



UAEM | Universidad Autónoma
del Estado de México

UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO
CENTRO UNIVERSITARIO UAEM TEXCOCO

“Predicción de Estados Mentales a partir de
Electroencefalografías”

Tesis

**Que para obtener el título de
Ingeniero en Computación**

**presenta
Ignacio Cristian Ayala Ballina**

**Asesor
Dr. Jair Cervantes Canales**

**Revisores
Dra. Laura Yadira Domínguez Jalili
Dr. Josué Espejel Cabrera**

Texcoco, Estado de México, octubre de 2024



UAEM | Universidad Autónoma
del Estado de México

AUTONOMOUS UNIVERSITY OF MEXICO STATE THESIS PROTOCOL

Mental State Prediction by Electroencefalograms

Submitted by

Ignacio Cristian Ayala Ballina

As a fulfillment of the requirement for the degree of

Computer Science Engineering

Thesis Advisor:

Ph.D. Jair CERVANTES

Texcoco, Estado de México.

October 2024

Abstract

The prediction of mental states from electroencephalograms using brain wave signal processing techniques is a very little known topic in this approach since in the most recent research for this type of predictions facial recognition has been used as an alternative but unfortunately these biometric data are not always correct since people can show a neutral or different state to what they are actually feeling. For this reason, the recognition of certain patterns in brain waves will give us a better reading of the state in which people are such as stress, fatigue, concentration, etc. In this thesis, several pattern recognition techniques are implemented, establishing certain characteristics that are related to different mental states, performing a performance analysis for the prediction of mental states from EEG.

Resumen

La predicción de estados mentales a partir de electroencefalografías utilizando técnicas de procesamiento de señales de ondas del cerebro es una tema muy poco conocido en este enfoque ya que en las más recientes investigaciones para este tipo de predicciones se ha utilizado el reconocimiento facial como una alternativa pero lamentablemente esos datos biométricos no siempre son correctos ya puede las personas pueden mostrar un estado neutral o diferente a la que en realidad se está sintiendo para ello en el reconocimiento de ciertos patrones en la ondas cerebrales nos darán una mejor lectura del estado en el que se encuentran las personas como el estrés, la fatiga, la concentración etc. En esta Tesis se implementan varias técnicas de reconocimiento de patrones estableciendo ciertas características que están relacionadas con diferentes estados mentales realizando un análisis del desempeño para la predicción de estados mentales a partir de EEG.

Índice general

1. Introducción	2
1.1. Problemática	3
1.2. Justificación	3
1.3. Objetivos	4
1.4. Hipótesis	5
1.5. Estado del arte	5
2. Preliminares	11
2.1. Técnicas de clasificación	11
2.1.1. Redes Neuronales	12
2.1.2. Support Vector Machines	14
2.1.3. Árboles de decisión	16
2.1.4. Clasificación Bayesiana	18
2.2. Validación Cruzada	20
2.3. Técnicas de Evaluación de desempeño	21
2.3.1. Curva ROC y Área bajo la Curva (AUC-ROC)	21
2.3.2. Métricas de Clasificación Multiclase	22
2.3.3. Matriz de Confusión	23
2.3.4. Verdadero positivo (VP)	24
2.3.5. Verdadero Negativo (VN)	24
2.3.6. Falso positivo (FP)	24
2.3.7. Falso Negativo (FN)	24

2.3.8. Precisión	25
2.3.9. Sensibilidad	25
2.3.10. Especificidad	25
2.3.11. Valor F1	25
2.4. Técnicas de selección de características	25
2.4.1. Métodos de Filtrado	26
2.4.2. Métodos Wrapper	27
2.4.3. Métodos Integrados	27
2.4.4. Algoritmos Genéticos	28
2.4.5. Métodos Basado en Aprendizaje No Supervisado	28
2.4.6. Métodos Basados en Algoritmos de clasificación	29
3. Metodología	30
3.1. Diseño de la investigación	30
3.2. Conjunto de datos	31
3.3. Selección de características	32
3.3.1. Algoritmo Genético para la Selección de Características	32
3.3.2. Minimal Redundancy Maximal Relevance (MRMR)	33
3.4. Entrenamiento de Modelos	35
3.4.1. División de Datos	35
3.4.2. Selección de Algoritmos de Clasificación	36
3.4.3. Obtención de los modelos	36
3.4.4. Evaluación de Modelos	37
4. Resultados experimentales	38
4.1. Descripción del Conjunto de Datos EEG	38
4.1.1. Origen del Conjunto de Datos	38
4.2. Resultados Experimentales	40
4.2.1. Naive Bayes	40
4.2.2. Redes Neuronales	43
4.2.3. SVM	45

4.2.4. Árboles de decisión	48
5. Conclusiones	51
5.1. Discusiones	51
5.2. Conclusiones	52

Índice de figuras

2.1. Red neuronal con una capa de entrada, una capa oculta y una capa de salida	14
2.2. Maximización del hiperplano de separación con SVM	16
2.3. Grafico de un árbol de decisión	18
2.4. Gráfica AUC-ROC	22
3.1. Gráfica de metodología para clasificación de EEG	30
4.1. Matrices de confusión del clasificador Naive Bayes con diferentes características	43
4.2. Matrices de confusión para redes neuronales con diferentes características	45
4.3. Matrices de confusión para SVM con diferentes características	48
4.4. Matrices de confusión para Árboles de decisión con diferentes características	50

Lista de Tablas

4.1. Resultados con el algoritmo Bayesiano y diferentes características	42
4.2. Resultados con el algoritmo Bayesiano y diferentes características	45
4.3. Resultados con SVM y diferentes características	47
4.4. Resultados con Árboles de decisión y diferentes características	50

Capítulo 1

Introducción

Las señales de EEG son señales eléctricas generadas por las neuronas cerebrales registradas en la superficie del cuero cabelludo” [17]. Esta técnica es utilizada en la investigación y debidos a su capacidad de capturar cambios en la actividad cerebral. En los últimos años ha surgido como una herramienta prometedora para la predicción de estados mentales. La predicción de estados mentales a partir de EEG implica la interpretación de patrones complejos en los datos electroencefalográficos para inferir estados emocionales, cognitivos y comportamiento de las personas además estos estados mentales pueden incluir la atención, la concentración, el estrés, la fatiga, entre otros. La capacidad de predecir estados del cerebro tiene aplicaciones significativas en diversos campos como la neurociencia cognitiva, la salud mental y las interfaces cerebro-computadora (BC). Los avances recientes en algoritmos de aprendizaje automático (Machine Learning) y procesamiento de señales han contribuido en la precisión y confiabilidad en los modelos predictivos para la clasificación de las señales neuronales del cerebro e identificar características específicas en las señales EEG que están asociadas con diferentes estados mentales. En esta tesis se enfoca en el desarrollo y evaluación de modelos predictivos que utilizan datos EEG para inferir estados mentales específicos. A lo largo del estudio, se abordarán cuestiones clave como la selección de características relevantes y la optimización de algoritmos de clasificación con el fin de avanzar en la comprensión de como los patrones de actividad cerebral reflejados en los datos obtenidos por EEG pueden ser utilizados para predecir estados mentales de

manera más precisa y confiable contribuyendo en el desarrollo de tecnologías que mejoren la interacción hombre-maquina.

1.1. Problemática

La precisión de estados mentales a partir de registros EEG representa un desafío complejo debido a varios factores en la naturaleza de los datos y los procesos que se realizan en el análisis e interpretación de estos como lo son el ruido y artefactos en las señales EEG ya que son altamente susceptibles a diversas fuentes de ruido y artefactos como el movimiento ocular, parpadeo, movimientos musculares y ruido eléctrico que pueden distorsionar las características relevantes de la actividad cerebral. Los datos EEG son multidimensionales y altamente complejos lo cual exige técnicas avanzadas de reducción de dimensionalidad y selección de características para poder identificar los patrones significativos que correlacionan a los estados mentales además de que existe una considerable variabilidad tanto entre diferentes individuos como dentro del mismo individuo en diferentes momentos o condiciones que pueden dificultar la generalización de los modelos predictivos. El desarrollo de los modelos predictivos requiere de grandes cantidades de datos EEG clasificados, sin embargo, la recopilación y clasificación de estos datos es un proceso laborioso y costoso lo cual limita la disponibilidad de datos adecuados para el entrenamiento y validación de los modelos. Además, la elección del algoritmo adecuado y la optimización de sus parámetros son cruciales para la precisión de la predicción ya que existen una gran variedad de algoritmos disponibles como Maquinas de Vectores de soporte (SVM), Redes Neuronales Artificiales (ANN), Redes Neuronales Convolucionales (CNN), Algoritmos de Bosques Aleatorios (Random Forests), K-Nearest Neighbors (KNN), etc.

1.2. Justificación

La capacidad de predecir estados mentales a partir de señales EEG tiene un potencial transformador y un impacto significativo en diversas áreas de la ciencia y la tecnología desde la salud mental hasta la interacción humano-maquina ya que aporta avances en la

neurociencia y salud mental que puede proporcionar nuevas herramientas para el diagnóstico y tratamiento de trastornos mentales como la depresión, la ansiedad y el trastorno de déficit de atención e hiperactividad (TDAH) además de ofrecer nuevos conocimientos sobre el funcionamiento del cerebro. Por otra parte, la predicción precisa de estados mentales puede mejorar significativamente la calidad de vida de las personas al monitorizar en tiempo real la actividad cerebral en ambientes laborales y detectar fatiga o estrés permitiendo intervenciones tempranas, así como en la educación que pueden ayudar a personalizar el aprendizaje en función del nivel de atención y concentración del estudiante. Además, la tecnología de predicción de estados mentales basada en EEG tiene un amplio potencial comercial que pueden estar en dispositivos de bienestar personal que monitorean el estado emocional hasta sistemas avanzados en automóviles que detectan la somnolencia del conductor evitando accidentes y mejorando la elección de decisiones día a día Cabe mencionar que la investigación en este campo presenta numerosos desafíos técnicos y metodológicos, desde la gestión del ruido hasta la variabilidad intra e Inter sujeto, abordar estos desafíos no solo mejora la precisión de estados mentales, sino que también genera nuevas técnicas y enfoques aplicables en problemas en el análisis de señales biomédicas además de que contribuirá al cuerpo de conocimiento en la neurociencia y la inteligencia artificial

1.3. Objetivos

Objetivo general: Evaluar modelos predictivos basados en datos de EEG para inferir estados mentales específicos, mejorando la precisión y fiabilidad de la predicción.

1. Obtener conjuntos de datos sobre estados mentales con EEG
2. Seleccionar y extraer características relevantes: Las señales que estén asociadas con diferentes estados mentales, empleando métodos de análisis de frecuencia, tiempo y espacio.
3. Implementar y comparar algoritmos de aprendizaje automático. Los métodos de clasificación que se compararán son Maquinas de vectores de soporte (SVM), Redes neuronales (ANN) y árboles de decisión.

4. Evaluar el rendimiento de los modelos predictivos. Para ello se utilizarán métricas de precisión, sensibilidad, especificidad y área bajo la curva.
5. Explorar aplicaciones prácticas: Como pueden ser áreas de salud mental, la educación, entorno laboral y las interfaces cerebro-computadora (BCI) para demostrar su utilidad y viabilidad.

1.4. Hipótesis

Se espera que la implementación de algoritmos de aprendizaje automático, combinado con técnicas avanzadas de preprocesamiento y extracción de características, permite predecir con precisión estados mentales específicos a partir de datos EEG superando las limitaciones actuales relacionadas con el ruido. Se estima que el uso de técnicas de preprocesamiento como el filtrado de señales y la eliminación de ruido mejora significativamente la calidad de los datos EEG aumentando la precisión de los modelos predictivos de estados mentales además la aplicación de métodos de análisis de frecuencia, tiempo y espacio para la extracción de características de las señales EEG permitiendo identificar patrones relevantes. Se hipotetiza que los modelos predictivos desarrollados pueden ser integrados en sistemas eficaces de monitoreo en tiempo real y en aplicaciones prácticas, como la salud mental, la educación y el trabajo para mejorar la calidad de vida de las personas que se encuentran en situaciones de estrés, depresión, ansiedad, etc. Si se aplican técnicas de preprocesamiento como filtrado de señales, la eliminación de ruido y la normalización de datos, se espera que reduzca significativamente el ruido y los artefactos en los registros EEG mejorando la calidad de los datos y por lo tanto mejora la precisión de los modelos predictivos de estado mentales.

