



UAEM | Universidad Autónoma
del Estado de México

UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO

CENTRO UNIVERSITARIO UAEMEX TEXCOCO

TESIS

**Análisis de Desempeño en la Detección de Estados de Confusión
Utilizando EEG**

Tesis que presenta

Alan Uribe Bautista

Para obtener el grado de

Ingeniero en Computación

Revisores de Tesis:

Dra. Laura Yadira Domínguez

Jalili

Dr. Josué Espejel Cabrera

Asesor de Tesis:

Dr. Jair Cervantes Canales

Texcoco, Estado de México

Noviembre del 2024



UAEM | Universidad Autónoma
del Estado de México

AUTONOMOUS UNIVERSITY OF THE STATE OF MEXICO

UAEMEX TEXCOCO UNIVERSITY CENTER

THESIS

**Performance Analysis in the Detection of Confusional States
Using EEG**

Submitted by

Alan Uribe Bautista

As a fulfillment of the requirements for the degree of
Computer Science Engineering

Thesis Advisor:
Ph.D. Jair Cervantes Canales

Thesis Reviewers:
**Ph.D. Laura Yadira Domínguez
Jalili**

Ph.D. Josué Espejel Cabrera

Texcoco, Estado de México

November 2024

Abstract

This thesis addresses the challenge of detecting confusion states from electroencephalographic (EEG) signals, a significant issue in the field of cognitive monitoring and real-time diagnostics. A comprehensive comparison of the performance of various supervised classification algorithms, including Support Vector Machines (SVM), Neural Networks, Decision Trees, and k-Nearest Neighbors (k-NN), is conducted to determine which one offers the highest accuracy and effectiveness in identifying confusion states.

The research includes the implementation of advanced feature extraction and selection techniques, essential for reducing the dimensionality of EEG data and improving the quality of the classification process. Through a rigorous cross-validation approach, the performance of each classifier is evaluated using key metrics such as accuracy, sensitivity, specificity, and the area under the ROC curve (AUC).

The results of the thesis demonstrate that while all classifiers exhibit competent performance in detecting confusion states, there are significant differences among them, with some models showing a greater ability to handle the inherent variability of EEG signals. Additionally, it is evident that appropriate feature selection positively impacts the improvement of classifier performance.

Finally, the thesis offers recommendations on the use of these models in practical applications, suggesting that the combination of specific classifiers with feature selection techniques can optimize accuracy in confusion detection, which is highly relevant for implementation in clinical and educational settings.

Resumen

En esta tesis se aborda la problemática de la detección de estados de confusión a partir de señales electroencefalográficas (EEG), un desafío significativo en el ámbito del monitoreo cognitivo y diagnóstico. Se lleva a cabo una comparación exhaustiva del desempeño de diferentes algoritmos de clasificación supervisados, entre ellos, máquinas de soporte vectorial (SVM), redes neuronales, árboles de decisión y k-Nearest Neighbors (k-NN), con el objetivo de determinar cuál de ellos ofrece la mayor precisión y eficacia en la identificación de estados de confusión.

La investigación incluye la implementación de técnicas avanzadas de extracción y selección de características, esenciales para reducir la dimensionalidad de los datos EEG y mejorar la calidad del proceso de clasificación. A través de un enfoque riguroso de validación cruzada, se evalúa el rendimiento de cada clasificador utilizando métricas clave como la precisión, sensibilidad, especificidad y el área bajo la curva ROC (AUC).

Los resultados de la tesis demuestran que, si bien todos los clasificadores presentan un rendimiento competente en la detección de estados de confusión, existen diferencias significativas entre ellos, con algunos modelos mostrando una mayor capacidad para manejar la variabilidad inherente de las señales EEG. Además, se evidencia que la selección adecuada de características tiene un impacto positivo en la mejora del desempeño de los clasificadores.

Finalmente, la tesis ofrece recomendaciones sobre el uso de estos modelos en aplicaciones prácticas, sugiriendo que la combinación de clasificadores específicos con técnicas de selección de características puede optimizar la precisión en la detección de confusión, lo que es de gran relevancia para su implementación en contextos clínicos y educativos.

Índice general

1. Introducción	2
1.1. Problemática	3
1.2. Justificación	4
1.3. Objetivos	5
1.3.1. Objetivo General	5
1.3.2. Objetivos Específicos	5
1.4. Hipótesis	5
1.5. Estado del arte	6
2. Antecedentes	9
2.1. Enfoques para identificar y gestionar estados de confusión	10
2.2. Métodos de Clasificación en el Análisis de EEG	12
2.2.1. Técnicas de aprendizaje máquina	12
2.2.2. Redes Neuronales Artificiales (RNA)	13
2.2.3. Support Vector Machines	16
2.2.4. Árboles de decisión	21
2.2.5. Construcción del Árbol	22
2.2.6. Métricas de Impureza	23
2.2.7. Recursión	24
2.2.8. Predicción	24
2.2.9. Clasificación Bayesiana	25
2.2.10. Teorema de Bayes	25

2.2.11. Clasificación	26
2.2.12. Cálculo de Probabilidades	26
2.2.13. Ejemplo de Cálculo	26
2.3. Métricas de Desempeño	27
2.3.1. Matriz de Confusión	27
2.3.2. Precisión	28
2.3.3. Sensibilidad (Recall)	28
2.3.4. Especificidad	29
2.3.5. Valor F1	29
2.3.6. Curva ROC y Área Bajo la Curva (AUC-ROC)	29
2.3.7. Validación Cruzada	30
2.3.8. Métricas de Clasificación Multi-clase	30
3. Metodología	32
3.1. Selección de los conjuntos de datos	33
3.2. Selección de clasificadores	34
3.3. Entrenamiento de Clasificadores	35
3.3.1. Validación cruzada estratificada	36
3.4. Evaluación del Desempeño	38
4. Resultados experimentales	42
4.1. Conjunto de datos	42
4.1.1. Conjunto de datos 1	42
4.1.2. Conjunto de datos 2	43
4.1.3. Correlación de las variables del conjunto de datos 1	45
4.1.4. Correlación de las variables del conjunto de datos 2	47
4.2. Evaluación de los Clasificadores	50
4.2.1. Resultados conjunto de datos 1	50
4.2.2. Resultados conjunto de datos 2	54
4.3. Discusión de Resultados	56

5. Conclusiones**60**

Índice de figuras

2.1. Clasificación (caso lineal separable)	13
2.2. Estructura y componentes básicos de una red neuronal	14
2.3. Pesos y función de activación de una neurona	16
2.4. Clasificación (caso lineal separable)	18
2.5. Estructura básica de un árbol de decisión	22
2.6. Clasificación (caso lineal separable)	25
3.1. Metodología utilizada para clasificación mediante EEG	33
4.1. Matriz de correlación para conjunto de datos 1	45
4.2. Matriz de correlación para conjunto de datos 2	48
4.3. Matrices de confusión de varios modelos	54

Índice de cuadros

- 4.1. Resultados utilizando todas las características 51
- 4.2. Resultados utilizando varias métricas de desempeño 53
- 4.3. Resultados obtenidos con los tres mejores modelos de clasificación 55

Capítulo 1

Introducción

En el campo de la neurociencia y la psicología, la detección precisa de estados mentales es fundamental para comprender el funcionamiento del cerebro y mejorar las intervenciones clínicas. Uno de los métodos más utilizados para monitorear la actividad cerebral es el electroencefalograma (EEG), que captura las señales eléctricas generadas por el cerebro. Estas señales contienen una riqueza de información que puede ser analizada para detectar diferentes estados mentales, entre ellos, la confusión.

La identificación temprana y precisa de estados de confusión es crucial en contextos clínicos y educativos, donde puede servir como un indicador temprano de deterioro cognitivo, fatiga o trastornos neurológicos. Sin embargo, el análisis de las señales EEG es un desafío debido a su alta dimensionalidad y la presencia de ruido. Por lo tanto, la selección del clasificador adecuado es vital para maximizar la precisión y la eficiencia en la detección de estos estados.

En la última década, el aprendizaje automático ha emergido como una herramienta poderosa para el análisis de señales EEG, ofreciendo técnicas avanzadas de clasificación que pueden superar a los métodos tradicionales. Sin embargo, la elección del clasificador más efectivo para un problema específico sigue siendo un área de investigación activa, ya que el rendimiento de un clasificador puede variar significativamente dependiendo del tipo de dato y de la tarea a realizar.

El objetivo de esta tesis es realizar una comparación exhaustiva del desempeño de

diversos clasificadores al detectar estados de confusión utilizando señales EEG. Para ello, se implementarán y evaluarán múltiples algoritmos de clasificación, incluyendo tanto métodos clásicos como técnicas de vanguardia en el campo del aprendizaje automático. Los clasificadores serán evaluados en términos de precisión, sensibilidad, especificidad y eficiencia computacional, utilizando conjuntos de datos reales de EEG.

