



Institución Universitaria

**Metodología para la identificación biométrica a partir de señales
EEG en múltiples estados emocionales**

Carolina María Duque Mejía

Instituto Tecnológico Metropolitano

Facultad de Ingenierías

Medellín, Colombia

2024

**Metodología para la identificación biométrica a partir de señales
EEG en múltiples estados emocionales**

Carolina María Duque Mejía

Tesis presentada como requisito parcial para optar al título de:

Magister en Automatización y Control Industrial

Directores:

Ph.D. Miguel Alberto Becerra Botero

MSc. Andrés Eduardo Castro Ospina

Línea de investigación:

Máquinas Inteligentes y Reconocimiento de Patrones

Instituto Tecnológico Metropolitano

Facultad de Ingenierías

Medellín, Colombia

2024

Agradecimientos

Agradezco profundamente a mi familia por su apoyo incondicional. Mi especial reconocimiento a mi asesor, Miguel Alberto Becerra, por guiarme en este camino, compartir su conocimiento y brindarme la confianza necesaria para el desarrollo de esta tesis. También agradezco a mi tutor, Andrés Castro, por su valioso acompañamiento a lo largo de este trabajo. Quiero expresar mi gratitud a mis compañeros de universidad, quienes me han apoyado, motivado y han sido amigos invaluable. A los profesores que me brindaron la oportunidad de aprender de sus clases, les agradezco sinceramente por todas sus enseñanzas.

Resumen

La necesidad de garantizar la seguridad y la autenticación precisa en sistemas automatizados ha impulsado la investigación en técnicas avanzadas de identificación biométrica que ha demostrado ser una aproximación efectiva para la autenticación personal, aprovechando características únicas de los individuos haciendo uso de señales electroencefalografía (EEG). Sin embargo, se ha observado que las emociones pueden impactar significativamente las señales, lo que a su vez puede afectar la precisión de la identificación. Esta investigación se centra en comprender cómo diferentes estados emocionales pueden alterar las características de las señales EEG y, por lo tanto, influir en la confiabilidad de los sistemas de identificación. Por lo cual se propone un sistema de identificación biométrica a partir de señales EEG en múltiples estados emocionales con el fin de mejorar la seguridad y la exactitud de los modelos de predicción.

Para esto se utilizaron 4 diferentes bases de datos SEED, LUMED, MAHNOB y DEAP; se realizó extracción de características, fusión de datos, y por último se entrenaron diferentes modelos de clasificación incluyendo máquinas de soporte vectorial (SVM), k-vecinos más cercanos (k-NN), redes neuronales, bosques aleatorios (Random Forest) y regresión lineal. Estos métodos son aplicados para modelar las complejas relaciones entre las señales EEG y los estados emocionales, mejorando así la capacidad de los sistemas para adaptarse a las variaciones emocionales de los usuarios.

Después del análisis, se obtuvo que la fusión de clasificadores con la base de datos DEAP obtuvo una exactitud máxima de 98.35% lo que demuestra que la metodología planteada puede ser utilizada y genera confiabilidad en los diferentes estados emocionales.

Palabras Clave: Identificación Biométrica, Reconocimiento de Emociones, Aprendizaje de Máquinas, optimización

Abstract

The need to ensure security and accurate authentication in automated systems has driven research into advanced biometric identification techniques, proving to be an effective approach for personal authentication by leveraging unique individual characteristics using electroencephalographic (EEG) signals. However, it has been observed that emotions can significantly impact these signals, consequently affecting identification accuracy. This research focuses on understanding how different emotional states can alter EEG signal characteristics, thereby influencing the reliability of identification systems. Therefore, a biometric identification system based on EEG signals in multiple emotional states is proposed to enhance the security and accuracy of prediction models.

Four different databases, namely SEED, LUMED, MAHNOB, and DEAP, were utilized for feature extraction, data fusion, and the training of various classification models, including Support Vector Machines (SVM), k-Nearest Neighbors (k-NN), neural networks, Random Forests, and linear regression. These methods are applied to model the intricate relationships between EEG signals and emotional states, thereby enhancing the systems' ability to adapt to users' emotional variations.

After the analysis, it was found that the fusion of classifiers with the DEAP database achieved a maximum accuracy of 98.35%, demonstrating that the proposed methodology can be used and generates reliability in the different emotional states.

Keywords: biometric identification, emotion recognition, machine learning, optimization

Tabla de contenidos

Agradecimiento	III
Resumen	IV
Abstract	V
Abreviaturas y acrónimos	VIII
1. Introducción.....	1
1.1 Descripción del problema	3
1.2 Hipótesis.....	5
1.3 Objetivos	5
1.3.1 General	5
1.3.2 Específicos	5
2. Estado del Arte y Marco Teórico	5
2.1 Identificación biométrica	6
2.2 Las señales EEG aplicadas a la Biometría	7
2.2.1 Historia de la biometría.....	7
2.2.2 Avances tecnológicos en la biometría.....	8
2.2.3 Señales EEG	9
2.2.4 Protocolo 10-20 (ubicación espacial de los electrodos).....	11
2.2.5 Tipos de ondas cerebrales.....	12
2.2.6 Biometría en señales EEG.....	13
2.3 Reconocimiento de emociones	14
2.4 Clasificación de las emociones	16
3. Marco teórico	18
3.1 Preprocesamiento	18
3.2 Técnicas de preprocesamiento de señales EEG	19
3.3 Extracción de características de señales EEG.....	20
3.3.1 Transformada Wavelet.....	22
3.3.2 Entropía de Shannon (H)	23

3.3.3	Entropía de Rényi	23
3.3.4	Entropía Difusa	24
3.3.5	Entropía Muestral.....	24
3.4	Selección de características.....	25
3.4.1	RelieF	25
3.5	Clasificación en machine learning	26
3.6	Métodos de clasificación para biometría y emociones.....	26
3.6.1	Máquinas de vectores de soporte.....	30
3.6.2	K vecinos más cercanos.....	31
3.6.3	Redes neuronales	32
3.6.4	Árboles de decisión	34
3.6.5	Regresión lineal	35
3.7	Fusión de datos	36
3.7.1	Stacking	36
4	Materiales y Métodos	37
4.1	Bases de datos	38
4.1.1	DEAP	38
4.1.2	MAHNOB	38
4.1.3	SEED.....	39
4.1.4	LUMED-2.....	39
4.2	Preprocesamiento	39
4.3	Extracción de Características	40
4.4	Selección de Características	42
4.5	Identificación de emociones	43
4.6	Identificación Biométrica:	43
4.7	Identificación Biométrica + Emociones:.....	44
5	Resultados y Discusiones	45
5.1	Resultados	45
5.2	Discusión	49
6	Conclusiones	50
7	Referencias	51

Índice de tablas

Tabla 2-1: Línea del tiempo de la identificación biométrica, datos obtenidos de (GÓMEZ, 2020; Maersa, 2010; Mayhew, 2018; Zen, 2013)	8
Tabla 2-2: Dispositivos de captura de datos	9
Tabla 3-1: Métodos de extracción de características y clasificación biométrica.....	27
Tabla 3-2: Métodos de extracción de características y clasificación de emociones, tomado de (BENÍTEZ ALDÁS, 2018; Li et al., 2023; Sovatzidi & Iakovidis, 2023).....	29
Tabla 4-1: Características obtenidas de ReliefF con pesos	43
Tabla 5-1: Características relevantes obtenidas con el algoritmo Relief F en orden de relevancia .	45
Tabla 5-2: Resultados promedio de precisión de los modelos de predicción de emociones.....	45
Tabla 5-3: Resultados promedio de precisión de los modelos de clasificación para la identificación biométrica sin considerar las emociones	47
Tabla 5-4: Resultados promedio de precisión de los modelos de clasificación para la identificación biométrica considerando las emociones	48
Tabla 5-5: Promedio de exactitud de modelos de clasificación.....	48

Índice de ilustraciones

Figura 2-1: Partes del encéfalo	10
Figura 2-2: Representación de electroencefalogramas, creada por Dalle.....	11
Figura 2-3: Relación entre hemisferios y electrodos, tomado de (Bitbrain, 2020).....	12
Figura 2-4: Representación de las ondas EEG (Suhaimi et al., 2020).....	13
Figura 2-5: Representación de las emociones teniendo en cuenta excitación y valencia.....	17
Figura 3-1: Representación de los pasos de preprocesamiento de señales EEG.....	19
Figura 3-2: Diagrama del proceso de extracción de características	22
Figura 3-3: Ilustración de SVM creado en Matlab	30
Figura 3-4: Ilustración de K-NN tomada de (Atallah et al., 2019)	31
Figura 3-5: Interpretación de un modelo de red neuronal	33
Figura 3-6: Interpretación de un árbol de decisión tomado de (Khan et al., 2021)	35
Figura 3-7: Representación de regresión lineal	35
Figura 4-1: Metodología propuesta	38
Figura 4-2: Diagrama de flujo de las etapas de caracterización	41
Figura 5-1: Promedio de exactitud de los diferentes modelos de machine learning	49

Abreviaturas y acrónimos

EEG	Electroencefalograma
EMG	Electromiograma
ECG	Electrocardiograma
SVM	Máquina de vectores de soporte
SVM-RBF	máquina de vectores de soporte con kernel de base radial
K-NN	K-Nearest Neighbors
MOBCS-K-NN	K-Nearest Neighbors multiobjetivo
CNN	Convolutional Neural Network
LSTM	Long Short Term Memory
GRU	Gated Recurrent Unit
DWT	Transformada discreta de wavelet
PSD	Power Spectral Density
LDA	Linear Discriminant Analysis
BCI	Brain-Computer Interface
ESVM	Ensemble Support Vector Machine
RNN	Redes neuronales recurrentes
FAR	Tasa de aceptación falsa
FRR	Tasa de falso rechazo
DNN	Redes neuronales de aprendizaje profundo
PCA	Análisis de componentes principales
SNC	Sistema nervioso central
fMRI	Resonancia magnética funcional
ICA	Análisis de Componentes Independientes
AR	Modelos autorregresivos
FFT	Transformada rápida de Fourier
STFT	Transformada de Fourier en tiempo corto
PSD	Densidad espectral de Potencia
HHT	Transformada de Hilbert-Huang
CSP	Common Spacial Patterns

TDCSP	Time dependent Common Spatial Patterns
RNN	Recurrent Neural Network
FCM	Fuzzy C Means
FKM	Fuzzy K- Means
HOSA	Higher order Spectral Analysis
ANN	Artificial Neural Networks
QDA	Quadratic discriminant analysis
PLV	Valor de bloqueo de Fase
RSPWVD	Smoothed pseudo-Wigner–Ville distribution}
PSD	Power Spectral Density
NB	Naïve Bayes
RBF	Función de base radial
RNA	Red Neuronal Artificial
ReLU	Unidad Lineal Rectificada
MSE	Error Cuadrático Medio
RF	Random Forest
EOG	Electrooculograma
GSR	Galvanic skin response
BVP	Presión de volumen en sangre
FBSE	Fourier-Bessel series expansion-based
MVMD	Multivariate variational mode decomposition
DL	Deep learning
MSGCN	Multi-stream GCN
FC	Functional connectivity
CAR	Common average reference
FIR	Finite Impulse Response
ASR	Artifact Subspace Reconstruction

1. Introducción

La identificación biométrica y el reconocimiento de emociones son campos de investigación en rápida evolución que juegan un papel crucial en el desarrollo de sistemas de seguridad e interfaces hombre-máquina avanzadas. Tradicionalmente, los métodos de identificación humana han dependido de contraseñas, tarjetas de acceso y pines, los cuales, aunque ampliamente utilizados, presentan vulnerabilidades significativas, incluyendo el riesgo de ser robados, perdidos u olvidados.

Frente a estos retos, la identificación biométrica emerge como una solución prometedora, aprovechando características físicas o señales fisiológicas únicas para cada individuo, como la huella dactilar, el iris, el rostro, la voz, y señales como electroencefalograma (EEG), electromiograma (EMG), electrocardiograma (ECG), entre otros. Estos métodos biométricos no solo ofrecen una alternativa más segura, sino que también introducen nuevos desafíos relacionados con la precisión, la facilidad de adquisición y la robustez frente a intentos de suplantación (Zhong, Wenxiaoa, b;An, Xingweia;Di, Yanga;Zhang, Lixina, b;Ming, Donga, 2021).

La historia de los avances en identificación biométrica muestra una evolución desde métodos simples hasta soluciones altamente sofisticadas. Inicialmente, los métodos se centraban en características físicas estáticas, pero recientemente, se ha explorado el potencial de las señales EEG para ofrecer soluciones más seguras y personalizadas. Estas señales son especialmente prometedoras debido a su dificultad para ser duplicadas o manipuladas, lo que las hace ideales para aplicaciones de seguridad crítica.

Adicionalmente, el reconocimiento de emociones mediante señales biométricas, como los (EEG), ha ganado interés debido a su potencial para crear sistemas de identificación más sofisticados y personalizados, adicionalmente estas señales cumplen con las condiciones de universalidad, singularidad, permanencia, medibilidad y rendimiento (Belhadj, 2017). Las señales EEG tienen gran potencial para discernir entre individuos, y se han estudiado con el objetivo de incrementar la seguridad de los sistemas biométricos. Sin embargo, este enfoque enfrenta desafíos únicos, incluyendo la variabilidad de las señales debido a estados emocionales fluctuantes, enfermedades y otros factores individuales que pueden afectar la precisión del sistema.

Una de las señales que han venido tomando mucha fuerza en sistemas biométricos son los EEG los cuales se generan por la actividad eléctrica del cerebro y son utilizados para identificar patologías como tumores cerebrales, disfunciones cerebrales, trastornos del sueño, entre otros. En (Alyasseri et al., 2022) fue propuesto un sistema biométrico a partir de señales EEG en el cual se formula un problema de optimización binaria para la selección de los canales, se implementó una máquina de vectores de soporte (SVM) con kernel de base radial (SVM-RBF) usando características basadas en coeficientes autorregresivos; el método propuesto obtuvo una precisión del 94.13% usando 23 sensores con 5 coeficientes autorregresivos. En (Abdi Alkareem Alyasseri et al., 2022) se presenta un novedoso método de selección de canales EEG, versión binaria K-Nearest Neighbors (K-NN) multiobjetivo (MOBCS-K-NN), obteniendo una precisión del 93.86% usando 24 sensores y coeficientes autorregresivos AR20. En (Radwan S.H; El-Telbany; Arafa W.; Ali Rasha, 2022)

propusieron un método de identificación biométrica con redes neuronales profundas de extremo a extremo para la tarea de clasificación, se aplicaron 3 modelos discriminativos de aprendizaje profundo: Convolutional Neural Network (CNN), Long Short Term Memory (LSTM) y Gated Recurrent Unit (GRU), los resultados mostraron que la precisión de CNN, LSTM y GRU fueron de 96.17%, 97.83% y 96.53%, respectivamente. En (Hendrawan et al., 2021) describen un sistema biométrico a partir de un solo canal de EEG, las señales fueron segmentadas con una longitud de 5 segundos, y se extrajo la banda Alfa por medio de la transformada discreta de wavelet (DWT), se aplicó Power Spectral Density (PSD), Linear Discriminant Analysis (LDA) y SVM para la clasificación, el método obtuvo un rendimiento del 86% de exactitud usando LDA. En (Alsumari et al., 2023) implementaron 2 canales de EEG con una ventana temporal de 5 segundos, se aplicó CNN obteniendo una tasa de acierto del 99%.

Los sistemas biométricos a partir de señales EEG han demostrado buen rendimiento en la identificación, pero aún es un tema abierto de investigación debido a que estas señales pueden ser afectadas por las emociones, enfermedades entre otros. Lo anterior genera una variación en las señales de referencia que son usadas para el entrenamiento de los sistemas, llevando con ello a disminuir el rendimiento. Particularmente para la identificación de emociones, se han realizado múltiples estudios usando señales EEG (Kumar & Kumar, 2021). En (Sakalle A., Tomar P.a., 2021) propusieron un sistema de ondas cerebrales portable para el reconocimiento de emociones positivas, negativas y neutrales, usando las bases de datos DEAP y SEED las cuales contienen señales EEG, el mejor rendimiento se obtuvo usando LSTM, logrando una precisión del 94.12%. En (Galvão F., Alarcão S.M., 2021) diseñan un modelo de aprendizaje de máquinas, usando un modelo de regresión K-NN con distancia Manhattan, características de las bandas Alfa, Beta y Gamma y asimetría diferencial de la banda Alfa, los resultados obtenidos demuestran que el modelo puede predecir la valencia y el arousal, con una exactitud del 84.4%. Teniendo en cuenta la información anterior es de vital importancia el desarrollo de técnicas de identificación biométrica que sean efectivas, de bajo costo computacional y con efectos positivos sobre las emociones, ya que estas suelen ser un factor que disminuye la exactitud del sistema, al no tener en cuenta las variaciones en las señales EEG producidas por los diferentes estados emocionales, los resultados obtenidos pueden disminuir su precisión.

En términos de costo computacional, los métodos propuestos en esta investigación buscan optimizar el uso de recursos. La selección eficiente de canales EEG y el empleo de algoritmos optimizados permiten no solo mejorar la precisión sino también reducir los requisitos de procesamiento, lo que se traduce en sistemas más rápidos y menos costosos. Esta aproximación es crucial, especialmente en aplicaciones donde los recursos de hardware pueden ser limitados (Ortega-Rodríguez et al., 2023).

A pesar de estos avances, la identificación biométrica basada en EEG sigue enfrentando el reto de adaptarse a las variaciones en las señales causadas por emociones y otros estados fisiológicos. Esto resalta la necesidad de desarrollar métodos que no solo sean precisos y de bajo costo computacional, sino que también sean capaces de manejar la complejidad introducida por los estados emocionales de los individuos.

Dada esta panorámica, esta tesis se centra en el desarrollo de un modelo de identificación biométrica basado en señales EEG que toma en cuenta los estados emocionales de los individuos

para mejorar la precisión y seguridad del sistema. Este trabajo busca contribuir al campo de la identificación biométrica y el reconocimiento de emociones mediante el desarrollo de técnicas que aborden efectivamente los desafíos mencionados, con un enfoque particular en la selección de canales que maximicen la información relevante, reduciendo así el costo computacional y aumentando la robustez del sistema.

1.1 Descripción del problema

La biometría es el reconocimiento automático de un individuo en función de sus características biológicas (señales o rasgos) y de comportamiento, esta es implementada por medio de dispositivos que capturan una o varias características por medio de cámaras, micrófonos, sensores, entre otros, los cuales almacenan la información de la persona y la comparan a través de un algoritmo previamente entrenado que ya cuenta con los datos de las personas, lo que permite comparar similitudes e identificar y o autenticar al individuo (Belhadj, 2017). La metodología más común para el desarrollo de un sistema biométrico consta de 4 pasos: recolección de la base de datos de las personas a identificar o autenticar, segmentación, caracterización y el proceso de modelado, el cual se lleva a cabo usualmente usando máquinas de aprendizaje tales como: SVM (Das et al., 2021), CNN (Debie et al., 2021), K-NN (Joseph, A.A.a, Pog, E.I.A.P.a, Chin, K.L.a, Liang, D.B.B.a, Mat, D.A.A.a, Song, N.S.a, Rulaningtyas, 2021), entre otros (Alkeem E.A, Yeun C.Y, Yun J., Yoo P.D, Chae M., Chae M., Rahman A., 2021).

Una de las señales fisiológicas que se han venido estudiando es el EEG, este es un registro gráfico de la actividad eléctrica del cerebro que se toma en el cuero cabelludo. Dicha grabación representa las fluctuaciones de voltaje resultantes de los flujos de corriente iónica dentro de las neuronas del cerebro. Estas señales presentan una dinámica compleja que dependen de procesos cognitivos y emocionales, por lo que son estudiadas para múltiples aplicaciones como Brain-Computer Interface (BCI) (Curran & Stokes, 2003), identificación de emociones, estudios funcionales del cerebro, y más recientemente se han estudiado para identificación biométrica, debido a que cumple con los principios de biometría (permanencia, universalidad, medibilidad, confiabilidad y unicidad) (Lucero, Boris A. et al., 2020). Sin embargo, aún demanda múltiples estudios para comprobar esta hipótesis, a pesar de los resultados satisfactorios en términos del desempeño reportados en la literatura con algunas bases de datos (Callaghan, 2023).

En (Das et al., 2021) utilizan señales EEG para la identificación biométrica usando una base de datos pública de 109 usuarios, en este estudio implementaron Ensemble Support Vector Machine (ESVM) logrando una precisión de 96.16%. En (X. Zhang et al., 2020) se utilizó un sistema multimodal llamado DeepKey que combina señales EEG y señales de marcha, la base de datos fue recolectado por medio de Emotiv EPOC+, Para la extracción de características, utilizaron un filtro de banda Butterworth para aislar la banda Delta de los datos de EEG. Dicho estudio implementó redes neuronales recurrentes (RNN) para identificar en paralelo el *id* de EEG y el *id* de marcha otorgando solo acceso a quien cumplía con las dos condiciones, los resultados mostraron un buen desempeño en términos de la tasa de aceptación falsa (FAR) y la tasa de falso rechazo (FRR) evidenciando el potencial para implementarlos en entornos prácticos. En (Barayeu et al., 2020) se implementó la

base de datos EEG Motor Movement/Imagery Dataset de PhysioNet. Para el preprocesamiento y extracción de características, en ella se aplicaron ventanas deslizantes y filtros de corte en MATLAB, y emplearon la Descomposición Modal Empírica para evaluar la complejidad de la señal, concentrándose en las primeras cuatro Funciones de Modo Intrínsecas y calculando su Densidad Espectral de Potencia. Se implementó un decodificador de 2 etapas, en la primera, las características de la señal fueron extraídas con redes neuronales de aprendizaje profundo (DNN), luego se analizó con componentes principales (PCA) y en la segunda etapa se utilizó SVM. El estudio fue realizado en 105 sujetos, logrando una tasa FAR de 2.55% y una precisión general de 88.29%.