1.5. Estado del arte

La inteligencia artificial no es mala y no está aquí para reemplazarnos si no que aumenta nuestras habilidades y mejora lo que hacemos y desarrollamos debido a que los algoritmos de inteligencia artificial aprenden de manera diferente que los humanos, son

capaces de ver relaciones y patrones que son difíciles de ver además la inteligencia artificial transformara todas las industrias pero debemos ser conscientes de sus limitaciones la cual una de las principales es su aprendizaje a través de los datos ya que no existe otra forma de incorporar el conocimiento lo cual significa que cualquier irregularidad o imprecisión de los datos se reflejara en los resultados por lo que “En la actualidad la minería de datos representa un recurso importante en el procesamiento de los datos, con ellos se logra identificar patrones y relaciones ocultas en los datos los cuales permiten la creación de modelos que ayudan a un mejor entendimiento y diagnóstico de ciertas patologías como la epilepsia. Uno de los avances de la minería de datos es el análisis computarizado de las señales electroencefalográficas (EEG), este permite caracterizar los desordenes de la actividad cerebral a través de la información oculta contenida en las señales EEG de pacientes epilépticos” [15]. Gracias a estos resultados resulta más fácil comprender el funcionamiento del cerebro humano y con ello determinar ciertos tratamientos para la epilepsia y en el caso de esta tesis para ver alternativas en el tratamiento de estados mentales como lo es la depresión y la falta de concentración que dificultan a las personas a desarrollarse en un ambiente laboral o en un lugar de estudios Además, es importante comprender la importancia de la inteligencia artificial y sus beneficios ya que la inteligencia artificial nos permite automatizar procesos para desarrollar tareas repetitivas, rutinarias y de optimización por otra parte su importancia radica en que aporta una mayor precisión que el ser humano y reduce los fallos provocados por los humanos, permite el análisis y la explotación de los datos derivados producción, etc. “La investigación de Inteligencia Artificial (IA) lleva años en continuo crecimiento y no tiene visos de ralentizarse, aportando modelos más complejos, más grandes y de respuesta más rápida. Estos modelos se entrenan actualmente con miles de millones de unidades de datos, lo que los hace mucho más potentes que sus antecesores de no hace tantos años, lo que ha llevado a que en unos pocos años los modelos lingüísticos se hayan hecho mucho más potentes” [1]. Por lo tanto, los avances en los modelos de Inteligencia Artificial han provocado que avances científicos, médicos, fabrica, producción y trabajo sean mas eficientes y con mejoría exponencial y para esta tesis nos ayuda a comprender mas sobre el gran enigma del funcionamiento del cerebro humano a través del procesamiento y clasificación de datos electroencefalográfi-

cos para poder saber los diferentes tipos de estados mentales que nos afectan en nuestra vida diaria. Cabe recalcar que no solo es importante comprender como el uso de datos electroencefalográficos y el continuo avance de la Inteligencia Artificial (IA) sino que también hay que reconocer que “El uso de modelos matemáticos permite representar la no linealidad del EEG con la intención de describir y comprender los procesos fisiológicos de la dinámica de un cerebro normal o patológico. Diferentes técnicas del análisis no lineal han sido aplicadas para tratar de describir estos fenómenos. Una herramienta valiosa para modelar y clasificar los procesos fisiológicos es las maquinas de soporte vectorial, SVM” [15]. Esta tesis explora el uso de SVM como un clasificador principal para analizar señales cerebrales, debido a su alta precisión y eficacia en la identificación de patrones asociados con distintos estados neurológicos, como se describe en estudios previos. Además, la adaptación de SVM a problemas multiclase permite abordar la no linealidad de estas señales, optimizando la precisión del diagnóstico. En el contexto de esta investigación, el análisis de señales EEG es crucial para la detección y clasificación de patrones asociados a diversas funciones cerebrales, lo que puede contribuir al diagnóstico de trastornos neurológicos y comprensión del comportamiento cerebral bajo distintas condiciones “El cerebro es la parte central del sistema nervioso humano, controla nuestras emociones, pensamiento, comportamientos, sentidos, etc., siendo la base de todas las actividades de la vida. Las señales de EEG son señales eléctricas generadas por las neuronas cerebrales registradas en la superficie del cuero cabelludo o en la corteza cerebral que refleja la actividad y el estado del cerebro. Cuando los humanos realizan diferentes acciones, producen diferentes sentimientos o realizan una serie de actividades fisiológicas como el pensamiento, cierta información de la enfermedad también se reflejará en las señales de EEG”. [17] entonces dado a que el cerebro es importante no solo para nuestro cuerpo si no también afecta nuestra vida diaria es importante su investigación y comprensión para dar soluciones a problemas que nos afectan como la falta de concentración, insomnio, estrés etc. Por otra parte existen varios argumentos sobre el uso de herramientas para poder detectar patrones o ciertas características en las señales EEG y con base a eso determinar a que tipo de enfermedad está asociada o para el caso de esta tesis la predicción de estados mentales a partir de EEG, pero además de que existen ciertas herramientas que nos ayudan de-

teectar con más facilidad esas características nos encontramos con ciertos obstáculos que primero debemos resolver para obtener una mayor eficiencia en los resultados ya que estas señales son susceptibles a características que no son relevantes o alteran la calidad de la información. En este caso nos encontramos con un obstáculo muy importante que es el ruido en los datos electroencefalográficos. “Debido a que el ruido es un factor común en las señales adquiridas hace que las muestras de diferentes clases posean cierta similitud en su comportamiento estadístico, por esta razón en general en los procesos de reconocimiento de patrones se utiliza una etapa de preprocesamiento” [12]. Además, la variabilidad de los patrones de EEG, la necesidad de grandes volúmenes de datos etiquetados y la complejidad en la interpretación de los modelos de aprendizaje automático son desafíos actuales que se tiene que resolver para que futuras generaciones sean capaces de solucionar problemas o estados mentales que afectan su día a día ya sea en lo académico o en un ambiente laboral. El uso de algoritmo de aprendizaje automático para la predicción de estados mentales a partir de EEG ha tenido relevancia en los últimos años y no solo eso si no que también el uso de redes neuronales profundas, las máquinas de soporte vectorial (SVM) y los algoritmos de Bosque aleatorio (Random Forest) son herramienta que se han utilizado con éxito en la clasificación para las señales electroencefalográficas. A lo largo de las últimas décadas, el desarrollo tecnológico ha transformado de manera significativa el ámbito de la medicina, impactando tanto en el diagnóstico como en los tratamientos disponibles para distintas patologías. Como menciona [2], estos avances han mejorado notablemente la calidad de vida de los pacientes y han aumentado las probabilidades de recuperación a niveles que anteriormente parecían inalcanzables. Estos progresos no solo han facilitado una mayor precisión en el diagnóstico, sino que también han permitido el uso de herramientas innovadoras para la investigación y el tratamiento de enfermedades neurológicas, como es el caso de los sistemas de análisis de señales electroencefalográficas (EEG) para la identificación de patrones en el cerebro humano, lo cual resulta relevante en el contexto de esta investigación. En la actualidad, el uso de sistemas de cómputo en el campo médico ha permitido avances significativos, especialmente en la adquisición y procesamiento de datos médicos complejos, como las imágenes de alta resolución utilizadas para estudiar órganos como el cerebro y el corazón. [2] señalan que los procedimientos

matemáticos robustos, junto con la mejora constante de la tecnología computacional, han dado lugar a métodos más precisos y eficientes para el diagnóstico y la investigación, lo cual ha permitido un mayor entendimiento del funcionamiento de estos órganos, tanto en condiciones normales como patológicas. Estos a veces tecnológicos no solo han reducido los tiempos de ejecución de los estudios, sino que también han aportado información crítica para el análisis de señales electroencefalográficas (EEG), que se aplican en esta tesis para la identificación y clasificación de patrones neuronales en diferentes estados cerebrales. Los avances tecnológicos han permitido no solo mejorar el procesamiento de datos, sino también el análisis de señales bioeléctricas como el electroencefalograma (EEG), las cuales juegan un papel crucial en la comprensión de la actividad cerebral y sus aplicaciones. [13] destacan la importancia del EEG, ya que permite estudiar la actividad cerebral de manera no invasiva, proporcionando información valiosa sobre diversas condiciones neurológicas y discapacidades. En particular, los potenciales evocados, que se generan como respuesta a estímulos externos, constituyen una herramienta fundamental para evaluar la conectividad cerebral ante diferentes estímulos visuales, auditivos o somatosensoriales. Integrando estas técnicas con métodos computacionales y modelos de aprendizaje automático, como los propuestos en esta tesis, se pueden desarrollar sistemas de manera precisa, lo cual representa un avance en el desarrollo de algoritmos como en la mejora de la calidad de las señales obtenidas contribuyendo significativamente al progreso en la investigación neurocientífica, facilitando aplicaciones prácticas en pacientes con diversas alteraciones neurológicas [2] [13]. Para que las señales EEG puedan ser analizadas correctamente, es necesario someterlas a un proceso de preprocesamiento que optimice la calidad de los datos. En [14] se resalta la importancia de este paso, que incluye la aplicación de filtros, ventanas y otras técnicas, para eliminar artefactos y ruidos que puedan distorsionar el análisis espectral. Esto es especialmente relevante en estudios que buscan extraer características específicas de las señales, como el uso de frecuencias dominantes o la identificación de patrones neuronales asociado a tareas cognitivas o motoras. En el contexto de esta investigación, el preprocesamiento es un paso fundamental para garantizar que las características relevantes de las señales EEG puedan ser capturadas de manera adecuada, maximizando así la eficiencia de los algoritmos de clasificación propuestos. Los

métodos empleados para el preprocesamiento deben asegurar que los datos de entrada sean limpios y representen con precisión la actividad neuronal, de modo que los modelos de aprendizaje automático puedan identificar correctamente las correlaciones entre las señales y las tareas específicas. Al combinar estas técnicas con los enfoques de selección de características presentados anteriormente [2] [13] se logra un robusto y eficiente para la clasificación de estados cerebrales, facilitando el desarrollo de aplicaciones prácticas en el campo de la neurociencia clínica. En conclusión, los estados mentales a partir de EEG mediante algoritmos de aprendizaje automático muestra un campo en rápido desarrollo con aplicaciones prometedoras y desafíos significativos. La integración de técnicas avanzadas de procesamiento de señales y aprendizaje automático, junto con enfoques personalizados multimodales, tienen el potencial de transformar nuestra capacidad para comprender y predecir los estados mentales, con aplicaciones en neurociencia, medicina y tecnología de interfaz cerebro-computadora lo cual beneficiaría mucho en el tratamiento de ciertas irregularidades del cerebro que desembocan a enfermedades y trastornos que impiden el correcto funcionamiento de las personas en ambientes laborales o estudiantiles con ello se podrían crear alternativas y tratamiento por una correcta atención en los estudiantes que tienen problemas de concentración o a los empleados que viven en constante estrés para crear un plan de organización que se adapte a su capacidad.

Capítulo 2

Preliminares

En este capítulo se describen técnicas y métodos con el fin de valorar y evaluar el desempeño de los mismos.

2.1. Técnicas de clasificación

Las técnicas de clasificación son fundamentales en el análisis de datos y juegan un papel crucial en la predicción de estados mentales a partir de electroencefalografías (EEG) ya que existen diferentes técnicas de aprendizaje automático según el tipo de información (estructurada y no estructurada) y el modelo de aprendizaje utilizado. Además, los modelos dirigidos a información estructurada se pueden clasificar en función de la información utilizada para el aprendizaje. “Hoy en día se manejan grandes cantidades de información, esto hace que sea inevitable el uso de herramientas robustas para garantizar la fiabilidad del sistema, a pesar de esto, dentro de esta inmensa cantidad de datos todavía existe una enorme masa de información oculta de gran importancia, a la que se puede acceder por técnicas clásicas de recuperación de información. El descubrimiento de esta información oculta es posible gracias a Minería de Datos o Data Mining, que nos permite la elaboración de resultados apropiados, pues durante la misma se aplica algoritmo automático encargado de extraer el conocimiento inherente a los datos. Sin embargo, esta etapa se ve intervenida en gran medida por la calidad de los datos que llegan para su análisis desde la etapa previa” [16].

El aprendizaje no supervisado descubre patrones ocultos y agrupaciones de un conjunto de datos sin la necesidad de que el humano tenga que intervenir ya que cuenta con la capacidad de descubrir similitudes y diferencias en la información lo cual lo hace ideal para análisis exploratorio de datos.

2.1.1. Redes Neuronales

Las redes neuronales han evolucionado el campo del aprendizaje automático debido a su capacidad para aprender representaciones complejas de los datos. En el contexto de EEG se han utilizado con éxito para extraer características especiales de las señales cerebrales. El cerebro humano es lo que inspira la arquitectura de las redes neuronales ya que las células del cerebro humano también conocidas como neuronas forman una red compleja y con un alto nivel de interconexión enviando señales eléctricas entre si para que los humanos puedan procesar la información, una red neuronal artificial es una manera similar ya que esta formada por neuronas artificiales que trabajan en conjunto para resolver un problema [11][10]. En este campo las herramientas más famosas son las redes neuronales artificiales (ANN) y el aprendizaje profundo también conocido como Deep Learning (DL) ya que son las herramientas más sobresalientes.

Las neuronas artificiales están agrupadas en capas en la cuales se dividen en tres tipos; Una capa de entrada el cual no esta formada por neuronas artificiales, simplemente recibe los datos de entrada, una capa oculta ya que no son visibles ni desde entrada ni desde la salida además el numero de capas ocultas son muy variables y va a depender del objetivo a obtener y por último tenemos una capa de salida que en conjunto con el tipo de escenario o problema a resolver que nos encontremos (clasificación o regresión) tendrá una o más neuronas. La Figura 2.1 muestra una red neuronal con 3 capas, una de entrada, una de salida y una oculta. Además, el aprendizaje profundo es un subconjunto que utiliza redes neuronales multicapa también conocidas como redes neuronales profundas para poder simular el complejo poder de toma de decisiones del cerebro humano, este es un aspecto de la ciencia de datos impulsando muchas aplicaciones y servicios que mejoran la automatización realizando tareas analíticas y físicas sin intervención humana lo cual

esto permite muchos productos y servicios cotidianos como asistentes digitales, controles remotos de TV habilitados por voz, detección de fraudes con tarjetas de crédito, vehículos autónomos e IA generativa, en otras palabras intentan imitar el cerebro intentan imitar el cerebro humano a través de una combinación de entradas de datos, pesos y sesgos, todos los cuales actúan como neuronas de silicio ya que estos elementos trabajan en conjunto para reconocer, clasificar y describir con precisión los objetos dentro de los datos. Estas constan de múltiples capas de nodos interconectados, cada uno de los cuales se basa en la capa anterior para refinar y optimizar la predicción o categorización en progresión de cálculos a través de la red también llamada propagación hacia adelante. Las capas de entrada y salida de una red neuronal profunda se denominan capas visibles, la capa de entrada es donde el modelo de aprendizaje profunda ingiere los datos para su procesamiento y la capa de salida es donde se realiza la predicción o clasificación final. Las redes neuronales artificiales (ANN) y el aprendizaje profundo (DL) son grandes herramientas ya que pueden analizar grandes conjuntos de datos e información en este caso para trabajar con los datos electroencefalográficos ya que permiten mejorar la predicción, protocolos de diagnóstico y reduce los errores médicos además de contribuir a la mejora de la salud humana.