Esta comparación no solo permitirá identificar el clasificador más adecuado para la tarea específica de detección de confusión, sino que también proporcionará una comprensión más profunda de las fortalezas y limitaciones de cada método en el contexto del análisis de señales EEG. Los resultados de esta investigación podrán guiar futuras aplicaciones y estudios en la detección de estados mentales utilizando técnicas de aprendizaje automático, contribuyendo así al avance de la neurociencia computacional y la psicología cognitiva.

1.1. Problemática

La detección precisa de estados de confusión a partir de señales EEG representa un desafío significativo debido a la complejidad inherente de estas señales y la naturaleza sutil de la confusión como estado mental. Las señales EEG son altamente variables y están influenciadas por numerosos factores, lo que complica la tarea de extraer características relevantes para la clasificación. Además, el estado de confusión es un constructo cognitivo que puede manifestarse de maneras diversas y estar influenciado por condiciones internas y externas, lo que añade otra capa de dificultad a su detección.

Los clasificadores utilizados para interpretar estas señales deben ser lo suficientemente robustos para manejar la alta dimensionalidad y el ruido presente en los datos EEG, al mismo tiempo que son sensibles a las variaciones sutiles que indican un estado de confusión. A pesar de los avances en el campo del aprendizaje automático, no existe un consenso claro sobre qué tipo de clasificador es más adecuado para esta tarea, ya que diferentes clasificadores pueden presentar variaciones significativas en su desempeño dependiendo del tipo de datos y de la metodología empleada.

La falta de estandarización en los procedimientos de evaluación y la diversidad de enfoques utilizados en la literatura agravan la dificultad de seleccionar el clasificador

óptimo para la detección de confusión. Este panorama fragmentado evidencia la necesidad de una comparación sistemática y exhaustiva de los diferentes clasificadores, a fin de identificar los métodos más efectivos y comprender las circunstancias bajo las cuales cada uno de ellos podría ser preferible.

1.2. Justificación

La selección de un clasificador adecuado para la detección de estados de confusión utilizando EEG es crucial no solo para mejorar la precisión al diagnosticar en contextos clínicos y educativos, sino también para optimizar el uso de recursos computacionales y reducir el tiempo de procesamiento. Una comparación exhaustiva de diferentes clasificadores permitirá identificar las fortalezas y debilidades de cada enfoque, proporcionando una base sólida para futuras investigaciones y aplicaciones en la detección automática de estados mentales.

La investigación en este campo tiene el potencial de mejorar significativamente las herramientas de monitoreo cognitivo, permitiendo intervenciones más rápidas y personalizadas para individuos que experimentan confusión, lo que podría tener un impacto positivo en áreas como la neuropsicología, la neurología, y la educación. Además, una comprensión más clara de cómo diferentes clasificadores procesan y analizan las señales EEG contribuirá al desarrollo de modelos más precisos y eficientes, lo que a su vez facilitará la integración de estas tecnologías en entornos clínicos y educativos.

Este estudio no solo beneficiará a los investigadores y profesionales en neurociencia y aprendizaje automático, sino que también tiene el potencial de mejorar la calidad de vida de los pacientes y estudiantes al proporcionar herramientas más precisas para la detección temprana de estados de confusión y la intervención adecuada.

1.3. Objetivos

1.3.1. Objetivo General

Comparar y evaluar el desempeño de diversos clasificadores en la detección de estados de confusión a partir de señales EEG, con el fin de identificar el modelo más eficaz para su aplicación en contextos clínicos y educativos.

1.3.2. Objetivos Específicos

1. Implementar y entrenar una variedad de clasificadores supervisados, incluyendo pero no limitados a máquinas de soporte vectorial (SVM), redes neuronales, árboles de decisión, y aive Bayes (k-NN), utilizando un conjunto de datos EEG previamente etiquetado con estados de confusión.
2. Extraer y seleccionar características relevantes de las señales EEG que sean útiles para la detección de estados de confusión.
3. Evaluar el desempeño de cada clasificador en términos de precisión, sensibilidad, especificidad, y área bajo la curva ROC (AUC), utilizando técnicas de validación cruzada.
4. Comparar los resultados obtenidos entre los diferentes clasificadores para identificar el modelo que ofrece el mejor equilibrio entre precisión y eficiencia computacional.
5. Realizar un análisis de las limitaciones y ventajas de cada clasificador en la detección de estados de confusión, proporcionando recomendaciones para su aplicación en escenarios prácticos.

1.4. Hipótesis

La hipótesis de esta tesis es que existen diferencias significativas en el desempeño de los distintos clasificadores al detectar estados de confusión utilizando EEG. Se espera que

ciertos clasificadores ofrezcan un rendimiento superior en la identificación de estados de confusión, lo que resultará en mejores herramientas de diagnóstico y monitoreo cognitivo.

1.5. Estado del arte

El estado de confusión en jóvenes es un problema cada vez más frecuente en la actualidad, especialmente en el ámbito educativo. Este fenómeno puede deberse a una combinación de factores que afectan tanto su desarrollo cognitivo como emocional [1]. Entre las posibles causas destacan el exceso de información, la sobrecarga cognitiva, el uso excesivo de tecnologías digitales, y la falta de habilidades para gestionar el estrés y la ansiedad. Estos elementos, en conjunto, dificultan la capacidad de los estudiantes para concentrarse, procesar información de manera eficiente y adquirir nuevos conocimientos [5] [6] [9] [7].

En los últimos años, varios investigadores han estudiado este fenómeno en detalle con el objetivo de identificar cuándo un estudiante está en un estado de confusión durante el proceso de aprendizaje. Este esfuerzo busca desarrollar herramientas y metodologías que permitan a los educadores detectar señales tempranas de confusión en sus estudiantes [9]. Estas investigaciones han utilizado desde análisis cualitativos hasta mediciones neurofisiológicas (como el uso de EEG o rastreo ocular) para determinar en qué momentos los alumnos experimentan dificultades para comprender los contenidos.

Los resultados de estos estudios son importantes, ya que permiten a los docentes intervenir de manera proactiva cuando detectan que un estudiante está confundido. De esta manera, pueden ajustar sus estrategias pedagógicas y adoptar métodos más adecuados para el perfil del alumno como 1) Utilizar sistemas que ajustan la dificultad de las tareas según el progreso del estudiante. 2) Proporcionar explicaciones adicionales en tiempo real para corregir errores y aclarar conceptos mal entendidos. 3) Implementar plataformas interactivas que identifiquen patrones de confusión basados en las respuestas o interacciones de los estudiantes con el material.

Además, algunos autores sugieren que la confusión no siempre es negativa [8]. En ocasiones, puede ser un indicador de aprendizaje activo, en el que los estudiantes están desafiando sus propias ideas y buscando nuevas formas de entender conceptos comple-

jos. En este sentido, la confusión, bien manejada, puede ser una oportunidad para el aprendizaje profundo y la resolución de problemas [2].

La confusión en los estudiantes no es simplemente un obstáculo, sino un síntoma de un problema más amplio que afecta la forma en que los jóvenes de hoy interactúan con la información y adquieren conocimientos. Para los educadores, comprender y abordar este estado de confusión es crucial para mejorar los resultados académicos. Las investigaciones en esta área no solo ofrecen una ventana al estado mental de los estudiantes, sino que también proporcionan herramientas y estrategias que pueden hacer que el aprendizaje sea más efectivo y menos estresante [2].

En los últimos años, algunos autores incluso han realizado investigaciones para identificar cuando un alumno está en un estado de confusión, esto con el objetivo de que el profesor pueda actuar en consecuencia y modificar o implementar otras técnicas para mejorar el aprendizaje de los niños [4] [3].

En esta tesis, se utiliza la electroencefalografía (EEG) para la identificación automática de confusión y estados mentales, así como para evaluar niveles de concentración en estudiantes. Este enfoque propuesto podría en el futuro ayudar a los educadores a personalizar sus estrategias pedagógicas, proporcionando información en tiempo real sobre el estado cognitivo y emocional de los alumnos. Al detectar signos de confusión o falta de concentración, los docentes pueden intervenir de manera oportuna, ajustando el contenido o las técnicas de enseñanza para mejorar el proceso de aprendizaje.