Recientemente, ha sido reportado un reducido número de estudios que se han enfocado en analizar la identificación biométrica a partir de señales EEG en conjunto con las emociones, para determinar sus efectos y mejorar el desempeño de la identificación (Chen et al., 2020), en este estudio al usar el conjunto de datos de emoción DEAP para evaluar el rendimiento del modelo GSLT-CNN, este alcanzó una precisión del 99% en la identificación de 32 sujetos. Los resultados sugieren que los datos de EEG asociados a emociones contienen características más específicas del sujeto, lo que puede conducir a una alta precisión en la predicción de la identidad. Sin embargo, son pocos los estudios que se han realizado para analizar los efectos de las emociones sobre los sistemas de identificación biométrica basada en EEG (Bilucaglia et al., 2019; Ozdemir et al., 2021; Xueyuan Xu, Tianyuan Jia, Qing Li, Fulin Wei, Long Ye, 2021). Actualmente, hay varios asuntos por explorar como el efecto de las emociones en la biometría, ya que las áreas del cerebro que están relacionadas con el control de las emociones están en el lado derecho e izquierdo del cerebro, pero hasta el momento no se saben qué canales brindan mayor información que pueda aumentar la exactitud de los sistemas de identificación, siendo de gran importancia esto, debido a que muchas zonas del cerebro no brindan información relevante, lo que lleva a un incremento en el costo computacional y en algunos casos introduciendo ruido al sistema. En (Pane et al., 2018) se realiza un estudio para determinar qué combinación de canales aportan mayor información en la identificación de las emociones y qué bandas de frecuencia son las más idóneas, la precisión más alta en este estudio fue de 99.85% en un escenario de 15 canales, en el mismo estudio se confirma que las bandas de frecuencia más fiables son la Alfa, Beta y Gamma.

Se considera de alta importancia el análisis de los estados emocionales y sus efectos sobre la identificación biométrica, considerando los cambios en la dinámica de las señales cerebrales, ocasionados por las emociones y la dependencia entre canales EEG, que dan como resultado información altamente correlacionada. Estos efectos son reflejados en los canales utilizados para la identificación biométrica como una perturbación, afectando su desempeño. Por lo anterior, en este trabajo se propone el desarrollo de un sistema de identificación biométrica a partir de señales EEG en contexto con las emociones con mayor robustez ante perturbaciones generadas por los cambios en los estados emocionales del individuo. Procurando evidenciar de manera más objetiva el cumplimiento de las reglas de la biometría.

La presente tesis aborda el desafío de desarrollar un sistema de identificación biométrica robusto utilizando señales EEG, que pueda adaptarse y responder efectivamente a las variaciones en los estados emocionales de los individuos. A pesar de los avances en la biometría a través de EEG, que muestran un alto potencial para la identificación precisa de individuos, los cambios en las emociones y otros estados fisiológicos pueden alterar significativamente las señales biométricas, reduciendo la fiabilidad y precisión de estos sistemas. Este estudio se enfoca en explorar cómo las variaciones

emocionales afectan las señales EEG y busca desarrollar metodologías que minimicen este impacto, mejorando la capacidad del sistema para mantener una alta precisión en entornos reales y dinámicos. El objetivo es crear un sistema que no solo sea preciso y de bajo costo computacional, sino que también sea capaz de manejar las complejidades introducidas por las fluctuaciones emocionales, ofreciendo así una solución más eficiente y segura para la identificación biométrica.

1.2 Hipótesis

El desempeño de los sistemas de inteligencia computacional para la identificación biométrica a partir de señales EEG considerando las emociones de cada individuo logra mejorar y robustecer los sistemas biométricos.

1.3 Objetivos

1.3.1 General

Proponer una metodología de identificación biométrica basada en técnicas de inteligencia computacional y fusión de datos a partir de señales EEG en contexto con el estado emocional de los individuos

1.3.2 Específicos

- Caracterizar las señales EEG usando medidas tiempo frecuencia con alta capacidad discriminante para identificar emociones e individuos.
- Proponer una metodología de identificación biométrica y emociones basado en máquinas de aprendizaje supervisado
- Validar la metodología propuesta usando medidas de desempeño para técnicas de clasificación y de biometría

2. Estado del Arte y Marco Teórico

Un sistema de biometría completo debe ser inherentemente robusto para garantizar su eficacia en diversas condiciones y entornos, manteniendo un alto nivel de precisión en la identificación de individuos a pesar de las variaciones en las señales biométricas. Además, debe resistir intentos de fraude, como la presentación de datos biométricos falsificados o la suplantación de identidad, y operar de manera confiable y segura a largo plazo. La robustez también implica la protección de la privacidad de los usuarios y la integridad de los datos biométricos, siendo esencial para la confiabilidad y seguridad en aplicaciones que van desde el control de accesos hasta la autenticación en servicios en línea (Gil Pacheco, 2003).

En el contexto de la identificación biométrica, la aspiración a la robustez y fiabilidad necesarias involucra aspectos cruciales. La captura de datos de rasgos biométricos debe diseñarse para adaptarse a condiciones variables, considerando factores como iluminación, ángulos de captura y calidad de imagen, o en el caso de señales fisiológicas, utilizando equipos especializados. La incorporación de técnicas avanzadas de procesamiento de señales y visión por computadora puede mitigar variaciones inherentes en las señales biométricas. La seguridad del sistema exige protección contra intentos de manipulación o suplantación, mediante la implementación de algoritmos antifraude y la detección de ataques, garantizando la integridad de los datos biométricos. La gestión adecuada del ciclo de vida de los datos, incluido su almacenamiento seguro y la adopción de protocolos de privacidad, es esencial para preservar la confidencialidad y cumplir con las regulaciones. La continuidad operativa y actualizaciones periódicas del sistema asegurarán su adaptabilidad a medida que evolucionen las amenazas y tecnologías (Kant, 2020).

2.1 Identificación biométrica

Es la ciencia encargada en cuantificar rasgos fisiológicos o conductuales que lleven a la identificación de un individuo por medio de análisis estadísticos. Este mecanismo está implícito en nosotros y nos ayuda a reconocer a las personas por su tono de voz, la forma de su cuerpo, las características de su rostro, entre muchas otras. La autenticación biométrica hace referencia a la confirmación de la identidad, por otro lado, la identificación biométrica consiste en reconocer si una persona es quien dice ser.

El reconocimiento de la identidad, dada la diversidad de la población mundial, que actualmente asciende a aproximadamente 8 mil billones de personas, puede lograrse a través de tres enfoques principales:

- **Conocimiento Personal:** Este método involucra información que solo la persona en cuestión conoce. Ejemplos: contraseñas, códigos PIN o números de identificación personal. La característica distintiva de este enfoque es que la seguridad reside en la confidencialidad de la información; sin embargo, esta puede ser olvidada por el usuario o interceptada por terceros.
- **Objetos Únicos en Posesión:** La identidad también puede verificarse mediante elementos físicos que la persona posee. Esto incluye documentos de identidad como cédulas de ciudadanía, pasaportes o carnés de identificación. Aunque más tangibles que el conocimiento personal, estos objetos pueden ser duplicados, robados o extraviados, lo que representa un riesgo de seguridad.
- **Rasgos Físicos o Comportamentales (Identificación Biométrica):** Esta forma de identificación se basa en características únicas e intransferibles de las personas, como la huella dactilar, el rostro, o la voz (A. K. Jain, 2008). Dada su naturaleza intrínseca a cada individuo, la identificación biométrica ofrece un nivel de seguridad difícil de falsificar, superando significativamente los métodos basados en conocimiento personal o posesiones física

La identificación biométrica se destaca entre los métodos anteriores debido a su robustez frente a la falsificación, olvido, pérdida o robo. Esta fortaleza la convierte en una opción preferente para

sistemas de seguridad que requieren un alto nivel de confiabilidad. La identificación biométrica puede ser bastante segura cuando se utilizan sistemas unimodales, bimodales o multimodales, los cuales hacen referencia a una, dos o más características fisiológicas (Meltzer-camino, 2018; Teja Chavali et al., 2023).

Uno de los principales problemas computacionales en la biometría es la necesidad de procesar y analizar grandes volúmenes de datos biométricos de manera eficiente y en tiempo real. Esto incluye, el filtrado, la extracción de características, la comparación de patrones y la autenticación en sistemas que deben operar con alta precisión. Por ello los investigadores han realizado esfuerzos en encontrar técnicas que optimicen los procesos, en (Moctezuma & Molinas, 2020) presentan un método de identificación basado en EEG que combina características de un solo canal en el dominio temporal con información por canal. Las características por canal se crean utilizando matrices simétricas, donde los elementos se calculan basándose en el coeficiente de correlación de Pearson entre pares de canales. Estas características por canal se introducen luego en un perceptrón multicapa (MLP) para la clasificación, logrando disminuir el costo computacional y mejorando la precisión, también se han implementados métodos modernos como en (M. Benomar, Steven Cao, Manoj Vishwanath, Khuong Quoc Vo, 2022) donde utilizan modelos de aprendizaje profundo como ResNet, Inception y EEGNet en un sistema basado en Raspberry Pi en tiempo real. Los modelos demostraron ser efectivos, con EEGNet alcanzando una precisión del 86.74%. Además, el sistema permite la identificación de sujetos en tiempo real y se destaca por su portabilidad y bajo costo, lo que lo convierte en una solución viable para aplicaciones prácticas.

2.2 Las señales EEG aplicadas a la Biometría

Las señales EEG proporcionan una fuente rica y compleja de datos que pueden ser explotados para aplicaciones como la identificación biométrica y el reconocimiento de emociones. En el caso de la identificación biométrica, se ha avanzado significativamente, permitiendo la aplicación no solo de rasgos sino también de señales EEG para identificar individuos. Esto ha sido posible gracias a los avances tecnológicos que facilitan la integración de estas señales, las cuales, con sus características únicas y variedad de ondas cerebrales, han llevado a la creación de protocolos efectivos para su adquisición. Por tanto, las señales EEG muestran un gran potencial en el ámbito biométrico cuando se utilizan adecuadamente.

2.2.1 Historia de la biometría

En los últimos años, la identificación biométrica ha logrado una gran popularidad, lo que ha permitido el desarrollo de nuevos métodos para la identificación. Actualmente, la biometría se encuentra en dispositivos electrónicos, edificios, bancos, entre mucho otros y a pesar de que parece una tecnología reciente, la biometría se remonta a la prehistoria, en la Tabla **2-1** se presenta de manera concisa los hitos clave en la evolución de la biometría, desde sus orígenes en la prehistoria hasta los desarrollos contemporáneos (GÓMEZ, 2020; Maersa, 2010; Mayhew, 2018; Zen, 2013).

Tabla 2-1: Línea del tiempo de la identificación biométrica, datos obtenidos de (GÓMEZ, 2020; Maersa, 2010; Mayhew, 2018; Zen, 2013)

Asirios, babilónicos, japoneses y chinos, usaban las huellas dactilares para realizar transacciones comerciales, las cuales quedaban registradas en tabletas de arcilla	500 A.C
El libro persa del siglo XIV "Jaamehol-Tawarikh" incluye comentarios sobre la práctica de identificar a las personas a partir de sus huellas digitales	Siglo XIV
Malpighi identificó diferencias en los patrones de huellas digitales	1686
Purkine, identificó la naturaleza única de las huellas dactilares	1823
El anatomista y médico alemán JCA Mayer escribió Placas anatómicas de cobre con explicaciones apropiadas, Mayer fue el primero en declarar que la piel de la cresta de fricción es única.	1788
Alphose Bertillon, jefe del departamento fotográfico de la policía de París desarrolló un sistema antropométrico para identificar criminales, funcionaba mediante la medición de ciertas longitudes y ancho de la cabeza y del cuerpo, y con el registro de las marcas características (tatuajes, cicatrices, etc.)	1870
Azizul Haque desarrolló el primer sistema robusto en India para Sir Edward Henry, Inspector General de Policía en Bengala, India	1900
Las prisiones estatales de Nueva York comienzan a usar huellas digitales	1903
Se propone el concepto de usar el patrón de iris para la identificación	1936
El reconocimiento facial se vuelve semiautomático y se crea el primer modelo de producción acústica del habla	1960
El FBI financia el desarrollo de sensores de huella digital	1975
Se implementa el primer sistema de reconocimiento facial semiautomático y se desarrolla la técnica Eigenface para el reconocimiento facial	1988
Se comienza a investigar otras técnicas de reconocimiento de patrones y redes neuronales desarrolladas en lenguaje assembler y fortran	1994
Apple incluye escáneres de huellas digitales en teléfonos inteligentes dirigidos al consumidor, desde ese momento, el mercado inició la venta masiva de dispositivos electrónicos con reconocimiento de huella, cara, voz, etc.	2013
El banco BBVA permite firmar con biometría todas las operaciones bancarias de sus clientes	2022

2.2.2 Avances tecnológicos en la biometría

Los individuos pueden ser reconocidos por medio de dispositivos no invasivos o invasivos, Los no invasivos son aquellas tecnologías que usamos diariamente, las cuales solo están en contacto parcial

o total sobre el cuerpo y permiten extraer información del individuo, algunos dispositivos se muestran en la Tabla 2-2

Tabla 2-2: Dispositivos de captura de datos

<p>Dispositivo para reconocimiento de huella dactilar (<i>Todo Tintas y Suministros, 2023</i>)</p>	
<p>Dispositivo para reconocimiento facial (<i>Biométrica, 2023</i>)</p>	
<p>Dispositivo de reconocimiento de voz (<i>mactronica, 2023</i>)</p>	
<p>Dispositivo para toma de señales EEG (<i>Mindmetriks, 2023</i>)</p>	
<p>Dispositivo para el reconocimiento del iris (<i>kimaldi, 2023</i>)</p>	

2.2.3 Señales EEG

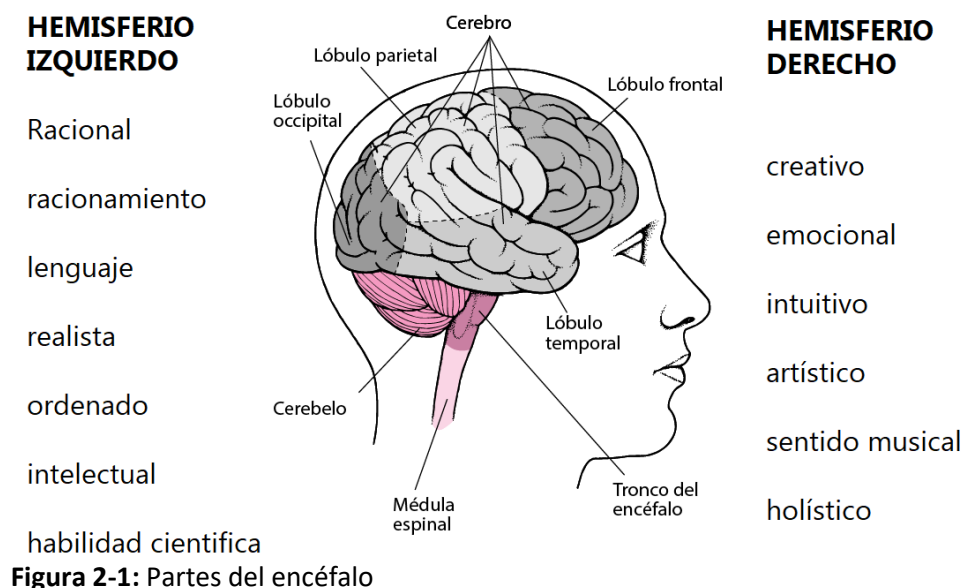
Los avances tecnológicos en biometría han marcado un hito en el reconocimiento individual, ya sea a través de dispositivos no invasivos o invasivos. Las tecnologías no invasivas, presentes en nuestra vida diaria, establecen contacto parcial o total con el cuerpo, permitiendo la extracción de información clave del individuo, como se detalla en la Tabla 2-2. Este contexto de identificación biométrica se convierte en un punto de partida esencial al adentrarnos en la exploración de la electroencefalografía (EEG) y su relación con el encéfalo humano.

El encéfalo humano constituye la parte más compleja de todo nuestro sistema nervioso central (SNC), según(Diamond et al., 2014) “casi todos los órganos del cuerpo humano son potencialmente trasplantables. Sin embargo, y a pesar del trasplante, la persona es la misma, mientras que el trasplante del encéfalo equivaldría al trasplante de la persona”. El encéfalo nos permite tener conciencia de nosotros mismo y nos da la capacidad de hablar y movernos.

Por otra parte, el cerebro dirige las funciones de nuestro cuerpo, gracias a él tenemos la capacidad de almacenar recuerdos y generar pensamientos, el cerebro a su vez regula los movimientos del cuerpo y coordina el habla y el equilibrio.

El cerebro humano se divide en dos hemisferios conectados entre sí: derecho e izquierdo. Cada uno de estos hemisferios se especializa en funciones diferentes, a su vez tienen una relación inversa con el cuerpo humano, lo que quiere decir que el hemisferio derecho coordina el movimiento del lado izquierdo del cuerpo y viceversa.

El hemisferio derecho tiende a dominar en el procesamiento de recuerdos a través de imágenes e interpretaciones, y es responsable de las funciones no verbales, incluyendo el procesamiento de emociones, imágenes y experiencias sensoriales como el sabor. Por otro lado, el hemisferio izquierdo tiene un dominio más fuerte en el procesamiento de símbolos, letras, números y palabras, lo que generalmente se asocia con las funciones racionales y lingüísticas del cerebro como se muestra en la Figura 2-1. Es importante recordar que ambos hemisferios colaboran en numerosas tareas cognitivas (Romeo Urrea, 2015).



Al dirigirnos hacia la electroencefalografía, es esencial comprender cómo esta técnica permite analizar la actividad cerebral a través de señales bioeléctricas.

La electroencefalografía es un método no invasivo de análisis de la actividad cerebral del ser humano a través de señales bioeléctricas, estas señales son tomadas a través de discos de metal llamados electrodos, los cuales se ubican en el cuero cabelludo, en la Figura 2-2 se puede ver la ilustración de las señales EEG y el dispositivo de captura de la señal (sprint diagnostic, 2022).

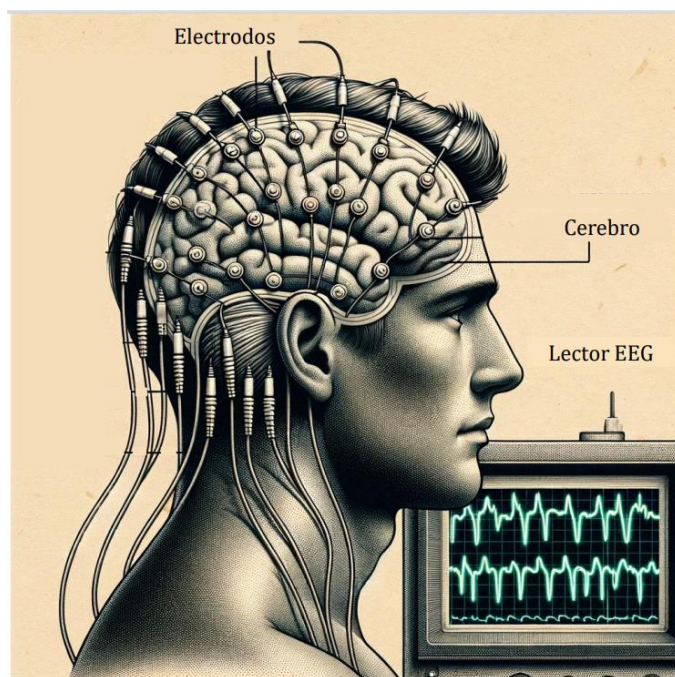


Figura 2-2: Representación de electroencefalogramas, creada por Dalle

2.2.4 Protocolo 10-20 (ubicación espacial de los electrodos)

Existen varios sistemas internacionales para la toma de las señales EEG. Entre ellas está 10-5, 10-10 y 10-20. El sistema 10-20 se creó en 1947 debido a que la ubicación de los electrodos es crítica si queremos realizar experimentos que sean reproducibles, o si queremos comparar nuestras grabaciones con los datos de otras personas, el primer sistema en crearse fue el 10-20 y propuso un total de 21 electrodos para examinar el cerebro de un adulto como se muestra en la Figura 2-3 (Bitbrain, 2020), este sistema hasta el momento es el más utilizado (Valer Jurcak 1, Daisuke Tsuzuki, 2007)




Figura 2-3: Relación entre hemisferios y electrodos, tomado de (Bitbrain, 2020)

2.2.5 Tipos de ondas cerebrales

Las ondas cerebrales son los impulsos eléctricos generados por cadenas de neuronas, estas señales se distinguen por su frecuencia. Existen 5 tipos de ondas cerebrales llamadas Alfa, Beta, Teta, Gamma y Delta como se muestra en la Figura 2-4 (Suhaimi et al., 2020), algunas de ellas cuentan con bajas frecuencias y otras con unas más elevadas, estas 5 ondas mantienen activas a lo largo del día y dependiendo de la actividad realizada algunas de ellas tienden a tener más fuerza que otras (Sciotto & Niripil, 2018).