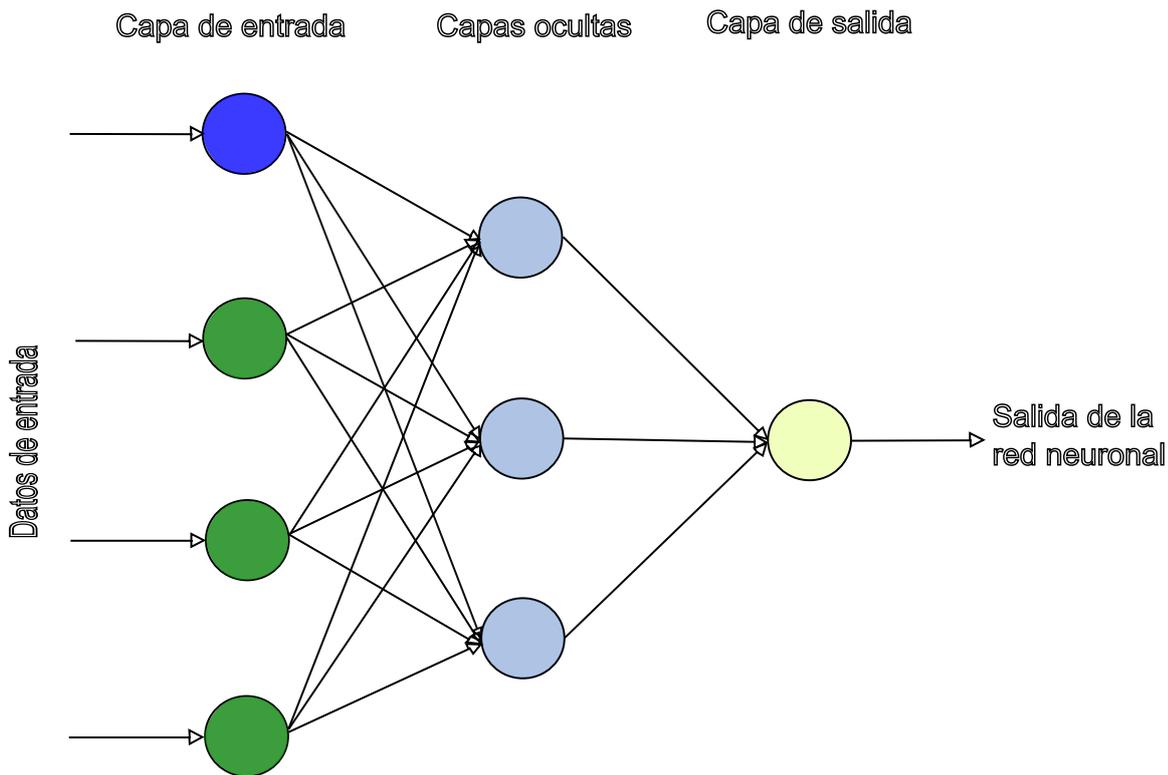


Figura 2.1: Red neuronal con una capa de entrada, una capa oculta y una capa de salida

2.1.2. Support Vector Machines

Las SVM son un conjunto de método de aprendizaje supervisado que se utiliza para la clasificación, regresión y detección de valores atípicos ya que este método es eficaz en espacios de grandes dimensiones además de que utiliza un subconjunto de puntos de entrenamiento en la función de decisión por lo que también es eficiente en el uso de la memoria [6]. El objetivo de este algoritmo SVM es encontrar un hiperplano que separe de la mejor forma posible dos clases diferentes de puntos de datos lo cual implica el hiperplano con el margen mas amplio entre dos clases. El margen se define como la anchura máxima de la región paralela al hiperplano que no tiene puntos de datos anteriores [8]. Este se utiliza en muchos problemas de clasificación y regresión incluidas procesamiento del lenguaje natural, reconocimiento de imágenes y de voz y aplicaciones médicas de procesamiento de señales lo cual es importante en este tema de detección de predicción de estados mentales a partir de electroencefalografías ya que nos ayudara a clasificar las señales neuronales

clave para determinar si las personas tienen un cierto estado mental que afecta en sus actividades.

El entrenamiento de soporte vectorial (SVM) se asemeja a resolución de problemas de optimización cuadrática, donde se ajusta un hiperplano que maximiza el margen entre clases con cierta flexibilidad. Esto permite que el SVM maneje errores o excepciones en los datos de entrenamiento. La Figura 2.2 muestra como las SVM maximizan el hiperplano de separación entre clases. Es importantes destacar que los SVM son ampliamente utilizados y logran un rendimiento robusto en diversas tareas de clasificación y regresión, lo que los convierte en una herramienta valiosa para la clasificación de las señales neuronales del cerebro. Aunque originalmente son diseñados para clasificación binaria, los SVM pueden ser adaptados a problemas multiclase mediante la combinación de múltiples clasificadores binarios. Esto se logra, por ejemplo, a través de métodos como “uno contra uno” o “unos contra todos”, permitiendo que los SVM manejen situaciones más complejas [5]. Los kernels, una característica clave de los SVM, proporciona flexibilidad adicional, permitiendo que estos algoritmos gestionen problemas no lineales el mapear los datos a espacios de mayor dimensión. Esto facilita la identificación de patrones que no serian detectables en un espacio lineal. Para construir la superficie de decisión, los SVM utilizan únicamente los vectores de soporte, que son los puntos de datos más críticos seleccionados durante el proceso de entrenamiento. Una vez completado el entrenamiento, los datos restantes de vuelven irrelevantes para la construcción del modelo, lo que hace que los SVM sean eficientes en el uso de los datos para la toma de decisiones.

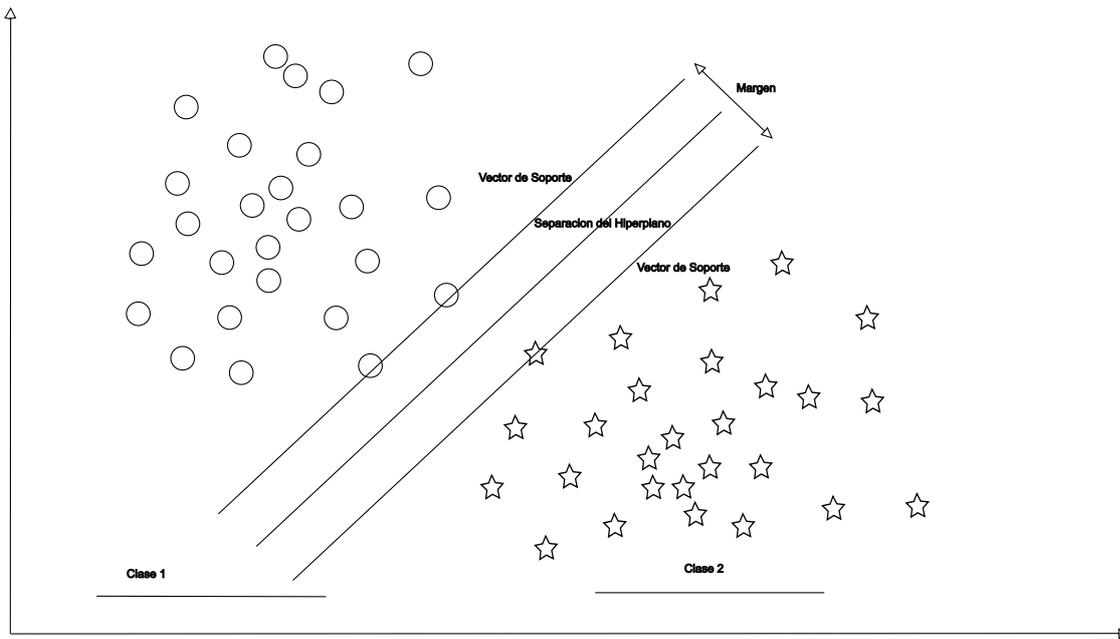


Figura 2.2: Maximización del hiperplano de separación con SVM

2.1.3. Árboles de decisión

Un árbol de decisión es un algoritmo de aprendizaje supervisado que no depende de parámetros predeterminados, lo que lo hace versátil para tareas tanto de clasificación como de regresión. Su estructura se organiza de manera jerárquica en forma de árbol, compuesto por un nodo raíz, ramas que representan decisiones, nodos internos que realizan particiones basadas en características y nodos hoja que contienen las predicciones finales [7]. Esta metodología permite descomponer un problema complejo en una serie de decisiones más simples, facilitando la interpretación y la implementación en el análisis de señales neuronales del cerebro. Un árbol de decisión también puede emplearse para desarrollar modelos predictivos automatizados, aplicables en el aprendizaje automático, la minería de datos y la estadística. Este enfoque, conocido como “aprendizaje basado en árboles de decisión”, utiliza observaciones sobre un conjunto de datos para predecir el valor de una variable objetivo. En estos árboles, los nodos representan datos específicos en lugar de decisiones. Este tipo de árbol, conocido como “árbol de clasificación”, utiliza cada ramificación para representar un conjunto de atributos o reglas de clasificación, aso-

ciadas a una etiqueta de clase específica que se encuentra al final de cada ramificación. La Figura 2.3 muestra el grafo de un árbol de decisión. Las reglas en los árboles de decisión, comúnmente expresadas en formato “Si... entonces...”, permite que, por ejemplo, si se cumple las condiciones 1,2 y 3, entonces el resultado X será la predicción con una certeza Y. A medida que se añaden más datos al árbol, el modelo de vuelve mas preciso en la clasificación de nuevas observaciones. Además, cuando la variable predicha es un numero real, como un precio, el árbol de decisión se denomina “árbol de regresión”. Estos arboles permiten manejar resultados posibles que son infinitos y continuos, ampliando así la capacidad predictiva del modelo para problemas mas complejos en la clasificación de señales neuronales.

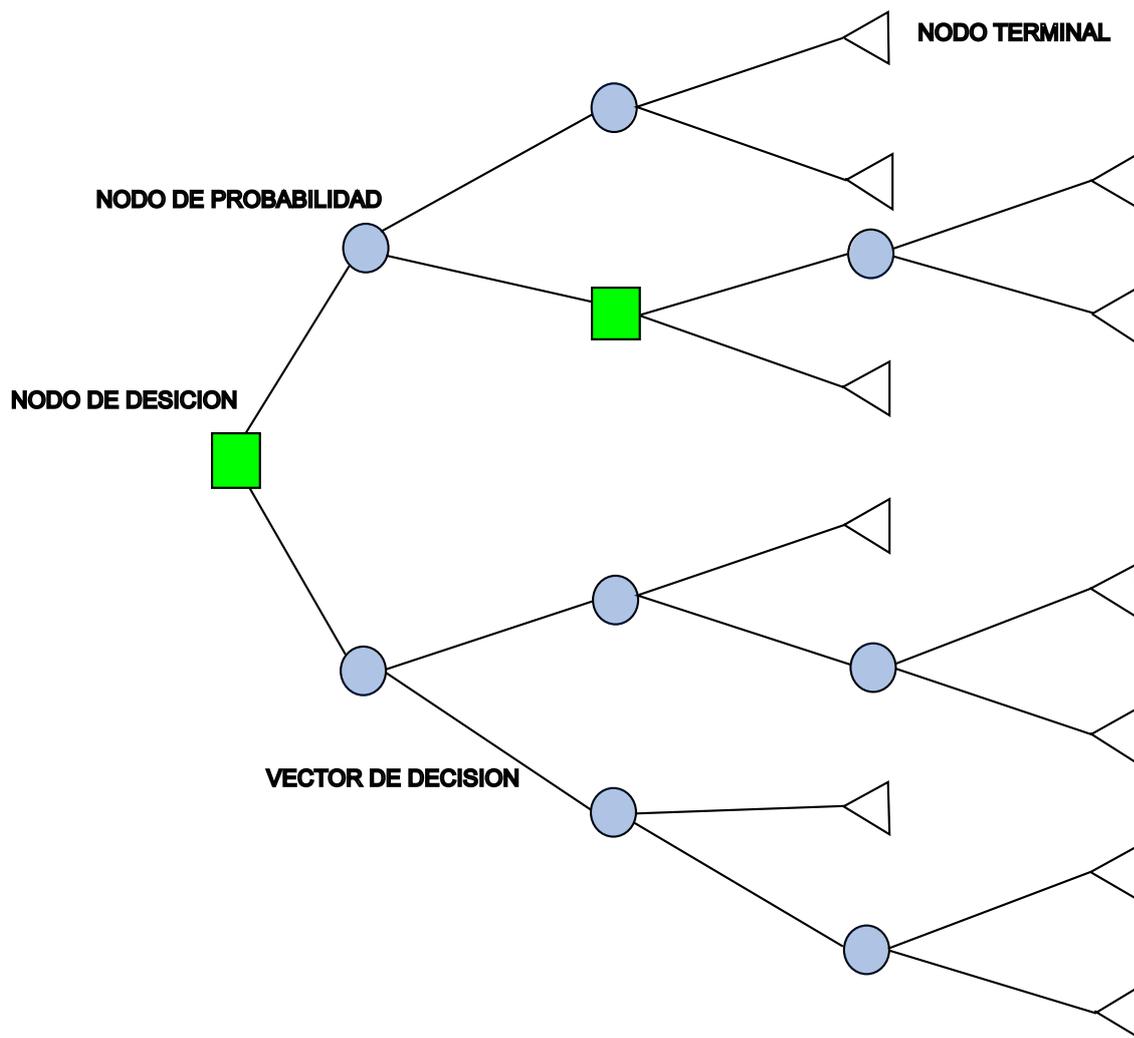


Figura 2.3: Grafico de un árbol de decisión

2.1.4. Clasificación Bayesiana

El clasificador Bayesiano, conocido como Naive Bayes, es uno de los clasificadores mas empleados debido a su simplicidad y eficiencia, Es una técnica de clasificación supervisada que construye modelos predictivos basados en el Teorema de Bayes, estimando la probabilidad de posibles resultados a partir de los datos de entrada [9]. Este clasificador se fundamenta en la suposición de que todas las variables son independientes entre sí, dado que la clase ya esta definida. Es decir, cada variable X_i se considera condicionalmente independiente de las demás características, dado el conocimiento de la clase. Por ejemplo,

para identificar una fruta como una manzana, se podría considerar su color rojo, su forma redonda y su diámetro alrededor de 7 cm. El clasificador Bayesiano asume que cada una de estas características influye en la probabilidad de que la fruta sea una manzana de manera independiente de las otras características.

Una de las principales ventajas del clasificador Bayesiano es que requiere una pequeña cantidad de datos de entrenamiento para estimar los parámetros necesarios (medias y varianzas de las variables) para la clasificación. Al asumir la independencia de las variables, solo es necesario calcular las varianzas dentro de cada clase, en lugar de toda la matriz de covarianza.

El proceso de aprendizaje en Naive Bayes puede interpretarse como la búsqueda de la clase mas probable para un conjunto de datos de entrenamiento, utilizando la información previa sobre la probabilidad de cada clase. Esta capacidad para manejar datos de manera eficiente y realizar predicciones precisas con un modelo simple lo convierte en una herramienta valiosa para la clasificación de señales neuronales del cerebro. El teorema de Bayes se expresa matemáticamente de la siguiente manera:

$$P(A|B) = (P(A)P(B|A))/P(B) \quad (2.1)$$

Donde: $P(A|B)$ es la probabilidad posterior de que ocurra la clase A dado el conjunto de características B $P(B|A)$ es la probabilidad de observar características B dado que la clase A es verdadera. $P(A)$ es la probabilidad a priori de la clase A. $P(B)$ es la probabilidad total de las características B.

