupaciones que se realizó son: características estadísticas, características adicionales (features en el dominio del tiempo diferentes a las estadísticas y entropías), características del dominio de la frecuencia, características del dominio tiempo – frecuencia. El cálculo del tiempo aproximado de las variantes de entropía se realiza de forma individual. Se realizó esta división debido a que el número de features en el dominio del tiempo son numerosas y las variantes de entropía tienen un alto costo computacional.

Tabla 10. Tiempo de ejecución de extracción de características - usuario 2

Características	1 canal (seg)	1 ensayo 32 canales	40 ensayos 32 canales (1 usuario)
Estadística	0.055000	1.760	70.40
Adicionales	0.220964	5.974	23.935
Dominio Frecuencia	1.114581	35.667	1426.68
Tiempo - Frecuencia	0.047963	1.535	61.40
Entropía Shanon	0.272020	8.705	348.20
Entropía Aproximada	3.471318	111.082	4443.28
Muestra Entropía	3.368673	107.798	4311.92
Entropía Permutación	0.061990	1.984	79.36

Se deduce que la agrupación de características “Adicionales” toman menor tiempo de extracción a pesar de estar constituidas por varios algoritmos como: Energy, Root mean square, Line Length, Average power, Higuchi Fractal Dimension, Preproslan Fractal Dimension, Hjorth, Zero Crossing y Higher Order Crossing. Luego, se está la agrupación de las características de Tiempo - Frecuencia y características Estadísticas.

Por otro lado, se evidencia que las características del Dominio Frecuencia conllevan un mayor tiempo de ejecución a comparación con las demás características. Seguidas por las variantes de entropía Aproximada y de Muestra.

3.9.2 Dataset SEED

En el dataset SEED se toma como ejemplo los datos del experimento 2, el primer usuario con su video 3, con su canal 0 (FP1), obteniendo un total de 27801 datos que representan una señal a procesar. Se procede a promediar 3 ejecuciones de nuestro propio paquete que calcula los features para una señal dada.

En la Tabla 11, se resume el tiempo aproximado en segundos, que toma la extracción de características de los diferentes dominios en el dataset SEED. El cálculo del tiempo de ejecución de las características se realizó bajo el mismo criterio que en DEAP, es decir, se agrupo las diferentes features en Estadística, Adicionales, Dominio Frecuencia, Tiempo – Frecuencia, mientras que, las variantes de entropía se tomaron una por una.

Tabla 11. Tiempo de ejecución de extracción de características - usuario 1

Características	1 canal (seg)	1 ensayo 32 canales
Estadística	0.898666	28.757.312
Adicionales	0.742518	23.760.576
Dominio Frecuencia	1.834.431	58.701.792
Tiempo - Frecuencia	0.028671	917.472
Entropía Shanon	0.926451	29.646.432
Entropía Aproximada	87.969.536	2.815.025.152
Muestra Entropía	77.954.650	2.494.548.800
Entropía Permutación	0.570499	18.255.968

Se observa que la agrupación de características Tiempo - Frecuencia son las que toman menor tiempo de extracción. Luego, tenemos la agrupación de las características Adicionales y características Estadísticas. Además, las variantes de entropías Aproximada y de Muestra conllevan un mayor tiempo de extracción si se compara con las demás características, seguidas por la entropía de permutación.

3.9.3 Vectores de extracción de características

La extracción de características se realizó en ambos dataset DEAP y SEED tomando en cuenta los dominios del tiempo, frecuencia y tiempo - frecuencia, utilizando el lenguaje de programación Python y las diferentes librerías que tiene a disposición para el análisis y procesamiento de grandes cantidades de datos.

A continuación, se describe las librerías utilizadas y los parámetros enviados para el cálculo de las características en los diferentes dominios.

- **Vector de características en dominio del tiempo**

El cálculo de características en el dominio del tiempo respecto a medidas estadísticas se realizó utilizando las librerías Scipy para el cálculo de Mean, Variance, Skewness y Kurtosis. Se utilizó la librería Numpy para el cálculo de Standard Deviation y Maximum. La librería Statistics permitió el cálculo de Mean of the normalized absolute values of the first and second. El parámetro de entrada de las medidas estadísticas es la señal EEG enviada como vector de una dimensión.

El cálculo de características como Energy, Root mean square, Line Length y Average Power se realizó utilizando diferentes funciones de la librería Math y Numpy.

Características en dominio del tiempo como Higuchi Fractal Dimension, Preproslan Fractal Dimension y Hjorth se calcularon utilizando la librería `eeglib.features`. Las características Zero Crossing y Higher Order Crossing se calcularon utilizando la librería `Numpy`. Finalmente, el cálculo de entropía de Shannon se realizó utilizando la librería `scipy.stats`, mientras que, las entropías Approximate, Sample y Permutation se realizaron utilizando la librería `EntropyHub`.

Este segundo grupo de características del dominio del tiempo también reciben como parámetro de entrada la señal EEG enviada como vector de una dimensión, excepto Higher Order Crossing que a más del vector de la señal EEG recibe como parámetro de entrada el número de términos que se incluirán en la secuencia, representada por el recuento de Zero Crossing, en nuestro caso representado por $k = 9$.

- **Vector de características en dominio de la frecuencia**

En la generación de características de dominio de la frecuencia se utilizó varias librerías y parámetros de entrada acorde a la característica a calcular.

Por ejemplo, Spectral entropy se calculó utilizando la librería `EntropyHub`, cuyo parámetro de entrada es la señal EEG enviada como vector de una dimensión. Power ratio se calculó utilizando la librería `eeglib.features` teniendo como parámetros de entrada el vector de la señal EEG, las bandas de frecuencia alpha (8, 12), beta (12, 30), delta (1, 4) y theta (4, 7), y el valor de frecuencia representado por $freqRes = 0.5$. Power Spectral Density se calculó utilizando la librería `Scipy` para la estimación del método Welch, enviando como parámetros de entrada el vector de la señal EEG y el valor de frecuencia representado por $fs = 128$. Fast Fourier Transform se calculó utilizando la librería `Scipy` enviando como parámetros de entrada el vector de la señal EEG y las cinco bandas de frecuencia con los valores ya mencionados.

Finalmente, el cálculo de las features Rational Asymmetry y Differential Asymmetry se realizó utilizando la librería `Statistics` basado en la potencia de los electrodos en los hemisferios izquierdo y derecho del cerebro para las bandas alfa, beta, teta y gamma, teniendo como parámetro de entrada el vector de la señal EEG.

- **Vector de características en dominio tiempo - frecuencia**

El cálculo de las características en dominio tiempo – frecuencia se realizó utilizando la librería `pywt`. El cálculo de Discrete Wavelet Transform requiere como de entrada la señal EEG enviada como vector de una dimensión y el Wavelet Madre. El segundo parámetro

corresponde al uso de la familia de wavelets Daubechies [15], representada en nuestro trabajo por *db1* y *nivel* = 5.

El cálculo de Wavelet Entropy implica calcular previamente Wavelet Energy dada por cuadrado de los elementos que componen el vector. Este cálculo entrega un array de tamaño [número_niveles + 1], donde el primer elemento del array siempre será los coeficientes de aproximación. El resto de elementos del array serán los coeficientes de detalle de la señal presentándose ordenados de mayor nivel a menor nivel. Así, el segundo elemento del array será los coeficientes de detalle del último nivel (nivel 5) y el último elemento del array será los coeficientes de detalle del primer nivel (nivel 1).

Una vez obtenidos los coeficientes wavelets, se tomó como valor estadístico el promedio, para mantener la misma dimensión que el resto de características calculadas, con esto evitamos perder información importante de la señal EEG y la obtención de un vector de las mismas dimensiones que el resto de vectores obtenidos en los dominios de tiempo y frecuencia para poder enviarlo al clasificador.

3.10 Reducción de dimensiones

Los vectores creados a partir de la extracción de características EEG en los diferentes dominios del tiempo, frecuencia y tiempo - frecuencia pueden no estar correlacionadas con los estados emocionales y conducir a la degradación del rendimiento de los clasificadores.

PCA es una técnica de transformación lineal no supervisada, utilizada ampliamente para la extracción de características y reducción de la dimensionalidad de datos, se optó por utilizarla en este trabajo para reducción de la dimensionalidad con el fin de ayudar a aumentar la velocidad y la estabilidad del clasificador. Para ello, se usó la librería sklearn de Python y 15 componentes principales, ya que este número de componentes explican más del 99.99% de la variabilidad de los datos en los dominios del tiempo, frecuencia y tiempo-frecuencia como se muestra en la Figura 18. Donde, el primer componente es el que más explica la varianza y va reduciéndose exponencialmente, en nuestro caso se consideró el 99.99% para elegir los compatibles.

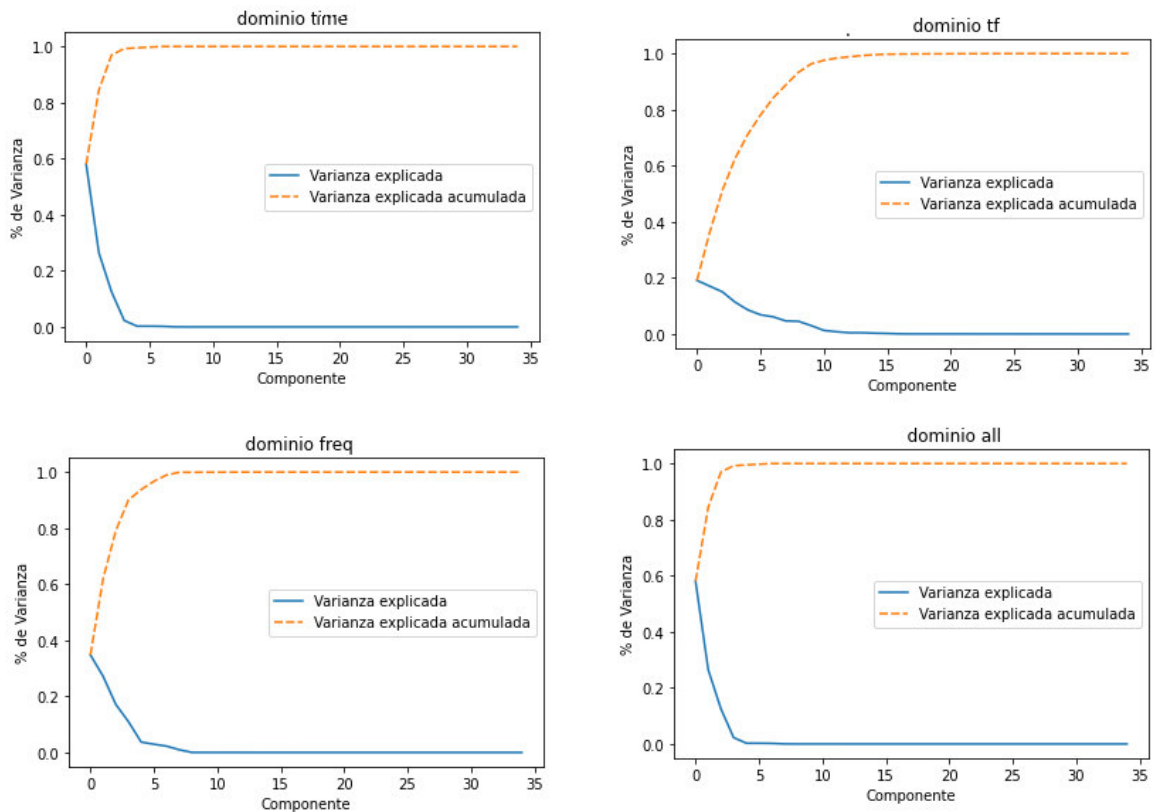


Figura 18. Variabilidad de datos con PCA

3.11 Clasificación y evaluación de rendimiento

Uno de los objetivos de este trabajo es utilizar diferentes vectores de características para detectar y clasificar estados emocionales, empleando diferentes algoritmos de clasificación con el fin de evaluar qué métodos de extracción de características aporta más información y produce clasificadores con mejores rendimientos.