La capacidad de medir estados mentales a través del EEG no solo permite a los educadores identificar cuándo un estudiante está luchando con el material, sino que también puede contribuir a la creación de entornos de aprendizaje más efectivos. Por ejemplo, estudios recientes han demostrado que el EEG puede revelar patrones de actividad cerebral asociados con la carga cognitiva y el compromiso emocional durante el aprendizaje [8] [2]. Además, el uso de tecnologías como el aprendizaje adaptativo puede optimizar la experiencia de aprendizaje, ajustando automáticamente los recursos en función de la información obtenida del EEG.

Al implementar esta tecnología, se abre la posibilidad de transformar la educación tradicional en un proceso más dinámico y centrado en el estudiante, donde la identificación

temprana de la confusión y otros estados mentales puede llevar a un aprendizaje más profundo y significativo.

Capítulo 2

Antecedentes

En este Capítulo, se proporciona una revisión de la literatura y los estudios previos relacionados con la identificación de confusión y estados mentales en el ámbito educativo mediante el uso de electroencefalografía (EEG). La comprensión de estos antecedentes es esencial ya que sienta las bases teóricas y prácticas que justifican el enfoque propuesto en esta tesis.

A lo largo de este Capítulo, se explorarán los avances tecnológicos en el uso del EEG para evaluar la actividad cerebral de los estudiantes, así como las teorías psicológicas que respaldan la relación entre la actividad cerebral y el rendimiento académico. Se examinarán estudios anteriores que han analizado la conexión entre la confusión, la carga cognitiva y los estados de concentración, destacando la importancia de estas variables en el proceso de aprendizaje.

Además, se discutirá cómo las intervenciones basadas en el análisis de datos EEG han mostrado resultados prometedores en la mejora de la enseñanza y el aprendizaje, lo que resalta la relevancia del presente estudio en el contexto educativo contemporáneo. Este capítulo no solo proporcionará un marco teórico sólido, sino que también subrayará la necesidad de abordar la confusión y la falta de concentración en el aula, evidenciando la relevancia de la investigación en el ámbito de la neuroeducación.

2.1. Enfoques para identificar y gestionar estados de confusión

Existen en la literatura varios enfoques que han sido utilizados para identificar y gestionar el estado de confusión en estudiantes. A continuación, se mencionan algunos de los más relevantes:

1. **El uso de tecnologías avanzadas** en el aula ha permitido a los investigadores rastrear y analizar en tiempo real el comportamiento de los estudiantes. Estos enfoques incluyen:

- **Aprendizaje Adaptativo:** Plataformas de aprendizaje adaptativo, como Knewton o Smart Sparrow, personalizan el contenido y los recursos de aprendizaje según el progreso del estudiante. Estas plataformas son capaces de detectar cuándo un alumno está confundido o estancado en un tema, mediante la evaluación de su interacción con el contenido (errores frecuentes, tiempos prolongados en ciertas preguntas, etc.). A partir de esta información, el sistema ajusta automáticamente la dificultad o la naturaleza de los ejercicios para facilitar la comprensión.
- **Learning Analytics:** El análisis de grandes volúmenes de datos (big data) provenientes del comportamiento de los estudiantes en plataformas en línea permite identificar patrones de confusión. Estas herramientas recopilan datos como el número de veces que un alumno revisa una sección, el tiempo que tarda en resolver una pregunta y las interacciones con otros recursos. Los docentes pueden utilizar estos análisis para identificar en qué momentos o áreas específicas los estudiantes presentan mayor confusión.
- **Inteligencia Artificial (IA) y Machine Learning:** Se ha utilizado el machine learning para predecir cuándo un estudiante puede estar confundido. Los algoritmos de IA pueden entrenarse para detectar patrones en las respuestas de los estudiantes, correlacionando errores frecuentes o pausas prolongadas con esta-

dos de confusión. Este enfoque ayuda a los profesores a intervenir de manera oportuna y personalizada.

2. **La neuroeducación y Biofeedback** han sido claves para detectar la confusión mediante el uso de técnicas neurofisiológicas. Este enfoque se basa en mediciones de la actividad cerebral y de otras señales fisiológicas. Investigaciones recientes han utilizado dispositivos de EEG para medir la actividad cerebral de los estudiantes mientras realizan tareas cognitivas. Estudios han encontrado que ciertos patrones de ondas cerebrales, como un aumento en las ondas theta, pueden estar asociados con la confusión o la falta de comprensión. Este enfoque proporciona una manera objetiva y precisa de identificar cuándo un estudiante está teniendo dificultades cognitivas. Por otro lado, el Biofeedback mide además del EEG la conductancia de la piel (respuesta galvánica) y el ritmo cardíaco para detectar estrés y confusión en los estudiantes. Al monitorear estas señales fisiológicas, los educadores pueden obtener una visión más completa del estado emocional y cognitivo del alumno, lo que les permite ajustar su enseñanza en consecuencia.
3. **Los sistemas de tutoría inteligente** están diseñados para imitar a un tutor humano. Estos sistemas utilizan algoritmos avanzados que ajustan las explicaciones y proporcionan retroalimentación personalizada en función del nivel de confusión de un estudiante.
4. **Rastreo ocular.** Los dispositivos de eye-tracking permiten analizar el movimiento de los ojos y la fijación en ciertas áreas de una pantalla. Las investigaciones han encontrado que los patrones oculares pueden ser indicadores de confusión; por ejemplo, una mayor dispersión en los movimientos de los ojos o un tiempo prolongado en ciertas áreas de un texto suelen estar relacionados con dificultades de comprensión. En estudios experimentales, el rastreo ocular ha sido utilizado para mejorar la enseñanza de materias complejas, como las matemáticas y las ciencias. Cuando un sistema detecta que el alumno está confuso (por ejemplo, fijando la mirada en una misma parte del texto repetidamente), se activa una intervención, como una expli-

cación adicional o un ejercicio de repaso.

5. El uso de entornos virtuales de aprendizaje permite aplicar modelos cognitivos para identificar cuando un estudiante se encuentra confundido. Por ejemplo, en entornos de realidad virtual (VR), los estudiantes pueden interactuar con objetos y escenarios tridimensionales. Al monitorear sus acciones y respuestas dentro de este entorno, es posible detectar señales de confusión o falta de comprensión de las instrucciones.

En estos entornos, los estudiantes pueden recibir retroalimentación inmediata basada en su comportamiento, como si tardan demasiado en realizar una tarea o si repiten ciertos errores. Este enfoque también permite a los estudiantes explorar los conceptos a su propio ritmo y experimentar una inmersión más profunda, lo que puede reducir la confusión a largo plazo.

2.2. Métodos de Clasificación en el Análisis de EEG

En esta Sección se enumeran y describen algunas técnicas de clasificación comunmente utilizadas para analisis de EEG. Existen diferentes técnicas de aprendizaje automático según modelo de aprendizaje utilizado. Comunmente se utiliza un modelo dependiendo de su proposito y del tiempo de información disponible.

2.2.1. Técnicas de aprendizaje máquina

La detección de estados de confusión utilizando señales de electroencefalografía (EEG) es un área de investigación activa, en la que las técnicas de aprendizaje automático (Machine Learning, ML) desempeñan un papel clave para identificar patrones cerebrales asociados a diferentes estados mentales. Las técnicas de aprendizaje automático se dividen comunmente en dos categorías principales:

1. El aprendizaje no supervisado busca encontrar patrones o relaciones en los datos cuando no se dispone de información sobre la etiqueta o clase que se va a predecir en las muestras del constructor.

2. El aprendizaje supervisado por su parte contiene toda la información necesaria para predecir o clasificar una población (variables y etiquetas de clase)

La Figura 2.1 muestra los principales paradigmas del aprendizaje máquina.

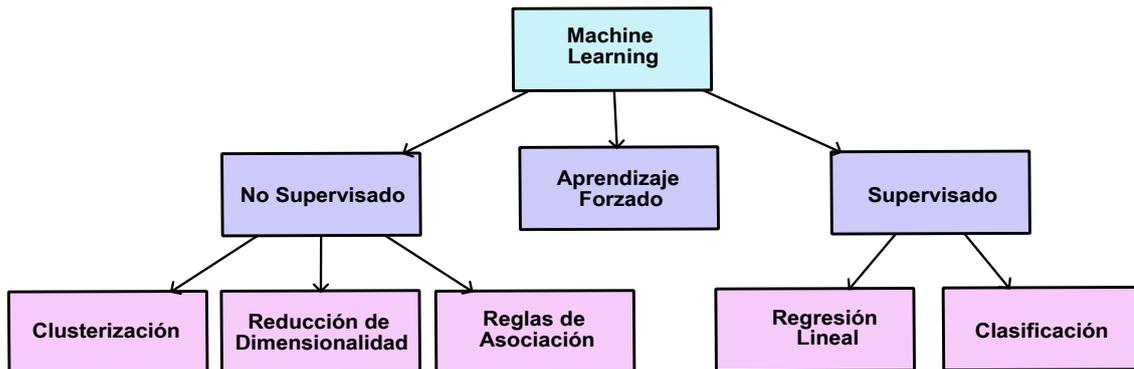


Figura 2.1: Clasificación (caso lineal separable)

2.2.2. Redes Neuronales Artificiales (RNA)

Las redes neuronales artificiales (RNA) son uno de los métodos de aprendizaje automático más importantes y más utilizados. Las RNA son sistemas computacionales inspirados en el cerebro humano, capaces de aprender patrones complejos en los datos, estas han sido utilizadas para crear sistemas que puedan reconocer patrones, predecir comportamientos y resumir automáticamente información de un conjunto de datos.