El algoritmo de clasificación basado en el teorema de Bayes sigue estos pasos:

1. Se estiman probabilidades condicionales $P(A|B)$ para cada clase A y características B en el conjunto de datos de entrenamiento.
2. Se calculan probabilidades a priori $P(A)$ para cada clase A utilizando los datos de entrenamiento.
3. Se utiliza el teorema de Bayes para calcular la probabilidad posterior $P(A|B)$ para cada clase A dado el conjunto de características B.

4. Se asigna la clase al objeto correspondiente que tenga la mayor probabilidad posterior, utilizando la siguiente fórmula:

$$Clase = \underset{B}{\operatorname{argmax}} P(B) \prod_{i=1}^n P(A_i|B) \quad (2.2)$$

Este proceso permite clasificar un nuevo objeto basándose en la probabilidad máxima de que pertenezca a una clase específica, considerando las características observadas. Este enfoque es particularmente útil en la clasificación de señales neuronales, donde se debe tomar una decisión basada en datos complejos y posiblemente ruidosos.

2.2. Validación Cruzada

La validación cruzada es una técnica utilizada para evaluar la robustez de un modelo en diferentes subconjuntos de datos. El método más común, la validación cruzada k-fold, divide el conjunto de datos en k subconjuntos, permitiendo entrenar y evaluar el modelo k veces. Esta técnica asegura que el modelo generalice bien y no se sobreajuste a un subconjunto específico de datos [3]. En este contexto se utiliza un enfoque en el cual, de manera iterativa, se oculta un punto de datos del conjunto de entrenamiento, se entrena el modelo con el resto de los datos, y luego se predice el valor del punto oculto. Este valor predicho se compara con el valor real para evaluar el rendimiento del modelo. El proceso se repite para todos los puntos del conjunto, permitiendo obtener una estimación precisa de cómo el modelo funcionaría en datos no observados. Este enfoque es particularmente valioso en la clasificación de señales EEG para predecir estados mentales, dado que permite evaluar el rendimiento del modelo sin requerir datos adicionales. Al simular la predicción de puntos desconocidos basándose en los datos existentes, se obtiene una métrica robusta de la capacidad del modelo para hacer predicciones confiables en nuevas situaciones. Si los errores en la validación cruzada son significativos, es probable que el modelo tenga dificultades para generalizar a nuevos conjuntos de datos, lo que sugiere la necesidad de ajustar los parámetros del modelo o explorar nuevas técnicas de clasificación. Este método, cuando se implementa con k iteraciones (k-fold cross-validation), garantiza que todos los datos

se utilicen tanto para el entrenamiento como para validación ofreciendo una evaluación más completa y balanceada del desempeño del clasificador.

2.3. Técnicas de Evaluación de desempeño

En el campo del reconocimiento de patrones, es crucial evaluar el desempeño de los clasificadores utilizando diversas técnicas que proporcionan métricas cuantitativas. Estas métricas permiten una comprensión más profunda de la eficiencia de un modelo de clasificación, especialmente aplicaciones como la clasificación de señales neuronales en el cerebro.

2.3.1. Curva ROC y Área bajo la Curva (AUC-ROC)

La curva ROC (Receiver Operating Characteristic) es una representación gráfica que muestra el rendimiento de un clasificador binario a diferentes umbrales de decisión. El área bajo la curva (AUC-ROC) es una medida cuantitativa del desempeño del clasificador donde un valor cercano a 1 indica un mejor rendimiento en la clasificación de señales neuronales. Las curvas ROC (Receiver Operating Characteristic) son una herramienta eficaz para evaluar el rendimiento de un clasificador en una amplia gama de valores posibles de una variable predictora. En el contexto de la clasificación de señales neuronales mediante EEG, LA CURVA Roc permite identificar el mejor umbral de decisión, asegurando que se maximice el área bajo la curva (AUC), lo que garantiza un equilibrio adecuado entre sensibilidad y especificidad. En aplicaciones como la detección de estados mentales, este equilibrio es crucial para lograr una clasificación precisa sin comprometer el rendimiento del modelo. Al igual que en contextos médicos donde se busca optimizar el desempeño de una prueba diagnóstica, en la clasificación de EEG no es suficiente contar con un modelo altamente sensible pero poco específico. Es necesario un enfoque global que considere las implicaciones de los errores en la clasificación, dado que una alta tasa de falsos positivos o negativos pueden afectar significativamente los resultados de la investigación o aplicación. Asimismo, la curva Roc se utiliza para definir puntos de corte que optimizan el rendimien-

to de los clasificadores. En el análisis de EEG, estos puntos de corte pueden asociarse a la identificación mas precisa de ciertos patrone neuronales o estados mentales, permitiendo ajustar el modelo de acuerdo con las características específicas de los datos.

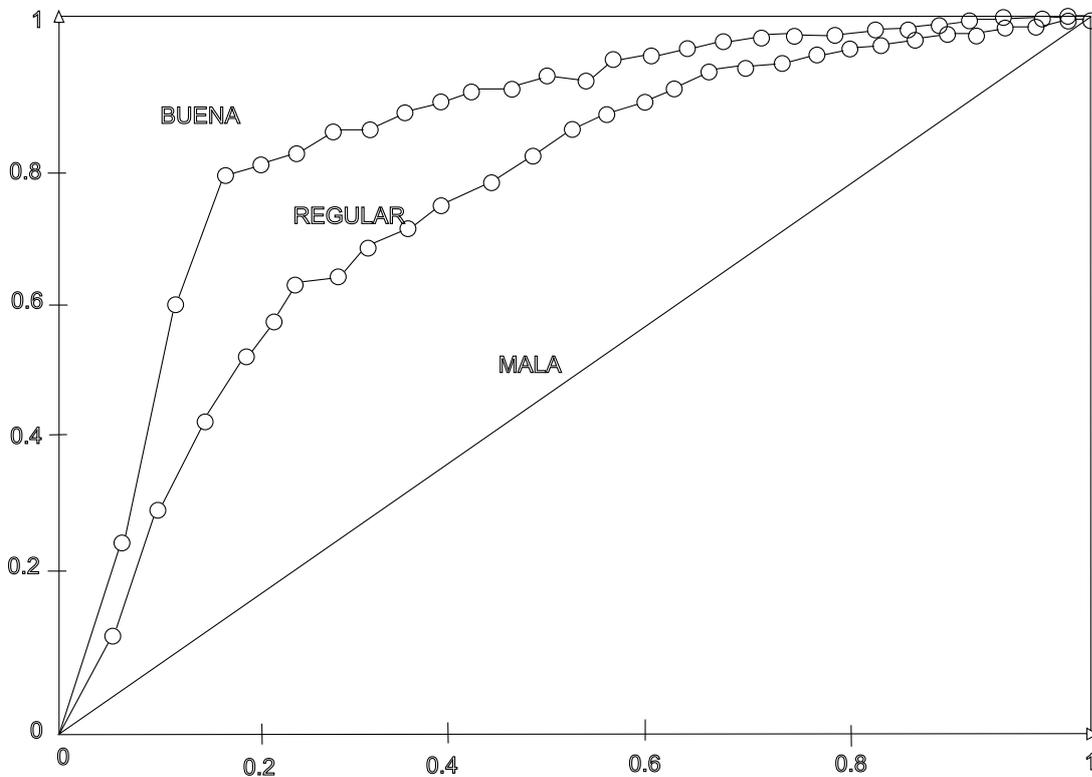


Figura 2.4: Gráfica AUC-ROC

2.3.2. Métricas de Clasificación Multiclase

En problemas de clasificación con más de dos clases, como podría ser la diferencia entre varios estados mentales a partir de señales neuronales, se utilizan métricas adicionales, estas incluyen la matriz de confusión multiclase, la precisión macro/micro ponderada y la métrica de error multiclase, que ayuda a evaluar de manera integral el desempeño del clasificador en escenarios complejos. En los problemas de clasificación multiclase, a diferencia de la clasificación binaria, no es necesario seleccionar un umbral de puntuación para hacer predicciones. En su lugar, la predicción corresponde a la clase con la puntuación mas alta calculada por el modelo. Sin embargo, si se desea aumentar la confianza

en las predicciones, se puede definir un umbral mínimo, aceptando únicamente aquellas predicciones cuya puntuación sea superior al umbral. Para evaluar el rendimiento en problemas multiclase, se suelen emplear métricas similares a las usadas en la clasificación binaria. Cada clase se trata como un problema binario, donde se agrupa el resto de las clases como una sola clase negativa. A partir de aquí, se calculan métricas como precisión, sensibilidad o F1 para cada clase y luego se promedian. Ese promedio puede realizarse de manera macro (dando igual importancia a todas las clases) o ponderada (teniendo en cuenta la frecuencia de cada clase). Por ejemplo, en el análisis de EEG, estas métricas son fundamentales para evaluar la eficacia de los clasificadores multiclase que predice diferentes estados mentales. En el contexto de clasificación de señales EEG, el uso de la métrica F1 media ponderada puede ser clave, dado que ciertas clases (por ejemplo, ciertos estados mentales o emociones) podrían ser menos frecuentes y el rendimiento de clasificación para estas clases debe ser adecuadamente ponderado para reflejar su importancia.

2.3.3. Matriz de Confusión

La matriz de confusión es una herramienta fundamental para evaluar el desempeño de un clasificador. Esta tabla muestra el número de Verdaderos Positivos (VP), Falsos Positivos (FP), Verdaderos Negativos (VN) y Falsos Negativos (FN) que resultan de las predicciones del modelo. A partir de esta matriz, se pueden calcular métricas esenciales como la precisión, la sensibilidad, la especificidad y valor F1, que son fundamentales para comprender la capacidad del modelo para clasificar correctamente las señales neuronales. En esta tesis, el uso de la matriz de confusión permitirá evaluar como el modelo de clasificación procesa las señales EEG y como diferencia correctamente entre los diferentes estados mentales. Al comparar las predicciones del modelo con los valores reales, se puede asegurar la validez y eficiencia del sistema de clasificación empleado, ajustando los parámetros según sea necesario para mejorar la precisión en futuras predicciones.

2.3.4. Verdadero positivo (VP)

Se refiere a cuando el modelo clasifica correctamente un caso positivo, es decir, cuando tanto la predicción como el valor real pertenecen a la clase positiva. En el contexto de la clasificación de señales EEG para predecir estados mentales, un verdadero positivo ocurre cuando el algoritmo predice correctamente un estado mental determinado que coincide con el estado real de la persona.

2.3.5. Verdadero Negativo (VN)

En este caso, el modelo predice correctamente un valor negativo. Esto significa que, tanto en la predicción como en la realidad, el caso pertenece a la clase negativa. En la clasificación de EEG, un verdadero negativo se presentaría cuando el modelo identifica correctamente que el individuo o se encuentra en un estado mental específico que se está monitoreando.

2.3.6. Falso positivo (FP)

Un falso positivo ocurre cuando el modelo predice un valor positivo incorrectamente, es decir, el modelo predice que un estado mental específico está presente cuando, en realidad, no lo está. Esto se conoce como error de tipo I, y es crucial minimizarlo para evitar que el sistema clasifique de manera errónea a las personas en estado mentales que no corresponden.

2.3.7. Falso Negativo (FN)

Este error se presenta cuando el modelo clasifica incorrectamente un caso real positivo como negativo, lo que significa que el sistema no logra identificar correctamente un estado que realmente está presente. Este es un error de tipo II, y es particularmente problemático en la clasificación de señales EEG por que podría llevar a no detectar estados mentales críticos o relevantes. Estas métricas ayudan a comprender el rendimiento del modelo y son esenciales para optimizar la clasificación utilizados en la predicción de estados mentales a

partir de EEG.

2.3.8. Precisión

La precisión se define como la proporción de verdaderos positivos con respecto al total de predicciones positivas. Esta métrica es crucial cuando el soto de los falsos positivos es alto, como en la clasificación de patrones cerebrales donde una clasificación incorrecta podría llevar a interpretaciones erróneas.

2.3.9. Sensibilidad

La sensibilidad, también conocida como recall, es la proporción de verdaderos positivos con respecto al total de positivos reales. Esta métrica es particularmente importante en la detección de señales neuronales críticas, donde es esencial minimizar los falsos negativos.

2.3.10. Especificidad

La especificidad mide la proporción de verdaderos negativos con respecto al total de negativos reales, y es vital en contextos donde la correcta identificación de señales no relevantes es tan importante como la detección de las relevantes

2.3.11. Valor F1

El valor F1 combina la precisión y la sensibilidad en una única métrica que proporciona una evaluación balanceada del rendimiento del clasificador, especialmente útil cuando se requiere un equilibrio entre ambas métricas.

2.4. Técnicas de selección de características

La selección de características es un proceso esencial en el análisis de datos y el aprendizaje automático. Su objetivo principal es identificar las características mas relevantes de un conjunto de datos, eliminando aquellas redundantes o irrelevantes, para mejorar el

rendimiento y la eficiencia de los modelos predictivos. En el contexto de esta tesis, que se enfoca en la clasificación de señales cerebrales mediante técnicas de machine learning, la selección de características es fundamental para optimizar la precisión del clasificador y reducir la complejidad computacional. Este enfoque tiene varias ventajas clave, como la reducción del costo computacional, lo que permite un entrenamiento más rápido de los modelos de clasificación, así como la mejora en la capacidad de generalización del modelo al centrarse solo en las características más relevantes. Además, este proceso facilita una mejor interpretación de los datos subyacente, ayudando a comprender los patrones presentes en las señales cerebrales. Al aplicar técnicas de selección de características a los datos EEG, se priorizan los atributos que proporcionan la mayor capacidad predictiva, mejorando el rendimiento global del clasificador en la predicción de estados mentales o patologías neurológicas. Este proceso también puede ayudar a evitar el sobreajuste, un problema común cuando se utilizan demasiadas características no informativas en un modelo.