Lo primero a realizar es un split con 80% y 20% para train y test, respectivamente. Luego, se asoció los datos con los features extraídos previamente, para construir los diferentes vectores de entrada a los clasificadores.

Los algoritmos utilizados fueron SVM, k-NN y ANN que en la RSL presentan un buen rendimiento acorde al vector de características ingresado al clasificador. En el clasificador SVM se utilizó un kernel rbf y el parámetro “auto” como gamma. En el clasificador k-NN se utilizó el valor de k=5. Estos dos clasificadores fueron implementados a partir de diferentes funciones que ofrece la librería sklearn.

Finalmente, el clasificador ANN se implementó utilizando las funciones de la librería keras, se asignó 1000 épocas, 3 capas dado el número de cuadrantes a clasificar de las cuales

las 2 primeras capas son de activación con RELU con 64 neuronas cada capa, la última capa de salida tiene 4 salidas su función de activación es softmax, en la compilación se utiliza el parámetro "categorical_crossentropy" y optimizador "Adam" [58].

El ingreso de vectores de características para los diferentes clasificadores mencionados utilizando los dataset DEAP y SEED, consistió en organizar en un mismo vector, una a continuación de otra, las características de los canales de los diferentes usuarios en base a los siguientes experimentos:

- Experimento 1: Vector con 21 características en dominio del tiempo.
- Experimento 2: Vector con 6 características en dominio de la frecuencia.
- Experimento 3: Vector con 2 características en dominio tiempo – frecuencia.
- Experimento 4: Vector general con 29 características.

3.11.1 Resultados en dataset DEAP

Los diferentes vectores de entrada a los clasificadores basados en los experimentos, se llevaron a cabo utilizando PCA con 15 componentes principales y también sin utilizar PCA, cabe mencionar que para pruebas se realizó el balanceo de datos utilizando la librería imblearn con la función SMOTETomek. A continuación, se mencionan los resultados obtenidos con el dataset DEAP para la clasificación de los cuadrantes LALV, HAHV, HALV y LAHV.

- **Vector de entrada con características en el dominio del tiempo**

El primer experimento consistió en realizar un vector con las 21 características calculadas en dominio del tiempo, es decir, el vector tiene características de las variantes de entropía, medidas estadísticas y otras medidas adicionales mencionadas en las secciones anteriores.

En la Figura 19, se observa la matriz de confusión resultante de los clasificadores SVM, k-NN y ANN con y sin el uso de PCA. Respecto al clasificador sin uso de PCA tenemos que en SVM las clases con mayor número de aciertos son LALV, HAHV y LAHV, mientras que la clase HALV se confunde con la clase HAHV. La matriz de confusión resultante del clasificador k-NN refleja que en el set de las clases con mayor número de aciertos son HAHV, HALV y LAHV, mientras que la clase LAHV se confunde con las demás clases. Finalmente, en la matriz de confusión del clasificador ANN se observa que las clases mejor clasificadas son LALV y HAHV, mientras que las clases HALV y LAHV se confunden con la clase HAHV.




Figura 19. DEAP - Resultados del vector de tiempo sin PCA

En la Figura 20, se observa la matriz de confusión resultante de los clasificadores SVM, k-NN y ANN utilizando PCA. El clasificador SVM en este caso no muestra un mejor resultado sino lo contrario este algoritmo tiende a clasificar las clases como HAHV. El clasificador k-NN tiene mejor acierto en para clases HAHV y HALV, sin embargo, la clase LALV es confundida con la HAHV y la clase LAHV se confunde con las clases HAHV y HALV. Por último, el clasificador ANN tiende a clasificar las clases como LALV.




Figura 20. DEAP - Resultados del vector de tiempo con PCA.

A continuación, se muestra el resultado con y sin PCA utilizando la técnica de balanceo de datos SMOTETomek como parte de las pruebas realizadas, como se muestra en la Figura 21. El clasificador SVM sin el uso de PCA tiende a clasificar mejor las clases LALV y HALV mientras que las clases HAHV y LAHV son las clases que más se confunden. En este clasificador se observa que el uso de PCA tiende a clasificar todas las clases como HALV. Por otro lado, el clasificador KNN tiene una mejor categorización de la clase HALV, las clases LALV, HAHV y LAHV se confunden mayormente con la clase HALV, lo mismo sucede al utilizar PCA. Por último, el clasificador ANN sin utilizar PCA clasifica de mejor manera las clases LALV y HAHV, mientras que las clases HALV y LAHV tienden a confundirse en su mayoría con la clase HAHV. El uso de PCA en este clasificador mejora la clasificación únicamente de la clase HALV.

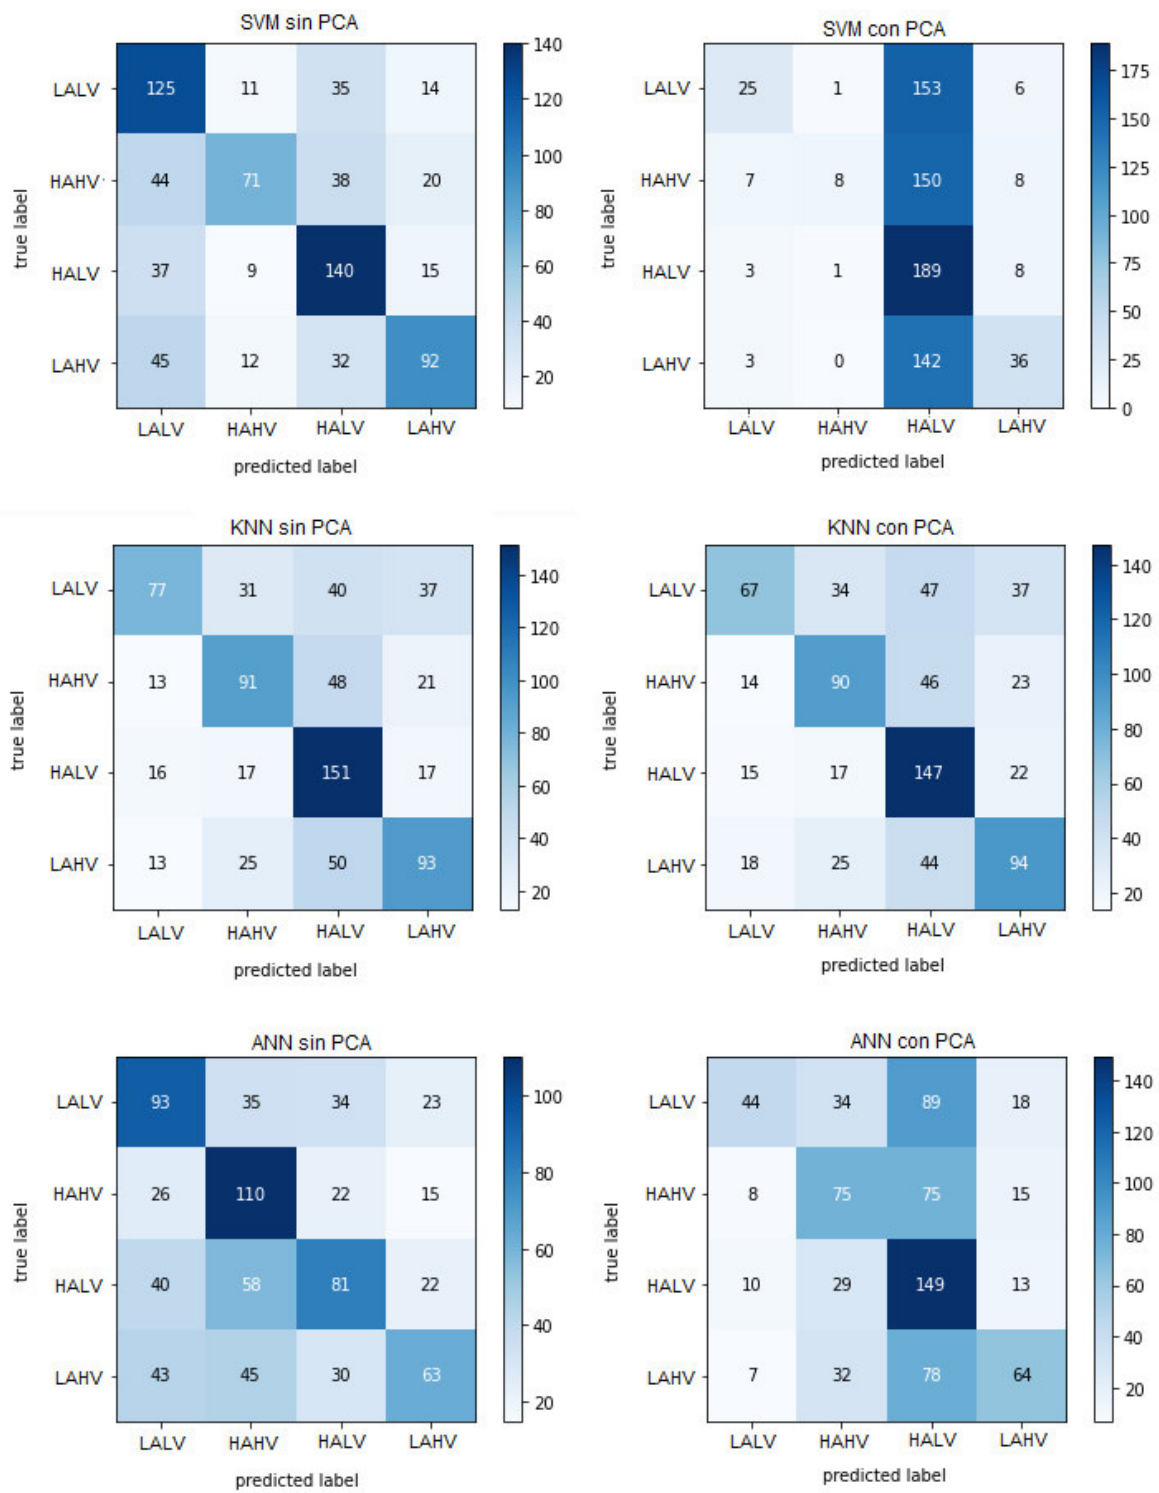


Figura 21. DEAP - Resultados del vector de tiempo con SMOTETomek

- **Vector de entrada con características en el dominio de la frecuencia**

El segundo experimento consiste en realizar un vector con las 6 características calculadas en dominio de la frecuencia. El tamaño del vector de características de entrenamiento es de 993x13632 y el vector de características de pruebas es de 247x13632 sin el uso de PCA.