Las redes neuronales artificiales son modelos inspirados en el funcionamiento de las redes neuronales biológicas. Estas son herramientas poderosas capaces de aprender y generalizar muy bien, lo que les permite reconocer patrones, predecir comportamientos y tomar decisiones específicas. Las redes neuronales pueden capturar relaciones no lineales entre los datos de EEG y los estados de confusión. Al ser capaces de aprender automáticamente características, pueden obtener mejores resultados cuando los datos son numerosos. La Figura 2.2 muestra la estructura y componentes básicos de una red neuronal.

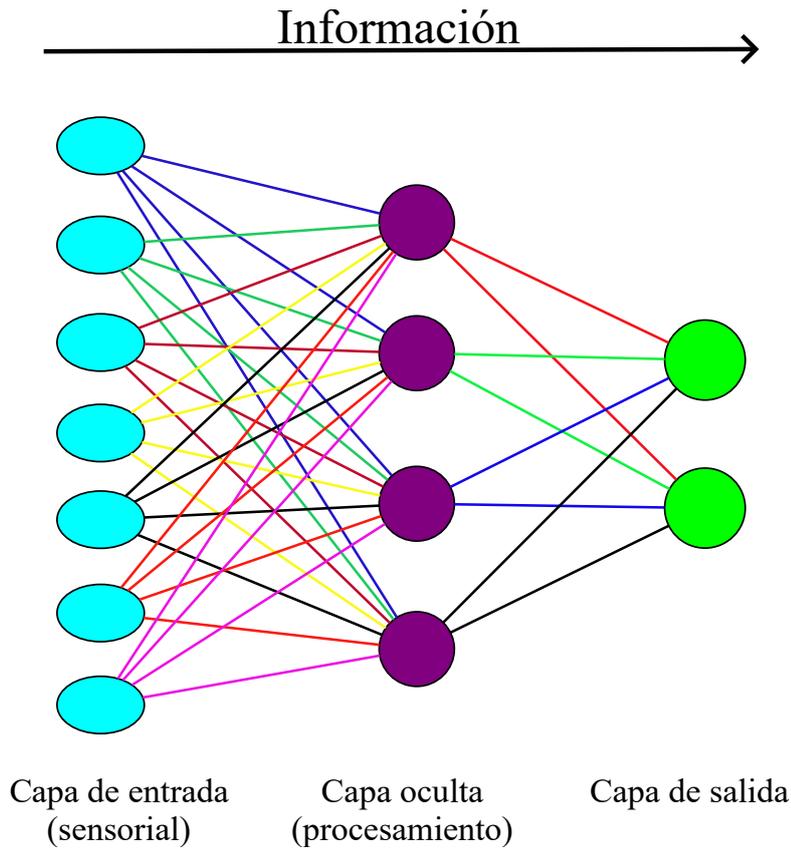


Figura 2.2: Estructura y componentes básicos de una red neuronal

Neurona Artificial

Sea un conjunto de entradas $\mathbf{x} = [x_1, x_2, \dots, x_n]$, un conjunto de pesos asociados $\mathbf{w} = [w_1, w_2, \dots, w_n]$ y un sesgo o umbral b . La salida z de la neurona es la combinación lineal de las entradas y los pesos, más el sesgo:

$$z = \sum_{i=1}^n w_i x_i + b = \mathbf{w}^T \mathbf{x} + b$$

A continuación, se aplica una **función de activación** $f(z)$ para generar la salida final de la neurona:

$$y = f(z)$$

La Figura [2.3](#) muestra el funcionamiento de la función de activación y los pesos de

entrada a una neurona. Algunas funciones de activación comunes son:

- **Función sigmoide:**

$$f(z) = \frac{1}{1 + e^{-z}}$$

- **Tangente hiperbólica:**

$$f(z) = \tanh(z)$$

- **Rectified Linear Unit (ReLU):**

$$f(z) = \max(0, z)$$

- **Softmax** (para clasificación multiclase):

$$f(z_i) = \frac{e^{z_i}}{\sum_j e^{z_j}}$$

Capa de Neuronas

Una **capa** está formada por varias neuronas. Si tenemos m neuronas en una capa, la salida de la capa será:

$$\mathbf{y} = f(\mathbf{W}\mathbf{x} + \mathbf{b})$$

donde:

- \mathbf{W} es una matriz de pesos de tamaño $m \times n$,
- \mathbf{x} es el vector de entrada de tamaño n ,
- \mathbf{b} es el vector de sesgos de tamaño m ,
- f es la función de activación aplicada de manera elemento por elemento.

Red Neuronal Multicapa (MLP)

Una **Red Neuronal Multicapa** consiste en varias capas de neuronas. La salida de cada capa se convierte en la entrada de la siguiente. Para una red con L capas, la relación entre las entradas y las salidas de cada capa l es:

$$\mathbf{y}^{(l)} = f^{(l)}(\mathbf{W}^{(l)}\mathbf{y}^{(l-1)} + \mathbf{b}^{(l)})$$

donde:

- $\mathbf{y}^{(l)}$ es la salida de la capa l , - $\mathbf{W}^{(l)}$ es la matriz de pesos de la capa l , - $\mathbf{b}^{(l)}$ es el vector de sesgos de la capa l , - $f^{(l)}$ es la función de activación de la capa l .

Función de Costo

Para entrenar una red neuronal, se utiliza una **función de costo** que mide el error entre las predicciones de la red y los valores reales. Algunas funciones de costo comunes son:

- **Error cuadrático medio (MSE)** para regresión:

$$J(\mathbf{w}, \mathbf{b}) = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2$$

donde y_i es el valor real, \hat{y}_i es la predicción, y m es el número de muestras.

- **Entropía cruzada** para clasificación:

$$J(\mathbf{w}, \mathbf{b}) = -\frac{1}{m} \sum_{i=1}^m [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]$$

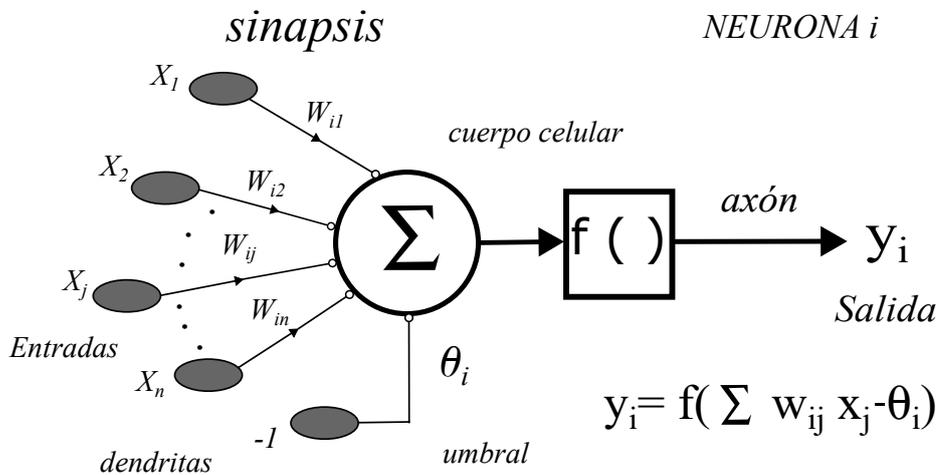


Figura 2.3: Pesos y función de activación de una neurona

2.2.3. Support Vector Machines

Las SVM, fueron desarrolladas por Cortés y Vapnik (1995), con el propósito de realizar clasificación binaria[Cortes1995]. Las máquinas de vectores de soporte (SVM) son

un conjunto de técnicas de aprendizaje automático que se introdujeron inicialmente para resolver problemas de clasificación, pero que posteriormente se han extendido para abordar diversas situaciones [Cervantes2008] [Cervantes2006] [Cervantes2007]. Estas técnicas se fundamentan en la teoría del aprendizaje estadístico y en los principios de optimización convexa. En la actualidad, las SVM se utilizan en diversas áreas de aplicación, tales como la bioinformática, la clasificación de textos y la visión por computadora [Cervantes2023] [Jalili2021].