Ondas Delta (1 a 3 Hz)

Son aquellas que tienen mayor amplitud y se les asocia con el sueño profundo, esta onda se relaciona con las actividades de las que no somos conscientes, ejemplo el ritmo cardiaco. Estas ondas también se observan en estados de meditación. La producción del ritmo delta, coincide con la regeneración y restauración del sistema nervioso central (García, 2015).

Onda Teta (3.5 a 8 Hz)

Son aquellas que se asocia a la imaginación y la reflexión, estas ondas aparecen también en la meditación profunda, dichas ondas son de suma importancia en el aprendizaje, se producen entre la vigilia y el sueño y al procesar información inconsciente como pesadillas o miedos (Romero, 2012).

Onda Alfa (8 a 13 Hz)

Las señales alfa aparecen en estados de escasa actividad cerebral y relajación, son ondas de mayor amplitud que las betas, por lo general las alfa aparecen como una gratificación después de un trabajo bien hecho (Ortega p, 2005).

Ondas Beta (12 a 33 Hz)

Las ondas beta aparecen en los estados en que la atención está dirigida a tareas cognitivas externas, maneja una frecuencia rápida, se asocia con tareas mentales intensas(Lundqvist et al., 2018).

Ondas Gamma (25 a 100 Hz)

Las ondas gamma se originan en el tálamo, estas señales se relacionan con tareas de alto procesamiento cognitivo (García, 2015).




Figura 2-4: Representación de las ondas EEG (Suhaimi et al., 2020)

A su vez las señales cerebrales pueden ser descritas de la siguiente manera

Definición de la señal en tiempo discreto:

$$x[n] \text{ con } n = 1, 2, 3, \dots, N \text{ con } F_s = 128 \text{ Hz}$$

donde n representa el número de la muestra de la señal, N el número de muestras de la señal y F_s es la frecuencia de muestreo.

2.2.6 Biometría en señales EEG

La investigación en biometría mediante señales EEG explora el reconocimiento de emociones a través de patrones cerebrales únicos. Esta rama no solo se centra en la identificación precisa de estados emocionales, sino que también desempeña un papel crucial en la detección de emociones

ocultas, contribuyendo así a abordar problemas relacionados con la salud mental. Además, esta disciplina no se limita solo al ámbito médico, sino que se extiende a la investigación y el marketing, donde desempeña un papel destacado en el desarrollo de estrategias que buscan mejorar la satisfacción del cliente (Montoya Capote, 2021).

A medida que exploramos la clasificación de emociones, desde las primarias hasta las secundarias, y utilizamos dimensiones como la valencia y el arousal, se nos revela una ventana hacia la comprensión profunda de las complejas interacciones emocionales y su influencia directa en la experiencia humana. Este enfoque no solo enriquece la identificación biométrica, sino que también proporciona valiosas perspectivas sobre cómo los patrones cerebrales pueden desentrañar los misterios de la emocionalidad humana (Andrea F., 2016).

El proceso que se le realiza a las señales EEG para ser utilizada en biometría inicia con la recolección de datos, los datos se obtienen utilizando un sistema de electroencefalografía, donde los electrodos colocados estratégicamente en el cuero cabelludo capturan la actividad eléctrica del cerebro. Estos datos reflejan patrones neurales que son únicos para cada individuo. Después de la recolección de los datos crudos de EEG, los cuales son susceptibles a diversas fuentes de ruido, se les realiza un preprocesamiento, crucial para filtrar señales irrelevantes y reducir artefactos (Yamashita et al., 2020).

Luego se extraen características específicas de las señales EEG, tales como bandas de frecuencia (Alfa, Beta, etc.), potenciales evocados o patrones de conectividad neural. Estas características son fundamentales para distinguir entre los patrones cerebrales de diferentes sujetos.

Luego para realizar un análisis de los datos se utilizan técnicas de aprendizaje automático y algoritmos de reconocimiento de patrones para clasificar los datos y asociarlos con identidades específicas. Modelos como redes neuronales (H. Zhang, 2023), máquinas de vectores de soporte (SVM) (Hasan et al., 2021) o análisis discriminante son comunes.

Se finaliza con la validación esta evalúa la precisión del sistema biométrico utilizando métricas como la tasa de verdaderos positivos (sensibilidad) y verdaderos negativos (especificidad), además de la tasa de error igual (EER). La efectividad de la biometría EEG se mide a través de su capacidad para identificar correctamente a los individuos bajo diversas condiciones. Las métricas de desempeño incluyen la tasa de aceptación falsa (FAR), la tasa de rechazo falso (FRR) y la precisión general del sistema.

Los sistemas de biometría basados en EEG son especialmente valiosos en contextos donde la seguridad es crítica. Pueden utilizarse para controlar el acceso a instalaciones sensibles o sistemas de información, proporcionando un nivel de seguridad que es difícil de alcanzar con métodos biométricos más convencionales.

2.3 Reconocimiento de emociones

Las emociones son las respuestas a un acontecimiento que viene acompañado de cambios fisiológicos, los cuales nos predisponen a actuar. Una de las características de las emociones es su alta intensidad en un corto periodo de tiempo, lo cual se diferencia de los sentimientos.

Las emociones son un campo de estudio en la actualidad debido a que en muchos casos no se logra identificar las emociones en las personas, ya que han desarrollado métodos para camuflarlas (Cui et al., 2023), eso presenta un problema serio debido a que en algunos casos estas emociones están asociadas a enfermedades como la depresión u otros problemas emocionales por ello la importancia de identificarlas para poder realizar intervenciones y tratamientos de manera temprana y efectiva. A su vez en el campo de la investigación y el marketing identificar las emociones aumenta la eficacia de las estrategias de marketing con el fin de mejorar la satisfacción del cliente.

El proceso que se realiza a estas señales EEG inicia con la recolección de datos, la cual se realiza a través de electroencefalogramas, donde múltiples electrodos colocados en el cuero cabelludo registran la actividad eléctrica del cerebro. Estos datos son esenciales para identificar patrones asociados con diferentes estados emocionales. Cada sesión de recolección puede generar grandes volúmenes de datos, dado que se capturan múltiples canales a altas tasas de muestreo para obtener señales precisas y detalladas. Una vez recolectados, los datos EEG pasan por varias etapas de procesamiento: Incluye la filtración de ruido, la normalización y la corrección de artefactos para limpiar las señales de interferencias no deseadas. Luego se procede a la extracción de características donde se usan técnicas como la transformada de Fourier, análisis wavelet o métodos de aprendizaje automático los cuales se utilizan para extraer características relevantes de las ondas cerebrales que correlacionan con estados emocionales específicos. Luego Utilizando algoritmos de aprendizaje supervisado o no supervisado, los patrones extraídos son clasificados en categorías emocionales basadas en dimensiones de valencia (positividad-negatividad) y arousal (activación-desactivación). Los resultados del análisis pueden proporcionar insights sobre cómo las emociones afectan el comportamiento humano y pueden ser aplicados para mejorar la interacción usuario-máquina en diversas aplicaciones.

Para evaluar la efectividad de los sistemas de clasificación de emociones basados en EEG, se utilizan métricas como la precisión, la sensibilidad y la especificidad. Estas métricas ayudan a determinar qué tan bien el modelo puede identificar correctamente diversas emociones y bajo qué condiciones.

En el ámbito actual de la identificación de emociones utilizando EEG, se han producido avances significativos que han enriquecido tanto la teoría como la práctica. Investigaciones recientes como (Yan et al., 2023) presentan un enfoque para el reconocimiento de emociones mediante el análisis de la dinámica no lineal topológica de las señales EEG, utilizando técnicas de reconstrucción del espacio de fase y homología persistente para explorar las propiedades topológicas del espacio de fase. Este estudio logra una alta precisión en la clasificación de estados emocionales, utilizando los conjuntos de datos DEAP y DREAMER y técnicas de aprendizaje como SVM y RF. Alcanzaron una precisión de 82.39% usando SVM para el conjunto de datos DEAP. Por otro lado, con el método de RF, lograron una precisión de 83.52% para el mismo conjunto de datos

En (Peng & Liu, 2023) se enfoca en mejorar la precisión del reconocimiento de emociones a través de señales EEG utilizando el algoritmo de optimización por enjambre de partículas binarias (BPSO). Este estudio innovador propone y evalúa un método que selecciona características de EEG más representativas y precisas para identificar emociones, utilizando técnicas de preprocesamiento y

clasificación avanzadas. El enfoque clave del artículo radica en su uso del BPSO para seleccionar características óptimas a partir de un conjunto comprensivo que incluye atributos de dominios temporal, frecuencial, tiempo-frecuencia y de entropía diferencial. Esta selección permite afinar el proceso de reconocimiento emocional al mejorar la precisión en la clasificación de emociones como felicidad, tristeza, ira y neutralidad. el estudio alcanzó una precisión máxima del 91.78% en el reconocimiento de la emoción de felicidad, superando el desempeño del algoritmo de PSO tradicional, que logró un 76.12% de precisión.

2.4 Clasificación de las emociones

Se ha hablado que existen 4 emociones primarias, pero según algunos autores como Matsumoto, Ekman (2009) y Damasio (2000) existen 6 emociones primarias. En un estudio preliminar sobre las emociones se obtuvo que la teoría de dichos autores es correcta, siendo estas las 6 emociones primarias: tristeza, sorpresa, enojo-ira, miedo, felicidad y desprecio (Carla et al., 2017).

Las emociones secundarias son la combinación de las emociones primarias, las emociones se pueden graficar haciendo uso de la valencia y arousal como se muestra en la Figura 2-5.

La valencia es la dimensión principal sobre la cual se construye la experiencia emocional, es el componente motivacional de la emoción (placer vs. displacer) y se origina en estructuras neurobiológicas primarias y separadas, una que activa el sistema motivacional apetitivo y otra que activa el sistema motivacional defensivo (Le-Doux, 2000). Esta primacía de la valencia y la existencia de estructuras separadas han sido observadas no solo en humanos, sino también en primates y demás mamíferos a través de resonancia magnética funcional (fMRI) (Bradley, 2009; Dolin, Zborovskaya, & Zamakhovev, 1965; Lang & Bradley, 2010).

El arousal es la dimensión que refleja la energía invertida durante la emoción, es la cantidad de activación simpática que se experimenta durante la experiencia emocional. Las investigaciones han demostrado que el arousal suele estar en función de la valencia, ya que la activación de alguno de los sistemas motivacionales primarios, sea el apetitivo o el defensivo, va acompañado de un aumento en el arousal (Bradley, 2009; Bradley, Codispoti, Cuthbert, & Lang, 2001).

La dominancia es la dimensión más reciente, hace referencia al grado de control que la persona percibe sobre su respuesta emocional y su función es la interrupción o continuidad de la respuesta conductual. Esta dimensión se origina en estructuras cerebrales más recientes del cerebro y tiene como función la inhibición, el retraso, la evaluación del contexto y la planificación (Vila et al., 2001; Carlos Gantiva, 2016).

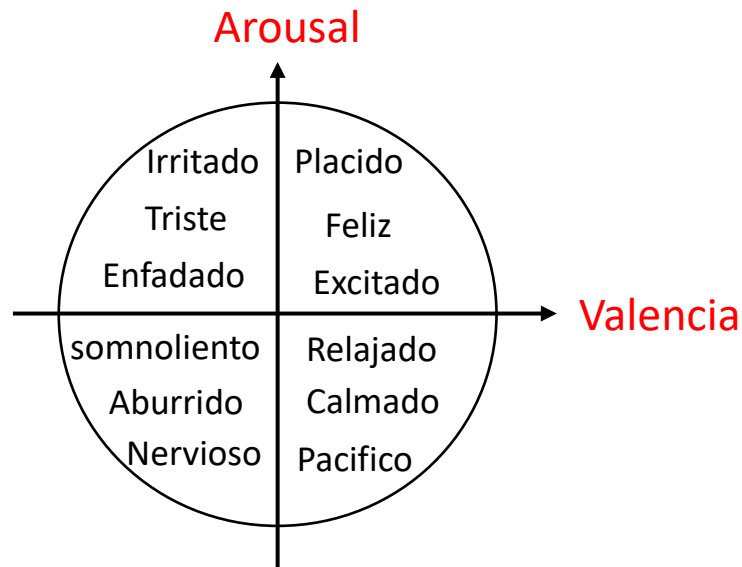


Figura 2-5: Representación de las emociones teniendo en cuenta excitación y valencia

Algunos de los desafíos que enfrenta la identificación biométrica por medio de señales EEG es la reducción del número de canales EEG para disminuir la complejidad computacional incrementa el riesgo de baja estabilidad y fiabilidad de los datos. Esta es una preocupación significativa dado que las señales EEG son altamente susceptibles a ruidos y variaciones (Peng & Liu, 2023). A su vez los problemas de costo computacional al evaluar datos extensos de EEG multicanal eleva el costo computacional, lo que es un desafío para aplicaciones en tiempo real y sistemas de bajo consumo energético.

Otro de los desafíos que se presentan en la seguridad y la privacidad dado que los datos de EEG contienen información sensible, proteger estos datos contra accesos no autorizados es crucial. Por ello en (Goshvarpour & Goshvarpour, 2023) La propuesta aborda esto mediante el diseño de una plantilla cancelable que es transformada y no invertible, protegiendo así los datos crudos de EEG, por otro lado el autor discute la capacidad del sistema para resistir múltiples tipos de ataques, incluyendo ataques de preimagen y de escalada, destacando la importancia de evaluar la resistencia del sistema frente a estos intentos de suplantación.

En (Wang et al., 2022) plantean un reto de utilizar un solo canal EEG lo que plantea un desafío significativo en términos de la complejidad y calidad de los datos recogidos. Los datos de un solo canal pueden no capturar toda la información necesaria para realizar autenticaciones biométricas precisas y robustas. Al limitarse a un solo canal, existe el desafío inherente de una posible reducción en la precisión y robustez del sistema biométrico, ya que los patrones más complejos que podrían ser detectados por múltiples canales pueden pasar desapercibidos.

3. Marco teórico

3.1 Preprocesamiento

El preprocesamiento de datos es el procedimiento de transformar datos sin procesar en un formato más adecuado para análisis posteriores. Esta etapa es fundamental en muchas aplicaciones, incluyendo el modelado de machine learning, debido a su impacto en la calidad y relevancia de los datos utilizados.

En particular, el preprocesamiento de señales EEG adquiridas desde el cuero cabelludo ilustra claramente su importancia. Estas señales no reflejan directamente la actividad cerebral, ya que están sujetas a múltiples fuentes de ruido y distorsión. Factores como las interferencias de la red eléctrica, así como los movimientos oculares y musculares, pueden alterar significativamente estas señales, que son de naturaleza eléctrica de bajo nivel.

Dentro de este contexto, los movimientos comunes, como el parpadeo o el desplazamiento ocular, son particularmente problemáticos, ya que pueden distorsionar las señales EEG de manera notable. Por lo tanto, el objetivo principal del preprocesamiento en este ámbito es separar las señales relevantes de las irrelevantes.

Esta distinción es crucial, ya que la calidad de los datos preprocesados determina en gran medida la exactitud de las predicciones de los modelos de machine learning. La etapa de preprocesamiento, a menudo subestimada, juega un rol fundamental en la eficacia de estos modelos. Como señala (Amari, 2023), la precisión de las predicciones del modelo depende en gran medida de cómo se manejen y procesen los datos en esta fase inicial. En la **Figura3-1** se presentan los pasos que se aplican a las señales EEG

Las técnicas de preprocesamiento son variadas y se realizan dependiendo del tipo de señal con la que se va a trabajar por ejemplo en (Yamashita et al., 2020), se implementó un método de preprocesamiento que inicio con un filtro digital, este se utilizó para manejar el ruido y las frecuencias no deseadas en los datos de EEG, luego se aplicaron medidas Contra Artefactos, esto con el fin de reducir los efectos de los artefactos en las señales EEG, como los causados por movimientos musculares y oculares y se finalizó con Épocas, este paso implica segmentar los datos de EEG en ventanas de tiempo más manejables para el análisis posterior.

Otro ejemplo de preprocesamiento es el aplicado en (Rosli et al., 2021) donde se usa una serie de técnicas destinadas a mejorar la calidad de las señales para su posterior análisis. Primero, se aplican medidas para contrarrestar artefactos, utilizando un filtro digital. Este filtro es un filtro IIR tridimensional aplicado a cada ensayo individual, que ayuda a eliminar frecuencias indeseadas fuera de la banda de interés, que suele ser entre 4 y 40 Hz, típicamente donde se observan las actividades del EEG. Además, se utilizan medidas contra artefactos como el análisis de componentes principales (PCA) y el análisis de componentes independientes (ICA) para separar y descartar componentes de ruido no deseados de las señales EEG. Finalmente, se implementa un método de época, donde los datos se segmentan en ventanas de tiempo específicas para el análisis, garantizando que solo se utilicen datos relevantes para la autenticación o identificación biométrica.



Figura 3-1: Representación de los pasos de preprocesamiento de señales EEG

3.2 Técnicas de preprocesamiento de señales EEG

El preprocesamiento de señales EEG implica el uso de diversos métodos que varían según el tipo de señales que se vayan a procesar. En el caso de las señales EEG, es esencial considerar las bandas de interés que se utilizarán en el estudio, ya que estas desempeñan un papel crucial en el análisis. Uno de los aspectos fundamentales en esta etapa es la normalización de los datos, que tiene como objetivo llevar los valores de las señales a una escala común, generalmente en un rango de 0 a 1. Esta normalización es esencial, puesto que los algoritmos de machine learning tienden a funcionar de manera más efectiva cuando los datos se presentan en una escala uniforme (Mladenov et al., 2013).

Además de la normalización, se aplican técnicas de filtrado para eliminar los posibles ruidos presentes en las señales EEG. Estos ruidos pueden estar relacionados con movimientos oculares registrados en las señales, así como interferencias eléctricas, como el ruido de 60 Hz (en el caso de Colombia). Para abordar estos desafíos, se utilizan técnicas como el Análisis de Componentes Independientes (ICA), el Análisis de Componentes Principales (PCA) y diversos tipos de filtros, como los adaptativos, wavelet, notch, espaciales, entre otros. Además, se aplican filtros de promedio móvil para suavizar las señales EEG (Daniel & Isasa, 2020).

3.3 Extracción de características de señales EEG

La importancia de las características en las señales EEG se centra en la necesidad de identificar y utilizar atributos específicos de estas señales para aplicaciones efectivas de machine learning. Las características son aspectos distintivos o patrones dentro de las señales EEG que pueden ser indicativos de estados mentales, respuestas neuronales o condiciones de salud. La selección adecuada de estas características es esencial, ya que permite que los modelos de machine learning se enfoquen en la información más relevante y discriminativa. Este enfoque mejora la precisión de los modelos al reducir la complejidad y el ruido de los datos, facilitando la detección de patrones significativos y la realización de predicciones más precisas.

Existen diferentes técnicas de extracción de características, entre ellas tenemos técnicas en el dominio del tiempo, de la frecuencia, tiempo-frecuencia, espaciales y no lineales; las diferentes técnicas buscan describir una señal por medio de sus características, algunas de las técnicas utilizadas en EEG son varianza, desviación estándar, coeficiente de correlación y parámetros de Hjorth; estos métodos suponen menor complejidad computacional; también existen los modelos autorregresivos (AR), transformada rápida de Fourier (FFT), transformada de Fourier en tiempo corto (STFT), potencia espectral, transformada wavelet, transformada de Hilbert-Huang, patrones espaciales comunes, entropía entre otros (Medina et al., 2018).

Los métodos en el dominio del tiempo como lo son los modelos AR poseen ventajas respecto a técnicas como el FFT, teniendo mejor resolución en frecuencia y mejores estímulos espectrales en segmentos cortos de señales EEG; entre sus limitaciones se sabe que no existen alineamientos claros de cómo seleccionar los parámetros de los estímulos espectrales, además requiere un orden óptimo del modelo AR, ya que un modelo demasiado bajo tiende a suavizar el espectro y uno muy alto tiende a introducir picos falsos.

Entre los métodos en el dominio de la frecuencia está FFT, entre sus ventajas esta que pueden mapearse desde el dominio del tiempo al dominio de la frecuencia, para indagar la distribución de la amplitud de espectros y reflejar las diferentes tareas del cerebro, entre sus limitaciones esta que no son adecuadas para representar señales no estacionarias, en las cuales su contenido espectral varía con el tiempo (Bakheet et al., 2022).

La STFT, por su lado, son simples y fáciles de implementar, pero entre sus limitaciones los segmentos más largos pueden violar la suposición de cuasi estacionariedad requerida por la transformada de Fourier (Lalor et al., 2021).

La Densidad espectral de Potencia (PSD) da información de la distribución de la energía de la señal entre sus diferentes frecuencias, aunque es limitada para presentar información adicional en la escala de tiempo, teniendo en cuenta que las señales EEG poseen características no estacionarias y de no linealidad (Manuel, 2005).

Entre las técnicas en tiempo-frecuencia tenemos las wavelet, estas son especiales en el tratamiento de señales no estacionarias, permiten descomponer la señal en tiempo y frecuencia, lo que permite el uso simultáneo de intervalos largos de tiempo para la información de baja frecuencia e intervalos cortos de tiempo para información de alta frecuencia. Entre sus limitaciones se requiere una correcta wavelet madre y un número de niveles de descomposición adecuados para un correcto análisis de las señales EEG.