En la Figura 22, se observa la matriz de confusión resultante de los diferentes clasificadores utilizando en este trabajo, sin la implementación de PCA. Respecto al set de entrenamiento del clasificador SVM se observa que las clases con mayor número de aciertos son LALV, HAHV y HALV, mientras que la clase LAHV se confunde con la clase HAHV. En el clasificador k-NN las clases con mayor número de aciertos son HAHV, HALV y LAHV siendo la clase LALV la clase que mayor error tiene al clasificarla confundiéndose con el resto de las clases. El clasificador ANN tiende a clasificar mejor las clases con características en dominio de la frecuencia, a pesar que en cierto grado las confunde con la clase HAHV.




Figura 22. DEAP - Resultados del vector de frecuencia

En la Figura 23, se observa la matriz de confusión resultante de los clasificadores SVM, k-NN y ANN, con y sin la implementación de PCA combinada con el uso de la técnica SMOTETomek. El uso de PCA junto con el balanceo de datos produce que el clasificador SVM tienda a clasificar las clases como HALV, mientras que sin el uso de PCA SVM clasifica bastante bien los cuatro cuadrantes. Respecto al clasificador k-NN el resultado de la clasificación con y sin uso de PCA son bastante similares identificando en mayor número las clases HALV y LAHV mientras que las clases LALV y HAHV tienden a confundirse con las clases HALV. El clasificador ANN tiene un buen resultado en la clasificación de los cuatro cuadrantes sin el uso de PCA, sin embargo, la implementación de PCA clasifica correctamente la clase HALV obteniendo una baja clasificación del resto de las clases.

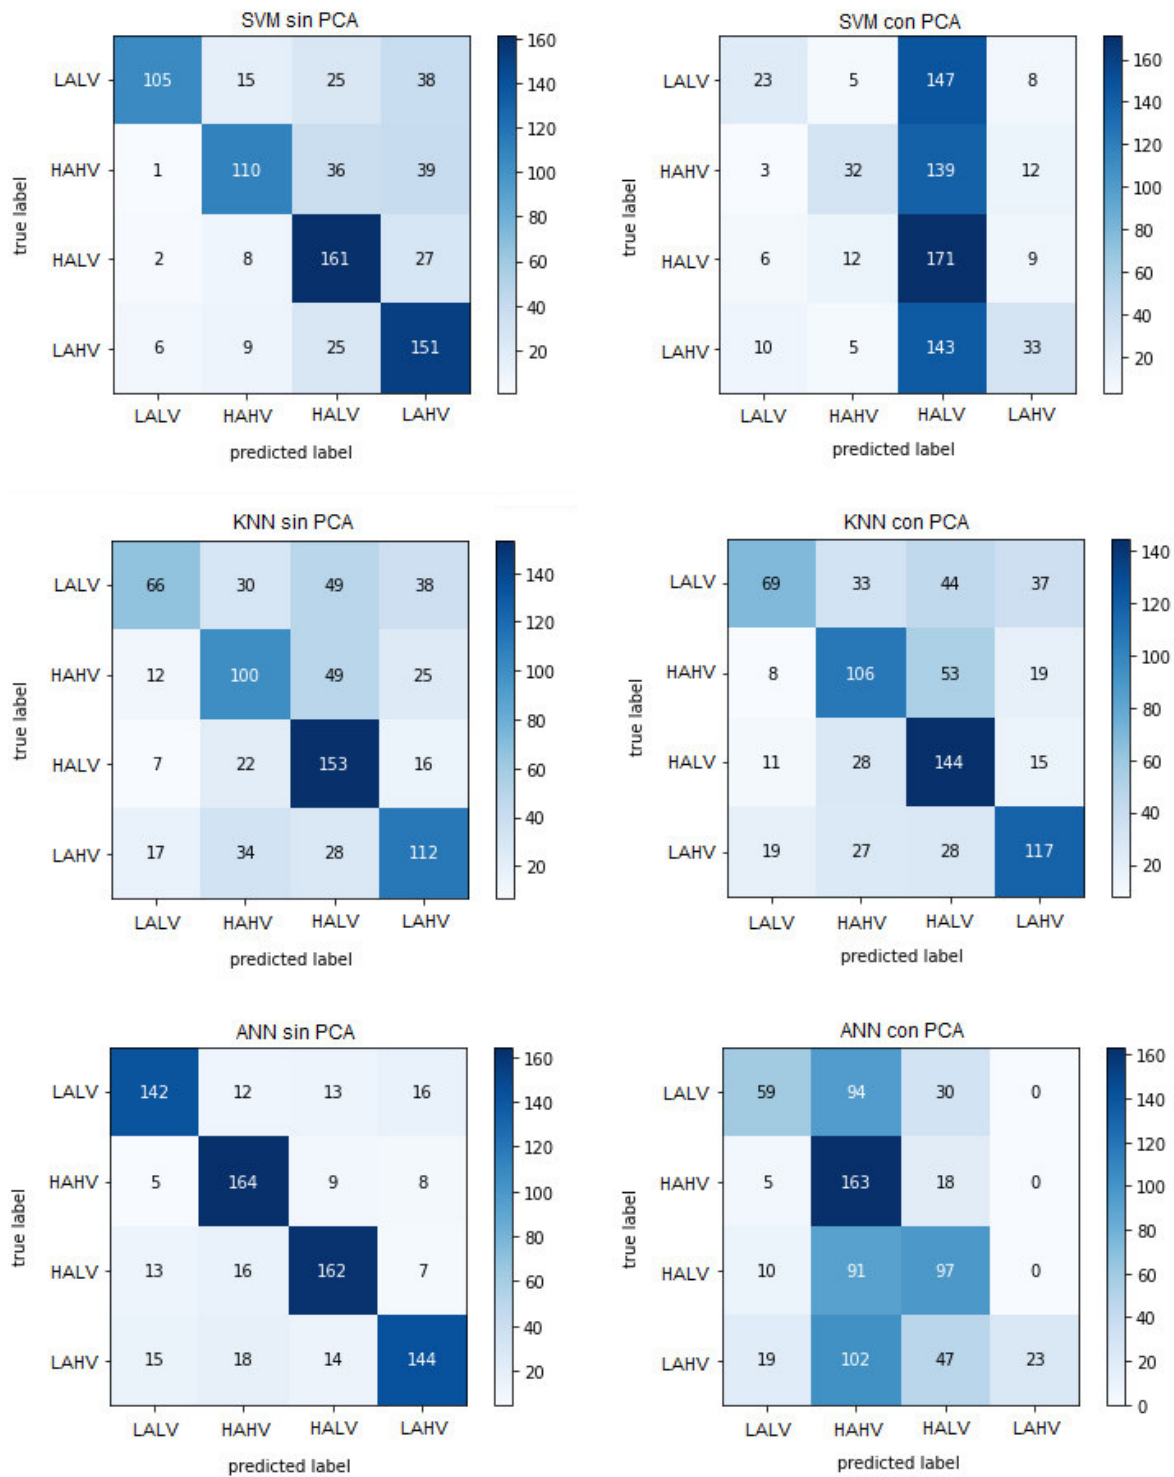


Figura 23. DEAP - Resultados del vector de frecuencia con SMOTETomek

- **Vector de entrada con características en el dominio del tiempo – frecuencia**

El tercer experimento consiste en realizar un vector con las 2 características calculadas en dominio de tiempo - frecuencia. El tamaño del vector de características de entrenamiento es de 993x7168 y el vector de características de pruebas es de 247x7168 sin la implementación de PCA.

En la Figura 24, se muestra los resultados obtenidos sin utilizar PCA. En el set de entrenamiento del clasificador SVM las clases con mayor número de aciertos es HAHV, el resto de las clases se confunden en mayoría con la clase HAHV. En el clasificador k-NN las clases con mayor número de aciertos son HALV y HALV, siendo las clases LALV y LAHV las que presentan mayor error en la clasificación confundiéndose con HAHV. Respecto al clasificador ANN realiza una identificación aceptable de los cuatro cuadrantes.




Figura 24. DEAP - Resultados del vector de tiempo-frecuencia sin PCA

En la Figura 25, se observa la matriz de confusión resultante de los clasificadores SVM, k- y ANN, luego de implementar PCA. El clasificador SVM tiende a clasificar las clases como HAHV. El clasificador k-NN identifica mejor las clases HAHV y HALV siendo la clase LALV y LAHV las que mayormente se confunde con el resto de las clases. Finalmente, ANN clasifica mejor la clase LALV, mientras que el resto de las clases tiende a confundirlas con LALV.




Figura 25. DEAP - Resultados del vector de tiempo-frecuencia con PCA

En la Figura 26, se observa la matriz de confusión resultante de los clasificadores SVM, k-NN y ANN, sin y con la implementación de PCA y la técnica de SMOTETomek. En el caso de SVM sin el uso de PCA los cuatro cuadrantes tienen una buena clasificación, sin embargo, implementando PCA tiende a clasificar las clases como LALV. En k-NN se obtienen resultados similares en ambos casos, es decir, con y sin el uso de PCA identificando mejor las clases HALV y LAHV, las clases LALV y HAHV tienden a confundirse con la clase HALV. Finalmente, ANN tiene una buena clasificación de las clases sin el uso de PCA.