SVM es una técnica ampliamente utilizada para la clasificación de datos en dos o más clases. Funciona buscando el hiperplano óptimo que maximiza la separación entre las diferentes clases. A continuación se muestran algunos conceptos importantes relacionados con el enfoque SVM. Separación de hiperplano: En el contexto de la clasificación binaria, el hiperplano juega un papel crucial al actuar como una frontera que separa dos clases distintas. El propósito principal radica en hallar un hiperplano óptimo que logre maximizar la distancia entre las instancias pertenecientes a cada una de las clases.

Margen: El margen se define como la distancia existente entre el hiperplano de separación y la instancia más cercana de cada clase. El objetivo del SVM es encontrar un hiperplano que maximice dicho margen.

Vectores de soporte: Estos datos son los más cercanos al hiperplano de separación y son esenciales para establecer los límites. Estos puntos determinan la ubicación y orientación del hiperplano.

Kernel Trick: El SVM tiene la capacidad de utilizar el "Kernel Trick" para abordar datos no lineales. Esta técnica implica la conversión de los datos originales a un espacio de características multidimensional que puede ser descompuesto de manera lineal.

Núcleo: Es una función que calcula el producto escalar en este espacio transformado sin necesidad de realizar explícitamente la transformación.

Optimización convexa: La fórmula matemática del SVM consiste en resolver un problema de optimización convexa. El propósito es minimizar una función de pérdida que aborde los errores de clasificación y, al mismo tiempo, maximice las ganancias.

Regresión usando SVM: Además de la clasificación, SVM también puede ser utilizado para abordar problemas de regresión. El propósito en este caso es encontrar el hiperplano

que se ajuste de manera óptima a los datos.

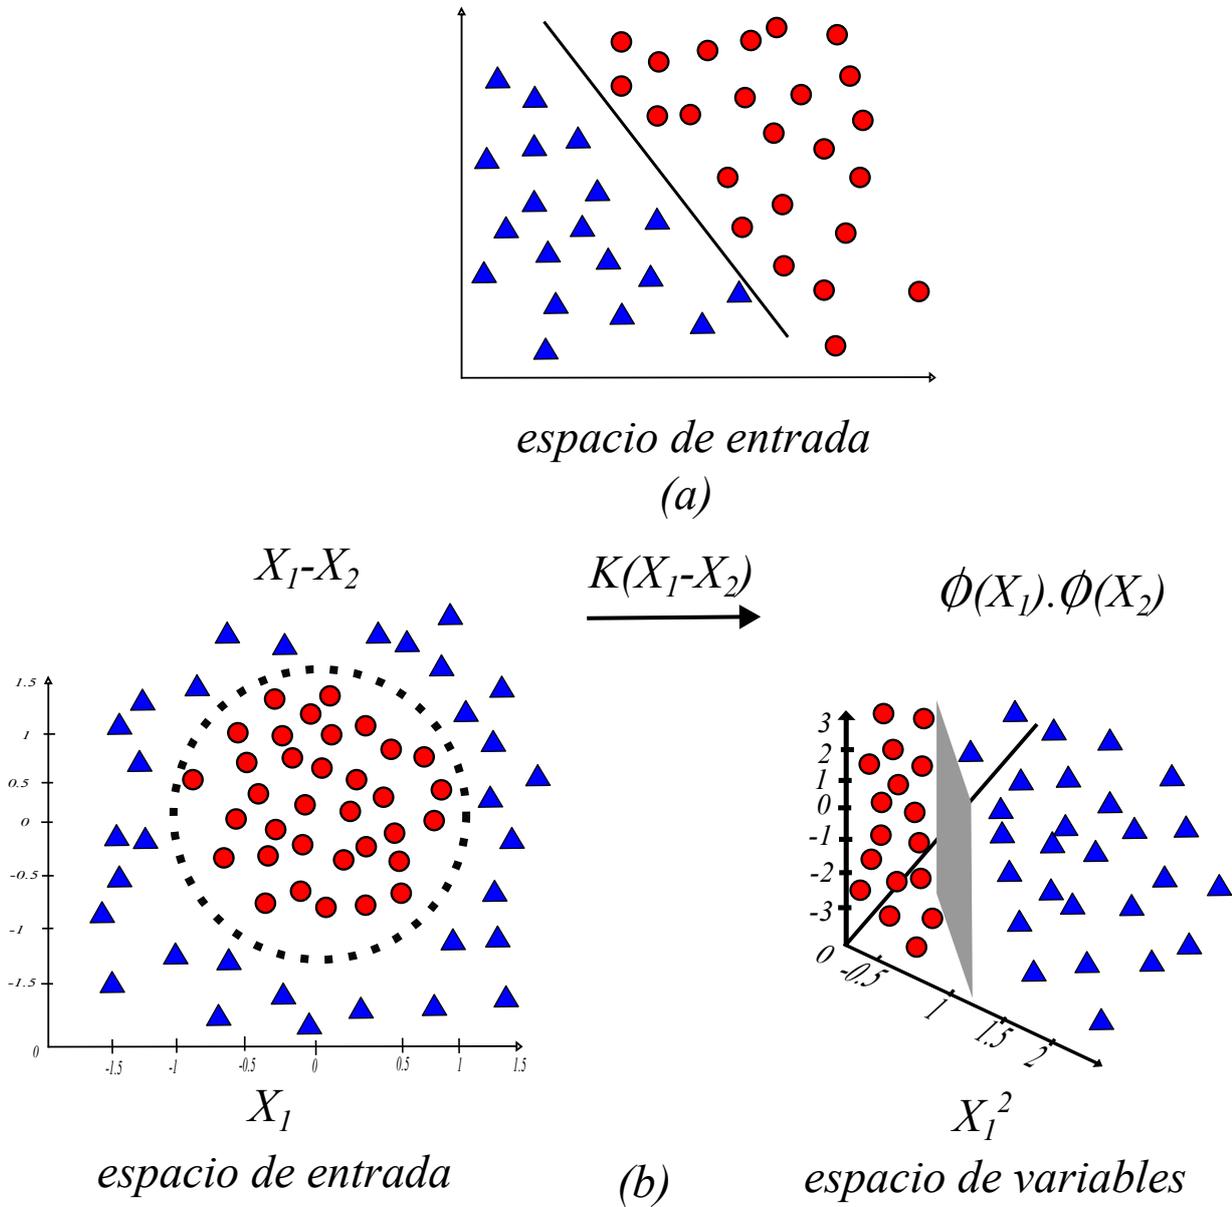


Figura 2.4: Clasificación (caso lineal separable)

Separación Lineal

Dado un conjunto de entrenamiento $\{(\mathbf{x}_i, y_i)\}_{i=1}^m$, donde $\mathbf{x}_i \in \mathbb{R}^n$ es el vector de características de la i -ésima muestra y $y_i \in \{-1, 1\}$ es la clase correspondiente, el objetivo de SVM es encontrar un hiperplano que divida los puntos de ambas clases de la forma:

$$\mathbf{w}^T \mathbf{x} + b = 0$$

donde $\mathbf{w} \in \mathbb{R}^n$ es el vector normal al hiperplano y b es el sesgo.

Para asegurar que las muestras estén correctamente clasificadas y con un margen máximo, se busca que:

$$y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \quad \forall i$$

La Figura 2.4(a) muestra un ejemplo de un conjunto de datos linealmente separable.

Margen y Problema de Optimización

El margen es la distancia entre los puntos más cercanos de cada clase y el hiperplano. El objetivo es maximizar este margen, lo que equivale a minimizar $\|\mathbf{w}\|^2$, sujeto a las restricciones anteriores. Esto se puede formular como un problema de optimización:

$$\begin{aligned} & \min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \\ & \text{sujeto a: } y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1, \quad \forall i \end{aligned}$$

Este es un problema de optimización cuadrática convexo.

SVM con Margen Suave (Soft Margin)

En muchos casos, los datos no son separables linealmente. Para manejar esto, se introducen variables de holgura $\xi_i \geq 0$ que permiten errores de clasificación:

$$y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \quad \forall i$$

El nuevo objetivo es minimizar tanto el tamaño del margen como la penalización por errores de clasificación, lo que se formula como:

$$\min_{\mathbf{w}, b, \xi} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m \xi_i$$

donde C es un parámetro que controla el equilibrio entre maximizar el margen y minimizar los errores.