La transformada de Hilbert-Huang (HHT) no requieren condiciones sobre linealidad y estacionariedad de la señal, permite la descomposición adaptativa y multiescalar de la señal y no requiere ninguna función para su descomposición, entre sus limitaciones se define mediante un algoritmo iterativo y carece de una fórmula matemática, cuyos resultados finales van a depender de la forma en la cual el algoritmo fue implementado y la definición de las variables y estructuras de control (Nacional et al., 2016).

Entre las técnicas espaciales tenemos las Common Spacial Patterns (CSP), que tienen la capacidad de proyectar señales EEG procedentes de varios canales en un subespacio donde se destacan las diferencias entre las clases y se minimizan las similitudes. El método alternativo time dependent Common Spatial Patterns (TDCSP) optimiza los filtros CSP y refleja de forma efectiva los cambios de la distribución espacial discriminativa en el tiempo. Entre sus limitaciones requiere no solo el entrenamiento de las muestras sino también la información de la clase a la que pertenecen las muestras para calcular la matriz de transformación lineal, esta técnica requiere de gran cantidad de electrodos (Medina et al., 2018).

Entre las técnicas no lineales, encontramos la entropía, la cual es robusta en el análisis de segmentos cortos de datos, resiste a los valores atípicos, es capaz de lidiar con el ruido mediante el ajuste adecuado de sus parámetros y se puede aplicar a señales estocásticas y determinísticamente caóticas. Presenta diversas alternativas que permiten caracterizar la complejidad de la señal con los cambios en el tiempo y cuantificar los cambios dinámicos de los eventos relacionados con la señal EEG, entre sus limitaciones no existen directrices claras sobre como elegir los parámetros m (longitud del vector de la serie) y r (tolerancia similar), antes de calcular la entropía aproximada o muestral; estos parámetros afectarán la entropía de cada registro de datos EEG durante diferentes tareas mentales, y por consiguiente, la precisión de clasificación en última instancia también se verá afectada.

Los coeficientes de Lyapunov aprovechan el comportamiento caótico de una señal EEG para realizar tareas de clasificación que combinados con otras características lineales o no lineales permiten obtener mejores resultados, entre sus limitaciones se deben hacer mayores esfuerzos para encontrar los parámetros óptimos para calcular los exponentes de Lyapunov y mejorar su desempeño (Lara et al., 2003).

A continuación, en la **Figura 3-2** se ilustra el proceso desde la carga de los datos de las señales EEG hasta la conformación del vector de características.

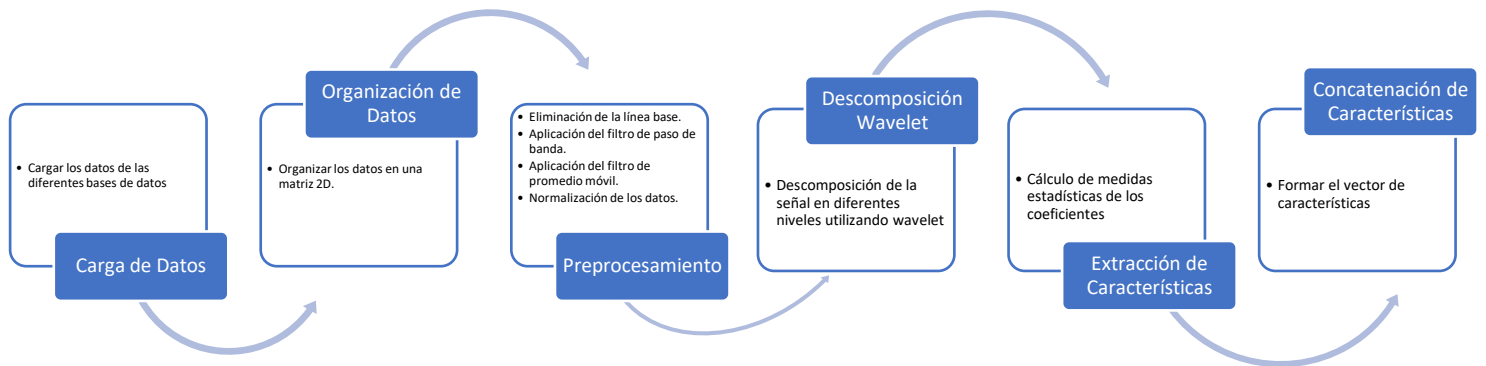


Figura 3-2: Diagrama del proceso de extracción de características

3.3.1 Transformada Wavelet

La transformada wavelet es una herramienta matemática utilizada para el análisis de señales y datos a diferentes escalas de resolución, tanto en el dominio del tiempo como en el de la frecuencia. La transformada wavelet representa una señal como una suma ponderada de funciones de base.

La transformada wavelet discreta de una señal $x(t)$ se define como:

Donde:

$$W(a, b) = \int_{-\infty}^{\infty} X(t) \cdot Psi * \left(\frac{t-b}{a}\right) dt \quad (3-1)$$

$W(a, b)$ es el coeficiente de la transformada wavelet discreta en la escala a y el desplazamiento b .

$X(t)$ es la señal original que queremos analizar.

$Psi(t)$ es la función madre de la wavelet (base de la wavelet).

a es el factor de escala que controla la anchura de la wavelet en el dominio del tiempo.

b es el desplazamiento (traslación) de la wavelet en el dominio del tiempo.

El asterisco (*) representa la operación de conjugado complejo.

La función $\Psi(t)$ es una función de wavelet específica que cumple ciertas propiedades deseables, como tener una media nula y estar bien localizada tanto en el tiempo como en la frecuencia. La elección de la función madre de la wavelet $\Psi(t)$ determina las características de la transformada wavelet (Laaziz, 2022).

3.3.2 Entropía de Shannon (H)

La entropía refleja cuán bien se puede predecir el comportamiento de cada parte respectiva de la trayectoria a partir de la otra. Básicamente, una entropía más alta indica sistemas más complejos o caóticos, y por lo tanto, menos previsibilidad (Phung et al., 2014).

La entropía proporciona información sobre la variabilidad y aleatoriedad de las señales. La entropía de Shannon se define como:

$$H(X) = -\sum_{i=1}^n P(x_i) \cdot \log(P(x_i)) \quad (3-2)$$

Donde:

$H(X)$ es la entropía de la señal X .

$P(x_i)$ es la probabilidad de que el valor x_i ocurra en la señal X .

3.3.3 Entropía de Rényi

Es una medida de la incertidumbre en una distribución de probabilidad. Fue desarrollada por el matemático húngaro Alfred Rényi. Esta entropía cuantifica la información contenida en una distribución de probabilidad de una manera más flexible que la entropía de Shannon (Hadiyoso et al., 2020).

La entropía de Rényi se define como:

$$H_{\alpha}(X) = \frac{1}{1-\alpha} \log(\sum_{i=1}^n P(x_i^{\alpha})) \quad (3-3)$$

Donde:

$H_{\alpha}(X)$ es la entropía de Rényi de la distribución de probabilidad $\$X\$$.

α es un parámetro que controla la sensibilidad de la medida de entropía, y debe ser diferente de 1 (es decir, $\alpha \neq 1$). Cuando α se acerca a 1, la entropía de Rényi se asemeja a la entropía de Shannon.

Esta entropía es útil en situaciones en las que se necesita una medida de diversidad o información más flexible que la entropía de Shannon.

3.3.4 Entropía Difusa

La Entropía Difusa es una medida de la irregularidad o complejidad en una señal, conceptualmente similar a la entropía de Shannon pero adaptada para manejar señales ruidosas o imprecisas. Se utiliza en el procesamiento de señales y el análisis de datos para cuantificar la variabilidad y la estructura de una serie de tiempo o señal. (Patel et al., 2021).

Dada una señal X de longitud N :

Se elige un parámetro m que define la longitud de la ventana. Estableciendo un umbral r para determinar la similitud entre puntos dentro de la ventana. Para cada ventana de longitud m , se cuentan los pares de puntos que son similares (la distancia entre ellos es menor o igual a r). Se calcula la probabilidad $C_m(r)$ de que dos conjuntos de m puntos dentro de la ventana sean similares.

La Entropía Difusa $FE(m, r)$ se calcula como:

$$FE(m, r) = -\log\left(\frac{C_m(r)}{C_{m+1}(r)}\right) \quad (3-4)$$

Donde:

$FE(m, r)$ es la entropía difusa para una longitud de ventana de m y un umbral r .

$C_m(r)$ es la probabilidad de similitud para una longitud de ventana de m y un umbral r .

$C_{m+1}(r)$ es la probabilidad de similitud para una longitud de ventana de $m + 1$ y el mismo umbral r .

Valores más altos de Entropía Difusa indican una mayor complejidad o irregularidad, mientras que valores más bajos sugieren una mayor regularidad en la serie de tiempo.

3.3.5 Entropía Muestral

La entropía muestral se calcula de manera similar a la entropía de Shannon, pero utilizando las frecuencias relativas de los valores en una muestra como estimaciones de las probabilidades, esta entropía se usa para caracterizar la incertidumbre o la información contenida en los conjuntos de

datos (Manis et al., 2023). Si tenemos una muestra de datos $\{x_1, x_2, \dots, x_m\}$, donde cada x_i puede tomar uno de los n valores únicos, la entropía muestral, H_s , se calcula como:

$$H_s = -\sum_{i=1}^n \hat{p}(x_i) \log_2 \hat{p}(x_i) \quad (3-5)$$

Donde:

$\hat{p}(x_i)$ es la frecuencia relativa del i -ésimo valor único en la muestra, es decir, $\hat{p}(x_i) = \frac{\text{Número de veces que } x_i \text{ ocurre en la muestra}}{m}$.

3.4 Selección de características

La selección de características es un proceso crítico en el campo de la identificación biométrica, especialmente cuando se trata de interpretar y analizar señales de electroencefalografía (EEG) para identificar estados emocionales. Este proceso implica identificar y seleccionar aquellos atributos de los datos que son más relevantes y significativos para el problema de clasificación o predicción en cuestión. La importancia de la selección de características radica en su capacidad para mejorar la eficiencia y efectividad de los algoritmos de aprendizaje automático, reduciendo la dimensión de los datos, eliminando el ruido o la información redundante, y, en última instancia, mejorando la precisión de la identificación (Trabelsi et al., 2022).

La selección de características se convierte en un pilar fundamental. Esto se debe a que las señales EEG contienen una gran cantidad de información, donde solo una fracción de ella es relevante para discernir entre diferentes estados emocionales. La capacidad de seleccionar las características más informativas permite no solo mejorar la precisión de los modelos de clasificación emocional o de identificación biométrica, sino también aumentar la eficiencia computacional y facilitar la interpretación de los resultados.

3.4.1 ReliefF

El algoritmo ReliefF es un método ampliamente utilizado para la selección de características que presenta muchas ventajas, como su simplicidad y velocidad de computación rápida. Se utiliza para calcular los pesos de las características basándose en el aprendizaje de muestras. La idea básica del algoritmo es determinar el peso de las características, es decir, evaluar la calidad de las características según su capacidad para distinguir entre muestras cercanas entre sí. La evaluación de la calidad de la característica se determina por la capacidad del vecino más cercano de una clase

para distinguir entre los vecinos más cercanos de cualquier otra clase. La selección de canales se puede realizar en función de los resultados de la selección de características (Topic et al., 2022).

Entrada: Para cada instancia de entrenamiento, un vector de valores de atributos y el valor de la clase.

Salida: El vector W de estimaciones de las cualidades de los atributos.

Algoritmo 1: pseudocódigo de ReliefF

Inicialice todos los pesos $W[A]$ a 0.0 ;

1 **para** cada i de 1 a m haga:

2 Seleccione una instancia aleatoria $R_i;S$

3 Encuentre los k vecinos más cercanos H_j de R_i ;

4 **para** cada clase $C \neq \text{clase}(R_i)$ haga:

5 Encuentre los k vecinos más desfavorables $M_j(C)$ de clase C ;

6 **para** cada atributo A de 1 a a haga:

7 $W[A] := W[A] - \sum_{j=1}^k \text{diff}(A, R_i, H_j) / (m \cdot k) +$

8 $\sum_{C \neq \text{class}(R_i)} \left[\frac{P(C)}{1 - P(\text{class}(R_i))} \sum_{j=1}^k \text{diff}(A, R_i, M_j(C)) \right] / (m \cdot k);$

3.5 Clasificación en machine learning

La clasificación es una de las tareas que más se llevan a cabo por los sistemas inteligentes, ya sean desarrollados por la estadística (regresión lineal, análisis discriminante) o la inteligencia artificial (SVM, K-NN, Recurrent Neural Network (RNN)) (Parra, 2019). Su principal objetivo consiste en asignar una entrada o instancia a una de varias categorías predefinidas en función de sus características o atributos. Esta tarea es ampliamente utilizada en una variedad de aplicaciones, desde diagnósticos médicos hasta reconocimiento de patrones en imágenes y detección de spam en correos electrónicos.

Cada uno de estos métodos tiene sus propias ventajas y desventajas, y la elección del algoritmo adecuado depende en gran medida de la naturaleza de los datos y el problema de clasificación a abordar. Además, en los últimos años, se han desarrollado nuevas técnicas que han demostrado mejorar los resultados en diferentes campos (Sajjad Karimi; Mohammad Bagher Shamsollahi, 2023).

3.6 Métodos de clasificación para biometría y emociones

Existen un sinnúmero de métodos de clasificación ya sea para la identificación biométrica o para el reconocimiento de las emociones, en la Tabla 3-2 se presenta una recopilación de técnicas de preprocesamiento, extracción de características y clasificadores para las emociones así como en la Tabla 3-1 se presenta una recopilación de estudios de identificación biométrica, en este apartado

hablaremos de los métodos de clasificación más aplicados a la identificación biométrica a partir de señales EEG (BENÍTEZ ALDÁS, 2018; Li et al., 2023; Sovatzidi & Iakovidis, 2023).

Tabla 3-1: Métodos de extracción de características y clasificación biométrica

cita	Preproceso	Base de datos	Extracción y selección	Clasificación biométrica	exactitud
(Kamaraju et al., 2023)	Multivariate variational mode decomposition (MVMD)	Base de datos propia (35 sujetos)	Fourier-Bessel series expansion-based (FBSE) entropies	K-NN	93.4±7.0 %
(Ortega-Rodríguez et al., 2023)	FieldTrip, bandpass 4-40Hz, beta frequency band 13-30 Hz	Base de datos propia (13 personas) PhysioNet BCI (109 personas)	PCA, Wilcoxon test, fast fourier transform, Power Spectrum (PS), Asymmetry index	RBF-SVM K-fold, Cross-validation	99.9±1.39 %
(M. Benomar, Steven Cao, Manoj Vishwanath, Khuong Quoc Vo, 2022)	PREP pipeline, notch filter standardScaler, high pass filter 1Hz, low pass filter 50Hz	The BED (Biometric EEG Dataset) 21 sujetos	PCA, Wilcoxon test, optimal spatial filtering	Deep learning (DL)	86.74%
(Tian et al., 2023)	-	https://link.springer.com/chapter/10.1007/978-981-99-0479-2_294	functional connectivity (FC)	multi-stream GCN (MSGCN)	98.05%
(Kralikova et al., 2022)	Notch filter, Bandpass filter, common average reference (CAR)	Base de datos propio (21 sujetos)	1D-CNN	cross 5-fold, LDA, SVM, K-NN, DL	99%
(Wibawa et al., 2022)	Finite Impulse Response (FIR), Automatic	Base de datos propia (43 sujetos)	Power Spectral Density (PSD)	Naive Bayes, Neural Network, and SVM	97.7%

	Artifact Removal EOG (AAR-EOG), Artifact Subspace Reconstruction (ASR), and Independent Component Analysis (ICA)				
(Hendrawan et al., 2022)	ICA, Butterworth filter	Base de datos propia (8 sujetos)	The Power Spectral Density (PSD) feature is extracted from delta (0.5–4Hz), theta (4–8Hz), alpha (8–14Hz), beta (14–30Hz) and gamma (30–50Hz) bands, LDA	K-NN, SVM	80%
(Lai et al., 2022)	-	PhysioBank database (109)	CNN	CNN-ECOC-SVM	98.49%.
(Jijomon & Vinod, 2018)	Matlab edfread, 7.5 second window	PhysioNet database (109)	power spectral, PSD, Mean Correlation Coefficient (MCC)	Método propuesto por el autor	error rate of 0.016
(Waili et al., 2019)	2nd order Butterworth filter	Base de datos propia (6 sujetos)	Daubechies (db8) wavelet, PSD	Multilayer Perceptron Neural Network (MLPNN)	75.8%
(Jijomon Chettuthara Monsy, 2020)	Matlab edfread	PhysioNet database (16 sujetos)	frequency-weighted power (FWP)	Método propuesto por el autor	(EER) of 0.0039

Tabla 3-2: Métodos de extracción de características y clasificación de emociones, tomado de (BENÍTEZ ALDÁS, 2018; Li et al., 2023; Sovatzidi & Iakovidis, 2023).

Autores	Año	Preproceso	Extracción y selección	Clasificación de emociones
Murugappan, Nagarajan Ramachandran	2010	Filtro de superficie Laplaceano	Transformada wavelet. Fuzzy C Means (FCM) and Fuzzy K- Means (FKM)	Linear Discriminant Analysis (LDA) And k Nearest Neighbor (K-NN)
You-Yun Lee, Shulan Hsich	2014	FFT, EEGLAB	Correlación, Coherencia y sincronización de fase.	Análisis de discriminante Cuadrático
Daniela Iacovielloa Andrea Petraccab	2015	Filtro wavelet	PCA	SVM
Nitin Kumar, Kaushikee Khaund	2015	Blind source separation Blind Source separation technique Filtro de paso de banda 4.0-45.0 Hz	HOSA (Higher order Spectral Analysis)	LS-SVM, Artificial Neural Networks (ANN)
Nitin Kumar, Kaushikee Khaund	2016	Filtro Butterworth	Analisis Biespectral con HOSA	SVM
G. Mejía, A. Gómez	2016	Filtros Butterworth	Transformada wavelet estacionaria	Quadratic discriminant analysis (QDA)
Yong Zhang, Xiaomin Ji	2016	Algoritmo basado en Análisis Independiente de Componentes	Entropía de muestras, Entropía Cuadrática, Distribución de Entropía	SVM
Beatriz García	2016	Algoritmo basado en Análisis de Componentes independientes	Entropía de muestras, Entropía Cuadrática, Distribución de Entropía	SVM
Yasar Dasdemir, Esen Yildirim	2017	EEGLAB, MARA, AAR	Valor de bloqueo de Fase(PLV) con ANOVA para medir significancia.	SVM
Moon Inder Singh, Mandeep Singh	2017	Filtro de superficie Laplaceano	Transformada wavelet	SVM Polinomial
Baharch Nakisa, Mohammad Naim Rastgoo	2018	Filtro Butterworth y Notch	Algoritmos ACA, SA, GA, SPO	SVM

Jia Wen Li, Xiangyu Zeng, Huiming Zhao	2023	DWT, EMD	smoothed pseudo- Wigner–Ville distribution (RSPWVD)	K-NN, SVM, LDA, and LR
Georgia SOVATZIDI, Dimitris K. IAKOVIDIS	2023	Finite Impulse Response, Artefact Subspace Reconstruction (ASR)	Power Spectral Density (PSD)	Naïve Bayes (NB), K-NN, SVM, Fuzzy Cognitive Map (FCM)

3.6.1 Máquinas de vectores de soporte

Las SVM son un conjunto de algoritmos de aprendizaje supervisados que desarrollan métodos relacionados con los problemas de clasificación y regresión.