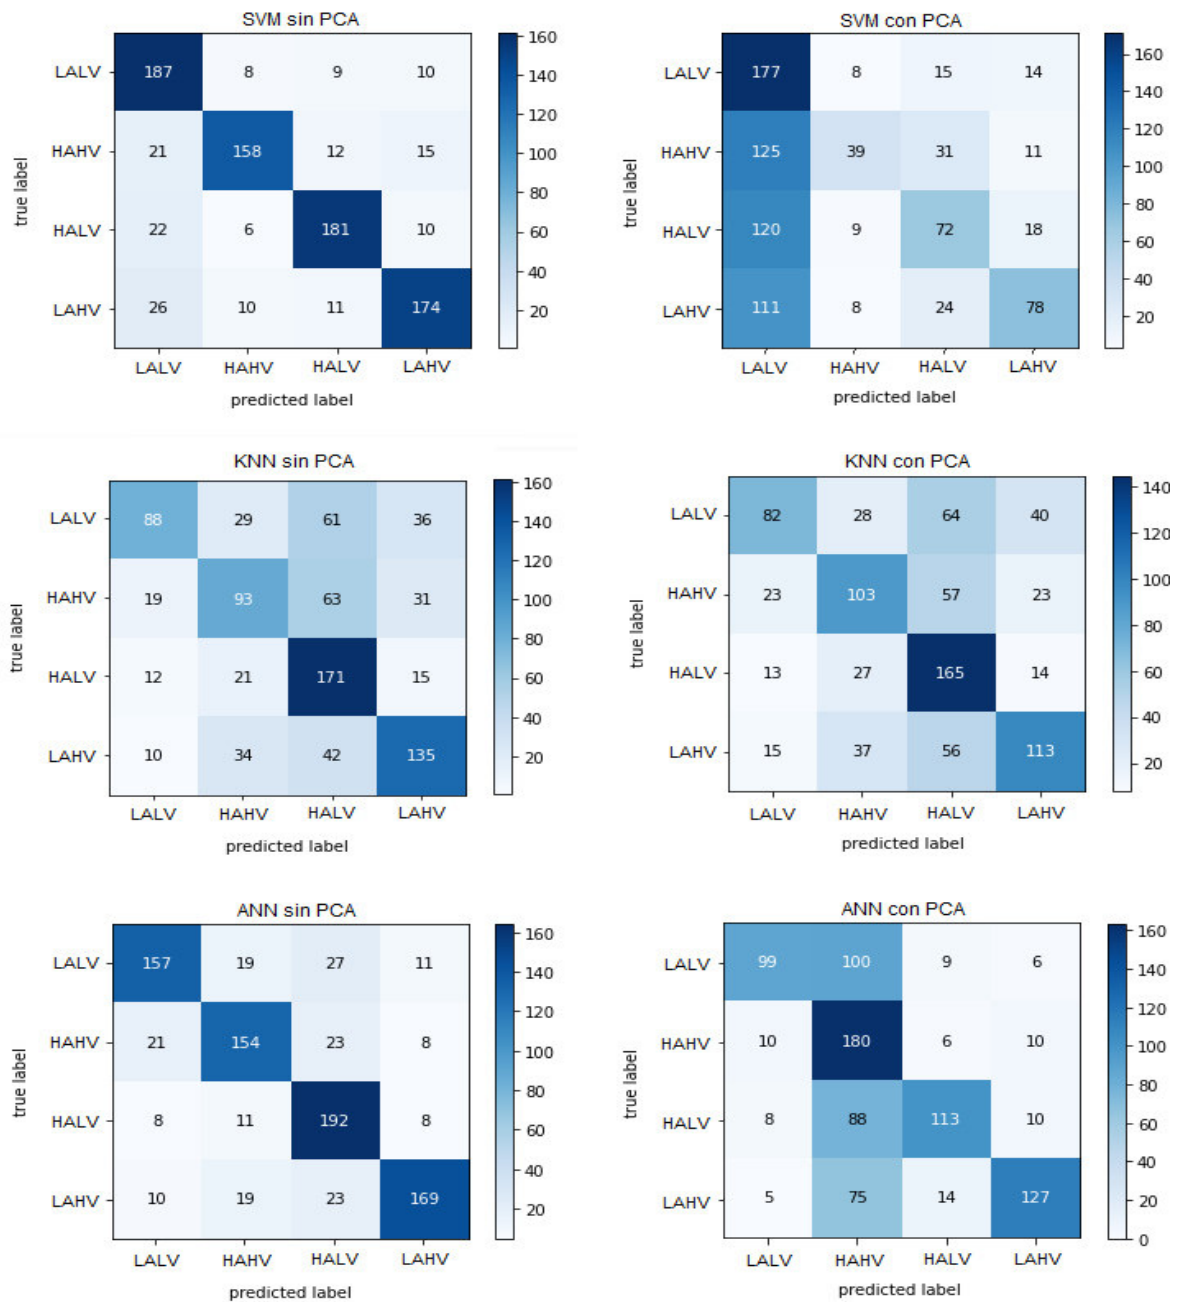


Figura 26. DEAP - Resultados del vector de tiempo-frecuencia con SMOTETomek

- **Vector de entrada con 29 características**

El cuarto experimento consiste en realizar un solo vector con todas las 29 características obtenidas, esto implica que, el vector está constituido por 21 características en el dominio del tiempo, 6 características del dominio de la frecuencia y 2 características del dominio tiempo - frecuencia.

En la Figura 27, se muestran los resultados sin el uso de PCA. El clasificador SVM clasifica mejor la clase HAHV mientras que las clases LALV, HALV y LAHV tienden a confundirse con HAHV, la clase HALV presenta más errores en la clasificación. El clasificador k-NN tiene un resultado similar a SVM, la clase mejor clasificada es HAHV y el resto de clases se confunden en mayoría con HAHV. El clasificador ANN reconoce mejor la clase LALV y el resto de las clases tienden a confundirse con LALV.




Figura 27. DEAP - Resultados del vector de 29 características sin PCA

El resultado de los clasificadores utilizando PCA se presentan en la Figura 28. Donde, SVM tiende a clasificar las clases como HAHV. EL clasificador k-NN categoriza mejor las clases HAHV y HALV, las clases LALV y LAHV tienden a ser confundidas con HAHV. ANN tiende a clasificar las clases como LALV.




Figura 28. DEAP - Resultados del vector de 29 características con PCA

La Figura 29, muestra el resultado de la implementación de la técnica SMOTETomek con y sin el uso de PCA. El clasificador SVM tiene un mejor acierto en las clases LALV y HALV mientras que las clases HAHV y LAHV tienden a ser confundida con LALV. El clasificador k-NN tiene resultados similares con y sin el uso de PCA, reconocer mejor la clase HALV, el resto de clases tienden a ser confundidas con HALV.