Solución Dual y Vectores de Soporte

Para resolver el problema de optimización, se puede formular su dual utilizando multiplicadores de Lagrange α_i . El problema dual es:

$$\begin{aligned} \max_{\boldsymbol{\alpha}} \quad & \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \\ \text{sujeto a:} \quad & 0 \leq \alpha_i \leq C, \quad \sum_{i=1}^m \alpha_i y_i = 0 \end{aligned}$$

Las soluciones $\alpha_i > 0$ corresponden a los **vectores de soporte**, que son las muestras más cercanas al hiperplano de separación.

El vector de pesos \mathbf{w} se puede obtener como:

$$\mathbf{w} = \sum_{i=1}^m \alpha_i y_i \mathbf{x}_i$$

Y el sesgo b se puede calcular utilizando cualquier vector de soporte.

SVM con Núcleo (Kernel Trick)

En muchos casos, los datos no son separables linealmente en su espacio original, por lo que se proyectan a un espacio de características de mayor dimensión utilizando una función de núcleo (kernel) $\kappa(\mathbf{x}_i, \mathbf{x}_j)$. La Figura 2.4(b) muestra como un conjunto de datos linealmente no separable es transformado a un linealmente separable aumentando la dimensionalidad del conjunto de datos. El problema dual con el truco del núcleo es:

$$\max_{\boldsymbol{\alpha}} \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \kappa(\mathbf{x}_i, \mathbf{x}_j)$$

Algunos núcleos comunes son:

- Núcleo lineal: $\kappa(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$ - Núcleo polinomial: $\kappa(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^T \mathbf{x}_j + 1)^d$ - Núcleo gaussiano (RBF): $\kappa(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right)$

Clasificación

Una vez entrenada la SVM, para clasificar un nuevo punto \mathbf{x} , se evalúa:

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = \sum_{i=1}^m \alpha_i y_i \kappa(\mathbf{x}_i, \mathbf{x}) + b$$

Si $f(\mathbf{x}) > 0$, la muestra es clasificada como $y = 1$, y si $f(\mathbf{x}) < 0$, es clasificada como $y = -1$.

2.2.4. Árboles de decisión

Los árboles de decisión son una técnica de aprendizaje automático supervisado utilizada tanto para la clasificación como para la regresión. Se basan en la idea de dividir el conjunto de datos en subconjuntos más pequeños mientras se toman decisiones basadas en las características de los datos [Quinlan1987]. Los árboles de decisión constan comúnmente de las siguientes componentes:

Nodo Raíz: Representa la característica más importante o relevante que divide el conjunto de datos inicial en dos o más subconjuntos. **Nodos Internos:** Representan características adicionales que se utilizan para dividir los subconjuntos en subconjuntos aún más pequeños. **Hojas (Nodos Terminales):** Representan las etiquetas de clasificación o los valores de regresión finales que se asignan a los subconjuntos después de todas las divisiones.

El algoritmo inicia seleccionando las características que mejor dividan el conjunto de datos en subconjuntos homogéneos, generalmente utilizando métricas como la ganancia de información o la impureza de Gini. Una vez hecho esto, divide el conjunto de datos en subconjuntos más pequeños basados en la característica seleccionada y repite estos pasos para cada subconjunto generado hasta que se cumple un criterio de paro. Algunos de los criterios de paro más comunes son: profundidad máxima, o pureza de subconjuntos. Una vez que encuentra el árbol es preciso eliminar subárboles o nodos para evitar el sobreajuste y mejorar la generalización del modelo.

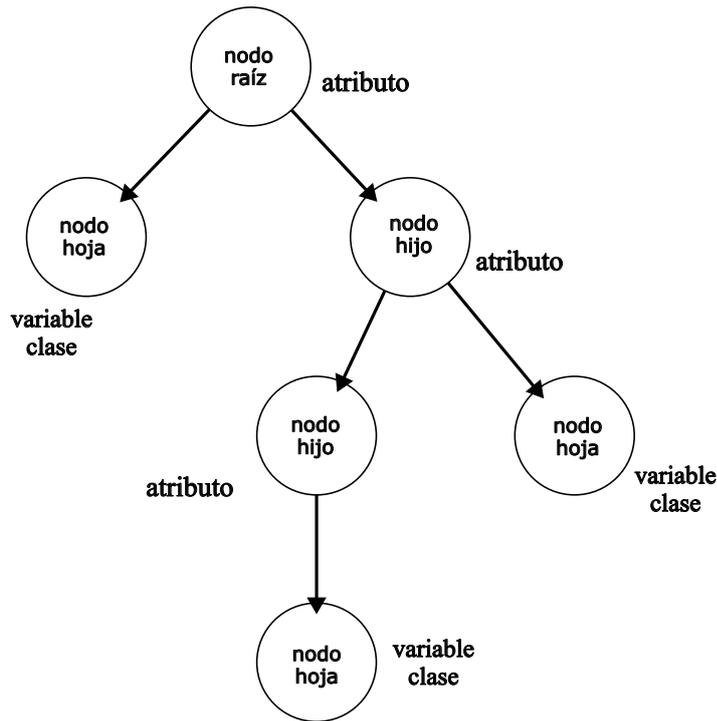


Figura 2.5: Estructura básica de un árbol de decisión

Los **árboles de decisión** son un modelo de aprendizaje supervisado que se utiliza tanto para problemas de clasificación como de regresión. El modelo divide iterativamente los datos en subconjuntos basados en una función de partición, construyendo una estructura de árbol donde cada nodo interno representa una característica y cada hoja una clase (en el caso de clasificación) o un valor numérico (en el caso de regresión). La Figura [2.5](#) muestra un clasificador de árbol con sus nodos y hojas.

2.2.5. Construcción del Árbol

La idea básica de un árbol de decisión es dividir el espacio de características en subconjuntos homogéneos de acuerdo a una métrica de "pureza." "impureza". Supongamos que tenemos un conjunto de datos de entrenamiento $\{(\mathbf{x}_i, y_i)\}_{i=1}^m$, donde $\mathbf{x}_i \in \mathbb{R}^n$ es el vector de características y y_i es la etiqueta de clase.

En cada nodo, buscamos la característica j y el umbral t que mejor separan los datos, lo cual se puede expresar como:

$$\arg \min_{j,t} \text{Criterio}(S_{\text{izq}}, S_{\text{der}})$$

donde S_{izq} y S_{der} son los subconjuntos creados al dividir el conjunto S en función de la característica j y el umbral t .

2.2.6. Métricas de Impureza

Las métricas más comunes para medir la calidad de una división son:

- **Índice Gini:**

$$G(S) = 1 - \sum_{k=1}^K p_k^2$$

donde p_k es la proporción de ejemplos de la clase k en el conjunto S , y K es el número de clases.

- **Entropía (en árboles basados en información):**

$$H(S) = - \sum_{k=1}^K p_k \log_2 p_k$$

- **Reducción de varianza (para problemas de regresión):**

$$\text{Varianza}(S) = \frac{1}{|S|} \sum_{i=1}^{|S|} (y_i - \bar{y})^2$$

donde \bar{y} es la media de las etiquetas y_i en el conjunto S .

La calidad de una partición viene dada por la disminución de la impureza después de la partición. Si se divide el conjunto S en dos subconjuntos S_{izq} y S_{der} , la reducción de la impureza se define como:

$$\Delta \text{Impureza} = \text{Impureza}(S) - \left(\frac{|S_{\text{izq}}|}{|S|} \text{Impureza}(S_{\text{izq}}) + \frac{|S_{\text{der}}|}{|S|} \text{Impureza}(S_{\text{der}}) \right)$$

2.2.7. Recursión

El proceso de construcción del árbol es recursivo. A partir de un nodo S , se evalúan todas las posibles divisiones (característica j y umbral t) y se selecciona la que maximice la reducción de la impureza. Este proceso se repite para los subconjuntos S_{izq} y S_{der} hasta que se cumpla un criterio de parada, como:

- El nodo contiene menos de un número mínimo de ejemplos.
- La impureza es menor que un umbral predefinido.
- Se alcanza una profundidad máxima.

2.2.8. Predicción

Para realizar una predicción con un árbol de decisión, se toma una muestra \mathbf{x} y se sigue su ruta a través del árbol desde la raíz hasta una hoja, comparando los valores de las características en cada nodo. La predicción de la clase (en problemas de clasificación) será la clase mayoritaria en la hoja, es decir:

$$\hat{y} = \arg \max_k p_k$$

donde p_k es la proporción de la clase k en la hoja.