2.4.1. Métodos de Filtrado

Para el proceso de selección de características dentro de modelos de clasificación, se pueden emplear diversas métricas para determinar la relevancia de cada variable respecto a la variable objetivo. Entre las más comunes se encuentra la correlación de Pearson, que evalúa la relación lineal entre las características y la variable del objetivo. Si la correlación es baja, las características pueden considerarse irrelevantes para el modelo y eliminarse. Por otro lado, el método de Información Mutua mide la dependencia entre las variables, independientemente de si la relación es lineal o no, permitiendo así identificar características que aporten información única a la variable de salida. Además, las pruebas estadísticas univariadas como la prueba t y la prueba chi-cuadrado, son útiles para determinar si las características tienen una relación significativa con la variable de interés. Estas pruebas evalúan la importancia estadística de cada característica de manera individual, lo que ayuda a filtrar variables irrelevantes en etapas iniciales del análisis de datos. Implementar estos métodos contribuye a la mejora del rendimiento de los modelos al reducir la dimensionalidad y minimizar el ruido dentro del conjunto de datos, lo que es fundamental para

la clasificación precisa de señales complejas como las EEG.

2.4.2. Métodos Wrapper

Los métodos Wrapper para la selección de características se basan en la evaluación directa del rendimiento a medida que se modifican las combinaciones de variables, buscando identificar el subconjunto óptimo de características. Estos métodos comprenden tres enfoques principales:

1. Selección hacia adelante (Forward Selection): Se parte de un conjunto vacío y se van agregando las características de una en una, eligiendo aquellas que, al ser incorporadas, mejoran el rendimiento del modelo de manera significativa.
2. Eliminación hacia atrás (Backward Elimination): A diferencia de la anterior, se comienza con el conjunto completo de características y se eliminan de forma progresiva aquellas que no aportan valor significativo al desempeño del modelo, hasta encontrar la combinación óptima.
3. Búsqueda exhaustiva (Exhaustive Search): Se consideran todas las combinaciones posibles de características, evaluándolas una por una hasta identificar el subconjunto que maximiza el rendimiento del modelo. Aunque esta técnica garantiza la mejor selección, es computacionalmente costosa y se utiliza en datasets con pocas características o cuando el rendimiento del modelo es crítico.

Estos métodos proporcionan un enfoque sistemático para seleccionar características relevantes, optimizando la precisión y reduciendo el sobreajuste lo cual resulta crucial en el procesamiento de datos complejos como los EEG.

2.4.3. Métodos Integrados

Los métodos integrados se caracterizan por realizar la selección de características simultáneamente durante la fase de entrenamiento del modelo. A diferencia de los enfoques de filtrado o wrapper, que se aplican antes o después del entrenamiento, los métodos de

integrados ajustan el modelo y seleccionan características de forma conjunta, logrando así un proceso más eficiente. Un ejemplo de estos métodos es la regularización L1, que se emplea en algoritmos como la regresión logística o las máquinas de soporte vectorial (SVM). Este tipo de regularización añade un término de penalización a la función de costo, incentivando que algunas características tengan coeficientes iguales a cero, permitiendo así un proceso de selección automática de características más relevantes para el modelo. De este modo, los métodos integrados logran simplificar el modelo y mejorar su generalización sin la necesidad de realizar un análisis de características por separado.

2.4.4. Algoritmos Genéticos

Los algoritmos genéticos se basan en principios de la evolución natural, como la selección, mutación y cruce, para identificar de manera automática un conjunto de características óptimo que mejore el rendimiento del modelo. Estos algoritmos simulan el proceso de selección natural, comenzando con una población inicial de posibles soluciones y, a través de varias generaciones, cambian y modifican características hasta encontrar un subconjunto que maximice el desempeño del modelo. De esta forma, se logra un enfoque sistemático para la selección de características que permite explorar de manera eficiente un amplio espacio de soluciones, identificando combinaciones de atributos que serían difíciles de detectar con métodos tradicionales.

2.4.5. Métodos Basado en Aprendizaje No Supervisado

En el contexto del aprendizaje no supervisado, algunas técnicas de selección de características resultan útiles para identificar patrones y relaciones en los datos sin la necesidad de etiquetas de clase. Entre estas técnicas se encuentra el Análisis de Componentes Principales (PCA), un método de reducción de dimensionalidad que permite seleccionar las características más relevantes al conservar solo aquellos componentes que representan la mayor variabilidad de los datos originales. Aunque su objetivo principal es la simplificación de la estructura de datos, PCA se utiliza para reducir la complejidad del modelo al eliminar atributos redundantes o irrelevantes y mantener únicamente la información más

significativa. Otra técnica es el Aprendizaje de Diccionario, que se asemeja a la extracción de características. Mediante este método, se aprende un conjunto de “átomos” o representaciones parciales de los datos de entrada, optimizando la forma en que se describen los patrones. De esta manera, se genera un subconjunto de características que capturan eficientemente la estructura interna del conjunto de datos, logrando un enfoque más compacto y representativo.

2.4.6. Métodos Basados en Algoritmos de clasificación

En los enfoques basados en algoritmos de clasificación, se pueden identificar características importantes mediante el uso de ciertas métricas proporcionadas por los modelos. Un ejemplo de esto es el uso de Árboles de Decisión y Bosques Aleatorios, los cuales generan indicadores que permiten evaluar la relevancia de cada atributo en el proceso de clasificación. Estos métodos calculan la importancia de las características analizando el impacto de cada una en la división de los nodos y en la reducción de la impureza durante la construcción del árbol. De este modo, las características con mayor relevancia se identifican como las que contribuyen más al rendimiento del modelo, facilitando así la selección de atributos. Por otro lado, en el caso de las Redes Neuronales, la importancia de las características puede ser evaluada a través de los coeficientes de pesos sinápticos asociados a cada conexión. Durante el proceso de entrenamiento de una red neuronal, estos pesos se ajustan de acuerdo a la influencia de cada característica en la predicción, permitiendo identificar que atributos tienen mayor impacto en el desempeño del modelo. Por ejemplo, el análisis de estos coeficientes proporciona una forma efectiva de seleccionar los elementos más relevantes para la clasificación.

Capítulo 3

Metodología

3.1. Diseño de la investigación

En esta sección se describen los pasos llevados a cabo para realizar los experimentos. La Figura 3.1 muestra los pasos llevados a cabo para realizar la clasificación de EEG. La Figura muestra el proceso completo comunmente utilizado.

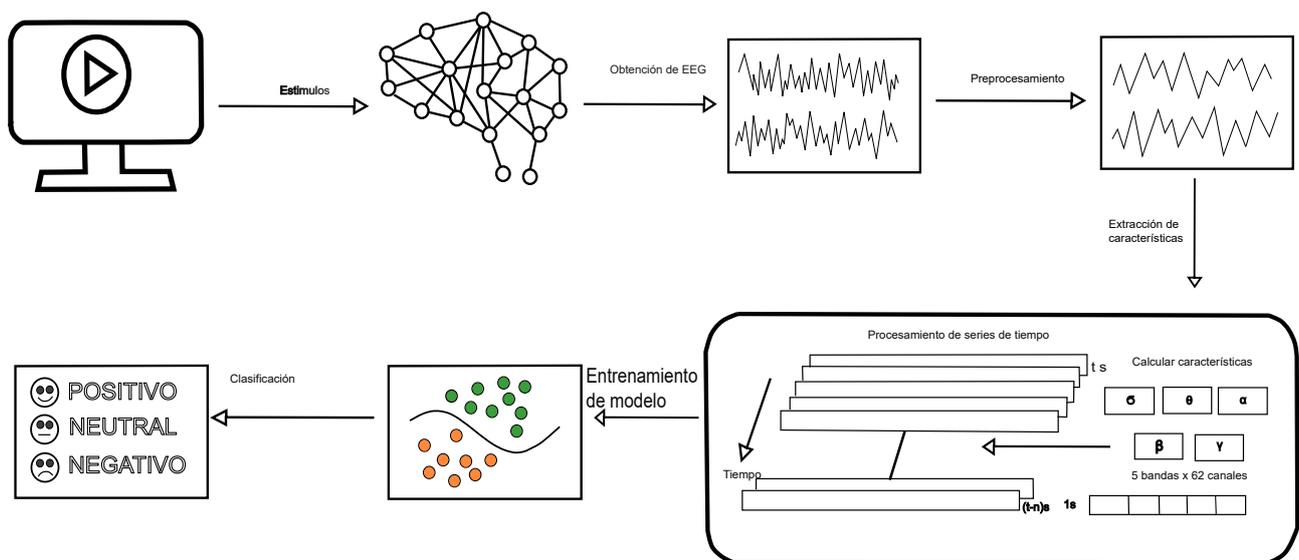


Figura 3.1: Gráfica de metodología para clasificación de EEG

3.2. Conjunto de datos

El conjunto de datos utilizado en este estudio fue obtenido de la plataforma Kaggle (<https://www.kaggle.com/>), específicamente diseñado para la clasificación de actividad cerebral. Este dataset está compuesto por características de las ondas cerebrales, las cuales han sido previamente re-muestreadas para garantizar una frecuencia uniforme y facilitar su análisis.

Los datos fueron recopilados de cuatro sujetos, dos hombres y dos mujeres, cada uno de los cuales fue expuesto a tres estados mentales distintos:

1. **Relajado:** Los participantes fueron inducidos a un estado de calma mediante estímulos que promovían la relajación.
2. **Concentrado:** Se les pidió realizar tareas que requerían enfoque mental, como seguimiento de objetos en movimiento o resolución de problemas.
3. **Neutral:** Un estado en el que los participantes no recibían estímulos específicos ni para relajar ni para concentrar, manteniendo un estado mental sin perturbaciones.

En total, el conjunto de datos contiene 2479 muestras, cada una representando un estado mental específico, y asociada con 988 características que describen diversas propiedades de las señales EEG (electroencefalográficas) registradas durante cada prueba. Además, cada muestra está acompañada por una etiqueta que indica el estado mental correspondiente. Esto resulta en una matriz de datos con dimensiones de 2479 filas (una por cada muestra) y 989 columnas, donde las primeras 988 columnas corresponden a las características de las señales EEG, y la última columna representa la etiqueta de clasificación del estado mental.

Este conjunto de datos es altamente valioso para entrenar modelos de clasificación que permitan distinguir entre los diferentes estados mentales a partir de las señales EEG, proporcionando una base sólida para desarrollar sistemas de interfaz cerebro-computadora o análisis cognitivos avanzados.

3.3. Selección de características

Con el objetivo de optimizar el desempeño de los clasificadores y reducir la complejidad computacional del modelo, se implementaron técnicas avanzadas de selección de características. Este proceso busca eliminar atributos redundantes e irrelevantes en el conjunto de datos, permitiendo que los algoritmos de clasificación trabajen con información más relevante y eficiente. Se emplearon dos enfoques para la selección de características: a) un algoritmo genético, que utiliza principios de la evolución natural, como la selección, el cruce y la mutación, para identificar el subconjunto óptimo de características, y b) el método Minimal Redundancy Maximal Relevance (MRMR), que selecciona aquellas características que maximizan la relevancia con respecto a la variable objetivo, al mismo tiempo que minimizan la redundancia entre ellas. Estos métodos permiten mejorar no solo la precisión del modelo, sino también su capacidad para generalizar mejor en datos no vistos, al reducir el riesgo de sobreajuste y facilitar una interpretación más clara de los resultados.

3.3.1. Algoritmo Genético para la Selección de Características

Un algoritmo genético (AG) es un enfoque basado en la evolución de las especies, que busca soluciones óptimas o cercanas al óptimo dentro de un espacio de búsqueda amplio. Para la selección de características, el algoritmo genético utiliza una representación binaria para indicar las características que deben seleccionarse y las que deben eliminarse. Cada individuo en la población representa un subconjunto de características, y la calidad de cada individuo se evalúa mediante una función de aptitud que refleja el rendimiento del modelo en ese subconjunto. los pasos clave se enumeran a continuación:

1. Se crea una población inicial de posibles soluciones (individuos). Cada individuo es un vector binario de longitud igual al número de características del conjunto de datos, donde un 1 indica que la característica está seleccionada, y un 0 que la característica no se incluye.
2. Cada individuo es evaluado mediante una función de aptitud. En este caso, la función

de aptitud puede basarse en el desempeño de un clasificador, como la precisión o el error del modelo entrenado solo con las características seleccionadas. A menudo, también se incluye una penalización por el número de características para evitar seleccionar demasiadas.

3. Se seleccionan los individuos más aptos (los mejores subconjuntos de características) para reproducirse, utilizando estrategias como la selección por torneo o por ruleta.
4. Dos individuos seleccionados (padres) se combinan para producir nuevos individuos (hijos), intercambiando parte de su información genética. Por ejemplo, el cruce podría intercambiar algunos bits entre dos individuos, lo que da lugar a nuevos subconjuntos de características.
5. Se aplican pequeñas alteraciones aleatorias en los individuos (normalmente invirtiendo un bit en el vector binario), lo que introduce variabilidad en la población y evita el estancamiento en óptimos locales.
6. Los individuos menos aptos son reemplazados por los descendientes generados en la población. Este ciclo de evaluación, cruce y mutación se repite durante varias generaciones hasta que el algoritmo converge hacia una solución óptima o se alcanza un criterio de parada (como un número máximo de generaciones o un rendimiento deseado).

3.3.2. Minimal Redundancy Maximal Relevance (MRMR)

El método MRMR (Minimal Redundancy Maximal Relevance) es un enfoque de selección de características basado en información mutua, que equilibra dos objetivos principales:

1. Maximizar la relevancia de las características seleccionadas con respecto a la variable objetivo.
2. Minimizar la redundancia entre las características seleccionadas para evitar la inclusión de características que aporten información similar o redundante.

El funcionamiento de MRMR se divide en los siguientes pasos:

1. **Cálculo de la Relevancia** La relevancia de una característica con respecto a la variable objetivo (o clase) se mide mediante la información mutua. La información mutua cuantifica cuánto saber el valor de una característica reduce la incertidumbre sobre la clase. Cuanto mayor es la información mutua entre una característica y la clase, más relevante es esa característica. la siguiente formula muestra la formula para calcular la información mutua:

$$I(X; Y) = \sum_{x \in X} \sum_{y \in Y} P(x, y) \log \frac{P(x, y)}{P(x)P(y)} \quad (3.1)$$

Donde $I(X; Y)$ es la información mutua entre la característica X y la clase Y , y $P(x, y)$ es la probabilidad conjunta de x y y .