En las SVM se representan los datos de entrada como vectores en un espacio de muchas dimensiones. Estos datos consisten en un conjunto de puntos que pertenecen a una de dos categorías posibles. El objetivo de un algoritmo SVM es construir un modelo que pueda predecir si un nuevo punto (cuya categoría es desconocida) pertenece a una de esas categorías. El modelo de SVM busca encontrar el hiperplano de separación óptimo que maximiza la distancia entre las categorías, lo que permite tomar decisiones precisas sobre la clasificación de nuevos datos (ARIOSRAMIREZ, 2017). En la **Figura 3-2** se ilustra un conjunto de muestra separados por un hiperplano

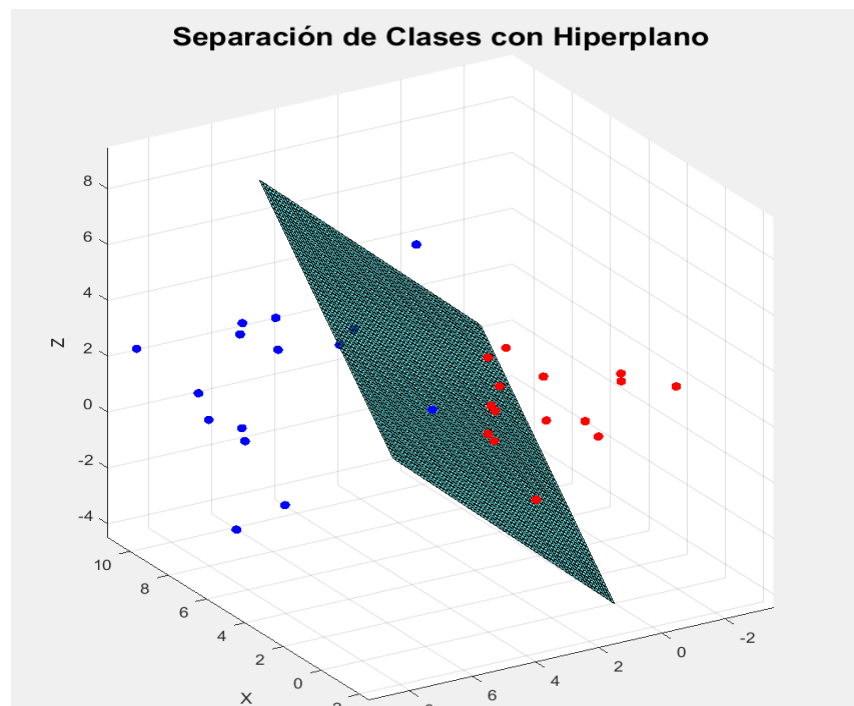


Figura 3-3: Ilustración de SVM creado en Matlab

Las ecuaciones que describen este método son las siguientes:

Función de Decisión: En una SVM lineal, la función de decisión para clasificar una muestra x se calcula tomando el producto punto entre el vector de características x y el vector de pesos w , al que se suma el sesgo b :

$$f(x) = w \cdot x + b \quad (3-6)$$

Para definir el margen entre clases y encontrar el hiperplano que maximiza el margen, se utiliza la función de costo, que se define como:

$$L(y_i, f(x_i)) = \max(0, 1 - y_i \cdot f(x_i)) \quad (3-7)$$

En casos en los que las clases no son linealmente separables en el espacio de características, se utiliza el truco del núcleo (kernel trick) para transformar los datos en un espacio de mayor dimensión donde puedan ser linealmente separables. Algunos núcleos comunes incluyen el núcleo lineal, el núcleo polinomial y el núcleo de función de base radial (RBF).

3.6.2 K vecinos más cercanos

k vecinos más cercanos, también conocido como K-NN, es un clasificador de aprendizaje supervisado no paramétrico, que utiliza la proximidad para hacer clasificaciones o predicciones sobre la agrupación de un punto de datos individual, como se ilustra en la **Figura 3-3** siendo p una muestra que evalúa las clases más cercanas a ella (Atallah et al., 2019).




Figura 3-4: Ilustración de K-NN tomada de (Atallah et al., 2019)

Este modelo puede ser usado para problemas de regresión o clasificación, K-NN estima el valor de la función de densidad de probabilidad o directamente la probabilidad a posteriori de que un elemento x pertenezca a la clase C_j a partir de la información proporcionada por el conjunto de ejemplos (Izanami et al., 2021)

En primer lugar, se debe definir el valor de k vecinos, luego se lleva a cabo la medición de la distancia, seguida de la selección de vecinos y , finalmente, la clasificación o regresión.

Para calcular la distancia entre dos muestras, x e y , se utiliza una métrica de distancia, como la distancia euclidiana, que es comúnmente empleada.

$$\text{Distancia}(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3-8)$$

Para la selección de los K vecinos más cercanos a una muestra de prueba $x_{pruebas}$, las muestras se ordenan según su distancia a $x_{pruebas}$ y se eligen las primeras K muestras.

En cuanto a la clasificación, la clase más común entre los K vecinos se asigna como la clase de la muestra de prueba $x_{pruebas}$.

3.6.3 Redes neuronales

Una Red Neuronal Artificial (RNA) es un modelo matemático inspirado en el comportamiento biológico de las neuronas y en cómo se organizan formando la estructura del cerebro. Las redes neuronales intentan aprender mediante ensayos repetidos como organizarse mejor a sí mismas para conseguir maximizar la predicción (Javier et al., 2009).

El primer modelo matemático de una neurona artificial, creado con el fin de llevar a cabo tareas simples, fue presentado en el año 1943 en un trabajo conjunto entre el psiquiatra y neuroanatomista Warren McCulloch y el matemático Walter Pitts. Un modelo de red neuronal se compone de nodos, que actúan como entrada, salida o procesadores intermedios. Cada nodo se conecta con el siguiente conjunto de nodos mediante una serie de trayectorias ponderadas. Basado en un paradigma de aprendizaje, el modelo toma el primer caso, y toma inicial basada en las ponderaciones. Se evalúa el error de predicción y modifica las ponderaciones para mejorar la predicción, a continuación, se evalúa el siguiente caso con las nuevas ponderaciones y se modifican para mejorar la predicción de los casos ya evaluados, el ciclo se repite para cada caso en lo que se denomina la fase de preparación o evaluación. Cuando se ha calibrado el modelo, con la muestra test se evalúan los resultados globales, en la **Figura 3-4** se ilustra la distribución de una red neuronal.




Figura 3-5: Interpretación de un modelo de red neuronal

Neurona Artificial:

La salida de una neurona artificial, también conocida como perceptrón, se calcula tomando la suma ponderada de las entradas, seguida de la aplicación de una función de activación. La ecuación se puede expresar de la siguiente manera:

$$y = f(\sum_{i=1}^n w_i x_i + b) \quad (3-9)$$

y es la salida de la neurona.

f es la función de activación.

w_i son los pesos asociados con las entradas x_i

b es el sesgo.

Función de Activación:

Las funciones de activación introducen no linealidades en la red, lo que permite a las redes neuronales aproximar funciones más complejas. Algunas de las funciones de activación más comunes son la Unidad Lineal Rectificada (ReLU) y la función sigmoide.

ReLU:

$$f(x) = \max(0, x) \quad (3-10)$$

Sigmoide:

$$f(x) = \frac{1}{1+e^{-x}} \quad (3-11)$$

La función de pérdida mide la discrepancia entre las salidas de la red neuronal y los valores esperados (etiquetas) y se utiliza para ajustar los parámetros de la red durante el proceso de entrenamiento. Ejemplos de funciones de pérdida incluyen el Error Cuadrático Medio (MSE) y la Entropía Cruzada.

MSE (Error Cuadrático Medio): La fórmula del Error Cuadrático Medio se expresa de la siguiente manera:

$$L(y_{verdadero}, y_{predicho}) = \frac{1}{n} \sum_{i=1}^n (y_{verdadero}^i - y_{predicho}^i)^2 \quad (3-12)$$

Entropía Cruzada (para problemas de clasificación): La fórmula de la Entropía Cruzada para problemas de clasificación se expresa como:

$$L(y_{verdadero}, y_{predicho}) = - \sum_i y_{verdadero}^i \log(y_{predicho}^i) \quad (3-13)$$

3.6.4 Árboles de decisión

Los árboles de decisión (RF) son una estructura jerárquica compuesta por un conjunto de nodos internos y nodos hoja (Rivera-Lopez & Canul-Reich, 2017) que clasifican un conjunto de datos, al clasificarlos desde el nodo raíz hasta algún nodo hoja. Cada nodo interno en el árbol especifica una condición de prueba que evalúa uno o varios atributos, y cada rama descendiente del árbol representa una secuencia de decisiones hechas por el modelo para determinar la membresía de la clase de un nuevo ejemplo no clasificado (Mitchell, 1997). A diferencia de otros modelos de clasificación considerados como cajas negras, los árboles de decisión son modelos de caja blanca que permiten ver de manera clara porque el modelo clasifica de una forma u otra, o argumentar dicha clasificación (Flores Rodríguez, 2021). En la **Figura 3-5** se ilustra un RF y su organización (Khan et al., 2021).

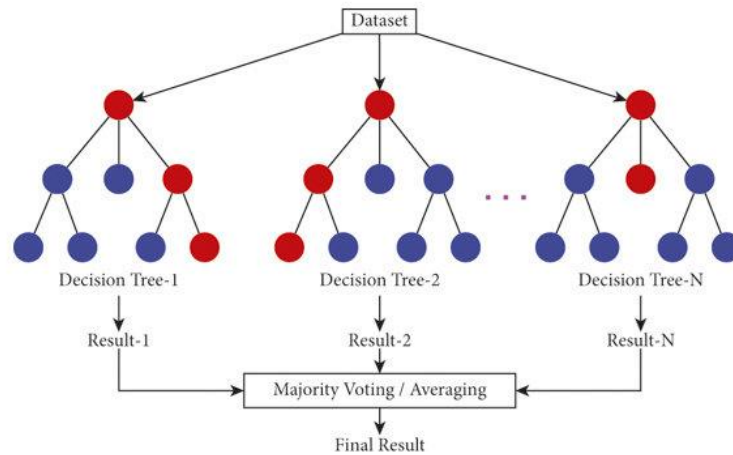


Figura 3-6: Interpretación de un árbol de decisión tomado de (Khan et al., 2021)

3.6.5 Regresión lineal

La regresión lineal es un algoritmo de aprendizaje supervisado que se utiliza en Machine Learning y en estadística. En su versión más sencilla, lo que haremos es “dibujar una recta” que nos indicará la tendencia de un conjunto de datos continuos (Larisparido, 2022)




Figura 3-7: Representación de regresión lineal

En la Figura 3-6 Los puntos simbolizan los datos de estudio y la recta representa el modelo de regresión lineal. La esencia de este modelo es capturar la relación lineal entre las variables, permitiendo hacer predicciones o inferencias sobre nuevos datos basándose en la tendencia observada en el conjunto de datos existente.

3.7 Fusión de datos

La fusión de datos, se refiere al proceso de combinar información de múltiples fuentes o modalidades para tomar decisiones más informadas o mejorar el rendimiento en una tarea específica. La fusión de datos es comúnmente utilizada en una variedad de aplicaciones, incluyendo la identificación biométrica, el reconocimiento de patrones, el procesamiento de señales y la toma de decisiones.

En la fusión de datos, las fuentes de información pueden ser de diferentes tipos, como datos numéricos, imágenes, texto, señales, o cualquier otra forma de datos. El objetivo principal de la fusión de datos es aprovechar la complementariedad de las diferentes fuentes de información para obtener una representación más completa y precisa de los datos o tomar decisiones más acertadas.

Existen varios enfoques para la fusión de datos, que incluyen:

- Fusión de características: Se combinan características extraídas de diferentes fuentes de datos en un solo conjunto de características (Liu et al., 2009).
- Fusión de decisiones: Se combinan las decisiones tomadas por diferentes algoritmos o modelos en una decisión final (Dwivedi & Dey, 2019).
- Fusión de niveles: Se fusionan datos en diferentes niveles de procesamiento, como el nivel de sensores o el nivel de decisión (Mohammad H. Safavipour, Mohammad Ali Doostari, 2023).
- Fusión de conocimiento: Se utiliza información semántica o contextual para combinar datos de manera más inteligente (Maneet Singh¹, Richa Singh¹, 2019).
- Fusión de aprendizaje automático: Se utilizan modelos de machine learning para combinar información de diferentes fuentes y tomar decisiones basadas en esta información combinada (Haider Mehraj¹, 2021).

La fusión de datos es especialmente útil cuando se trabaja con datos incompletos, ruidosos o ambiguos, ya que puede ayudar a mejorar la calidad de los resultados finales. También es fundamental en aplicaciones que requieren toma de decisiones en tiempo real o en entornos donde la redundancia de información es beneficiosa (Ulukaya et al., 2023).

3.7.1 Stacking

El stacking (apilamiento) se presenta como una estrategia poderosa para mejorar el rendimiento predictivo de los modelos.

Se tienen N modelos de machine learning entrenados para resolver un problema específico. Cada modelo produce una salida que denotamos como (X) , donde i representa el modelo específico y X son las características de entrada.

El proceso de *stacking* implica entrenar un modelo adicional, conocido como meta-modelo, que toma las salidas de los modelos base como características de entrada y genera una decisión final. Denotamos esta salida final como $S(X)$ (Fernández, 2021).

Matemáticamente, el proceso de stacking se puede representar de la siguiente manera:

1. Entrenamiento de modelos base: Se tienen N modelos de machine learning, y cada uno produce una salida:

$$M_1(X), M_2(X), \dots, M_n(X).$$

2. Combinación de salidas: Las salidas de los modelos base se combinan en un vector de características de entrada para el meta-modelo:

$$Z = [M_1(X), M_2(X), \dots, M_n(X)].$$

3. Entrenamiento del meta-modelo: El meta-modelo, que puede ser cualquier algoritmo de machine learning, se entrena utilizando el vector de características Z y las etiquetas o valores objetivo correspondientes.
4. Predicción final: Una vez que el meta-modelo está entrenado, se puede utilizar para hacer predicciones en nuevas instancias de datos:

$$S(X) = \text{Meta} - \text{Model}(Z).$$

El objetivo del *stacking* es aprovechar la diversidad de los modelos base y permitir que el meta-modelo aprenda a combinar sus salidas de manera óptima para mejorar el rendimiento general. El proceso de entrenamiento del meta-modelo generalmente implica la optimización de sus parámetros para minimizar una función de pérdida específica (Tahseen & Danti, 2022).

4 Materiales y Métodos

En el marco de nuestra metodología, hemos adoptado un enfoque integral para la identificación biométrica a partir de señales EEG, considerando los múltiples estados emocionales. Para ello, se seleccionaron cuidadosamente cuatro bases de datos esenciales, comúnmente utilizadas en la identificación biométrica y el reconocimiento de emociones: DEAP, MAHNOB, SEED y LUMED. Estas han sido identificadas en la revisión de la literatura como bases de datos relevantes y frecuentemente empleadas en estudios similares.

Inicialmente, cada base de datos se analiza de manera independiente para evaluar la variabilidad y consistencia de las señales EEG entre diferentes sujetos y emociones. Posteriormente, para enriquecer nuestro análisis y aumentar la robustez de nuestro modelo biométrico, los datos de estas bases son combinados. Este enfoque nos permite aprovechar la diversidad de las muestras y mejorar la generalización del modelo desarrollado.

El esquema metodológico se presenta de manera estructurada como se muestra en la figura 4-1. Se comienza con un proceso de preprocesamiento destinado a garantizar la calidad y coherencia de los

datos. Posteriormente se desglosa en dos escenarios fundamentales: la identificación de emociones y el reconocimiento biométrico.

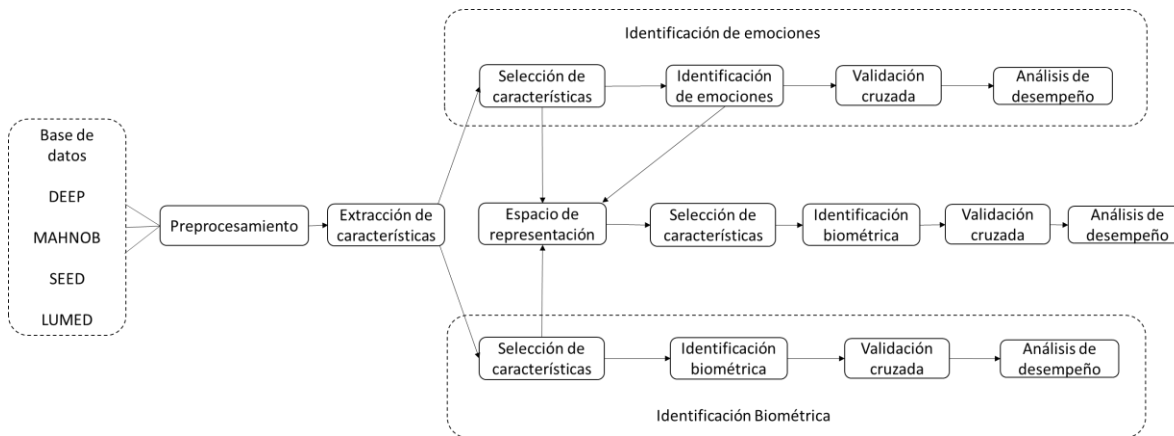


Figura 4-1: Metodología propuesta

4.1 Bases de datos

El creciente interés de los investigadores en el campo de la identificación biométrica ha llevado a la comunidad de investigadores a desarrollar una serie de bases de datos de señales EEG públicas, las cuales se han destinado en gran medida al estudio de los estados emocionales asociados a esas señales, para nuestro estudio se proponen las bases de datos DEAP, SEED, MAHNOB-HCI y LUMED, las cuales han sido muy utilizadas en este campo por ser de fácil acceso, y contener señales con periféricos y algunas de ellas tener preprocesamiento y caracterización, lo que permite realizar pruebas rápidas

4.1.1 DEAP

Esta base de datos cuenta con señales EEG y señales fisiológicas periféricas de 32 participantes, cada participante visualizó 40 videos musicales (extractos de 1 minuto) los cuales se calificaron en niveles de excitación (arousal), valencia, gusto, dominancia y familiaridad. De los 32 participantes 50% fueron femeninos con edades entre 19 y 37 y los hombres con una media de edad de 26.9, también se realizaron grabaciones periféricas de Electrooculograma (EOG), 4 de EMG (músculos cigomático mayor y trapecio), galvanic skin response (GSR), presión de volumen en sangre (BVP), temperatura y respiración. Adicionalmente, a 22 participantes se le realizaron grabaciones de su cara frontal, Las señales fueron grabadas de 32 canales a 512Hz (Koelstra et al., 2012).

4.1.2 MAHNOB

La base de datos cuenta con 27 participantes 11 hombres y 16 mujeres. Las grabaciones de señales EEG se grabaron en 32 canales a 256 Hz, también se realizaron videos de grabación de rostro y cuerpo usando 6 cámaras (60f/s), eye gaze (60 Hz) y audio a 44.1 kHz, Se grabaron 20 videos de los

cuales se obtiene *emotional keyword*, arousal, valencia, dominio, previsibilidad y se manejó un rango de evaluación de 1 a 9 (M. Soleymani, J. Lichtenauer, 2012).

4.1.3 SEED

Esta base de datos consta de señales EEG de 7 hombres y 8 mujeres con una media de edad entre 23 y 27 años y una desviación estándar de 2,37 años, para la base de datos se eligieron 15 clips de películas chinas como material de estímulo para generar emociones positivas, negativas y neutras, cada experimento consta de 15 ensayos, las señales EEG son tomadas con un gorro que cumple el sistema internacional 10-20 para 62 canales, estas señales son preprocesadas y fueron filtradas a 200 Hz, las etiquetas de cada señal corresponden a (-1 para negativo, 0 para neutral y +1 para positivo) (Wei-Long Zheng, n.d.).

4.1.4 LUMED-2

Loughborough University Multimodal Emotion Database-2 (LUMED-2) es un nuevo conjunto de datos de emociones multimodales que contiene la recopilación de datos multimodales simultáneos de 13 participantes (6 mujeres y 7 hombres) mostrando estímulos audiovisuales. La duración total de todos los estímulos es de 8 minutos y 50 segundos, que consisten en breves videoclips seleccionados de la web para provocar emociones específicas. después de cada sesión, se pidió a los participantes que etiquetaran los clips con el estado emocional sentido mientras los veían. Tres emociones diferentes resultaron del etiquetado: "triste", "neutral" y "feliz". Las expresiones faciales de los participantes se capturaron utilizando una cámara web a una resolución de 640x480 y a 30 f/s. Los datos de EEG de los participantes se capturaron utilizando un dispositivo de EEG inalámbrico ENOBIO de 8 canales, que tiene una resolución temporal de 500 Hz. Se filtraron los datos de EEG para el rango de frecuencia [0, 75Hz] y aplico la resta de la línea de base para cada ventana. En cuanto a los datos fisiológicos periféricos, se utilizó una pulsera EMPATICA E4, alimentada por Bluetooth, para registrar el GSR de los participantes (Erhan Ekmekcioglu, 2020).

4.2 Preprocesamiento

El preprocesamiento de las señales crudas se divide en tres pasos: 1) eliminación del ruido, 2) segmentación y 3) solapamiento de ventanas, que pueden ocurrir durante la segmentación. No todos estos pasos son necesarios, y dependiendo del sistema particular o del diseño experimental, algunos de estos pasos pueden omitirse. Las siguientes tres secciones se llevó a cabo un detallado preprocesamiento de las señales EEG de las bases de datos DEAP, SEED, Lumed, Mahnob. Considerando la importancia de las bandas específicas para el análisis, se aplicó la normalización de datos con el objetivo de homogeneizar los valores de las señales en un rango de 0 a 1, estrategia respaldada para optimizar la eficacia de algoritmos de machine learning.

En cuanto al filtrado, se abordaron desafíos relacionados con Las señales EEG a menudo están contaminadas por otros bioseñales como parpadeos, pulsaciones cardíacas y ruidos eléctricos ambientales, así como interferencias eléctricas como el ruido de 60 Hz, relevante en Colombia. Para lograr una señal aceptable, a veces se vuelve necesario realizar un preprocesamiento de las señales EEG. Para ello se emplearon filtros pasa bandas con frecuencias de corte específicas: para la banda delta (0.5-4 Hz), teta (4-8 Hz), alfa (8-13 Hz), beta (13-30 Hz) y gamma (30-45 Hz). Estas frecuencias

de corte se seleccionaron cuidadosamente para cada banda, preservando la información relevante y eliminando componentes no deseados.

Además, se utilizaron técnicas avanzadas como el Análisis de Componentes Independientes (ICA), el Análisis de Componentes Principales (PCA), y diversos filtros adaptativos, wavelet, notch, y espaciales. Complementariamente, se aplicaron filtros de promedio móvil para suavizar las señales EEG, conforme a las buenas prácticas de la literatura. Este enfoque integral de preprocesamiento establece las condiciones para un análisis preciso y robusto de las señales EEG

Después de la eliminación del ruido en la señal cruda, generalmente se realiza un paso de segmentación. Una grabación continua potencialmente contiene múltiples eventos de interés distribuidos dentro de la señal. La segmentación sirve al menos para dos propósitos: 1) dividir la larga serie en segmentos para aislar los eventos de interés; 2) normalizar el número de muestras para la extracción de características.