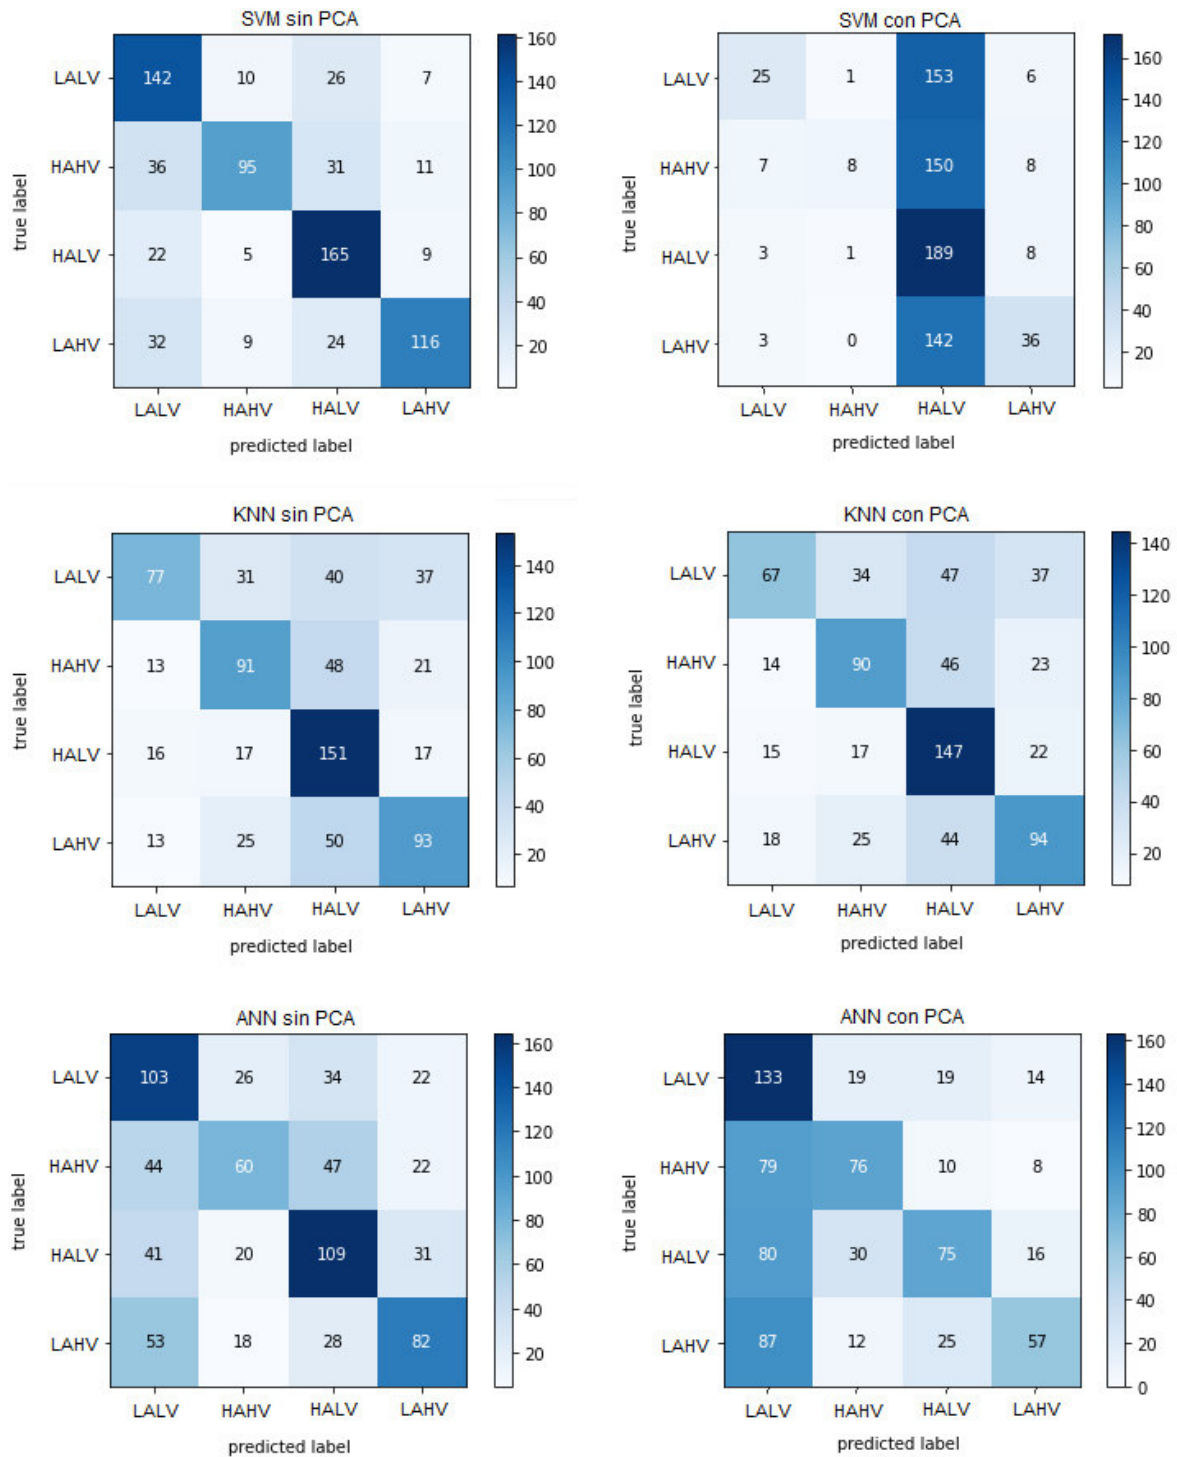


Figura 29. DEAP - Resultados del vector de 29 características con SMOTETomek

3.11.2 Resultados en dataset SEED

En esta sección se presenta los resultados obtenidos a partir de los diferentes vectores de entrada a los clasificadores basados en los experimentos antes mencionados. Los resultados mostrados son en base a la clasificación de las emociones neutral, sad, fear y happy. Cabe mencionar que en SEED no se utilizó técnicas de balanceo de datos. En la Figura 17, se muestra que los datos que se encuentran balanceados. Además, se muestran resultados obtenidos sin aplicar PCA ya que los porcentajes de Accuracy son más altos.

- **Vector de entrada con características en dominio del tiempo**

El tamaño del vector de características del dominio del tiempo sin el uso de PCA es 864x1120 en entrenamiento y 216x1120 en pruebas.

En la Figura 30, se observa la matriz de confusión resultante de los clasificadores SVM, k-NN y ANN. El clasificador SVM reconoce mejor la clase neutral y fear, mientras que las clases sad y happy las confunde con neutral. La clase fear es la que mejor identifica el clasificador k-NN las clases neutral, sad y happy tienden a confundirse con fear. El clasificador ANN tiene tendencia a clasificar las clases como neutral.




Figura 30. SEED - Resultados del vector de tiempo

- **Vector de entrada con características en el dominio de la frecuencia**

El tamaño del vector de características del dominio de la frecuencia es 864x488 en entrenamiento y 216x488 en pruebas.

En la Figura 31, se observa la matriz de confusión resultante de los diferentes clasificadores. SVM clasifica mejor las clases sad y happy, las clases neutral y fear tienden a confundirse con sad. El clasificador k-NN identifica mejor la clase fear el resto de clases tienden a confundirse con fear. Finalmente, ANN tiene una buena clasificación para las cuatro clases.




Figura 31. SEED - Resultados del vector de frecuencia

Vector de entrada con características en el dominio del tiempo – frecuencia

El tamaño del vector de características del dominio tiempo – frecuencia en entrenamiento es de 864x224 y el vector de características de pruebas es de 216x224.

A continuación, se muestra la matriz de confusión de los algoritmos de clasificación SVM, k-NN y ANN. Donde, SVM reconoce mejor la clase neutral, el resto de clases se confunden con neutral. En k-NN se reconocen mejor las clases fear y happy. El clasificador ANN tiene una buena clasificación en las cuatro clases.




Figura 32. SEED - Resultados del vector tiempo – frecuencia

- **Vector de entrada con todas 29 características**

El tamaño del vector de características de los tres dominios sin utilizar PCA es 864x1832 en entrenamiento y 216x1832 en pruebas, correspondiente al número de ejemplos y el número de características.

En la Figura 33, se observa la matriz de confusión resultante de los clasificadores SVM, k- y ANN en los datos de entrenamiento. SVM clasifica mejor la neutral y ferar, las clases sad y happy tienden a confundirse con sad. El clasificador k-NN tiene una mejor categorización

de las clases neutral y fear, mientras que las clases sad y happy tienden a confundirse con fear. Por último, ANN clasifica mejor la clase sad el resto de clases se confunden entre sí.




Figura 33. SEED - Resultados del vector con 29 características

3.11.3 Evaluación de clasificadores Dataset DEAP y SEED

Una vez clasificadas las emociones en base al espacio VA respecto a DEAP y las etiquetas de emociones correspondientes a neutral, sad, fear y happy para SEED, se procede a evaluar el rendimiento de los clasificadores utilizando la métrica Accuracy seleccionada en base a la RSL.

En la Tabla 12, se muestran los porcentajes obtenidos de la evaluación de los datos de prueba (test) de los clasificadores en cada uno de los cuatro experimentos realizados con DEAP con y sin el uso de PCA. En el dominio del tiempo tenemos el 66.2% de Accuracy utilizando el clasificador k-NN implementando las técnicas de PCA y SMOTE. El dominio de la frecuencia presenta un 66.0% con el clasificador SVM sin el uso de PCA y tampoco SMOTE. El dominio tiempo - frecuencia alcanza el 65.6% utilizando el clasificador SMV sin el uso de PCA y SMOTE. Finalmente, el vector con la combinación de las 29 características en los tres dominios alcanza el 66.2% utilizando k-NN implementando la técnica de PCA y SMOTE.

En base a los porcentajes presentados con DEAP, los vectores con mejor resultado son: el vector con características en dominio del tiempo y el vector con el conjunto de 29 características presentando en ambos casos el 66.2%. Sin embargo, entre ambos vectores el de dominio del tiempo representa menor costo computacional como lo expusimos en la Tabla 9. Además, el vector con características en dominio de la frecuencia obtiene el 66.0% de Accuracy, siendo el vector que implica un menor costo computacional entre los cuatro vectores de entrada creados.

Tabla 12. Evaluación de clasificadores en DEAP para VA

Vector con características en dominio de tiempo												
Met	Sin PCA			PCA			Sin PCA y SMOTE			PCA y SMOTE		
	SVM	k-NN	ANN	SVM	k-NN	ANN	SVM	k-NN	ANN	SVM	k-NN	ANN
F1	64.2	64.8	62.3	65.2	64.2	62.1	63.8	66.2	62.8	61.7	65.4	61.3

Vector con características en dominio de la frecuencia												
Met	Sin PCA			PCA			Sin PCA y SMOTE			PCA y SMOTE		
	SVM	k-NN	ANN	SVM	k-NN	ANN	SVM	k-NN	ANN	SVM	k-NN	ANN
F1	66.0	62.3	64.0	64.2	63.0	61.7	64.2	62.1	62.3	62.1	61.7	62.1

Vector con características en dominio tiempo - frecuencia												
Met	Sin PCA			PCA			Sin PCA y SMOTE			PCA y SMOTE		
	SVM	k-NN	ANN	SVM	k-NN	ANN	SVM	k-NN	ANN	SVM	k-NN	ANN
F1	65.6	65.2	62.1	64.4	64.0	63.0	63.6	64.2	63.0	62.6	64.4	64.8

Vector con 29 características												
Met	Sin PCA			PCA			Sin PCA y SMOTE			PCA y SMOTE		
	SVM	k-NN	ANN	SVM	k-NN	ANN	SVM	k-NN	ANN	SVM	k-NN	ANN
F1	64.8	64.8	61.9	65.2	64.2	62.1	63.8	66.2	62.1	61.7	65.4	63.2

En la Tabla 13, se observa los porcentajes obtenidos de la evaluación de los clasificadores de los cuatro vectores creados a partir de las características del tiempo, frecuencia y tiempo-frecuencia, utilizando el dataset SEED. En el dominio del tiempo se obtiene el 67.4% de Accuracy utilizando el clasificador SVM. En dominio de la frecuencia tenemos como mayor valor el 62.7% utilizando el clasificador k-NN. En cuanto al dominio tiempo – frecuencia el mayor valor es del 65.7% en los clasificadores SVM y ANN. El vector con las 29 características presenta el 66% como valore más alto utilizando el clasificador SVM. En el caso del dataset SEED tenemos que el vector con mejor porcentaje de clasificación es en el domino del tiempo con un 64.7% en Accuracy.

Tabla 13. Evaluación de clasificadores en SEED para VA

	Dominio del tiempo			Dominio de la frecuencia		
	SVM	k-NN	ANN	SVM	k-NN	ANN
Acc	67.4	63.9	61.6	61.8	62.7	61.8

	Dominio tiempo – frecuencia			29 características		
	SVM	k-NN	ANN	SVM	k-NN	ANN
Acc	65.7	63.9	65.7	66.0	63.9	62.5

El vector con características en el dominio del tiempo es el que mejores resultados obtienen en los dataset DEAP y SEED con porcentajes de 66.2% y 67.4% de Accuracy utilizando k-NN y SVM, respectivamente. Sin embargo, el resultado del vector con características de la frecuencia para DEAP es el que menor costo computacional y obtiene un 66.0% de Accuracy utilizando el clasificador SVM. La clasificación de estados emocionales la realizamos en base al modelo bidimensional VA considerando los cuadrantes HAHV, LAHV, HALV y HAHV.

3.12 Discusión

Varios autores realizan el reconocimiento de emociones a partir de la clasificación de las clases HV, LV, HA y LA del modelo bidimensional, es decir, clasifican la Valencia positiva/valencia negativa y Arousal alto/bajo utilizando el dataset publico DEAP.

Por ejemplo, Nawaz en su estudio realiza el reconocimiento de emociones utilizando características de uso común como: Entropías, Dimensión Fractal, Estadísticas, Wavelet y Funciones de Potencia. Clasifica las clases HV y LV obteniendo resultados promedio de 65,92% de Accuracy con el clasificador k-NN y de 69,73% con el clasificador SVM. En las clases HA y LA obtiene resultados promedio de 67,91% y 69,92 para k-NN y SVM respectivamente [15]. En [53] el autor obtiene en HV y LV resultados de 64.87%, 65.60% y 67.97% utilizando los clasificadores k-NN, SVM y ANN. Los vectores de entrada a los clasificadores están conformados por características estadísticas como: Variance, Kurtosis y Skewness, además, de variables como Zero Crossing Rate y Entropía de Shannon. El autor de [70], obtiene valores de Accuracy de 65% para Valencia y 63.3% para Arousal utilizando el clasificador SVM y características Spectral Power en dominio de la frecuencia y Relative Energy en dominio de tiempo-frecuencia para la clasificación de estados emocionales.