2. **Cálculo de la Redundancia** La redundancia se mide entre cada par de características seleccionadas utilizando también la información mutua. Si dos características tienen una alta información mutua entre sí, significa que son redundantes, ya que proporcionan información similar.
3. **Criterio de Selección** MRMR selecciona la característica que maximiza la diferencia entre la relevancia de esa característica con respecto a la clase y su redundancia con respecto a las características ya seleccionadas. Es decir, se busca una característica que proporcione información nueva sobre la clase y que no esté duplicando la información ya incluida en las características seleccionadas. El criterio MRMR se define como $\max(\text{Relevancia} - \text{Redundancia})$ y se expresa mediante la siguiente ecuación:

$$MRMR = \max \left(\frac{1}{|S|} \sum_{X_i \in S} I(X_i; Y) - \frac{1}{|S|} \sum_{X_i, X_j \in S} I(X_i; X_j) \right) \quad (3.2)$$

Donde S es el conjunto de características seleccionadas, $I(X_i; Y)$ es la información mutua entre la característica X_i y la clase Y , e $I(X_i; X_j)$ es la información mutua entre las características X_i y X_j .

4. **Proceso Iterativo** El proceso comienza seleccionando la característica más relevante, y luego, en cada iteración, se selecciona la siguiente característica que maximice el criterio MRMR. El proceso continúa hasta que se selecciona un número predefinido de características o hasta que no se pueden añadir más características que cumplan con el criterio.

3.4. Entrenamiento de Modelos

En esta sección, se detalla el proceso de entrenamiento de los modelos supervisados de aprendizaje automático, diseñados para predecir los estados mentales a partir de datos de electroencefalogramas (EEG). El enfoque propuesto combina las diferentes técnicas de clasificación y validación para asegurar la precisión y la capacidad de generalización de los modelos.

3.4.1. División de Datos

Para garantizar una evaluación justa del desempeño de los modelos, los datos fueron divididos en tres subconjuntos:

La división del conjunto de datos permite una evaluación exhaustiva del rendimiento de los modelos en diferentes fases del proceso de desarrollo.

1. Conjunto de entrenamiento (70 %): Utilizado para ajustar los parámetros de los modelos.
2. Conjunto de validación (15 %): Empleado para afinar los hiperparámetros y prevenir el sobreajuste, asegurando que el modelo generalice bien a datos no vistos.
3. Conjunto de prueba (15 %): Reservado exclusivamente para evaluar el rendimiento final de los modelos después del entrenamiento y la optimización.

3.4.2. Selección de Algoritmos de Clasificación

Para realizar los experimentos se entrenaron varios modelos de aprendizaje supervisado que han demostrado eficacia en tareas de clasificación en contextos similares. Los algoritmos seleccionados son:

1. **Máquinas de Soporte Vectorial (SVM)** Un modelo poderoso para la clasificación de alta dimensionalidad, que maximiza el margen entre clases y es particularmente efectivo en conjuntos de datos complejos.
2. **Redes Neuronales Artificiales (ANN)** Inspiradas en la estructura del cerebro, las ANN son capaces de capturar relaciones no lineales entre las características extraídas del EEG y los estados mentales.
3. **Naive Bayes** Este método de clasificación es basado en el Teorema de Bayes, que se utiliza para predecir a qué clase pertenece un conjunto de datos. Estos clasificadores son probabilísticos y asignan etiquetas de clase basándose en la probabilidad condicional de que los datos pertenezcan a una clase determinada.
4. **Árboles de decisión.** Los árboles de decisión son una técnica de aprendizaje supervisado utilizada tanto para clasificación como para regresión. Funcionan dividiendo un conjunto de datos en ramas, según características de entrada, hasta llegar a decisiones o predicciones finales.

Estos algoritmos fueron seleccionados debido a su capacidad para manejar datos de EEG complejos y de alta dimensionalidad, así como su habilidad para extraer patrones relevantes relacionados con los estados mentales.

3.4.3. Obtención de los modelos

Los modelos fueron entrenados utilizando las características previamente extraídas de las señales EEG, tales como las frecuencias cerebrales (alfa, beta, theta, delta) y otras métricas derivadas. Durante el entrenamiento, se implementaron las siguientes técnicas para mejorar la robustez de los modelos

1. **Validación cruzada** Se aplicó un esquema de validación cruzada en k pliegues para asegurar que los modelos no estuvieran ajustados solo a un subconjunto específico de datos, sino que fueran capaces de generalizar bien en distintas particiones del conjunto de entrenamiento. Este enfoque es esencial para reducir el riesgo de sobreajuste y aumentar la capacidad de generalización de los modelos en datos reales.
2. **Ajuste de hiperparámetros** Se utilizó la búsqueda de malla (grid search) para optimizar los hiperparámetros de los modelos. El ajuste fino de estos parámetros asegura que los modelos se desempeñen de manera óptima.

3.4.4. Evaluación de Modelos

Para evaluar el desempeño de los modelos, se utilizaron varias métricas que ofrecen una evaluación integral de su capacidad predictiva

1. **Precisión** La proporción de predicciones correctas sobre el total de predicciones, que mide el rendimiento general del modelo.
2. **Sensibilidad (recall)** Indica la capacidad del modelo para identificar correctamente los estados mentales positivos o de interés, minimizando falsos negativos.
3. **Especificidad** Refleja la capacidad del modelo para detectar correctamente los estados negativos, evitando falsos positivos.
4. **F1-score** Una métrica combinada que pondera tanto la precisión como la sensibilidad, ofreciendo una medida balanceada en situaciones con distribuciones desiguales entre clases.
5. **Área Bajo la Curva ROC (AUC)** Esta métrica proporciona una visión general de la capacidad del modelo para distinguir entre clases, siendo robusta en casos con desequilibrios en los datos.

Capítulo 4

Resultados experimentales

4.1. Descripción del Conjunto de Datos EEG

En esta Sección se describe en detalle el conjunto de datos

4.1.1. Origen del Conjunto de Datos

Este conjunto de datos consiste en registros de ondas cerebrales obtenidas mediante un EEG (Electroencefalograma), que se han procesado utilizando un método de extracción estadística de características. El conjunto de datos es el resultado de este procesamiento y contiene las características de las ondas cerebrales que han sido resampleadas, de modo que las señales puedan describirse matemáticamente en función del tiempo.

Los datos se recopilaron de cuatro personas: dos hombres y dos mujeres. Cada participante fue sometido a tres estados mentales diferentes:

1. Relajado
2. Concentrado
3. Neutral

Cada uno de estos estados fue registrado durante 60 segundos por participante, lo que da lugar a un conjunto de datos con grabaciones de EEG en esos tres estados para cada uno de los sujetos.

La herramienta utilizada para la grabación de las señales EEG fue la banda Muse EEG, que mide la actividad cerebral en los siguientes cuatro puntos específicos:

1. TP9
2. AF7
3. AF8
4. TP10

Estos puntos corresponden a ubicaciones estándar de electrodos en la cabeza, registrando la actividad eléctrica en esas regiones. Todos los datos se obtuvieron utilizando electrodos secos, lo que facilitó la captura no invasiva y rápida de las señales.

El procesamiento de los datos incluye un método estadístico para extraer características relevantes de las señales cerebrales. La extracción de características se llevó a cabo a partir de la serie temporal de las ondas cerebrales, con el objetivo de capturar patrones relevantes para cada estado mental.

El proceso incluye re-muestreo (resampling) de las señales, asegurando que las ondas cerebrales puedan ser descritas matemáticamente en una secuencia temporal.

Extracción estadística de características, que probablemente incluye medidas como la media, la desviación estándar, las potencias en diferentes bandas de frecuencia, y otras estadísticas descriptivas que ayudan a capturar los patrones de las señales.

Este conjunto de datos ha sido utilizado en múltiples proyectos de investigación relacionados con la clasificación de estados mentales. El estudio principal asociado a este conjunto de datos puede encontrarse en [4]. Este estudio investiga cómo se pueden clasificar los estados mentales (como relajación, concentración y estado neutral) utilizando señales EEG en el contexto de una interfaz cerebro-máquina. El conjunto de datos ha sido empleado en una variedad de proyectos de investigación, particularmente en el campo de las interfaces cerebro-máquina y la clasificación de estados mentales.

4.2. Resultados Experimentales

4.2.1. Naive Bayes

A continuación, se discuten los resultados obtenidos utilizando el clasificador Bayesiano bajo tres escenarios: 1) Con el conjunto de datos con todas las características. 2) Con el conjunto de datos con características reducidas usando un Algoritmo Genético (AG). 3) Con el conjunto de datos con características reducidas usando el método MRMR (Maximum Relevance Minimum Redundancy).

1. **Clasificación con todas las características.** El clasificador Bayesiano tiene un rendimiento aceptable cuando se utilizan todas las características. La Tabla 4.1 muestra los resultados obtenidos con los diferentes conjuntos de datos (con todas las características, selección usando un algoritmo genético y selección utilizando el algoritmo MRMR) La clase con mejor desempeño es la clase 2 (TP Rate: 92.3 %, F-Measure: 91.9 %, ROC AUC: 0.977), mientras que la clase 1 tiene el peor desempeño (TP Rate: 66.4 %, F-Measure: 72 %, ROC AUC: 0.890), lo que sugiere que el modelo tiene dificultades para distinguir correctamente esta clase, clasificando erróneamente muchos ejemplos de la clase 1 como clase 0 y clase 2, lo cual se refleja en la Matriz de Confusión donde hay 218 ejemplos incorrectamente clasificados como clase 0 La Figura 4.1 muestra las matrices de confusión obtenidas con los tres conjuntos de datos.
2. **Clasificación con características reducidas mediante Algoritmo Genético (AG).** La reducción de características usando el Algoritmo Genético mejora significativamente el rendimiento del clasificador Bayesiano en comparación con el uso de todas las características. El TP Rate promedio ponderado aumenta a 92.2 %, mostrando una mejora en la capacidad del modelo para identificar correctamente las instancias de todas las clases. La clase con mejor desempeño sigue siendo la clase 2 (TP Rate: 99.0 %, F-Measure: 96.5 %, ROC AUC: 0.987), y también se observa una gran mejora en la clase 1 (TP Rate: 89.3 %, F-Measure: 88.7 %, ROC AUC: 0.959). Esto sugiere que el uso de un enfoque evolutivo como el Algoritmo Genéti-

co selecciona características relevantes que maximizan la capacidad predictiva del modelo.

En la Matriz de Confusión, el número de clasificaciones incorrectas se reduce considerablemente, especialmente para la clase 1, donde el número de ejemplos incorrectamente clasificados como clase 0 baja a solo 43, frente a los 218 del conjunto completo de características.

- 3. Clasificación con características reducidas mediante MRMR.** La reducción de características con MRMR presenta un rendimiento inferior en comparación con el Algoritmo Genético y ligeramente inferior al uso de todas las características. El TP Rate promedio ponderado se reduce a 79.9 %, y la precisión promedio también disminuye ligeramente a 80.0 %. Este descenso en el rendimiento se debe principalmente al deterioro en la identificación de la clase 1 (TP Rate: 60.4 %, F-Measure: 67.4 %, ROC AUC: 0.874). Sin embargo, la clase 2 mantiene un rendimiento alto (TP Rate: 91.0 %, F-Measure: 90.6 %, ROC AUC: 0.974), lo que sugiere que el método MRMR es menos eficiente en seleccionar características que distinguen correctamente la clase 1.

En la Matriz de Confusión, se observa un aumento en el número de clasificaciones incorrectas para la clase 1, donde 260 ejemplos son clasificados erróneamente como clase 0, lo que indica que el modelo con MRMR tiene dificultades para discernir entre las clases 0 y 1.

El uso de características reducidas mediante el Algoritmo Genético (AG) mejora significativamente el rendimiento del clasificador Bayesiano, mientras que la reducción de características con MRMR no logra el mismo nivel de precisión, en particular, el modelo tiene dificultades con la clase 1.

Matriz de Confusión: El conjunto de características reducido por el AG logra una mejor discriminación entre las clases, reduciendo los errores de clasificación en todas las clases, mientras que MRMR produce más errores en el clasificador, especialmente entre las clases 0 y 1.

Área bajo la curva ROC: El AG mantiene un valor alto en todas las clases (ROC AUC de 0.976), lo que indica una mayor capacidad del clasificador para discriminar correctamente entre las clases, en comparación con el uso de todas las características o MRMR.

En conclusión, el Algoritmo Genético selecciona características que permiten al clasificador Bayesiano obtener un desempeño óptimo, superando tanto al conjunto con todas las características como al método MRMR. Aunque MRMR es un enfoque efectivo para la selección de características, no logra un rendimiento tan alto como el AG, posiblemente debido a su enfoque en maximizar la relevancia sin considerar interdependencias entre características de manera tan efectiva. En este caso, la reducción de características mediante un enfoque evolutivo como AG es altamente recomendable, dado el incremento sustancial en precisión y recall.

Tabla 4.1: Resultados con el algoritmo Bayesiano y diferentes características

Clasificador	Clase	TP Rate	FP Rate	Precisión	Recall	F-Measure	MCC	ROC Area	PRC Area
Bayes	0	0.882	0.133	0.766	0.882	0.820	0.726	0.940	0.852
	1	0.664	0.090	0.787	0.664	0.720	0.601	0.890	0.779
	2	0.923	0.043	0.915	0.923	0.919	0.878	0.977	0.917
	Promedio	0.823	0.088	0.823	0.823	0.820	0.735	0.935	0.849
Bayes (GA)	0	0.882	0.026	0.944	0.882	0.912	0.871	0.983	0.974
	1	0.893	0.061	0.881	0.893	0.887	0.829	0.959	0.936
	2	0.990	0.031	0.942	0.990	0.965	0.948	0.987	0.952
	Promedio	0.922	0.039	0.922	0.922	0.921	0.883	0.976	0.954
Bayes (MRMR)	0	0.884	0.158	0.734	0.884	0.802	0.698	0.945	0.904
	1	0.604	0.095	0.763	0.604	0.674	0.544	0.874	0.745
	2	0.910	0.049	0.903	0.910	0.906	0.859	0.974	0.912
	Promedio	0.799	0.100	0.800	0.799	0.794	0.700	0.931	0.853

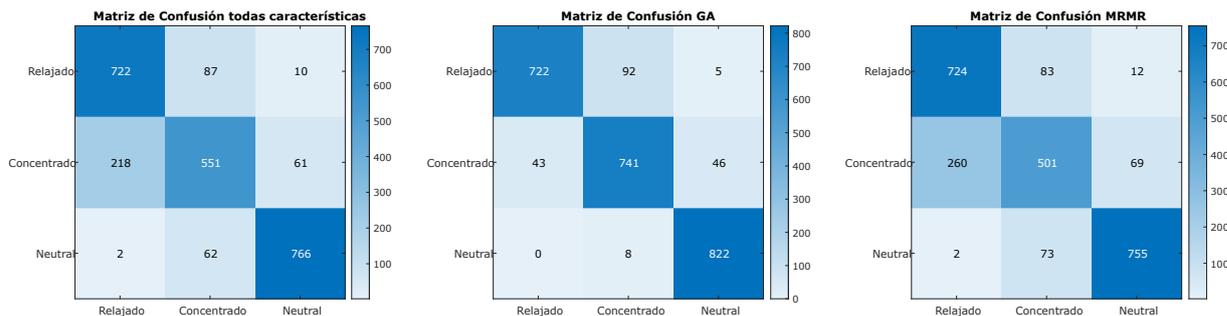


Figura 4.1: Matrices de confusión del clasificador Naive Bayes con diferentes características

4.2.2. Redes Neuronales

A continuación, se realiza un análisis comparativo de los resultados obtenidos con un clasificador de redes neuronales (NN) aplicado a tres conjuntos de datos: 1) con todas las características, 2) con características reducidas mediante Algoritmo Genético (GA), y 3) con características reducidas mediante el algoritmo MRMR.