En este trabajo, se llevó a cabo una serie de investigaciones sobre la optimización de la segmentación basada en la Transformada wavelet. La señal cruda se segmentó en varias ventanas no solapadas después de la eliminación de ruido. Inicialmente, cada grabación de 1 minuto se dividió en ventanas de tamaño 256, con pasos entre ventanas de 128, para la extracción de características. Se encontró que el rendimiento biométrico es bastante sensible al tamaño de la ventana.

La superposición es un procedimiento comúnmente empleado en algunas tareas de procesamiento de señales y reconocimiento de patrones, donde las ventanas de segmentación se superponen entre sí. Esto puede proporcionar una mejor oportunidad para capturar eventos intactos y evitar que eventos potencialmente significativos sean divididos por la segmentación. La cantidad óptima de superposición a menudo es una cuestión de evaluación empírica: comúnmente se puede utilizar un 50% de superposición de ventanas [47]. Con un 50% de superposición entre ventanas adyacentes, el número total de ventanas se duplica, lo que indica que la cantidad de características también se duplica. Por lo tanto, la información revelada a partir de los datos potencialmente aumenta, aunque la carga computacional también se incrementa.

4.3 Extracción de Características

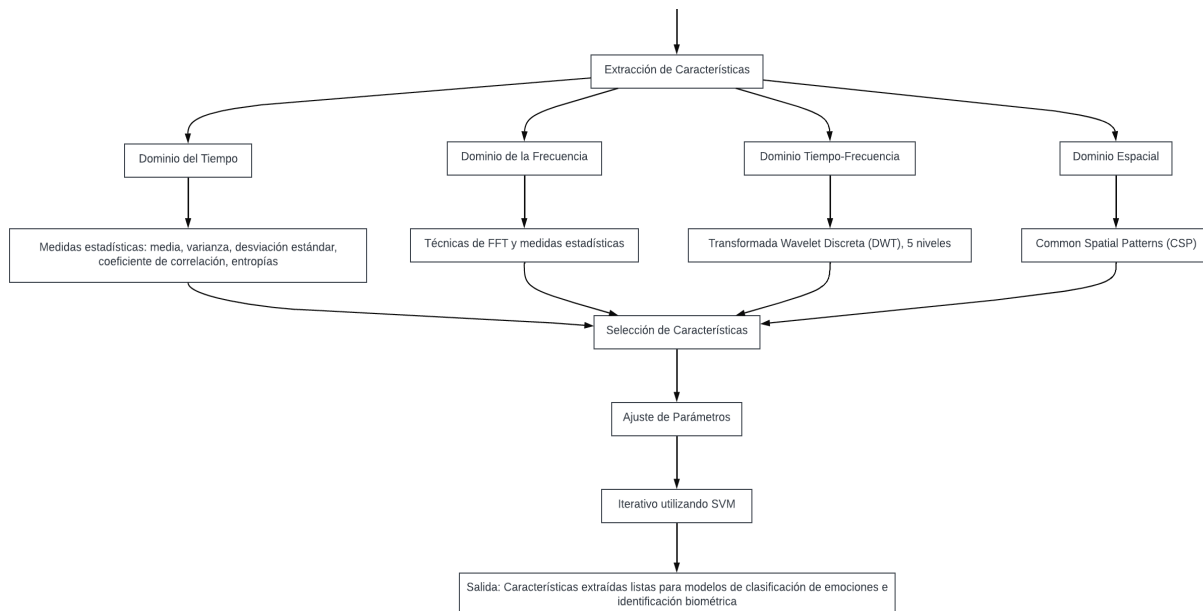
La extracción de características es una etapa fundamental en el procesamiento de señales EEG para su posterior aplicación en identificación biométrica y reconocimiento de emociones. En este estudio, se emplearán diversas técnicas para la extracción de características en el dominio del tiempo, frecuencia, tiempo-frecuencia, espaciales y no lineales para describir de manera efectiva las características de cada una de las señales EEG. Es importante resaltar que no todas las bases de datos tienen el mismo número de señales por los que los resultados pueden presentar variaciones en términos del peso de las características. En el dominio del Tiempo calcularon diversas medidas estadísticas lineales como no-lineales así: media, varianza, desviación estándar, coeficiente de correlación y diferentes tipos de entropía. En el dominio de la Frecuencia se calcularon las medidas estadísticas sobre los resultados entregados por Transformada Rápida de Fourier (FFT). Se calculó la transformada wavelet discreta descomponiendo la señal en 5 niveles, posibilitando el análisis

simultáneo de intervalos largos para información de baja frecuencia y cortos para información de alta frecuencia. Las decisiones sobre qué técnicas de extracción de características utilizar se basaron en la naturaleza de las señales EEG y los objetivos específicos del estudio. Por ejemplo, se emplearon diversas Wavelet madre (Daubechies, Mexican Hat y Symlet) debido a sus diferencias inherentes en la captura de detalles de las señales a diferentes escalas de frecuencia, lo cual es crucial para distinguir entre emociones y para la identificación biométrica. Finalmente, se obtuvieron características a partir de la técnica espacial Common Spatial Patterns (CSP) para proyectar señales EEG en un subespacio destacando diferencias y minimizando similitudes.

El ajuste de los parámetros de las transformadas y las entropías se realizó mediante un proceso iterativo de prueba y error con el algoritmo SVM, tanto para la construcción del modelo de clasificación de emociones, así como para la identificación de los individuos seleccionando aquellos parámetros que maximizaron la exactitud de los modelos. El procedimiento se hizo por bloques de características.

En la **Figura 4-2** se ilustra el diagrama de flujo de las etapas clave en el procesamiento de señales EEG para la extracción y selección de características. El proceso comienza con la entrada de datos EEG, seguido por la extracción de características en varios dominios: temporal, frecuencial, tiempo-frecuencia y espacial. Cada dominio implica el cálculo de medidas específicas, como estadísticas en el dominio del tiempo, transformadas FFT en el dominio de la frecuencia, la Transformada Wavelet Discreta (DWT) en el dominio tiempo-frecuencia, y patrones espaciales comunes (CSP) en el dominio espacial. Una vez extraídas, las características se someten a un proceso de selección para identificar las más relevantes para los objetivos del estudio. Posteriormente, se ajustan los parámetros iterativamente. El resultado final son características listas para su uso en modelos de clasificación de emociones e identificación biométrica.

Figura 4-2: Diagrama de flujo de las etapas de caracterización



4.4 Selección de Características

La selección de características en señales EEG se realizó mediante el algoritmo ReliefF. Este método, basado en aprendizaje de muestras, evaluó la relevancia de cada característica, asignándoles pesos según su capacidad para distinguir entre clases cercanas.

Como criterios de selección se establecieron normas específicas para la selección de características, considerando la importancia asignada por el algoritmo ReliefF. La selección de características mediante ReliefF es particularmente adecuada para este estudio debido a su capacidad para evaluar la importancia de las características en el contexto de muestras que son similares, pero pertenecen a diferentes clases. Este método es ideal para señales EEG, donde las diferencias sutiles entre clases (por ejemplo, diferentes emociones o individuos) pueden ser cruciales. ReliefF permite una evaluación detallada y diferenciada, priorizando características que consistentemente distinguen entre clases cercanas. La selección de características basada en pesos más altos es crucial, ya que dichas características demuestran una mayor capacidad discriminativa, esencial tanto para la identificación biométrica como para el reconocimiento de emociones.

La efectividad de las características seleccionadas fue validada mediante pruebas utilizando conjuntos de datos independientes. Se analizaron métricas de desempeño como precisión y sensibilidad, mostrando mejoras significativas en la clasificación tras la selección de características. Los ajustes iterativos se basaron en la retroalimentación de estos desempeños, permitiendo afinar el proceso para adaptarlo específicamente a las variaciones y particularidades de las señales EEG. Estos ajustes aseguraron que la selección de características fuera robusta y adaptada a las necesidades específicas del estudio.

Se realizaron ajustes iterativos en el proceso de selección de características, considerando retroalimentación continua de los resultados obtenidos. Esto permitió refinar y mejorar la selección de características, adaptándola a las características específicas de las señales EEG utilizadas en el estudio.

La implementación de este método de selección de características no solo mejoró la eficiencia computacional al centrarse en las características más relevantes, sino que también contribuyó a un análisis más preciso y robusto de las señales EEG. La combinación de técnicas de extracción y el método ReliefF proporcionó una estrategia integral para la selección efectiva de características

La implementación de este método de selección de características no solo mejoró la eficiencia computacional al centrarse en las características más relevantes, sino que también contribuyó a un análisis más preciso y robusto de las señales EEG. La combinación de técnicas de extracción y el método ReliefF proporcionó una estrategia integral para la selección efectiva de características. En la **Tabla 4-1** se presenta la ponderación en promedio alcanzada por las características más relevantes en la descomposición wavelet. Es importante resaltar que la suma de la ponderación no es 1 pero eso obedece a que se calculó un promedio de la ponderación para las diferentes descomposiciones y canales.

Tabla 4-1: Características obtenidas de ReliefF con pesos

Bases de Datos	Característica 1	Peso 1	Característica 2	Peso 2	Característica 3	Peso 3	Característica 4	Peso 4
DEAP	EnSh	0.3	EnSamp	0.21	media	0.19	CSP	0.13
SEED	EnSh	0.25	CSP	0.13	EnSamp	0.12	media	0.15
MAHNOB	EnSh	0.22	EnSamp	0.09	CSP	0.16	media	0.11
LUMED-2	EnSh	0.29	EnSamp	0.14	CSP	0.15	media	0.12

4.5 Identificación de emociones

Se procedió al desarrollo de distintos modelos mediante la implementación de diversos algoritmos de aprendizaje automático. En primer lugar, se emplearon Máquinas de Vector Soporte (SVM) para construir un modelo de clasificación capaz de encontrar hiperplanos óptimos y separar distintas clases emocionales. Luego, se utilizó el algoritmo Random Forest, que se basa en un conjunto de árboles de decisión, con el fin de mejorar la precisión y la generalización del modelo. Asimismo, se implementaron Redes Neuronales, diseñando arquitecturas profundas para capturar patrones complejos y no lineales presentes en las señales EEG. Además, se recurrió a la Regresión Lineal para evaluar la relación lineal entre ciertas características y estados emocionales. También se aplicó el algoritmo K-NN considerando el principio de parsimonia.

En la etapa de Entrenamiento y Validación, se dividió el conjunto de datos en conjuntos específicos para cada modelo. Se llevaron a cabo iteraciones de entrenamiento y validación cruzada, permitiendo así ajustar los parámetros y evaluar la capacidad de generalización de los modelos.

Posteriormente, se procedió a la Optimización de Hiperparámetros, donde se ajustaron aspectos clave de los modelos, como la selección del kernel en SVM o la profundidad de los árboles en Random Forest. Esta fase se llevó a cabo mediante técnicas de búsqueda, con el propósito de mejorar el rendimiento de cada algoritmo.

La Evaluación del desempeño de cada modelo fue exhaustiva, utilizando métricas como precisión, sensibilidad y especificidad. Se realizó un análisis detallado de las matrices de confusión para obtener una comprensión más profunda del comportamiento de los modelos.

Para culminar, se llevó a cabo un Análisis Comparativo entre los modelos SVM, Random Forest, k-NN, Redes Neuronales y Regresión Lineal. Este análisis permitió identificar el enfoque más efectivo en la tarea específica de identificación de emociones.

4.6 Identificación Biométrica:

En la fase de Identificación Biométrica, se emplearon distintos algoritmos de aprendizaje automático para desarrollar modelos robustos y precisos. Entre ellos, se destacó el uso de Máquinas de Soporte Vectorial (SVM), un algoritmo que busca encontrar hiperplanos óptimos para separar y

clasificar de manera eficiente las diferentes clases biométricas. Además, se implementó Random Forest, una técnica basada en conjuntos de árboles de decisión, con el objetivo de mejorar la precisión y la capacidad de generalización del modelo biométrico.

En paralelo, se utilizaron Redes Neuronales, diseñando arquitecturas profundas para capturar patrones complejos y no lineales presentes en las señales biométricas. Complementariamente, se recurrió a la Regresión Lineal para evaluar la relación lineal entre ciertas características específicas y las distintas identidades biométricas.

La fase de Entrenamiento y Validación incluyó la partición del conjunto de datos en conjuntos específicos para cada modelo, seguida de iteraciones de entrenamiento y validación cruzada para ajustar parámetros y evaluar la capacidad de generalización.

La Optimización de Hiperparámetros se centró en ajustar aspectos clave de los modelos, tales como la selección del kernel en SVM o la profundidad de los árboles en Random Forest, a través de técnicas de búsqueda que permitieron mejorar el rendimiento biométrico.

La Evaluación del Desempeño se realizó exhaustivamente, utilizando métricas como precisión, sensibilidad y especificidad. Asimismo, se llevó a cabo un análisis detallado de las matrices de confusión para obtener una comprensión más profunda del comportamiento de los modelos biométricos.

Finalmente, se ejecutó un Análisis Comparativo entre los modelos SVM, Random Forest, Redes Neuronales y Regresión Lineal, con el propósito de identificar el enfoque más efectivo en la tarea específica de Identificación Biométrica.

4.7 Identificación Biométrica + Emociones:

En la fase de Identificación Biométrica con Emociones, se amplió el enfoque anterior para abordar la complejidad de identificar tanto la identidad biométrica como las emociones asociadas. Se utilizaron algoritmos de aprendizaje automático como Máquinas de Soporte Vectorial (SVM), Random Forest, K-NN, Redes Neuronales y Regresión Lineal.

El proceso de Entrenamiento y Validación involucró la división del conjunto de datos en segmentos específicos para cada modelo, con iteraciones de entrenamiento y validación cruzada para ajustar parámetros y evaluar la capacidad de generalización.

La Optimización de Hiperparámetros se llevó a cabo, focalizándose en ajustar aspectos clave de los modelos para mejorar el rendimiento tanto en la Identificación Biométrica como en la detección de emociones.

La Evaluación del Desempeño se realizó, utilizando métricas como precisión, sensibilidad y especificidad. Se llevó a cabo un análisis detallado de las matrices de confusión para comprender el comportamiento de los modelos en la tarea combinada.

A través de un Análisis Comparativo entre SVM, K-NN, Random Forest, Redes Neuronales y Regresión Lineal, se buscó identificar el enfoque más efectivo para la tarea dual de Identificación Biométrica con Emociones.

En adición a los métodos individuales de clasificación, se exploró la técnica de Fusión de Clasificadores para mejorar la precisión y robustez en la Identificación Biométrica y detección de emociones. Esta técnica implica combinar las salidas de múltiples algoritmos de aprendizaje automático para aprovechar las fortalezas de cada modelo y mitigar sus debilidades. Se uso fusión de clasificadores para SVM, Random Forest, K-NN, Redes Neuronales y Regresión Lineal. La fusión permitió mejorar la capacidad de generalización y la precisión del sistema en comparación con los clasificadores individuales. Los resultados de la fusión de clasificadores fueron evaluados usando las mismas métricas de precisión, sensibilidad y especificidad.

5 Resultados y Discusiones

5.1 Resultados

En la tabla 5-1 se presentan los resultados del análisis de relevancia obtenido con las diferentes bases de datos. Los mejores resultados fueron obtenidos de las características obtenidas de la transformada wavelet destacando la entropía de Shannon (EnSh), la entropía muestral (EnSamp), *Common Spatial Patterns (CSP)*, media de las señales Fp1, F7 y FC1

Tabla 5-1: Características relevantes obtenidas con el algoritmo Relief F en orden de relevancia

Bases de datos	CARACTERISTICAS			
DEAP	EnSh	EnSamp	media	CSP
SEED	EnSh	CSP	EnSamp	media
MAHNOB	EnSh	EnSamp	CSP	media
LUMED-2	EnSh	EnSamp	CSP	media

Esta investigación ha explorado la precisión 5 modelos de clasificación en la tarea de identificación biométrica, tanto en presencia como en ausencia de emociones, utilizando las bases de datos DEAP, SEED, MAHNOB y LUMED-2. Los resultados se presentan en la **Tabla 5-2**, **Tabla 5-3**, **Tabla 5-4** y **Tabla 5-5**, cada una reflejando diferentes aspectos de la clasificación biométrica.

En la **Tabla 5-2**, las Redes Neuronales emergen como el modelo más preciso para la predicción de emociones en la base de datos DEAP con un 94.3%, una cifra que es competitiva con los hallazgos de la literatura actual en predictores similares. Esto indica la capacidad de las Redes Neuronales para capturar la complejidad de la dinámica variable generada por las emociones sobre las señales EEG. Por su parte, las Máquinas de Vector Soporte (SVM) y Random Forest presentan una robustez y consistencia notables, con la SVM alcanzando una precisión de más del 90% en todas las bases de datos.

Tabla 5-2: Resultados promedio de precisión de los modelos de predicción de emociones.

Clasificadores	DEAP	SEED	MAHNOB	LUMED-2	Promedio
----------------	------	------	--------	---------	----------

Máquinas de vector soporte	91.12%	89.5%	93.2%	90.87%	91.17%
Random Forest	90.79%	92.84%	91.33%	90.42%	91.34%
K-NN	85.66%	87.71%	84.9%	86.54%	86.45%
Redes neuronales	94.3%	87.05%	84.76%	85.82%	87.98%
Regresión lineal	54.51%	43.88%	55.07%	46.34%	49.95%

Los rendimientos obtenidos son comparables con los estudios reportados en la literatura como los resultados obtenidos en la clasificación con K-NN, logrando una precisión del 84.4% (Galvão F., Alarcão S.M., 2021). Aunque las Máquinas de Vector Soporte y K-NN en este trabajo presentan resultados ligeramente inferiores a los reportados en trabajos previos (94.12%) (Sakalle A., Tomar P.a., 2021), siguen siendo competitivos, indicando que la optimización de características y la selección de canales podrían incrementar su precisión.

Las Máquinas de Vector Soporte (SVM) y Random Forest también muestran un rendimiento fuerte y consistente, con medias de precisión del 91.17% y 91.34% respectivamente, lo que las hace opciones confiables para la predicción de emociones. Estos modelos equilibran precisión y robustez, haciéndolos adecuados para aplicaciones prácticas donde se requieren modelos confiables y eficientes.

En la **Tabla 5-3** se presentan los resultados de la precisión de los clasificadores para las cuatro bases de datos consideradas en este estudio. Los resultados muestran la precisión promedio de distintos modelos de clasificación para la identificación biométrica, excluyendo el factor emocional. Los modelos de Máquinas de Vector Soporte presentan una alta precisión en todas las bases de datos, con la mayor precisión observada en DEAP, alcanzando un 90.49%. Por otro lado, el modelo de K-NN muestra una variabilidad considerable, con la precisión más baja en SEED (35.46%). La Regresión Lineal, sigue siendo consistentemente el modelo de menor rendimiento. Estos resultados sugieren que la eficacia de los modelos de clasificación biométrica puede depender significativamente del tipo de base de datos, y la selección de un modelo adecuado requiere considerar la naturaleza y características de los datos con los que se trabaja. Adicionalmente, las Máquinas de Vector Soporte (SVM) presentan el mejor rendimiento global con una media de precisión del 90.09%. Este resultado enfatiza la eficacia y generalidad de las SVM en la tarea de identificación biométrica, destacando su capacidad para trabajar eficientemente con datos complejos y de alta dimensión como los derivados de señales EEG.

Random Forest logra una precisión promedio de 84.76%, lo que muestra su robustez y capacidad para manejar datos variados. Las Redes Neuronales ofrecen un desempeño con una media del 82.54%, que, aunque no supera a las SVM, sí demuestra potencialidad en este campo.

Las Redes Neuronales ofrecen un desempeño con una media del 82.54%, que, aunque no supera a las SVM, sí demuestra su competencia en este campo.

Tabla 5-3: Resultados promedio de precisión de los modelos de clasificación para la identificación biométrica sin considerar las emociones

Clasificadores	DEAP	SEED	MAHNOB	LUMED-2	Promedio
Máquinas de vector soporte	90.49%	89.56%	90.21%	90.12%	90.09%
Random Forest	83.15%	84.1%	85.63%	86.17%	84.76%
K-NN	41.68%	35.46%	66.7%	74.92%	54.69%
Redes neuronales	90.22%	87.91%	78.34%	73.69%	82.54%
Regresión lineal	43.77%	42.65%	53.38%	51.04%	47.71%

Esta tesis aporta un enfoque innovador al considerar los estados emocionales de los individuos, un factor que ha presentado retos para la precisión de los sistemas biométricos. La inclusión de emociones busca no solo incrementar la precisión sino también la seguridad del sistema biométrico propuesto. Al comparar con investigaciones previas, es notable que los métodos existentes han logrado precisiones elevadas, como el 99% en sistemas de CNN con dos canales de EEG (Alsumari et al., 2023), o hasta el 97.83% con LSTM (Radwan S.H; El-Telbany; Arafa W.; Ali Rasha, 2022). Sin embargo, estas metodologías no tienen en cuenta la variabilidad emocional que puede afectar la consistencia de las señales EEG.