Otros autores realizan el reconociendo de emociones en base a los cuatro cuadrantes del modelo bidimensional, es decir, clasifican los cuadrantes del modelo VA tomando en cuenta las clases HAHV, LAHV, HALV y HAHV. Por ejemplo, el autor de [57], realiza el reconocimiento de emociones en espacio VA obteniendo un promedio del 65.92% de Accuracy, utilizando características como Parámetros de Hjorth y Entropy en el dominio del tiempo, Fourier Transform, RASM y DASM en el dominio de la frecuencia y Discrete wavelet transform en dominio tiempo-frecuencia. En [67] realizan el reconocimiento de emociones utilizando Discrete Wavelet Transform y varias características estadísticas como vectores de entrada al clasificador SVM, obtiene resultados de 52.1% HAHV, 49.1% HALV, 49.6%

LAHV y 48.3% LALV, un Accuracy general del 49,7 % utilizando los 32 canales del dataset. Zheng, utiliza los dataset DEAP y SEED para la clasificación de emociones en base a la métrica de precisión media (mAR). El autor obtiene resultados promedio en VA de 41,84% y 65,56% utilizando clasificadores de SVM y ANN respectivamente para el dataset DEAP. En el dataset SEED obtiene valores promedio de 81,91% en emociones positivas, neutras y negativas utilizando ANN como clasificador. Los vectores de entrada de los clasificadores son del dominio de la frecuencia, las características utilizadas son PSD y DE para ambos dataset [48].

En el presente trabajo realizamos el reconocimiento de emociones en base al modelo bidimensional valencia/arousal (VA) que se divide en cuatro grupos: alto arousal - alta valencia (HAHV), alto arousal - baja valencia (HALV), bajo arousal - baja valencia (LALV) y bajo arousal - alta valencia (LAHV). Utilizamos varias características en los diferentes dominios tiempo, frecuencia y tiempo - frecuencia. Las características, clasificadores y métricas de evaluación fueron seleccionadas acorde a la periodicidad de uso y resultados encontrados en la RSL. Se realizaron cuatro vectores de entrada a los clasificadores: 1) Vector con 21 características correspondiente al dominio del tiempo; 2) Vector con 6 características en el dominio de la frecuencia; 3) Vector con 2 características en dominio tiempo - frecuencia; 4) Vector con 29 características formado por el conjunto de todas las características seleccionadas en los diferentes dominios.

Luego de realizar varias pruebas, el mayor porcentaje de Accuracy en VA para el dataset DEAP es de 66.2% con el vector de características en el dominio del tiempo utilizando el clasificador k-NN y las técnicas de PCA y SMOTE. Además, encontramos que el vector de características en dominio de la frecuencia obtiene un 66.0% de Accuracy utilizando el clasificador SVM, este vector representa un menor costo computacional en comparación con el resto de características empleadas en este trabajo. El porcentaje obtenido está por encima de lo presentado en [53] y [70] que clasifican dos clases y de [57], [67] y [48] que clasifican cuatro clases.

En el dataset SEED obtuvimos en 67.4% de Accuracy con el clasificador SVM y el vector en dominio del tiempo, nuestro porcentaje está por debajo de la literatura, sin embargo, cabe mencionar que en nuestro trabajo utilizamos 32 canales de la señal EEG y los 45 registros con los datos a diferencia de otros autores que utilizan ciertos datos al azar y pocos canales para clasificar en su mayoría emociones positivas, negativas y neutras.

Existen múltiples métodos propuestos para la clasificación de emociones basada en EEG, pero tienen ciertas limitaciones, incluido el número de estados emocionales considerados. Generalmente los métodos que tratan con un mayor número de clases y número de participantes tienden a disminuir su rendimiento. Aunque hay ciertos métodos con un número limitado de participantes que han informado de mayor precisión (> 80%), la generalización de tales métodos necesita una consideración mucho más cuidadosa.

CAPÍTULO 5. CONCLUSIONES

Se comparó métodos de extracción de características en los diferentes dominios usando los datasets públicos SEED y DEAP mediante la creación de cuatro vectores de entrada a los clasificadores. Los vectores de entrada fueron creados en base a los métodos de extracción de características utilizados con mayor periodicidad y que ofrecen mejores resultados en la RSL para los dominios del tiempo, frecuencia y tiempo-frecuencia. Además, se creó un vector con el conjunto de características de los tres dominios.

Se identificó que los dominios para extracción de características utilizados con mayor periodicidad en los datasets públicos SEED y DEAP en clasificación de emociones corresponden a la combinación de tres dominios: el dominio del tiempo y tiempo-frecuencia (DT-DTF) con un 27%, seguido por los dominios del tiempo y la frecuencia (DT-DF), y el dominio tiempo – frecuencia (DTF) con un 20%.

Luego de realizar varias pruebas se obtuvo que los métodos de extracción de características en el dominio del tiempo y la frecuencia tienen mayores porcentajes de Accuracy con un 66,2% y 66.0% para el dataset DEAP utilizando los clasificadores k-NN y SVM respectivamente. Donde, los métodos del dominio de la frecuencia representan un menor costo computacional. En caso del dataset SEED el mayor porcentaje de Accuracy es de 67.4% que corresponde al vector con características en dominio del tiempo.

En base a los experimentos realizados en este trabajo, los métodos de extracción de características en dominio del tiempo y frecuencia presentan mejores resultados al ser incluidos en la configuración de vectores de entrada, logrando un mejor rendimiento de clasificadores en el reconocimiento de estados emocionales usando señales EEG captadas con dispositivos BCI. Con esto se demuestra que, los métodos de extracción de características en dominio del tiempo y frecuencia son óptimos para el reconocimiento de emociones que constituyen los cuatro cuadrantes del modelo VA.

El teorema No-Free-Lunch (NFL) menciona que no existe un algoritmo de aprendizaje universal, en tareas de clasificación, ningún algoritmo es mejor en promedio que los demás. Por tanto, en cada configuración específica de características es necesaria una calibración.

La creación de vectores de entrada a los clasificadores con un grupo de características seleccionadas en base a periodicidad y rendimiento en la literatura necesita de consideraciones mucho más cuidadosas ya que existe mucha correlación entre los datos.

La contribución de este trabajo, radica en estudiar el reconocimiento de estados emocionales definidos en los cuatro cuadrantes del modelo bidimensional (VA) categorizando las clases HAHV, HALV, LALV y LAHV mediante la exploración de un conjunto más amplio de métodos de extracción de características en el dominio del tiempo, en el dominio de la frecuencia y en dominio tiempo-frecuencia, que los realizados en otros trabajos de la RSL, para la obtención de vectores de entrada a los clasificadores SVM, k-NN y ANN determinando que los métodos de extracción de características en el dominio del tiempo y la frecuencia obtienen mejores porcentajes en la clasificación de estados emocionales en el modelo VA.

Finalmente, como trabajo futuro se propone el estudio de reconocimiento de estados emocionales definidos en el modelo tridimensional (VAD), es decir, considerar los ejes correspondientes a Valencia - Arousal - Dominancia para abarcar un reconocimiento más amplio de emociones específicas. Otra posibilidad es, abordar el enfoque de regresión en lugar del de clasificación, debido a que los valores de valencia y arousal son continuos y así predecir la emoción del usuario a través de la señal EEG.

REFERENCIAS BIBLIOGRÁFICAS

- [1] A. Bablani and R. Edla, "Survey on Brain-Computer Interface: An Emerging Computational Intelligence Paradigm," *ACM Comput. Surv.*, vol. 52, no. 1, 2019, doi: 10.1145/3297713.
- [2] S. M. Alarcão and M. J. Fonseca, "Emotions recognition using EEG signals: A survey," *IEEE Trans. Affect. Comput.*, vol. 10, no. 3, pp. 374–393, Jun. 2019, doi: 10.1109/TAFFC.2017.2714671.
- [3] I. Daly, "Affective Brain–Computer Interfacing and Methods for Affective State Detection," *Brain–Computer Interfaces Handb.*, pp. 147–164, Jun. 2018, doi: 10.1201/9781351231954-8.
- [4] X. Li, D. Song, P. Zhang, G. Yu, Y. Hou, and B. Hu, "Emotion recognition from multi-channel EEG data through Convolutional Recurrent Neural Network," *Proc. - 2016 IEEE Int. Conf. Bioinforma. Biomed. BIBM 2016*, pp. 352–359, Jan. 2017, doi: 10.1109/BIBM.2016.7822545.
- [5] V. Bajaj and R. B. Pachori, "Detection of Human Emotions Using Features Based on the Multiwavelet Transform of EEG Signals," *Intell. Syst. Ref. Libr.*, vol. 74, pp. 215–240, 2015, doi: 10.1007/978-3-319-10978-7_8.
- [6] K.-E. Ko, H.-C. Yang, and K.-B. Sim, "Emotion recognition using EEG signals with relative power values and Bayesian network," *Int. J. Control. Autom. Syst.* 2009 75, vol. 7, no. 5, pp. 865–870, Oct. 2009, doi: 10.1007/S12555-009-0521-0.
- [7] A. M. Bhatti, M. Majid, S. M. Anwar, and B. Khan, "Human emotion recognition and analysis in response to audio music using brain signals," *Comput. Human Behav.*, vol. 65, pp. 267–275, Dec. 2016, doi: 10.1016/J.CHB.2016.08.029.
- [8] R. J. Dolan, "Neuroscience and psychology: Emotion, cognition, and behavior," *Science (80-.)*, vol. 298, no. 5596, pp. 1191–1194, Nov. 2002, doi: 10.1126/SCIENCE.1076358.
- [9] P. Vandy and M. Nofz, "HAL's long, long run," *ACM SIGCAS Comput. Soc.*, vol. 29, no. 4, pp. 8–10, Dec. 1999, doi: 10.1145/572199.572202.
- [10] R. A. Ramadan and A. V. Vasilakos, "Brain computer interface: control signals review," *Neurocomputing*, vol. 223, pp. 26–44, Feb. 2017, doi: 10.1016/J.NEUCOM.2016.10.024.
- [11] J. Wang and M. Wang, "Review of the emotional feature extraction and classification using EEG signals," *Cogn. Robot.*, vol. 1, pp. 29–40, Jan. 2021, doi: 10.1016/J.COGR.2021.04.001.