1. **Conjunto de datos con todas las características (NN original).** Con el conjunto completo de características, las redes neuronales ofrecen un desempeño excelente en términos de todas las métricas, con una notable precisión y capacidad de discriminación. La clase 2 tiene el mejor rendimiento, mientras que la clase 1 presenta un poco más de errores a clasificar. Los valores de F-Measure reflejan un buen balance entre precisión y recall, siendo los más altos para la clase 2 (0.990) y los más bajos para la clase 1 (0.908). En el caso de ROC Area, todos los valores son altos, superando el 0.92 para todas las clases, lo que indica una alta capacidad del clasificador para distinguir correctamente entre clases. Las matrices de confusión muestran que las clases están bien diferenciadas, con muy pocos errores de clasificación, especialmente en la clase 2.
2. **Conjunto de datos con características reducidas mediante AG (NN + GA).** La reducción de características con el algoritmo genético reduce el rendimiento del clasificador, particularmente para las clases 0 y 1. Aunque el clasificador sigue siendo eficaz para la clase 2, el aumento en los falsos positivos y la reducción en

la precisión general muestran que la eliminación de características relevantes afecta la calidad de la clasificación. Aunque la precisión para la clase 2 sigue siendo alta (0.974), las otras clases muestran una caída, especialmente la clase 0 con 0.800. En el caso de F-measure, La clase 2 sigue destacando con un F-Measure de 0.974, mientras que la clase 0 (0.835) y la clase 1 (0.796) muestran rendimientos más bajos.

3. **Conjunto de datos con características reducidas mediante MRMR (NN + MRMR).** La reducción de características con el algoritmo MRMR ofrece una mejora considerable sobre AG y se acerca más al rendimiento del conjunto original de características. Aunque hay una ligera disminución en algunas métricas en comparación con el conjunto completo, el clasificador sigue mostrando un buen equilibrio entre precisión y recall, con una clara ventaja en la clase 2.

El modelo entrenado con todas las características con redes neuronales tiene el mejor desempeño global, especialmente para la clase 2. Sin embargo, este puede ser un modelo más complejo y computacionalmente costoso. Para este clasificador en especial, la reducción de características con AG parece impactar negativamente el desempeño, especialmente en las clases 0 y 1, con un aumento en los falsos positivos y una reducción en la precisión. Esto sugiere que el AG puede haber eliminado características importantes para la clasificación correcta en estas clases.

El algoritmo MRMR ofrece una mejora considerable sobre AG, recuperando gran parte del desempeño original. Esto sugiere que MRMR es más eficaz al seleccionar las características más relevantes para el clasificador de redes neuronales, manteniendo un equilibrio adecuado entre rendimiento y reducción dimensional.

En todos los casos, la clase 2 tiene el mejor desempeño, con valores consistentemente altos en todas las métricas. Las clases 0 y 1 son más propensas a errores de clasificación, especialmente cuando se reduce el número de características.

El clasificador de redes neuronales tiene un rendimiento óptimo con el conjunto de datos completo. La reducción de características con MRMR es una estrategia eficaz para mantener un buen equilibrio entre rendimiento y eficiencia. Por otro lado, la reducción con AG parece ser menos efectiva y puede llevar a una pérdida significativa de información,

afectando la precisión del modelo en las clases más difíciles de clasificar.

Tabla 4.2: Resultados con el algoritmo Bayesiano y diferentes características

Modelo	Class	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area
NN	Relajado	0.944	0.052	0.899	0.944	0.921	0.881	0.946	0.870
	Concentrado	0.882	0.031	0.935	0.882	0.908	0.864	0.928	0.865
	Neutral	0.994	0.007	0.987	0.994	0.990	0.986	0.994	0.984
NN-GA	Relajado	0.872	0.107	0.800	0.872	0.835	0.749	0.882	0.740
	Concentrado	0.760	0.076	0.835	0.760	0.796	0.702	0.843	0.719
	Neutral	0.975	0.013	0.974	0.975	0.974	0.961	0.982	0.960
NN-MRMR	Relajado	0.916	0.065	0.874	0.916	0.894	0.841	0.924	0.825
	Concentrado	0.858	0.046	0.904	0.858	0.880	0.823	0.904	0.824
	Neutral	0.992	0.006	0.988	0.992	0.990	0.985	0.993	0.984

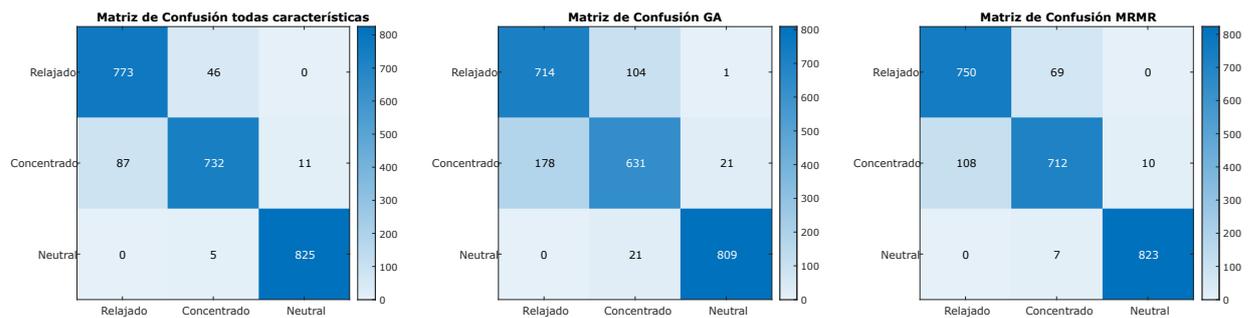


Figura 4.2: Matrices de confusión para redes neuronales con diferentes características

4.2.3. SVM

en esta Sección, se discuten los resultados obtenidos utilizando el clasificador SVM bajo tres escenarios: 1) Con el conjunto de datos con todas las características. 2) Con el conjunto de datos con características reducidas usando un Algoritmo Genético (AG). 3) Con el conjunto de datos con características reducidas usando el método MRMR (Maximum Relevance Minimum Redundancy).

1. **Conjunto de datos con todas las características (SVM).** Como lo muestra la Tabla 4.3 y las graficas de confusión 4.3, este conjunto de datos muestra un excelente

desempeño con una tasa promedio ponderada de precisión, recall y F-measure de 0.962, lo cual indica un rendimiento superior en la clasificación. Este modelo presenta el mejor rendimiento general, ya que no se han reducido las características, lo que permite al modelo explotar toda la información disponible. Esto resulta en una mayor precisión y recall para todas las clases. La clase 0 y la clase 2 tienen muy pocos errores de clasificación, aunque la clase 1 tiene más confusión con la clase 2, lo cual se refleja en el mayor número de falsos positivos. La clase 2 tiene el mejor rendimiento, con una precisión y recall superiores al 0.99, lo que indica una clasificación casi perfecta.

2. **Conjunto de datos con características reducidas usando Algoritmo Genético (SVM-GA).** Aquí observamos una ligera caída en el rendimiento global en comparación con el conjunto completo. El F-measure ponderado baja a 0.934, mostrando una ligera reducción en la capacidad de generalización del modelo. La tasa de acierto baja a 0.926 y la tasa de falsos positivos aumenta a 0.040, lo que indica que el modelo no es tan preciso para esta clase como en el caso del conjunto completo. La confusión entre las clases es más pronunciada, particularmente entre las clases 1 y 2. La clase 1 tiene más instancias clasificadas incorrectamente como clase 2 (23 errores) en comparación con el modelo usando todas las características. Aunque la reducción de características con GA mejora la eficiencia del modelo (menor cantidad de datos procesados), también se observa una ligera degradación en la precisión y recall para la mayoría de las clases, particularmente en la clase 1. Esto podría deberse a que el proceso de selección de características con GA no retiene toda la información relevante para la clasificación de ciertas clases, lo que afecta el rendimiento del modelo.
3. **Conjunto de datos con características reducidas usando MRMR (SVM-MRMR).** En este caso, el rendimiento del clasificador SVM mejora con respecto al uso de características reducidas con GA. El F-measure ponderado es de 0.941, más cercano al modelo con todas las características. Aunque hay una ligera mejora con respecto al modelo SVM-GA, sigue siendo inferior al modelo completo. La precisión

es de 0.923 y el recall de 0.904, lo que sigue reflejando una mayor confusión con otras clases. Al reducir el número de características con MRMR, la confusión entre las clases es menor que en el caso del modelo SVM-GA. Sin embargo, la clase 1 sigue mostrando errores al clasificar, con 25 instancias clasificadas incorrectamente como clase 2. La selección de características con MRMR logra un mejor equilibrio entre la reducción de características y el mantenimiento de un alto rendimiento en el modelo. Aunque todavía hay una pequeña disminución en la precisión y recall en comparación con el conjunto completo de características, el modelo con MRMR es más eficiente y presenta una menor pérdida de precisión en comparación con GA. Esto sugiere que MRMR es más efectivo al seleccionar características relevantes para este tipo de problema de clasificación.

Tabla 4.3: Resultados con SVM y diferentes características

Model	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
SVM	0.958	0.022	0.955	0.958	0.957	0.935	0.994	0.990	Relajado
	0.936	0.022	0.955	0.936	0.945	0.918	0.992	0.985	Concentrado
	0.993	0.012	0.977	0.993	0.985	0.978	0.999	0.998	Neutral
Promedio	0.962	0.019	0.962	0.962	0.962	0.944	0.995	0.991	
SVM-GA	0.926	0.040	0.920	0.926	0.923	0.884	0.986	0.977	Relajado
	0.895	0.044	0.912	0.895	0.903	0.855	0.981	0.958	Concentrado
	0.983	0.015	0.971	0.983	0.977	0.966	0.999	0.997	Neutral
Promedio	0.935	0.033	0.934	0.935	0.934	0.902	0.989	0.977	
SVM-MMR	0.941	0.033	0.933	0.941	0.937	0.906	0.993	0.987	Relajado
	0.904	0.038	0.923	0.904	0.913	0.870	0.986	0.975	Concentrado
	0.980	0.016	0.968	0.980	0.974	0.960	0.998	0.993	Neutral
Promedio	0.942	0.029	0.941	0.942	0.941	0.912	0.992	0.985	

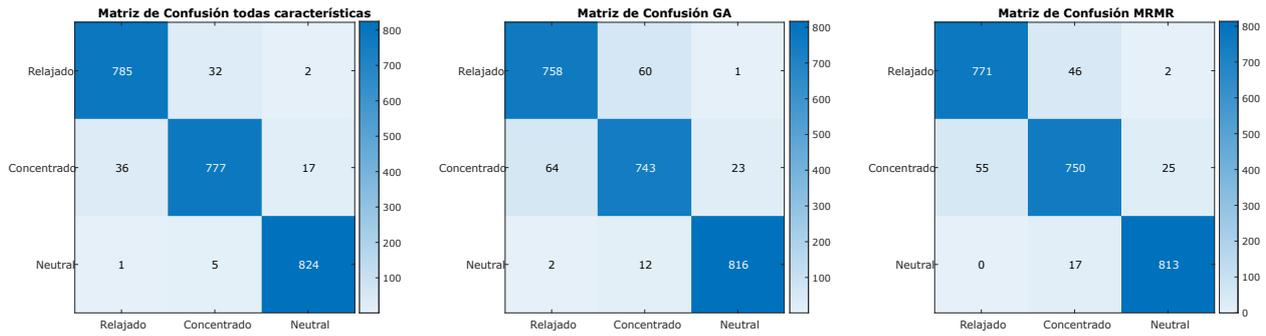


Figura 4.3: Matrices de confusión para SVM con diferentes características

4.2.4. Árboles de decisión

El análisis de los resultados de las tablas para los clasificadores basados en Árboles de Decisión (DT), tanto con el conjunto de datos completo como con los conjuntos reducidos mediante Algoritmo Genético (GA) y MRMR, permite una visión clara de cómo se desempeña el modelo con diferentes conjuntos de características. A continuación, se presenta un análisis y discusión de cada escenario.

1. **Árboles de Decisión con todas las características.** El clasificador con todas las características muestra un desempeño sólido y balanceado, con una excelente capacidad predictiva para todas las clases. Sin embargo, las clases 1 y 2 tienen un ligero incremento en la tasa de falsos positivos comparado con la clase 0. El valor promedio ponderado del F-Measure es de 0.959, lo que indica que el modelo es equilibrado en cuanto a precisión y recall. Además, el área bajo la curva ROC (ROC Area) y el área bajo la curva de precisión-recall (PRC Area) son extremadamente altos, cerca de 1.0, lo que refleja un rendimiento excelente.
2. **Árboles de Decisión con características reducidas mediante Algoritmo Genético (GA).** La reducción de características mediante GA ha mejorado ligeramente el desempeño del clasificador, principalmente en la precisión y la reducción de falsos positivos en la clase 0, sin sacrificar la calidad global del modelo. En este escenario, se observa una ligera mejora en la precisión de la clase 0 (0.943) y la clase

1 (0.946) en comparación con el conjunto de datos completo. La clase 2 mantiene una tasa de verdaderos positivos perfecta de 1.000, similar al escenario anterior. El F-Measure promedio ponderado sube a 0.963, lo que sugiere una ligera mejora en el balance entre precisión y recall en comparación con el conjunto completo. Los valores de ROC Area y PRC Area permanecen cercanos a 1.0, lo que respalda la alta calidad del modelo.