La propuesta de este estudio, al integrar la dimensión emocional, es que podría superar las precisiones reportadas previamente, ya que se enfoca en estabilizar la variabilidad que las emociones pueden introducir. Asimismo, este enfoque podría solventar las limitaciones observadas en métodos como el K-NN, que mostró una precisión reducida del 35.46% en la base de datos SEED (según los datos de la Tabla 5-3), sugiriendo que la incorporación de estados emocionales podría mejorar la robustez del modelo frente a variaciones en las señales.

Al comparar los resultados de la **Tabla 5-3** y la **Tabla 5-4**, se observa un incremento significativo en la precisión de los modelos de clasificación biométrica al incluir las emociones. Por ejemplo, las Máquinas de Vector Soporte (SVM) muestran un aumento del 3.73% en promedio, pasando de 90.09% (Tabla 5-3) a 93.82% (Tabla 5-4). Similarmente, Random Forest incrementa su precisión promedio en un 4.81%, de 84.76% a 89.57%. Este aumento de precisión refleja la capacidad de los modelos para capturar información adicional relevante cuando las emociones son consideradas. Las Redes Neuronales también experimentan una mejora del 6.3%, de 82.54% a 88.84%. Sin embargo, es notable que K-NN, aunque mejora de 54.69% a 58.59%, no alcanza la misma magnitud de mejora que los otros modelos, sugiriendo que su desempeño sigue limitado por su sensibilidad a la selección de características. La inclusión de emociones en la fusión de clasificadores muestra la mayor ganancia, llevando la precisión a 95.73%, lo cual resalta la efectividad de combinar diferentes enfoques para manejar la variabilidad emocional en la identificación biométrica.

Por otro lado, al evaluar los resultados presentados en la **Tabla 5-4**, se observa que la estrategia de Fusión de Clasificadores sobresale con una precisión de 98.35% en DEAP. Es importante resaltar que la fusión de clasificadores que mejor resultado presentó fue la realizada con la máquina de vector soporte utilizando como entrada la salida de los otros clasificadores. Este resultado entre diferentes

algoritmos puede ser especialmente efectiva debido a la capacidad de la SVM de manejar la alta dimensionalidad y complejidad de los datos de EEG emocionales.

Además, es notorio que los métodos de fusión tales como el voto mayoritario, mediana, media y el máximo, aunque ofrecen un enfoque diversificado para mejorar la confiabilidad de la clasificación, no alcanzaron la misma eficacia que la fusión centrada en la SVM. Esto podría sugerir que la calidad de la fusión depende no solo de la diversidad de los modelos sino también de la complementariedad y de cómo las fortalezas de un modelo pueden potenciar a otros.

Tabla 5-4: Resultados promedio de precisión de los modelos de clasificación para la identificación biométrica considerando las emociones

Clasificadores	DEAP	SEED	MAHNOB	LUMED-2	Promedio
Máquinas de vector soporte	94.57%	92.91%	93.76%	94.05%	93.82%
Random Forest	87.88%	88.37%	90.15%	91.89%	89.57%
K-NN	40.27%	45.61%	70.83%	77.65%	58.59%
Redes neuronales	96.78%	90.05%	89.23%	79.31%	88.84%
Regresión lineal	41.33%	39.44%	52.01%	49.23%	45.50%
Fusión de Clasificadores	98.35%	94.19%	94.84%	95.56%	95.73%

Al integrar las emociones en la clasificación biométrica como se muestra en la **Tabla 5-4**, la máquina de vector soporte sobresale significativamente, alcanzando la mayor precisión en casi todas las bases de datos, obteniendo un promedio de 93.82%. Este alto rendimiento respalda la premisa de que las emociones, cuando se integran adecuadamente, pueden mejorar significativamente la identificación biométrica.

Las redes neuronales muestran una mejora sustancial al considerar las emociones (**Tabla 5-4**), con una precisión de 96.78% en DEAP, frente a un 94.3% cuando solo se predice la emoción (**Tabla 5-2**) y un 90.22% en la identificación biométrica sin emociones (**Tabla 5-3**). Esto podría indicar que las Redes Neuronales se benefician del conjunto de datos que las emociones aportan, mejorando su capacidad de diferenciación entre los sujetos.

La Regresión Lineal muestra consistentemente el rendimiento más bajo en todas las mediciones, lo que refleja su inadecuación para tareas que requieren capturar relaciones no lineales complejas, como es el caso de la identificación biométrica a partir de señales EEG.

Tabla 5-5 Promedio de exactitud de modelos de clasificación

Modelos de Clasificación	Promedio Emociones	Promedio Biometría	Promedio biometría + emociones
Máquinas de vector soporte	91.17%	90.09%	93.82%
Random Forest	91.34%	84.76%	89.57%

K-NN	86.45%	54.69%	58.59%
Redes neuronales	87.98%	82.54%	88.84%
Regresión lineal	49.95%	47.71%	45.50%
Fusión de clasificadores	-	-	95.73%

En todos los casos de identificación biométrica mejora al evaluar las emociones, menos en la regresión lineal

Es importante destacar, como se muestra en la (Tabla 5.5) y la Figura 5-1, mientras la inclusión de emociones mejora significativamente la precisión en modelos complejos como las Redes Neuronales y SVM, el modelo K-NN no muestra la misma mejora, lo que indica la necesidad de una selección de características más refinada y tal vez un enfoque más especializado para datos emocionales. Adicionalmente, La Fusión de Clasificadores exhibe la mayor media de precisión con un 95.73%, lo que indica que la combinación estratégica de diferentes modelos puede aprovechar

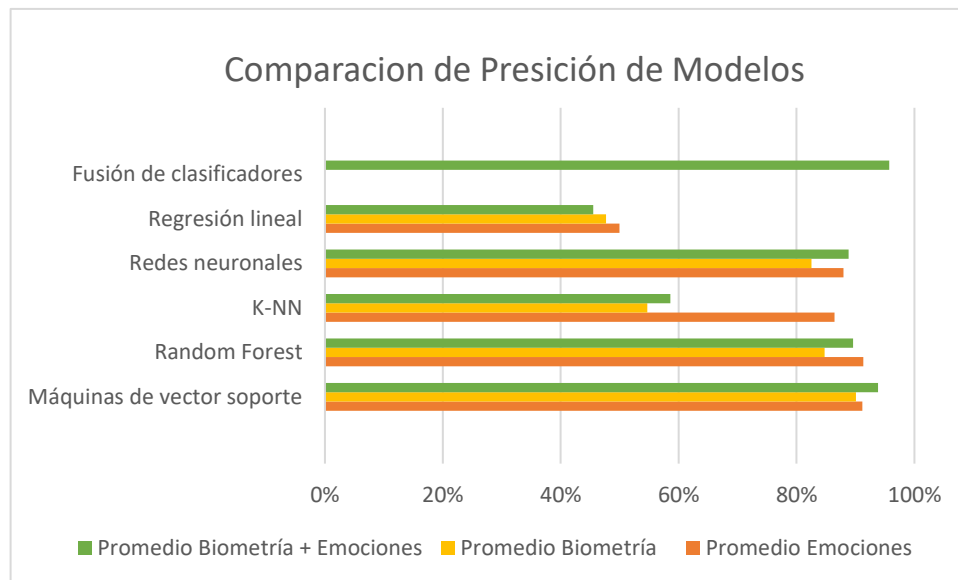


Figura 5-1: Promedio de exactitud de los diferentes modelos de machine learning

sus fortalezas individuales para mejorar significativamente el rendimiento general. Este alto nivel de precisión sugiere que la fusión de clasificadores es especialmente adecuada para manejar la variabilidad y complejidad introducida por las emociones en la identificación biométrica.

5.2 Discusión

La discusión de los resultados obtenidos en esta investigación ilustra el complejo paisaje de la identificación biométrica basada en EEG y la influencia de las emociones en la precisión de los modelos de clasificación. Los resultados mostraron que, aunque las Redes Neuronales alcanzaron una precisión considerable del 88.84% en la combinación de biometría y emociones, no fueron los

mejores entre los modelos evaluados. Las Máquinas de Vector Soporte (SVM) y el método de fusión de clasificadores destacaron con un 93.82% y un 95.73% de precisión respectivamente en el mismo escenario. Estos hallazgos no solo validan la eficacia de SVM y la fusión de clasificadores en el manejo de la complejidad emocional, sino que también sugieren su superioridad en la captura de características distintivas para la identificación biométrica. Este rendimiento es coherente con la literatura actual, que reconoce a SVM y a la fusión de clasificadores como herramientas poderosas en la clasificación de datos complejos.

Como modalidad biométrica, la implementación de señales EEG está afectada por diversos factores, lo que hace que métricas como las tasas de precisión (CRR, FAR y FRR) por sí solas no sean suficientes para representar su rendimiento. En esta tesis, se consideraron cuatro factores adicionales para evaluar el desempeño de un sistema biométrico: 1) el número de sujetos involucrados; 2) el número de electrodos utilizados; 3) el tamaño del conjunto de entrenamiento y 4) el tamaño del conjunto de prueba. Junto con la precisión, se calculó un puntaje de rendimiento utilizando los cinco factores. Sin embargo, la métrica propuesta tiene una limitación: no representa de manera efectiva los efectos del envejecimiento o cambio de las señales.

Por otro lado, la incorporación de la fusión de clasificadores ha resultado ser una estrategia prometedora, sobre todo cuando se centraliza en torno a la SVM, que actúa como un agregador de las salidas de otros modelos. Esta técnica ha superado la eficacia de métodos de fusión más convencionales como la media, mediana y el voto mayoritario, sugiriendo que la elección de modelos para la fusión debe ser estratégica y considerar la complementariedad de las fortalezas de cada clasificador.

Además, se debe resaltar la consistente subparidad de la Regresión Lineal en todas las mediciones, lo que refleja su inadecuación para tareas que requieren la captura de relaciones no lineales complejas, como es el caso de la identificación biométrica a partir de señales EEG. Esto reafirma la necesidad de modelos más sofisticados capaces de manejar la rica información contenida en las señales de EEG emocionales.

Se investigaron experimentalmente diversas cuestiones importantes relacionadas con el uso de señales EEG para el reconocimiento biométrico. Se encontró que, aunque convencionalmente el rango informativo de las señales EEG está entre 0 y 50 Hz o 60 Hz, en su implementación biométrica, la parte superior de la frecuencia (60 Hz-80 Hz) también es efectiva.

Se propusieron cuatro nuevas características biométricas basadas en EEG en la tesis. Dos de ellas se basan en la HHT y las otras dos son características basadas en wavelet. Las características derivadas de HHT, llamadas características InsAmp e InsFreq, proporcionaron el mejor rendimiento, mientras que las características wavelet lograron una menor precisión en ambos escenarios, de identificación y verificación.

El método propuesto permite la identificación biométrica y emocional con rendimientos comparables a los que se han mostrado previamente en la literatura.

6 Conclusiones

Los resultados de la investigación demuestran que las medidas de tiempo-frecuencia utilizadas para caracterizar las señales EEG poseen una capacidad discriminante considerable tanto para la identificación de emociones como de individuos. Las Máquinas de Vector Soporte (SVM), con una media de precisión del 93.82%, evidencian la efectividad de las características tiempo-frecuencia seleccionadas, cumpliendo con el objetivo de caracterización de señales EEG. Además, la Fusión de Clasificadores, que alcanza una precisión media del 95.73%, ilustra la potencia de combinar múltiples modelos para mejorar la discriminación, alineándose con la propuesta de una metodología de identificación biométrica teniendo en cuenta el estado emocional basada en máquinas de aprendizaje supervisado.

La metodología propuesta se ha validado con éxito a través de las medidas de desempeño, reflejando altas tasas de precisión en la clasificación biométrica, especialmente cuando se consideran las emociones en el análisis. Esto sugiere que la integración de las emociones en el modelo de identificación biométrica no sólo es viable, sino que mejora significativamente el rendimiento de los sistemas de clasificación. La fusión de clasificadores, en particular, destaca como un enfoque novedoso y robusto, superando a los modelos individuales en precisión y ofreciendo una solución confiable que podría ser aplicada en un contexto práctico.

La Tabla 5-1 revela que las características EnSh (entropía de Shannon), EnSamp (entropía de muestreo), CSP (Common Spatial Patterns) y la media, han sido identificadas como las más relevantes en la caracterización de las señales EEG a través de las bases de datos DEAP, SEED, MAHNOB y LUMED-2. La consistencia en la relevancia de estas características a través de diversas bases de datos enfatiza su robustez y su alta capacidad discriminante, lo que es crucial para alcanzar el primer objetivo de caracterizar las señales EEG para identificar emociones e individuos de manera efectiva.

Finalmente, la validación de la metodología propuesta, ahora con el apoyo de la relevancia de las características identificadas, refuerza las medidas de desempeño utilizadas para las técnicas de clasificación y de biometría. La precisión observada en la identificación biométrica, tanto en la presencia como en la ausencia de emociones, puede atribuirse en gran medida a la influencia de estas características discriminantes. Por lo tanto, se confirma que el tercer objetivo se ha logrado satisfactoriamente, con la metodología propuesta que demuestra su validez a través de un rendimiento de clasificación sólido y coherente.

7 Referencias

- A. K. Jain, A. R. and K. N. (2008). An introduction to biometrics. *International Conference on Pattern Recognition*, 1–1. <https://doi.org/10.1109/ICPR.2008.4760935>.
- Abdi Alkareem Alyasseri, Z., Alomari, O. A., Al-Betar, M. A., Awadallah, M. A., Hameed Abdulkareem, K., Abed Mohammed, M., Kadry, S., Rajinikanth, V., & Rho, S. (2022). EEG Channel Selection Using Multiobjective Cuckoo Search for Person Identification as Protection System in Healthcare Applications. *Computational Intelligence and Neuroscience*, 2022, 1–18. <https://doi.org/10.1155/2022/5974634>

- Alkeem E.A, Yeun C.Y, Yun J., Yoo P.D, Chae M., Chae M., Rahman A., A. A. T. (2021). *Robust Deep Identification using ECG and Multimodal Biometrics for Industrial Internet of Things*. 121(15708705). <https://doi.org/10.1016/j.adhoc.2021.102581>
- Alsumari, W., Hussain, M., Alshehri, L., & Aboalsamh, H. A. (2023). EEG-Based Person Identification and Authentication Using Deep Convolutional Neural Network. *Axioms*, 12(1). <https://doi.org/10.3390/axioms12010074>
- Alyasseri, Z. A. A., Alomari, O. A., Makhadmeh, S. N., Mirjalili, S., Al-Betar, M. A., Abdullah, S., Ali, N. S., Papa, J. P., Rodrigues, D., & Abasi, A. K. (2022). EEG Channel Selection for Person Identification Using Binary Grey Wolf Optimizer. *IEEE Access*, 10, 10500–10513. <https://doi.org/10.1109/access.2021.3135805>
- Amari, R. O. (2023). *IMPLEMENTACIÓN DE UNA INTERFAZ BCI PARA LA DETECCIÓN DE INTENCIÓN DE MOVIMIENTOS DE REHABILITACIÓN DE MIEMBRO SUPERIOR*. 31–41.
- Andrea F., M. (2016). Las Teorías De Las Emociones Y Su Relación Con La Cognición: Un Análisis Desde La Filosofía De La Mente. *Cuadernos de La Facultad de Humanidades y Ciencias Sociales- Universidad Nacional de Jujuy*, 49, 13–38. <http://www.redalyc.org/pdf/185/18551075001.pdf>
- ARIOSRAMIREZ. (2017). *PLATZI*. Máquinas de Vectores de Soporte (Clasificación y Regresión). <https://platzi.com/tutoriales/1180-redes-neuronales/2677-maquinas-de-vectores-de-soporte-clasificacion-y-regresion/>
- Atallah, D. M., Badawy, M., El-Sayed, A., & Ghoneim, M. A. (2019). Predicting kidney transplantation outcome based on hybrid feature selection and KNN classifier. *Multimedia Tools and Applications*, 78(14), 20383–20407. <https://doi.org/10.1007/s11042-019-7370-5>
- Bakheet, S., Al-Hamadi, A., & Youssef, R. (2022). A Fingerprint-Based Verification Framework Using Harris and SURF Feature Detection Algorithms. *Applied Sciences (Switzerland)*, 12(4). <https://doi.org/10.3390/app12042028>
- Barayeu, U., Horlava, N., Libert, A., & van Hulle, M. (2020). Robust Single-Trial EEG-Based Authentication Achieved with a 2-Stage Classifier. *Biosensors*, 10(9). <https://doi.org/10.3390/bios10090124>
- Belhadj, F. (2017). *Biometric system for identification aBelhadj, F. (2017). Biometric system for identification and authentication.nd authentication*.
- BENÍTEZ ALDÁS, M. R. (2018). Estudio y Análisis de Métodos para la Extracción de Características y Clasificación de Emociones Basados en EEG. *Universidad Autonoma De Madrid*, 143. https://repositorio.uam.es/bitstream/handle/10486/686643/benitez_aldas_marcosrafae_tfm.pdf?sequence=1&isAllowed=y
- Bilucaglia, M., Marco Duma, G., Mento, G., Semenzato, L., & Tressoldi, P. (2019). *EEG signal classification: an application to the emotion-related brain anticipatory activity*. December. <https://doi.org/10.20944/preprints201912.0340.v1>
- Biométrica, R. sistemas de identificación. (2023). *EQUIPOS PARA EL RECONOCIMIENTO FACIAL*. <https://www.reconoser.com.co/equipos-reconocimiento-facial.html>
- Bitbrain. (2020). *Colocación de electrodos EEG en un Layout Fijo vs. Variable*.

<https://www.bitbrain.com/es/blog/colocacion-electrodos-eeeg>

- Callaghan, G. (2023). *Progressive Graph Convolution Network for EEG Emotion Recognition*. 544, 126262–126262.
- Carla, F., Yanina, W., & Daniel Gustavo, P. (2017). ¿Cuántas Son Las Emociones Básicas? *Anuario de Investigaciones*, 26, 253–257.
- Carlos Gantiva, K. C. (2016). *CARACTERÍSTICAS DE LA RESPUESTA EMOCIONAL GENERADA POR LAS PALABRAS: UN ESTUDIO EXPERIMENTAL DESDE LA EMOCIÓN Y LA MOTIVACIÓN*. 10, 55–62. <https://www.redalyc.org/journal/2972/297248896005/html/>
- Chen, J. X., Mao, Z. J., Yao, W. X., & Huang, Y. F. (2020). EEG-based biometric identification with convolutional neural network. *Multimedia Tools and Applications*, 79(15–16), 10655–10675. <https://doi.org/10.1007/s11042-019-7258-4>
- Cui, G., Li, X., & Touyama, H. (2023). Emotion recognition based on group phase locking value using convolutional neural network. *Scientific Reports*, 13(1), 1–9. <https://doi.org/10.1038/s41598-023-30458-6>
- Curran, E. A., & Stokes, M. J. (2003). Learning to control brain activity: A review of the production and control of EEG components for driving brain-computer interface (BCI) systems. *Brain and Cognition*, 51(3), 326–336. [https://doi.org/10.1016/S0278-2626\(03\)00036-8](https://doi.org/10.1016/S0278-2626(03)00036-8)
- Daniel, I., & Isasa, V. (2020). *Detección y tratamiento de las señales EEG que permitan definir tareas de un drone*.
- Das, B. B., Ram, S. K., Pati, B., Panigrahi, C. R., Babu, K. S., & Mohapatra, R. K. (2021). SVM and Ensemble-SVM in EEG-Based Person Identification. *Advances in Intelligent Systems and Computing*, 1199, 137–146. https://doi.org/10.1007/978-981-15-6353-9_13
- Debie, E., Moustafa, N., & Vasilakos, A. (2021). Session Invariant EEG Signatures using Elicitation Protocol Fusion and Convolutional Neural Network. *IEEE Transactions on Dependable and Secure Computing*, February. <https://doi.org/10.1109/TDSC.2021.3060775>
- Diamond, M. C., Scheibel, A. B., & Elson, L. M. (2014). *libro de trabajo el Cerebro Humano*. www.ariel.eswww.espacioculturalyacademico.com
- Dwivedi, R., & Dey, S. (2019). A novel hybrid score level and decision level fusion scheme for cancelable multi-biometric verification. *Applied Intelligence*, 49(3), 1016–1035. <https://doi.org/10.1007/s10489-018-1311-2>
- Erhan Ekmekcioglu, Y. C. (2020). *Loughborough University Multimodal Emotion Dataset-2*. https://figshare.com/articles/dataset/Loughborough_University_Multimodal_Emotion_Data_set_-_2/12644033
- Fernández, R. (2021). Métodos de ensamblado en Machine Learning. *Eamo.Usc.Es*. http://eamo.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto_1686.pdf
- Flores Rodríguez, C. (2021). *Generación de árboles de decisión usando un algoritmo inspirado en la Física*. 1, 5–16.
- Galvão F., Alarcão S.M., F. M. J. (2021). *Predicting exact valence and arousal values from EEG*. 21(10). <https://doi.org/10.3390/s21103414>