- [12] G. Chanel, J. Kronegg, D. Grandjean, and T. Pun, "Emotion Assessment: Arousal Evaluation Using EEG's and Peripheral Physiological Signals," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 4105 LNCS, pp. 530–537, 2006, doi: 10.1007/11848035_70.
- [13] D. Acharya, A. Billimoria, N. Srivastava, S. Goel, and A. Bhardwaj, "Emotion recognition using fourier transform and genetic programming," *Appl. Acoust.*, vol. 164, p. 107260, Jul. 2020, doi: 10.1016/J.APACOUST.2020.107260.
- [14] W. Zheng, "Multichannel EEG-Based Emotion Recognition via Group Sparse Canonical Correlation Analysis," *IEEE Trans. Cogn. Dev. Syst.*, vol. 9, no. 3, pp. 281–290, Sep. 2017, doi: 10.1109/TCDS.2016.2587290.
- [15] R. Nawaz, K. H. Cheah, H. Nisar, and V. V. Yap, "Comparison of different feature extraction methods for EEG-based emotion recognition," *Biocybern. Biomed. Eng.*, vol. 40, no. 3, pp. 910–926, Jul. 2020, doi: 10.1016/J.BBE.2020.04.005.
- [16] P. Li *et al.*, "EEG Based Emotion Recognition by Combining Functional Connectivity Network and Local Activations," *IEEE Trans. Biomed. Eng.*, vol. 66, no. 10, pp. 2869–2881, Oct. 2019, doi: 10.1109/TBME.2019.2897651.
- [17] S. Agarwal, A. Rani, V. Singh, and A. P. Mittal, "EEG signal enhancement using cascaded S-Golay filter," *Biomed. Signal Process. Control*, vol. 36, pp. 194–204, Jul. 2017, doi: 10.1016/J.BSPC.2017.04.004.
- [18] X. W. Wang, D. Nie, and B. L. Lu, "EEG-based emotion recognition using frequency domain features and support vector machines," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 7062 LNCS, no. PART 1, pp. 734–743, 2011, doi: 10.1007/978-3-642-24955-6_87.
- [19] S. Koelstra *et al.*, "DEAP: A Database for Emotion Analysis using Physiological Signals," 2012. Accessed: Jun. 11, 2020. [Online]. Available: <http://www.eecs.qmul.ac.uk/mmv/datasets/deap/>.
- [20] W. L. Zheng, R. Santana, and B.-L. Lu, "SEED: Comparison of Classification Methods for EEG-based Emotion Recognition," in *IFMBE Proceedings*, vol. 51, Springer Verlag, 2015, pp. 1184–1187.
- [21] M. A. Lebedev and M. A. L. Nicolelis, "Brain-machine interfaces: past, present and future," *Trends Neurosci.*, vol. 29, no. 9, pp. 536–546, Sep. 2006, doi: 10.1016/J.TINS.2006.07.004.
- [22] L. F. Nicolas-Alonso and J. Gomez-Gil, "Brain Computer Interfaces, a Review," *Sensors 2012, Vol. 12, Pages 1211-1279*, vol. 12, no. 2, pp. 1211–1279, Jan. 2012, doi: 10.3390/S120201211.
- [23] T. O. Zander, C. Kothe, S. Welke, and M. Roetting, "Utilizing secondary input from

- passive brain-computer interfaces for enhancing human-machine interaction,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 5638 LNAI, pp. 759–771, 2009, doi: 10.1007/978-3-642-02812-0_86.
- [24] D. Steyrl, R. J. Kobler, and G. R. Müller-Putz, “On Similarities and Differences of Invasive and Non-Invasive Electrical Brain Signals in Brain-Computer Interfacing,” *J. Biomed. Sci. Eng.*, vol. 9, pp. 393–398, 2016, doi: 10.4236/jbise.2016.98034.
- [25] A. T. Chan, J. C. Quiroz, S. Dascalu, and F. C. Harris, “An Overview of Brain Computer Interfaces.”
- [26] T. O. Zander, C. Kothe, S. Jatzev, and M. Gaertner, “Enhancing Human-Computer Interaction with Input from Active and Passive Brain-Computer Interfaces,” pp. 181–199, 2010, doi: 10.1007/978-1-84996-272-8_11.
- [27] V. Jurcak, D. Tsuzuki, and I. Dan, “10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems,” *Neuroimage*, vol. 34, no. 4, pp. 1600–1611, Feb. 2007, doi: 10.1016/J.NEUROIMAGE.2006.09.024.
- [28] A. Khosla, P. Khandnor, and T. Chand, “A comparative analysis of signal processing and classification methods for different applications based on EEG signals,” *Biocybern. Biomed. Eng.*, vol. 40, no. 2, pp. 649–690, Apr. 2020, doi: 10.1016/J.BBE.2020.02.002.
- [29] R. W. Picard and J. Klein, “Computers that recognise and respond to user emotion: Theoretical and practical implications,” *Interact. Comput.*, vol. 14, no. 2, pp. 141–169, 2002, doi: 10.1016/S0953-5438(01)00055-8.
- [30] C. A. Frantzidis, C. Bratsas, C. L. Papadelis, E. Konstantinidis, C. Pappas, and P. D. Bamidis, “Toward emotion aware computing: An integrated approach using multichannel neurophysiological recordings and affective visual stimuli,” *IEEE Trans. Inf. Technol. Biomed.*, vol. 14, no. 3, pp. 589–597, May 2010, doi: 10.1109/TITB.2010.2041553.
- [31] R. W. Picard, “Affective computing: Challenges,” *Int. J. Hum. Comput. Stud.*, vol. 59, no. 1–2, pp. 55–64, 2003, doi: 10.1016/S1071-5819(03)00052-1.
- [32] H. Gunes, B. Schuller, M. Pantic, and R. Cowie, “Emotion representation, analysis and synthesis in continuous space: A survey,” *2011 IEEE Int. Conf. Autom. Face Gesture Recognit. Work. FG 2011*, pp. 827–834, 2011, doi: 10.1109/FG.2011.5771357.
- [33] D. Das Chakladar and S. Chakraborty, “EEG based emotion classification using ‘Correlation Based Subset Selection,’” *Biol. Inspired Cogn. Archit.*, vol. 24, pp. 98–106, Apr. 2018, doi: 10.1016/J.BICA.2018.04.012.

- [34] M. Zangeneh Soroush, K. Maghooli, S. K. Setarehdan, and A. M. Nasrabadi, "Emotion recognition using EEG phase space dynamics and Poincare intersections," *Biomed. Signal Process. Control*, vol. 59, p. 101918, May 2020, doi: 10.1016/J.BSPC.2020.101918.
- [35] X. Wu *et al.*, "Emotion models for textual emotion classification You may also like Investigating EEG-based functional connectivity patterns for multimodal emotion recognition Spatiotemporal dynamics of working memory under the influence of emotions based on EEG Data augmentation for enhancing EEG-based emotion recognition with deep generative models Emotion models for textual emotion classification," doi: 10.1088/1742-6596/772/1/012063.
- [36] R. Plutchik, "The Nature of Emotions," 2014. https://www.academia.edu/43620307/The_Nature_of_Emotions_Plutchik_2001_ (accessed Mar. 21, 2022).
- [37] A. S. Cowen and D. Keltner, "Self-report captures 27 distinct categories of emotion bridged by continuous gradients," *Proc. Natl. Acad. Sci. U. S. A.*, vol. 114, no. 38, pp. E7900–E7909, Sep. 2017, doi: 10.1073/PNAS.1702247114.
- [38] M. Abbasi, A. B.-S. C. on Information, and undefined 2019, "Summarizing emotions from text using Plutchik's wheel of emotions," *atlantis-press.com*, 2019, Accessed: Mar. 21, 2022. [Online]. Available: <https://www.atlantis-press.com/article/125908998.pdf>.
- [39] I. B. Mauss and M. D. Robinson, "Measures of emotion: A review," *Cogn. Emot.*, vol. 23, no. 2, pp. 209–237, 2009, doi: 10.1080/02699930802204677.
- [40] J. A. Russell and G. Pratt, "A description of the affective quality attributed to environments.," *J. Pers. Soc. Psychol.*, vol. 38, no. 2, pp. 311–322, 1980, doi: 10.1037/0022-3514.38.2.311.
- [41] H. Ruiz-Martin, "La autorregulación del aprendizaje, en ¿Cómo aprendemos? Una aproximación científica al aprendizaje y la enseñanza," 2020.
- [42] J. M. Mestre, "La Regulación de Emociones: Una vía para la Adaptación Symposium 'Emociones, Bienestar y Salud: Un enfoque desde la psicología positiva.'" View project European Network on Individualized Psychotherapy Treatment of Young People with Mental Disorders (TREATme) View project," 2012, Accessed: Mar. 22, 2022. [Online]. Available: <https://www.researchgate.net/publication/309428224>.
- [43] H. Lövhelm, "A new three-dimensional model for emotions and monoamine neurotransmitters," *Med. Hypotheses*, vol. 78, no. 2, pp. 341–348, Feb. 2012, doi: 10.1016/J.MEHY.2011.11.016.
- [44] M. M. Bradley and P. J. Lang, "Measuring emotion: The self-assessment manikin