En problemas de regresión, la predicción es simplemente el valor promedio de las etiquetas en la hoja:

$$\hat{y} = \frac{1}{|S_{\text{hoja}}|} \sum_{i \in S_{\text{hoja}}} y_i$$

2.2.9. Clasificación Bayesiana

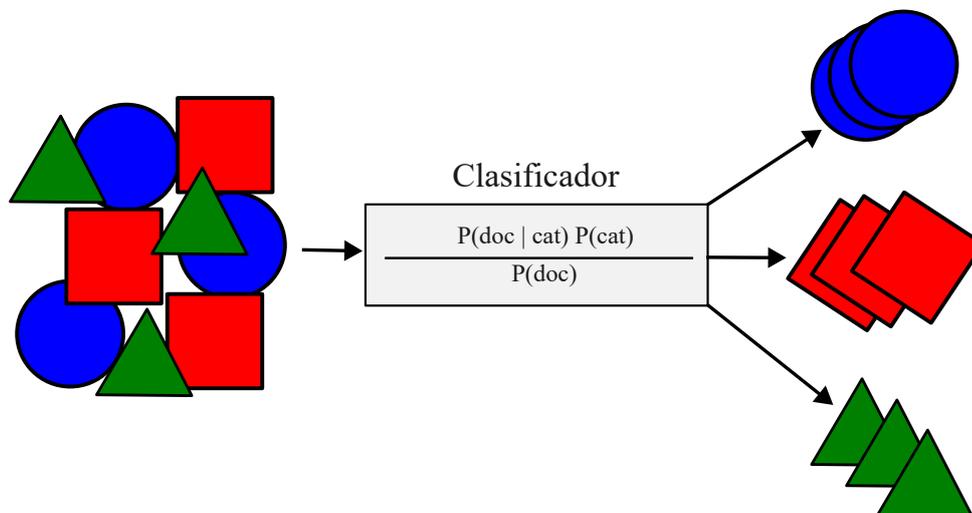


Figura 2.6: Clasificación (caso lineal separable)

El algoritmo Naive Bayes es un clasificador probabilístico basado en el Teorema de Bayes, con la suposición ingenua de independencia condicional entre las características dado el valor de la clase [Russell2003] [John2013].

2.2.10. Teorema de Bayes

El Teorema de Bayes establece que la probabilidad de una clase C_k dado un conjunto de características $\mathbf{x} = (x_1, x_2, \dots, x_n)$ es:

$$P(C_k | \mathbf{x}) = \frac{P(C_k)P(\mathbf{x} | C_k)}{P(\mathbf{x})}$$

Donde: - $P(C_k | \mathbf{x})$ es la probabilidad posterior de la clase C_k dada la observación \mathbf{x} . - $P(C_k)$ es la probabilidad a priori de la clase C_k . - $P(\mathbf{x} | C_k)$ es la probabilidad de observar \mathbf{x} dado que la clase es C_k . - $P(\mathbf{x})$ es la probabilidad de observar las características \mathbf{x} .

Suposición de Independencia Condicional

La suposición clave de Naive Bayes es que las características son condicionalmente independientes entre sí dado el valor de la clase. Esto implica que:

$$P(\mathbf{x} | C_k) = \prod_{i=1}^n P(x_i | C_k)$$

Es decir, la probabilidad conjunta de las características \mathbf{x} dado C_k es el producto de las probabilidades individuales de cada característica x_i dado C_k .

2.2.11. Clasificación

Para clasificar una nueva instancia \mathbf{x} , se calcula la probabilidad posterior para cada clase C_k y se asigna la clase que maximiza esta probabilidad:

$$\hat{C} = \arg \max_{C_k} P(C_k | \mathbf{x}) = \arg \max_{C_k} P(C_k) \prod_{i=1}^n P(x_i | C_k)$$

2.2.12. Cálculo de Probabilidades

Dependiendo del tipo de datos, las probabilidades condicionales $P(x_i | C_k)$ se pueden calcular de diferentes maneras:

- Para características discretas, $P(x_i | C_k)$ se estima como la frecuencia relativa de x_i en la clase C_k . - Para características continuas, se suele asumir una distribución normal (gaussiana) y calcular $P(x_i | C_k)$ utilizando la función de densidad de probabilidad:

$$P(x_i | C_k) = \frac{1}{\sqrt{2\pi\sigma_{C_k}^2}} \exp\left(-\frac{(x_i - \mu_{C_k})^2}{2\sigma_{C_k}^2}\right)$$

Donde μ_{C_k} y σ_{C_k} son la media y desviación estándar de la característica x_i para la clase C_k .

2.2.13. Ejemplo de Cálculo

Supongamos que tenemos dos clases, C_1 y C_2 , y una nueva instancia $\mathbf{x} = (x_1, x_2, \dots, x_n)$. El clasificador Naive Bayes calcularía las probabilidades posteriores de la siguiente manera:

$$P(C_1 | \mathbf{x}) = P(C_1) \prod_{i=1}^n P(x_i | C_1)$$

$$P(C_2 | \mathbf{x}) = P(C_2) \prod_{i=1}^n P(x_i | C_2)$$

La clase asignada sería:

$$\hat{C} = \arg \max_{C_1, C_2} (P(C_1 | \mathbf{x}), P(C_2 | \mathbf{x}))$$

La Figura 2.6 muestra como un clasificador Bayesiano infiere o clasifica a partir de probabilidades condicionales.

2.3. Métricas de Desempeño

En el campo del reconocimiento de patrones, la evaluación del desempeño de los clasificadores es fundamental para determinar su efectividad en la identificación de patrones y la toma de decisiones precisas. Las métricas de desempeño proporcionan medidas cuantitativas que ayudan a comprender, comparar y optimizar el comportamiento de los modelos de clasificación. La selección y el análisis de estas métricas permiten identificar los puntos fuertes y las limitaciones de un clasificador, así como ajustar su funcionamiento en función de los objetivos específicos de la tarea [Cervantes2017, Cervantes2013]. A continuación, se describen las métricas más comunes utilizadas para evaluar el desempeño de los clasificadores.

2.3.1. Matriz de Confusión

La matriz de confusión es una herramienta fundamental en la evaluación de clasificadores, ya que proporciona una representación tabular de las predicciones realizadas por el modelo frente a los valores reales de las clases. La matriz de confusión organiza los resultados en cuatro categorías: Verdaderos Positivos (VP), Falsos Positivos (FP), Verdaderos Negativos (VN) y Falsos Negativos (FN). A partir de estos valores, se pueden calcular métricas adicionales que ofrecen una visión detallada del desempeño del clasificador en

términos de precisión, sensibilidad, especificidad y el valor F1. La matriz de confusión es especialmente útil cuando el objetivo es identificar la capacidad de un modelo para diferenciar entre clases, ya que permite analizar tanto los aciertos como los errores de clasificación.

$$\text{Matriz de Confusión: } \begin{bmatrix} VP & FP \\ FN & VN \end{bmatrix}$$

2.3.2. Precisión

La precisión es una métrica que mide la proporción de predicciones correctas entre todas las predicciones positivas realizadas por el modelo. Se calcula como el cociente entre los Verdaderos Positivos (VP) y la suma de VP y los Falsos Positivos (FP). Una alta precisión indica que el clasificador tiene una baja tasa de falsos positivos, lo cual es importante en aplicaciones donde es crucial minimizar las alarmas falsas, como en sistemas de detección de fraudes o diagnósticos médicos.

$$\text{Precisión} = \frac{VP}{(VP + FP)} \quad (2.1)$$

2.3.3. Sensibilidad (Recall)

La sensibilidad, también conocida como *recall*, es la proporción de predicciones correctas de la clase positiva en relación con el total de positivos reales. Se calcula como el cociente entre los Verdaderos Positivos (VP) y la suma de VP y los Falsos Negativos (FN). Una alta sensibilidad es fundamental en aplicaciones donde es crítico detectar todos los casos positivos, como en la identificación de enfermedades en etapas tempranas, donde perder un positivo podría tener graves consecuencias.

$$\text{Sensibilidad} = \frac{VP}{(VP + FN)} \quad (2.2)$$

2.3.4. Especificidad

La especificidad mide la capacidad del clasificador para identificar correctamente los casos negativos. Es la proporción de Verdaderos Negativos (VN) respecto al total de negativos reales (VN + FP). Esta métrica es crucial en contextos donde el interés radica en minimizar los falsos positivos, como en pruebas de detección donde una clasificación positiva incorrecta puede causar preocupación injustificada o requerir intervenciones adicionales.

$$\text{Especificidad} = \frac{VN}{(VN + FP)} \quad (2.3)$$

2.3.5. Valor F1

El valor F1 combina precisión y sensibilidad en una métrica única, proporcionando una medida global del desempeño del clasificador en un contexto donde se busca equilibrio entre ambas métricas. El valor F1 es especialmente útil cuando el objetivo es lograr un balance entre la precisión y la sensibilidad, especialmente en problemas con clases desbalanceadas. Se calcula como la media armónica de precisión y sensibilidad.

$$\text{Valor F1} = 2 \times \frac{\text{Precisión} \times \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}} \quad (2.4)$$