- García, A. (2015). *Análisis de ondas cerebrales para determinar emociones a partir de estímulos visuales*. 137.
<https://cdigital.uv.mx/bitstream/handle/123456789/46639/GarciaDominguezAna.pdf?sequence=2&isAllowed=y>
- Gil Pacheco, K. A. (2003). Trabajo Especial De Grado. *Bibliogeo.Ing.Ucv.Ve*, 138.
http://bibliogeo.ing.ucv.ve/DB/bfiegucv/EDOCS/SRed/2012/10/T041500005176-0-TEG_ANAYA_RAQUEL_2004-000.pdf
- GÓMEZ, J. J. S. (2020). *BIOMETRÍA Y LA SEGURIDAD INFORMÁTICA EN LOS MÉTODOS DE AUTENTICACIÓN* [UNIVERSIDAD NACIONAL ABIERTA Y A DISTANCIA – UNAD].
<https://repository.unad.edu.co/bitstream/handle/10596/39060/jjsanchezg.pdf?sequence=3&isAllo>
- Goshvarpour, A., & Goshvarpour, A. (2023). Emotion Recognition Using a Novel Granger Causality Quantifier and Combined Electrodes of EEG. *Brain Sciences*, 13(5).
<https://doi.org/10.3390/brainsci13050759>
- Hadiyoso, S., Wijayanto, I., & Dewi, E. M. (2020). ECG Based Biometric Identification System using EEMD, VMD and Renyi Entropy. *2020 8th International Conference on Information and Communication Technology, ICoICT 2020*, 15–19.
<https://doi.org/10.1109/ICoICT49345.2020.9166202>
- Haider Mehraj1, A. H. M. (2021). Robust Multimodal Biometric System Based on Feature Level Fusion of Optimiseddeepnet Features. *Wireless Personal Communications (Springer US)*, 1–22.
- Hasan, M. M., Hasan, N., Afroz, D., Jibon, F. A., Hossen, M. A., Parvage, M. S., & Aongkon, J. S. (2021). Electroencephalogram Based Medical Biometrics using Machine Learning: Assessment of Different Color Stimuli. *Advances in Science, Technology and Engineering Systems Journal*, 6(3), 27–34. <https://doi.org/10.25046/aj060304>
- Hendrawan, M. A., Rosiani, U. D., & Sumari, A. D. W. (2022). Single Channel Electroencephalogram (EEG) Based Biometric System. *Proceeding - IEEE 8th Information Technology International Seminar, ITIS 2022, October*, 307–311. <https://doi.org/10.1109/ITIS57155.2022.10010103>
- Hendrawan, M. A., Saputra, P. Y., & Rahmad, C. (2021). Identification of optimum segment in single channel EEG biometric system. *Indonesian Journal of Electrical Engineering and Computer Science*, 23(3), 1847–1854. <https://doi.org/10.11591/ijeecs.v23.i3.pp1847-1854>
- Izanami, J., Romero, C., Joaquín, L., & Núñez, H. (2021). *Técnicas estadísticas para el pronóstico de la demanda mediante Matlab*.
- Javier, C., Germ, T., Una, R., & Neuronal, R. (2009). Redes Neuronales Artificiales Introducción Modelo neuronal de McCulloch-Pitts. *Revista De Educación Matemática*, 24(3), 22–30.
- Jijomon, C. M., & Vinod, A. P. (2018). EEG-based biometric identification using frequently occurring maximum power spectral features. *Proceedings of 2018 IEEE Applied Signal Processing Conference, ASPCON 2018*, 249–252. <https://doi.org/10.1109/ASPCON.2018.8748581>
- Jijomon Chettuthara Monsy, A. P. V. (2020). EEG-based biometric identification using frequency-weighted power feature. *The Institution of Engineering and Technology*, 9(6), 251–258.
<https://doi.org/https://www.doi.org/10.1049/IET-BMT.2019.0158>

- Joseph, A.A.a, Pog, E.I.A.P.a, Chin, K.L.a, Liang, D.B.B.a, Mat, D.A.A.a, Song, N.S.a, Rulaningtyas, R. . V. C. (jump link). (2021). *Online Person Identification based on Multitask Learning*. 13. <https://doi.org/10.30880/ijie.2021.13.02.014>
- Kamaraju, S. P., Das, K., & Pachori, R. B. (2023). *EEG Based Biometric Authentication System Using Multivariate FBSE Entropy*. 1–10.
- Kant, C. (2020). *Robust Biometric System Using Liveness Detection and Visual Cryptography*. 581–592. https://doi.org/https://www.doi.org/10.1007/978-981-16-3246-4_46
- Khan, M. Y., Qayoom, A., Nizami, M. S., Siddiqui, M. S., Wasi, S., & Raazi, S. M. K. U. R. (2021). Automated Prediction of Good Dictionary EXamples (GDEX): A Comprehensive Experiment with Distant Supervision, Machine Learning, and Word Embedding-Based Deep Learning Techniques. *Complexity*, 2021. <https://doi.org/10.1155/2021/2553199>
- kimaldi. (2023). *Terminal de reconocimiento de iris Anviz UltraMatch*. https://www.kimaldi.com/productos/sistemas_biometricos/anviz/terminal_de_reconocimiento_de_iris_anviz_ultramatch/
- Koelstra, S., Mühl, C., Soleymani, M., Lee, J. S., Yazdani, A., Ebrahimi, T., Pun, T., Nijholt, A., & Patras, I. (2012). DEAP: A database for emotion analysis; Using physiological signals. *IEEE Transactions on Affective Computing*, 3(1), 18–31. <https://doi.org/10.1109/T-AFFC.2011.15>
- Kralikova, I., Babusiak, B., & Smondrk, M. (2022). EEG-Based Person Identification during Escalating Cognitive Load. *Sensors*, 22(19). <https://doi.org/10.3390/s22197154>
- Kumar, A., & Kumar, A. (2021). DEEPHER: Human Emotion Recognition Using an EEG-Based DEEP Learning Network Model. *Engineering Proceedings*, 10(1), 32. <https://doi.org/10.3390/ecsa-8-11249>
- Laaziz, I. E. B. H. Z. A. T. T. T. Y. (2022). *A wavelet-based capsule neural network for ECG biometric identification*. 76, 103692–103692. <https://doi.org/https://doi.org/10.1016/j.bspc.2022.103692>
- Lai, C. Q., Ibrahim, H., Abdullah, M., & Suandi, S. A. (2022). *EEG-Based Biometric Close-Set Identification Using CNN-ECOC-SVM* (pp. 723–732). https://doi.org/10.1007/978-3-030-97610-1_57
- Lalor, E. C., Kelly, S. P., Finucane, C., Burke, R., Smith, R., Reilly, R. B., & McDarby, G. (2021). Desarrollo de una base de datos para el análisis de señales EEG durante la aritmetica mental. *Instname:Universidad Antonio Nariño*, 2005(19), 3156–3164. <http://repositorio.uan.edu.co/handle/123456789/3150>
- Lara, L., Stoico, C., Machado, R., & Castagnino, M. (2003). *Estimación de los exponentes de lyapunov*. XXII, 1441–1451.
- Larisparto. (2022). *Platzl*. ¿Qué Es y Para Qué Sirve Una Regresión Lineal En Machine Learning? <https://platzl.com/blog/que-es-regresion-lineal/>
- Li, W., Fang, C., Zhu, Z., Chen, C., & Song, A. (2023). Turning waste into wealth: Person identification by emotion-disturbed electrocardiogram. *IET Biometrics*, 12(3), 159–175. <https://doi.org/10.1049/bme2.12112>
- Liu, L., School of Software Engineering, University of Electronic Science and Technology, Chengdu,

- C., & Huang, ; Xiao-Feng Gu; Jian-Ping Li; Jie Lin; Jin-Xin Shi; Yuan-Yuan. (2009). Research on data fusion of multiple biometric features. *International Conference on Apperceiving Computing and Intelligence Analysis*. <https://doi.org/10.1109/ICACIA.2009.5361140>
- Lucero, Boris A., Saracini Chiara, M., & Muñoz-Quezada, M. T. (2020). *Bioethical aspects of the use of biometric identifiers*. 26. <https://doi.org/http://dx.doi.org/10.4067/S1726-569X2020000100043>
- Lundqvist, M., Herman, P., Warden, M. R., Brincat, S. L., & Miller, E. K. (2018). Gamma and beta bursts during working memory readout suggest roles in its volitional control. *Nature Communications*, 9(1), 1–12. <https://doi.org/10.1038/s41467-017-02791-8>
- M. Benomar, Steven Cao, Manoj Vishwanath, Khuong Quoc Vo, H. C. (2022). *Investigation of EEG-Based Biometric Identification Using State-of-the-Art Neural Architectures on a Real-Time Raspberry Pi-Based System*. 22, 9547–9547. <https://doi.org/https://www.doi.org/10.3390/s22239547>
- M. Soleymani, J. Lichtenauer, T. P. and M. P. (2012). *A Multimodal Database for Affect Recognition and Implicit Tagging*. 3, 42–55. <https://doi.org/10.1109/T-AFFC.2011.25>
- mactronica. (2023). *modulo reconocimiento voz elechouse v2*. <https://www.mactronica.com.co/modulo-reconocimiento-voz-elechouse-v3>
- Maersa. (2010). *Historia de la Biometría y la Huella Digital*. <https://www.maersa.com.mx/historia.html>
- Maneet Singh¹, Richa Singh¹, A. R. (2019). A comprehensive overview of biometric fusion. *Information Fusion (Elsevier)*, 52, 187–205.
- Manis, G., Bakalis, D., & Sassi, R. (2023). A Multithreaded Algorithm for the Computation of Sample Entropy. *Algorithms*, 16(6), 1–10. <https://doi.org/10.3390/a16060299>
- Manuel. (2005). *Análisis en el dominio de la frecuencia - Análisis de Fourier*. 27. <http://bibing.us.es/proyectos/abreproy/3828/fichero/Capitulos%252F4+Análisis+en+el+dominio+de+la+frecuencia.pdf>
- Mayhew, S. (2018). *History of Biometrics*. <https://www.biometricupdate.com/201802/history-of-biometrics-2>
- Medina, B., Sierra, J. E., & Ulloa, A. B. (2018). Técnicas de extracción de características de señales EEG en la imaginación de movimiento para sistemas BCI Extraction techniques of EEG signals characteristics in motion imagination for BCI systems. *Espacios*, 39(22), 36–48. <https://www.revistaespacios.com/a18v39n22/18392236.html>
- Meltzer-camino, D. (2018). *Recent advances in biometrics and its standardization: a survey*. September.
- Mindmetriks. (2023). *electroencefalogramas EEGs*. Dispositivo para toma de señales EEG
- Mitchell, T. M. (1997). McGraw-Hill series in computer science. McGraw-Hill. *Machine Learning*. <https://www.uv.mx/personal/emezura/files/2021/03/Thesis-Camilo.pdf>
- Mladenov, V. M., Koprinkova-Hristova, P. D., Palm, G., Villa, A. E. P., Appollini, B., & Kasabov, N. K. (Eds.). (2013). *Artificial Neural Networks and Machine Learning - {ICANN} 2013 - 23rd*

International Conference on Artificial Neural Networks (Vol. 8131). Springer.
<https://doi.org/10.1007/978-3-642-40728-4>

- Moctezuma, L. A., & Molinas, M. (2020). Towards a minimal EEG channel array for a biometric system using resting-state and a genetic algorithm for channel selection. *Scientific Reports*, *10*(1), 1–14. <https://doi.org/10.1038/s41598-020-72051-1>
- Mohammad H. Safavipour, Mohammad Ali Doostari, H. S. (2023). Deep Hybrid Multimodal Biometric Recognition System Based on Features-Level Deep Fusion of Five Biometric Traits. *Mohammad H. Safavipour, Mohammad Ali Doostari, Hamed Sadjedi, 2023*.
- Montoya Capote, A. (2021). *Procesamiento de señales EEG para el reconocimiento de emociones*.
- Nacional, U., Litoral, D. E. L., & Colominas, M. A. (2016). *Métodos guiados por los datos para el análisis de señales : contribuciones a la descomposición empírica en modos*.
- Ortega-Rodríguez, J., Gómez-González, J. F., & Pereda, E. (2023). Selection of the Minimum Number of EEG Sensors to Guarantee Biometric Identification of Individuals. *Sensors*, *23*(9), 1–19. <https://doi.org/10.3390/s23094239>
- Ortega p. (2005). *Diseño De Mecanismos De Procesamiento Interactivos Para EL Analisis de ondas cerebrales*.
- Ozdemir, M. A., Degirmenci, M., Izci, E., & Akan, A. (2021). EEG-based emotion recognition with deep convolutional neural networks. *Biomedizinische Technik*, *66*(1), 43–57. <https://doi.org/10.1515/bmt-2019-0306>
- Pane, E. S., Wibawa, A. D., & Pumomo, M. H. (2018). Channel Selection of EEG Emotion Recognition using Stepwise Discriminant Analysis. *2018 International Conference on Computer Engineering, Network and Intelligent Multimedia, CENIM 2018 - Proceeding*, *4*, 14–19. <https://doi.org/10.1109/CENIM.2018.8711196>
- Parra, F. (2019). *Estadística y Machine Learning con R*. <https://bookdown.org/content/2274/introduccion.html>
- Patel, P., Raghunandan, R., & Annavarapu, R. N. (2021). EEG-based human emotion recognition using entropy as a feature extraction measure. *Brain Informatics*, *8*(1). <https://doi.org/10.1186/s40708-021-00141-5>
- Peng, J., & Liu, R. (2023). Research on EEG signal emotion recognition based on improved GAPSO-SVM. *2023 IEEE 2nd International Conference on Electrical Engineering, Big Data and Algorithms, EEBDA 2023*, 1726–1729. <https://doi.org/10.1109/EEBDA56825.2023.10090851>
- Phung, D., Tran, D., Ma, W., Nguyen, P., & Pham, T. (2014). Using shannon entropy as EEG signal feature for fast person identification. *22nd European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN 2014 - Proceedings, April*, 413–418.
- Radwan S.H; El-Telbany; Arafa W.; Ali Rasha. (2022). Deep Learning Approaches for Personal Identification Based on EGG Signals. *Lecture Notes on Data Engineering and Communications Technologies*, *100*, 30–39. https://doi.org/10.1007/978-3-030-89701-7_3
- Rivera-Lopez, R., & Canul-Reich, J. (2017). Construction of near-optimal axis-parallel decision trees using a differential-evolution-based approach. *IEEE Access*, *6*, 5548–5563.

<https://doi.org/10.1109/ACCESS.2017.2788700>

- Romeo Urrea, H. (2015). El Dominio de los Hemisferios Cerebrales. *Ciencia Unemi*, 3(4), 8–15. <https://doi.org/10.29076/issn.2528-7737vol3iss4.2010pp8-15p>
- Romero, C. (2012). *Diseño e implementación de un sistema de adquisición de ondas cerebrales (EEG) de seis canales y análisis en tiempo, frecuencia y coherencia*. <https://www.ptonline.com/articles/how-to-get-better-mfi-results>
- Rosli, F. A., Ardeena, S., Abdullah, A. A., & Salim, M. S. (2021). Biometric authentication system using EEG biometric trait - A review. *AIP Conference Proceedings*, 2339(May). <https://doi.org/10.1063/5.0044955>
- Sajjad Karimi; Mohammad Bagher Shamsollahi. (2023). *Tractable Maximum Likelihood Estimation for Latent Structure Influence Models With Applications to EEG & ECoG Processing*. 45(8), 10466–10477. <https://doi.org/10.1109/TPAMI.2023.3244130>
- Sakalle A., Tomar P.a., B. H. A. D. B. A. . (2021). *A LSTM based deep learning network for recognizing emotions using wireless brainwave driven system*. <https://doi.org/10.1016/j.eswa.2020.114516>
- Sciotto, E. A., & Niripil, E. B. (2018). Salud En La Educación Ondas Cerebrales , Conciencia Y Cognición. *Salud En La Educación*, June.
- Sovatzidi, G., & Iakovidis, D. K. (2023). Interpretable EEG-Based Emotion Recognition Using Fuzzy Cognitive Maps. *Studies in Health Technology and Informatics*, 302, 992–996. <https://doi.org/10.3233/SHTI230324>
- sprint diagnostic. (2022). *Electroencephalography (EEG)*. <https://sprintdiagnostics.in/electroencephalography-eeeg>
- Suhaimi, N. S., Mountstephens, J., & Teo, J. (2020). EEG-Based Emotion Recognition: A State-of-the-Art Review of Current Trends and Opportunities. *Computational Intelligence and Neuroscience*, 2020. <https://doi.org/10.1155/2020/8875426>
- Tahseen, S., & Danti, A. (2022). Multi-layer Stacking-based Emotion Recognition using Data Fusion Strategy. *International Journal of Advanced Computer Science and Applications*, 13(6), 433–442. <https://doi.org/10.14569/IJACSA.2022.0130654>
- Teja Chavali, S., Tej Kandavalli, C., Sugash, T. M., & Subramani, R. (2023). Smart Facial Emotion Recognition With Gender and Age Factor Estimation. *Procedia Computer Science*, 218(2022), 113–123. <https://doi.org/10.1016/j.procs.2022.12.407>
- Tian, W., Li, M., & Hu, D. (2023). *Multi-band Functional Connectivity Features Fusion Using Multi-stream GCN for EEG Biometric Identification* (pp. 3196–3203). https://doi.org/10.1007/978-981-99-0479-2_294
- todo tintas y suministros*. (2023). <https://todotintasysuministros.com/lector-de-huellas/lector-de-huella-digital-persona-4500u>
- Topic, A., Russo, M., Stella, M., & Saric, M. (2022). Emotion Recognition Using a Reduced Set of EEG Channels Based on Holographic Feature Maps. *Sensors*, 22(9). <https://doi.org/10.3390/s22093248>

- Trabelsi, S., Samai, D., Dornaika, F., Benlamoudi, A., Bensid, K., & Taleb-Ahmed, A. (2022). Efficient palmprint biometric identification systems using deep learning and feature selection methods. *Neural Computing and Applications*, 34(14), 12119–12141. <https://doi.org/10.1007/s00521-022-07098-4>
- Ulukaya, S., A, S.;, S. mail to U., Sandıkçı, E. N., B;, & Eroğlu Erdem, Ç. (2023). Consensus and stacking based fusion and survey of facial feature point detectors. *Journal of Ambient Intelligence and Humanized Computing*, 14(8), 9947–9957. <https://doi.org/10.1007/s12652-021-03662-3>
- Valer Jurcak 1, Daisuke Tsuzuki, I. D. (2007). *10/20, 10/10, and 10/5 systems revisited: their validity as relative head-surface-based positioning systems*. <https://doi.org/10.1016/j.neuroimage.2006.09.024>
- Waili, T., Johar, M. G. M., Sidek, K. A., Nor, N. S. H. M., Yaacob, H., & Othman, M. (2019). EEG based biometric identification using correlation and MLPNN models. *International Journal of Online and Biomedical Engineering*, 15(10), 77–90. <https://doi.org/10.3991/ijoe.v15i10.10880>
- Wang, M., Wang, S., & Hu, J. (2022). Cancellable Template Design for Privacy-Preserving EEG Biometric Authentication Systems. *IEEE Transactions on Information Forensics and Security*, 17, 3350–3364. <https://doi.org/10.1109/TIFS.2022.3204222>
- Wei-Long Zheng, B.-L. L. (n.d.). *SEED Dataset*. <https://bcmi.sjtu.edu.cn/home/seed/index.html>
- Wibawa, A. D., Mohammad, B. S. Y., Fata, M. A. K., Nuraini, F. A., Prasetyo, A., & Pamungkas, Y. (2022). Comparison of EEG-Based Biometrics System Using Naive Bayes, Neural Network, and Support Vector Machine. *2022 International Conference on Electrical and Information Technology (IEIT)*, 408–413. <https://doi.org/10.1109/IEIT56384.2022.9967861>
- Xueyuan Xu, Tianyuan Jia, Qing Li, Fulin Wei, Long Ye, X. W. (2021). *EEG Feature Selection via Global Redundancy Minimization for Emotion Recognition*. <https://doi.org/10.1109/TAFFC.2021.3068496>
- Yamashita, M., Nakazawa, M., Nishikawa, Y., & Abe, N. (2020). Examination and it's evaluation of preprocessing method for individual identification in EEG. *Journal of Information Processing*, 28(November 2018), 239–246. <https://doi.org/10.2197/ipsjip.28.239>
- Yan, Y., Wu, X., Li, C., He, Y., Zhang, Z., Li, H., Li, A., & Wang, L. (2023). Topological EEG Nonlinear Dynamics Analysis for Emotion Recognition. *IEEE Transactions on Cognitive and Developmental Systems*, 15(2), 625–638. <https://doi.org/10.1109/TCDS.2022.3174209>
- Zen, C. (2013). *Biometria – Linea de Tiempo*. <https://codigodebarras.pe/biometria-linea-de-tiempo/>
- Zhang, H. (2023). *Biometric Authentication and Correlation Analysis Based on CNN-SRU Hybrid Neural Network Model*. 2023.
- Zhang, X., Yao, L. Y. profile imageLina, Huang, C. H. profile imageChaoran, Gu, T. G. profile imageTao, Yang, Z. Y. profile imageZheng, & Liu, Y. L. profile imageYunhao. (2020). DeepKey: A Multimodal Biometric Authentication System via Deep Decoding Gaits and Brainwaves. *ACM Transactions on Intelligent Systems and Technology*, 11(4), 1–24.

Zhong, Wenxiaoa, b;An, Xingweia;Di, Yanga;Zhang, Lixina, b;Ming, Donga, b. (2021). *Review on identity feature extraction methods based on electroencephalogram signals*. 38(6).
<https://doi.org/10.7507/1001-5515.202102057>