3. **Árboles de Decisión con características reducidas mediante MRMR.** El uso de MRMR para la reducción de características parece haber afectado ligeramente el desempeño del clasificador en comparación con el conjunto completo y con GA, especialmente en la tasa de falsos positivos de las clases 0 y 1. Aunque la calidad global sigue siendo alta, este método parece menos efectivo que GA en este caso. El F-Measure promedio ponderado es de 0.953, lo que representa una pequeña disminución en comparación con los otros dos modelos. Aun así, los valores de ROC Area y PRC Area siguen siendo muy altos, indicando que el modelo sigue siendo eficaz en términos generales.

El clasificador con todas las características muestra un buen balance entre precisión y recall, pero la reducción de características con GA logra un mejor rendimiento en términos de precisión y una reducción más significativa de los falsos positivos, especialmente en la clase 0.

GA parece ser más efectivo que MRMR para mejorar el rendimiento del clasificador. Aunque ambos métodos de reducción de características mantienen una alta capacidad predictiva, GA logra una mejoría en las métricas clave (TP Rate, Precision, FP Rate) sin sacrificar precisión en ninguna clase.

Dado el análisis, el clasificador con reducción de características mediante GA parece ser la mejor opción, ya que mejora ligeramente el desempeño del clasificador en comparación con el uso de todas las características y mantiene una mejor precisión y menor tasa de falsos positivos que MRMR.

Este análisis sugiere que el uso de técnicas de reducción de características, como GA, puede ser beneficioso para mejorar el rendimiento de los clasificadores sin sacrificar capa-

cidad predictiva.

Tabla 4.4: Resultados con Árboles de decisión y diferentes características

Método	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
Árboles de Decisión (Conjunto Completo)									
Relajado	0.935	0.004	0.992	0.935	0.963	0.946	0.995	0.992	0
Concentrado	0.942	0.030	0.940	0.942	0.941	0.911	0.993	0.986	1
Neutral	1.000	0.027	0.949	1.000	0.974	0.961	0.999	0.998	2
Promedio Ponderado	0.959	0.020	0.960	0.959	0.959	0.939	0.996	0.992	-
Árboles de Decisión con GA									
Relajado	0.943	0.002	0.996	0.943	0.969	0.955	0.997	0.994	0
Concentrado	0.946	0.027	0.947	0.946	0.946	0.919	0.994	0.989	1
Neutral	1.000	0.027	0.949	1.000	0.974	0.961	0.999	0.999	2
Promedio Ponderado	0.963	0.019	0.964	0.963	0.963	0.945	0.997	0.994	-
Árboles de Decisión con MRMR									
Relajado	0.932	0.006	0.987	0.932	0.959	0.940	0.994	0.989	0
Concentrado	0.929	0.031	0.938	0.929	0.933	0.900	0.990	0.981	1
Neutral	1.000	0.033	0.939	1.000	0.968	0.953	0.999	0.998	2
Promedio Ponderado	0.954	0.023	0.955	0.954	0.953	0.931	0.994	0.989	-

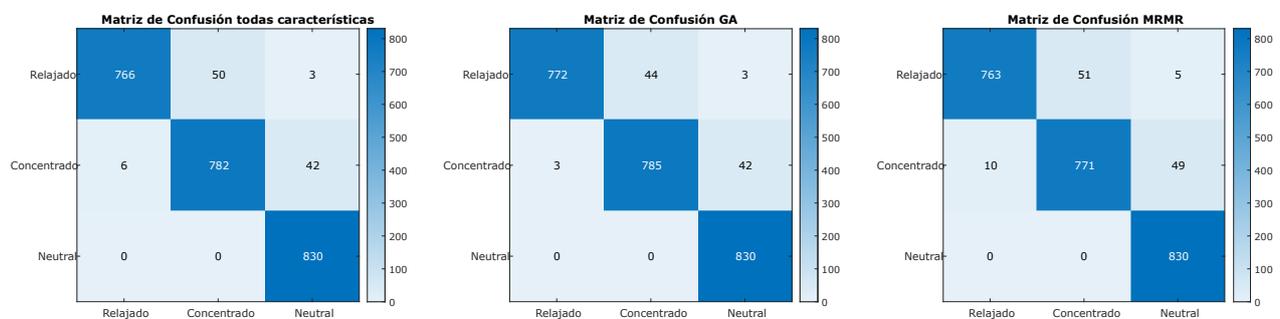


Figura 4.4: Matrices de confusión para Árboles de decisión con diferentes características

Capítulo 5

Conclusiones

5.1. Discusiones

A partir de los resultados mostrados en las secciones anteriores, podemos realizar una evaluación de la hipótesis planteada:

Los resultados obtenidos por los modelos, tanto con las características completas como reducidas, muestran un buen desempeño general en términos de precisión, tasa de verdaderos positivos (TP Rate), y otras métricas clave como el área bajo la curva ROC. Esto sugiere que los algoritmos de aprendizaje automático, en combinación con las técnicas de preprocesamiento aplicadas, están cumpliendo con el objetivo de predecir con precisión los estados mentales. Sin embargo, la ligera disminución en las métricas al reducir las características con algunos métodos (por ejemplo, GA) indica que el proceso de extracción de características puede impactar la precisión dependiendo de la técnica empleada.

La mejora significativa en el rendimiento predictivo en términos de métricas como el TP Rate, FP Rate y ROC Area cuando se aplican técnicas de preprocesamiento (como se observa en los modelos con reducción de características con MRMR), respalda la hipótesis de que estas técnicas contribuyen a la eliminación de ruido y artefactos, mejorando la calidad de los datos. El modelo basado en características reducidas por MRMR mostró resultados consistentes y un rendimiento superior en comparación con otros métodos de selección, sugiriendo que el preprocesamiento fue eficaz para mejorar la precisión de los

modelos.

Aunque los resultados de precisión y recall son prometedores, para evaluar si los modelos pueden ser integrados en sistemas de monitoreo en tiempo real se necesitarían pruebas adicionales, considerando factores como la eficiencia computacional y la latencia en la toma de decisiones. Sin embargo, la robustez de los modelos en la predicción de estados mentales sugiere que, con la optimización adecuada, estos podrían ser aplicables en entornos prácticos como la salud mental o la educación.

En conclusión, los resultados obtenidos respaldan la hipótesis de que los modelos predictivos basados en datos EEG, junto con técnicas de preprocesamiento avanzadas, pueden mejorar la precisión y calidad de los datos. Sin embargo, se deben considerar las diferencias en rendimiento entre diferentes métodos de selección de características para optimizar la integración en sistemas de tiempo real y aplicaciones prácticas.

5.2. Conclusiones

Los modelos implementados (SVM y árboles de decisión) han demostrado un alto rendimiento en la clasificación de estados mentales a partir de datos EEG, con tasas de precisión y recall que respaldan la capacidad de predecir con precisión estos estados. Esto valida la hipótesis de que, con la correcta aplicación de técnicas de preprocesamiento y extracción de características, es posible superar algunas limitaciones actuales relacionadas con el ruido y los artefactos en los registros EEG.

En particular, los modelos con reducción de características mediante AG han mostrado una mayor precisión en comparación con aquellos con reducción mediante MRMR, sugiriendo que la selección adecuada de las características es crucial para optimizar el rendimiento predictivo.

Para integrar estos modelos en sistemas de monitoreo en tiempo real, como los que se utilizarían en salud mental, educación o entornos laborales, se recomienda realizar pruebas de eficiencia computacional y evaluar el rendimiento en condiciones en las que el procesamiento rápido de señales sea fundamental. Implementar algoritmos de optimización o reducción de características adicionales podría mejorar la viabilidad de estas aplicaciones.

Dado que los estados mentales pueden variar considerablemente entre individuos, se recomienda explorar modelos personalizados para cada usuario, ajustando los algoritmos y técnicas de preprocesamiento según las características específicas de las señales EEG de cada persona.

Los resultados obtenidos tienen un alto potencial para impactar en áreas como la salud mental, permitiendo el desarrollo de herramientas no invasivas que monitoricen en tiempo real los estados emocionales de los usuarios. Esto podría ser particularmente útil en el manejo de trastornos como la depresión, el estrés o la ansiedad, brindando a los profesionales de la salud mental una herramienta adicional para monitorear y mejorar el bienestar de los pacientes.

El uso de estos sistemas en entornos educativos podría ofrecer retroalimentación en tiempo real sobre el estado cognitivo de los estudiantes, permitiendo personalizar los métodos de enseñanza para mejorar la concentración y el rendimiento académico.

En el ámbito laboral, estos sistemas podrían utilizarse para monitorear el estrés y la fatiga mental de los trabajadores, ayudando a mejorar la productividad y la calidad de vida en el trabajo. Esto podría ser particularmente valioso en trabajos que demandan alta concentración o en situaciones de alto estrés.

En resumen, los resultados obtenidos presentan un gran potencial para mejorar la calidad de vida de las personas en diversos contextos a través de la implementación de sistemas basados en el monitoreo y análisis de señales EEG.

Bibliografía

- [1] Alexandra Bedoya-Rojas et al. “Interfaz Cerebro Computador Basado en Señales EEG para el Control de Movimiento de una Prótesis de Mano Usando ANFIS”. En: *Lámpsakos* 10 (jun. de 2013), pág. 59. ISSN: 2145-4086. DOI: 10.21501/21454086.1053.
- [2] Rocío Jiménez Arévalo José Beltrán Ramírez Raúl Maciel Arellano. “la tecnología y la inteligencia artificial como futuro en el área médica”. Español. En: *Universitas-XXI, Revista de Ciencias Sociales y Humanas* (2014). ISSN: 1390-3837. URL: <https://www.redalyc.org/articulo.oa?id=476147261009>.
- [3] Daniel Berrar. “Cross-Validation”. En: *Encyclopedia of Bioinformatics and Computational Biology*. Elsevier, 2019, págs. 542-545. ISBN: 9780128114322. DOI: 10.1016/b978-0-12-809633-8.20349-x.
- [4] Jordan J. Bird et al. “A Study on Mental State Classification using EEG-based Brain-Machine Interface”. En: *2018 International Conference on Intelligent Systems (IS)*. IEEE, sep. de 2018. DOI: 10.1109/is.2018.8710576.
- [5] Jair Cervantes, Xiaou Li y Wen Yu. “Multi-Class SVM for Large Data Sets Considering Models of Classes Distribution.” En: *Proceedings of the 2008 International Conference on Data Mining, DMIN 2008*. Ene. de 2008, págs. 30-35.
- [6] Jair Cervantes et al. “A Fast SVM Training Algorithm Based on a Decision Tree Data Filter”. En: *Advances in Artificial Intelligence*. Springer Berlin Heidelberg, 2011, págs. 187-197. ISBN: 9783642253249. DOI: 10.1007/978-3-642-25324-9_16.

-
- [7] Jair Cervantes et al. “Data selection based on decision tree for SVM classification on large data sets”. En: *Applied Soft Computing* 37 (dic. de 2015), págs. 787-798. ISSN: 1568-4946. DOI: 10.1016/j.asoc.2015.08.048.
- [8] Jair Cervantes et al. “Support vector machine classification for large data sets via minimum enclosing ball clustering”. En: *Neurocomputing* 71.4-6 (2008), págs. 611-619. DOI: 10.1016/j.neucom.2007.07.028.
- [9] Cheng-Jin Du y Da-Wen Sun. “Object Classification Methods”. En: *Computer Vision Technology for Food Quality Evaluation*. Elsevier, 2008, págs. 81-107. ISBN: 9780123736420. DOI: 10.1016/b978-012373642-0.50007-7.
- [10] Adrian Trueba Espinosa et al. “Classification of radiological patterns of tuberculosis with a Convolutional neural network in x-ray images”. En: *ELCVIA Electronic Letters on Computer Vision and Image Analysis* 23.1 (jul. de 2024), págs. 47-59. ISSN: 1577-5097. DOI: 10.5565/rev/elcvia.1561.
- [11] Farid García-Lamont et al. “Computing the Number of Groups for Color Image Segmentation Using Competitive Neural Networks and Fuzzy C-Means”. En: *Intelligent Computing Theories and Application*. Ed. por De-Shuang Huang y Kang-Hyun Jo. Cham: Springer International Publishing, 2016, págs. 579-590. ISBN: 978-3-319-42294-7.
- [12] Cristian Guarnizo-Lemus. “Análisis de reducción de ruido en señales eeg orientado al reconocimiento de patrones”. En: *TecnoLógicas* 21 (dic. de 2008), pág. 67. ISSN: 0123-7799. DOI: 10.22430/22565337.248.
- [13] Alberto Lizcano-Portilla, Luis Mendoza y Zulmary Nieto-Sánchez. “Procesamiento de señales cerebrales provenientes de estímulos visuales y auditivos utilizando análisis wavelet y redes neuronales artificiales”. En: *Revista UIS Ingenierías* 19.2 (mayo de 2020), págs. 119-125. ISSN: 1657-4583. DOI: 10.18273/revuin.v19n2-2020013.

-
- [14] Leonardo Montes et al. “Präna: Una aplicación de la Inteligencia Computacional para el procesamiento de datos EEG en la clasificación de un estado mental”. En: sep. de 2017.
- [15] Angulo H. Naive et al. *Máquinas de aprendizaje para clasificar señales electroencefalográficas*. 2009. URL: <https://repositorio.unal.edu.co/handle/unal/28580>.
- [16] Guillermo Roberto Solarte Martínez y Carlos Alberto Ocampo. “Técnicas de clasificación y análisis de representación del conocimiento para problemas de diagnóstico”. En: *Scientia et Technica* 2.42 (2009). DOI: 10.22517/23447214.2639. URL: <https://revistas.utp.edu.co/index.php/revistaciencia/article/view/2639>.
- [17] Yanni Wu. “Métodos automáticos para la detección de apnea del sueño a partir del procesado de señales de EEG y ECG”. Available at <https://hdl.handle.net/10251/152442>. Master thesis. Valencia Spain: Universitat Politècnica de València. Departamento de Comunicaciones - Departament de Comunicacions, 2020.