- and the semantic differential,” *J. Behav. Ther. Exp. Psychiatry*, vol. 25, no. 1, pp. 49–59, 1994, doi: 10.1016/0005-7916(94)90063-9.
- [45] J. Redondo, I. Fraga, M. Comesaña, and M. Perea, “Estudio normativo del valor afectivo de 478 palabras españolas,” vol. 26, pp. 317–326, 2005.
- [46] J. M. Chen, P. C. Chang, and K. W. Liang, “Speech Emotion Recognition Based on Joint Self-Assessment Manikins and Emotion Labels,” *Proc. - 2019 IEEE Int. Symp. Multimedia, ISM 2019*, pp. 327–330, Dec. 2019, doi: 10.1109/ISM46123.2019.00073.
- [47] B. Kitchenham, O. Pearl Brereton, D. Budgen, M. Turner, J. Bailey, and S. Linkman, “Systematic literature reviews in software engineering – A systematic literature review,” *Inf. Softw. Technol.*, vol. 51, no. 1, pp. 7–15, Jan. 2009, doi: 10.1016/J.INFSOF.2008.09.009.
- [48] W. L. Zheng, J. Y. Zhu, and B. L. Lu, “Identifying stable patterns over time for emotion recognition from eeg,” *IEEE Trans. Affect. Comput.*, vol. 10, no. 3, pp. 417–429, 2019, doi: 10.1109/TAFFC.2017.2712143.
- [49] D. Garg and G. K. Verma, “Emotion Recognition in Valence-Arousal Space from Multi-channel EEG data and Wavelet based Deep Learning Framework,” *Procedia Comput. Sci.*, vol. 171, pp. 857–867, Jan. 2020, doi: 10.1016/J.PROCS.2020.04.093.
- [50] P. Ozel, A. Akan, and B. Yilmaz, “Synchrosqueezing transform based feature extraction from EEG signals for emotional state prediction,” *Biomed. Signal Process. Control*, vol. 52, pp. 152–161, Jul. 2019, doi: 10.1016/J.BSPC.2019.04.023.
- [51] M. Asadur Rahman, M. Faisal Hossain, M. Hossain, and R. Ahmmed, “Employing PCA and t-statistical approach for feature extraction and classification of emotion from multichannel EEG signal,” *Egypt. Informatics J.*, vol. 21, no. 1, pp. 23–35, Mar. 2020, doi: 10.1016/J.EIJ.2019.10.002.
- [52] F. Wang *et al.*, “Emotion recognition with convolutional neural network and EEG-based EFDMs,” *Neuropsychologia*, vol. 146, p. 107506, Sep. 2020, doi: 10.1016/J.NEUROPSYCHOLOGIA.2020.107506.
- [53] Z. Yin, L. Liu, J. Chen, B. Zhao, and Y. Wang, “Locally robust EEG feature selection for individual-independent emotion recognition,” *Expert Syst. Appl.*, vol. 162, p. 113768, Dec. 2020, doi: 10.1016/J.ESWA.2020.113768.
- [54] J. Atkinson and D. Campos, “Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers,” *Expert Syst. Appl.*, vol. 47, pp. 35–41, Apr. 2016, doi: 10.1016/J.ESWA.2015.10.049.
- [55] Y. Zhang, X. Ji, and S. Zhang, “An approach to EEG-based emotion recognition using combined feature extraction method,” *Neurosci. Lett.*, vol. 633, pp. 152–157, Oct.

- 2016, doi: 10.1016/J.NEULET.2016.09.037.
- [56] Q. Gao, C. han Wang, Z. Wang, X. lin Song, E. zeng Dong, and Y. Song, "EEG based emotion recognition using fusion feature extraction method," *Multimed. Tools Appl.*, vol. 79, no. 37–38, pp. 27057–27074, Oct. 2020, doi: 10.1007/S11042-020-09354-Y.
- [57] M. Khateeb, S. M. Anwar, and M. Alnowami, "Multi-Domain Feature Fusion for Emotion Classification Using DEAP Dataset," *IEEE Access*, vol. 9, pp. 12134–12142, 2021, doi: 10.1109/ACCESS.2021.3051281.
- [58] J. Li, S. Qiu, C. Du, Y. Wang, and H. He, "Domain adaptation for eeg emotion recognition based on latent representation similarity," *IEEE Trans. Cogn. Dev. Syst.*, vol. 12, no. 2, pp. 344–353, Jun. 2020, doi: 10.1109/TCDS.2019.2949306.
- [59] V. Gupta, M. Chopda, R. P.-I. S. Journal, and undefined 2018, "Cross-subject emotion recognition using flexible analytic wavelet transform from EEG signals," *ieeexplore.ieee.org*, Accessed: Oct. 11, 2021. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/8546787/>.
- [60] Y. Luo *et al.*, "EEG-Based Emotion Classification Using Spiking Neural Networks," *IEEE Access*, vol. 8, pp. 46007–46016, 2020, doi: 10.1109/ACCESS.2020.2978163.
- [61] A. M. Ismael, Ö. F. Alçin, K. H. Abdalla, and A. Şengür, "Two-stepped majority voting for efficient EEG-based emotion classification," *Brain Informatics*, vol. 7, no. 1, Dec. 2020, doi: 10.1186/S40708-020-00111-3.
- [62] M. S. Özerdem and H. Polat, "Emotion recognition based on EEG features in movie clips with channel selection," *Brain Informatics*, vol. 4, no. 4, pp. 241–252, Dec. 2017, doi: 10.1007/S40708-017-0069-3.
- [63] Z. Mohammadi, J. Frounchi, and M. Amiri, "Wavelet-based emotion recognition system using EEG signal," *Neural Comput. Appl.*, vol. 28, no. 8, pp. 1985–1990, Aug. 2017, doi: 10.1007/s00521-015-2149-8.
- [64] G. K. Verma and U. S. Tiwary, "Affect representation and recognition in 3D continuous valence–arousal–dominance space," *Multimed. Tools Appl.*, vol. 76, no. 2, Jan. 2017, doi: 10.1007/S11042-015-3119-Y.
- [65] M. K. Ahirwal and M. R. Kose, "Audio-visual stimulation based emotion classification by correlated EEG channels," *Health Technol. (Berl)*., vol. 10, no. 1, pp. 7–23, Jan. 2020, doi: 10.1007/S12553-019-00394-5.
- [66] E. S. Pane, A. D. Wibawa, and M. H. Purnomo, "Improving the accuracy of EEG emotion recognition by combining valence lateralization and ensemble learning with tuning parameters," *Cogn. Process.*, vol. 20, no. 4, pp. 405–417, Nov. 2019, doi: 10.1007/S10339-019-00924-Z.

- [67] M. Zubair and C. Yoon, "EEG based classification of human emotions using discrete wavelet transform," *Lect. Notes Electr. Eng.*, vol. 450, pp. 21–28, 2017, doi: 10.1007/978-981-10-6454-8_3.
- [68] P. Chen and J. Zhang, "Performance comparison of machine learning algorithms for EEG-signal-based emotion recognition," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 10613 LNCS, pp. 208–216, 2017, doi: 10.1007/978-3-319-68600-4_25.
- [69] L. Piho and T. Tjahjadi, "A Mutual Information Based Adaptive Windowing of Informative EEG for Emotion Recognition," *IEEE Trans. Affect. Comput.*, vol. 11, no. 4, pp. 722–735, Oct. 2020, doi: 10.1109/TAFFC.2018.2840973.
- [70] P. Arnau-González, M. Arevalillo-Herráez, and N. Ramzan, "Fusing highly dimensional energy and connectivity features to identify affective states from EEG signals," *Neurocomputing*, vol. 244, pp. 81–89, Jun. 2017, doi: 10.1016/J.NEUCOM.2017.03.027.
- [71] R. Sharma, R. B. Pachori, and P. Sircar, "Automated emotion recognition based on higher order statistics and deep learning algorithm," *Biomed. Signal Process. Control*, vol. 58, Apr. 2020, doi: 10.1016/J.BSPC.2020.101867.
- [72] M. Ali, A. H. Mosa, F. Al Machot, and K. Kyamakya, "EEG-based emotion recognition approach for e-healthcare applications," *Ubiquitous Futur. Networks, ICUFN*, vol. 2016-August, pp. 946–950, Aug. 2016, doi: 10.1109/ICUFN.2016.7536936.
- [73] M. L. R. Menezes *et al.*, "Towards emotion recognition for virtual environments: an evaluation of eeg features on benchmark dataset," *Pers. Ubiquitous Comput.*, vol. 21, no. 6, pp. 1003–1013, Dec. 2017, doi: 10.1007/S00779-017-1072-7.
- [74] Z. Guendil, Z. Lachiri, and C. Maaoui, "Computational framework for emotional VAD prediction using regularized Extreme Learning Machine," *Int. J. Multimed. Inf. Retr.*, vol. 6, no. 3, pp. 251–261, Sep. 2017, doi: 10.1007/S13735-017-0128-9.
- [75] M. Kumar Mukul, F. Matsuno, and M. Kumar MUKUL, "Feature Extraction from Subband Brain Signals and Its Classification," *SICE J. Control. Meas. Syst. Integr.*, vol. 4, no. 5, pp. 332–340, 2011, doi: 10.9746/jcmsi.4.332.
- [76] T. Kurita, "Principal Component Analysis (PCA)," *Comput. Vis.*, pp. 1–4, 2020, doi: 10.1007/978-3-030-03243-2_649-1.
- [77] V. Doma and M. Pirouz, "A comparative analysis of machine learning methods for emotion recognition using EEG and peripheral physiological signals," *J. Big Data*, vol. 7, no. 1, Dec. 2020, doi: 10.1186/S40537-020-00289-7.
- [78] O. Santa-Cruz, L. Del Mar Ramírez, and F. Trujillo-Romero, "Técnicas de aprendizaje automático aplicadas a electroencefalogramas."

- [79] S. Sun and R. Huang, "An adaptive k-nearest neighbor algorithm," *Proc. - 2010 7th Int. Conf. Fuzzy Syst. Knowl. Discov. FSKD 2010*, vol. 1, pp. 91–94, 2010, doi: 10.1109/FSKD.2010.5569740.
- [80] S. A. Dudani, "The Distance-Weighted k-Nearest-Neighbor Rule," *IEEE Trans. Syst. Man Cybern.*, vol. SMC-6, no. 4, pp. 325–327, 1976, doi: 10.1109/TSMC.1976.5408784.
- [81] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf. Process. Manag.*, vol. 45, no. 4, pp. 427–437, Jul. 2009, doi: 10.1016/J.IPM.2009.03.002.
- [82] A. Raden, "Imbalanced Classification in Python: SMOTE-Tomek Links Method," 2021. <https://towardsdatascience.com/imbalanced-classification-in-python-smote-tomek-links-method-6e48dfe69bbc> (accessed Jul. 03, 2022).
- [83] S. E. Moon, C. J. Chen, C. J. Hsieh, J. L. Wang, and J. S. Lee, "Emotional EEG classification using connectivity features and convolutional neural networks," *Neural Networks*, vol. 132, pp. 96–107, Dec. 2020, doi: 10.1016/J.NEUNET.2020.08.009.

ANEXOS

- A. Código extracción de características
- B. Código de balanceo de datos
- C. Código de implementación de PCA
- D. Código de clasificación (4 experimentos con distinto vector de entrada)

Los anexos A, B, C y D los pueden encontrar en el siguiente enlace

<https://github.com/mayra8503/emotionRecognitionEEG>

- E. Dataset DEAP

En este enlace está disponible el dataset DEAP de los datos pre-procesados con extensión .dat, con un peso de 2.72 GB.

<https://mega.nz/folder/FnwFyBhJ#T-ys1xkVO685wCB1Zt-qvQ/file/Avhh1CbC>

- F. Dataset SEED

En el siguiente enlace está disponible el paquete del dataset SEED IV de los datos pre-procesados con extensión .mat, con un peso de 6.88 GB.

<https://mega.nz/folder/FnwFyBhJ#T-ys1xkVO685wCB1Zt-qvQ/file/M6AE1YpK>