2.3.6. Curva ROC y Área Bajo la Curva (AUC-ROC)

La curva ROC (Receiver Operating Characteristic) es una representación gráfica que ilustra el desempeño de un clasificador binario al variar el umbral de decisión, lo cual permite observar la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos. El área bajo la curva (AUC-ROC) cuantifica el desempeño del clasificador; un AUC cercano a 1 indica un modelo altamente efectivo. La curva ROC es particularmente útil en problemas donde el umbral de decisión es ajustable y se desea evaluar el rendimiento del clasificador bajo diferentes condiciones.

$$\text{AUC-ROC} = \int_0^1 \text{ROC}(x) dx \quad (2.5)$$

2.3.7. Validación Cruzada

La validación cruzada es una técnica de evaluación que busca estimar el rendimiento de un modelo de manera robusta, utilizando diferentes subconjuntos del conjunto de datos original. En el método de validación cruzada k -fold, el conjunto de datos se divide en k subconjuntos (folds). El modelo se entrena y evalúa k veces, utilizando un fold diferente como conjunto de prueba en cada iteración, mientras que los otros $k - 1$ folds se emplean para entrenamiento. Esta técnica ayuda a reducir el sesgo en la evaluación y a evitar el sobreajuste, proporcionando una evaluación más representativa del rendimiento general del modelo.

2.3.8. Métricas de Clasificación Multi-clase

En problemas de clasificación con múltiples clases, se requieren métricas que consideren todos los posibles errores entre las distintas clases. En estos casos, se utilizan variantes de la matriz de confusión que contemplan cada clase y se pueden calcular métricas como la precisión macro (promedio de precisiones por clase) y micro ponderada (ponderada por el número de ejemplos en cada clase), así como el error de clasificación multi-clase. Estas métricas proporcionan una evaluación detallada del desempeño del clasificador en contextos donde existen múltiples categorías a diferenciar.

Precisión Macro y Micro

La precisión macro se calcula promediando la precisión de cada clase sin considerar el tamaño de la clase, mientras que la precisión micro pondera los resultados en función del tamaño de cada clase, proporcionando una visión balanceada en problemas con clases desiguales en tamaño.

$$\text{Precisión Macro} = \frac{1}{n} \sum_{i=1}^n \text{Precisión}_i$$

$$\text{Precisión Micro} = \frac{\sum_{i=1}^n VP_i}{\sum_{i=1}^n (VP_i + FP_i)}$$

Esta sección proporciona una visión integral de las métricas de desempeño en la clasificación, las cuales son esenciales para evaluar y optimizar modelos de clasificación. La elección adecuada y la interpretación de estas métricas permiten entender las fortalezas y debilidades de un modelo y ajustarlo de acuerdo con las necesidades de la aplicación específica, logrando un balance adecuado entre precisión y capacidad predictiva.

Capítulo 3

Metodología

En esta sección, se detalla la metodología empleada para llevar a cabo los experimentos realizados en el contexto de esta investigación. La Figura [3.1](#) presenta la metodología general diseñada para la clasificación de estados mentales mediante el uso de electroencefalografía (EEG). Esta metodología se basa en una serie de pasos sistemáticos que permiten la adquisición, el procesamiento y el análisis de los datos EEG con el objetivo de identificar diferentes estados mentales en los participantes.

Es importante mencionar que, en esta tesis, no levantamos ni obtuvimos personalmente los datos de EEG. En su lugar, recurrimos a dos conjuntos de datos disponibles en la literatura que se han utilizado previamente en investigaciones similares. La selección de estos conjuntos de datos se realizó cuidadosamente, considerando su relevancia, calidad y la adecuación a nuestros objetivos de investigación. Al utilizar estos datos, podemos beneficiarnos de muestras más amplias y diversas, lo que enriquece nuestro análisis y aumenta la validez de los resultados.

La metodología incluye etapas clave como la implementación de los algoritmos de clasificación que nos permiten interpretar y categorizar los datos de acuerdo con los criterios establecidos en nuestra hipótesis de investigación.

Esta estructura metodológica no solo facilita la reproducibilidad del estudio, sino que también contribuye a la comprensión de cómo los datos EEG pueden ser utilizados de manera efectiva para clasificar estados mentales, proporcionando un marco sólido para

futuros estudios en este campo.

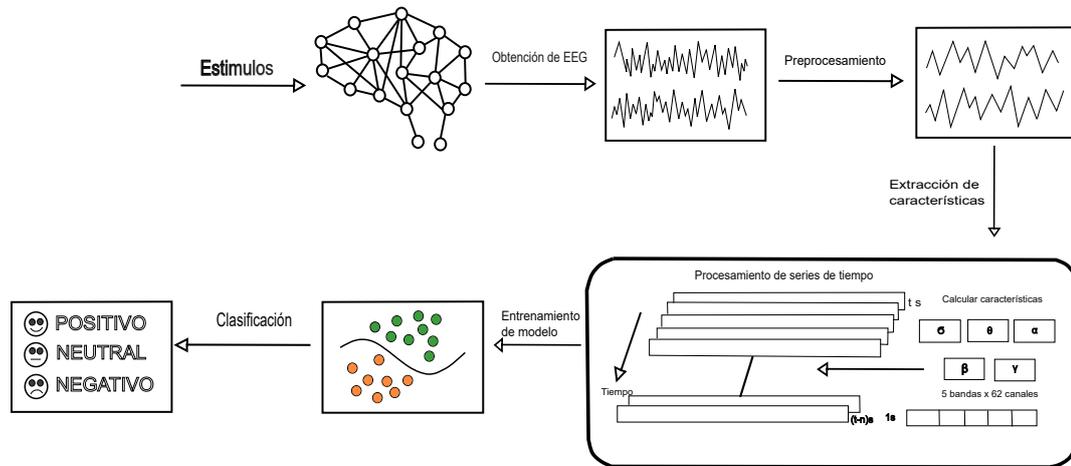


Figura 3.1: Metodología utilizada para clasificación mediante EEG

3.1. Selección de los conjuntos de datos

Para llevar a cabo los experimentos y evaluaciones propuestas en esta investigación, se seleccionaron cuidadosamente varios conjuntos de datos que contienen señales de EEG relevantes para la clasificación de los estados mentales. Los conjuntos de datos se obtuvieron de la plataforma Kaggle (<https://www.kaggle.com/>), una reconocida fuente de datos públicos y recursos de machine learning que ofrece gran variedad de conjuntos de datos de calidad y bien documentados. La elección de esta plataforma se debió a su accesibilidad, variedad de fuentes de datos y su relevancia en la comunidad científica para el análisis de señales biológicas, en particular las señales de EEG.

Los conjuntos de datos seleccionados para este estudio son:

1. Datos de ondas cerebrales EEG de estudiantes confundidos (Confused student EEG brainwave data): Este conjunto de datos se centra en la actividad cerebral de estudiantes durante situaciones de confusión, capturando las señales EEG mientras los estudiantes realizan diversas tareas académicas. Este tipo de datos es especialmente útil para investigar los patrones cerebrales asociados con la falta de comprensión o

el estado de confusión durante el aprendizaje. Dado que el objetivo de esta investigación es la clasificación de estados mentales a partir de señales EEG, este conjunto ofrece una excelente oportunidad para explorar cómo se pueden detectar y clasificar momentos de confusión en estudiantes.

2. Tareas de concentración personal con EEG (Personal EEG Concentration Tasks): Este conjunto de datos recoge las señales EEG de individuos mientras realizan tareas que requieren diferentes niveles de concentración. La información obtenida permite analizar cómo varía la actividad cerebral en función de la demanda cognitiva y los estados de atención de las personas. Este conjunto de datos es crucial para el análisis de la concentración mental, ya que proporciona una rica variedad de señales que reflejan distintos grados de atención y enfoque. Esto lo convierte en un recurso valioso para entrenar modelos de clasificación que busquen identificar estados de alta y baja concentración en los individuos.

Ambos conjuntos de datos fueron seleccionados debido a su relevancia para los objetivos de este estudio, ya que permiten trabajar con diferentes estados cognitivos que son representativos de los problemas reales que enfrentan los estudiantes en contextos académicos. Además, los datos están adecuadamente estructurados y documentados, lo que facilita su preprocesamiento y análisis. Esta selección proporciona una base sólida para entrenar modelos de aprendizaje automático que clasifiquen con precisión los estados mentales a partir de señales EEG, y permite evaluar la capacidad de los clasificadores para distinguir entre estados de confusión y concentración.

3.2. Selección de clasificadores

Se seleccionaron varios clasificadores capaces de manejar las señales de EEG, con el fin de garantizar la efectividad y la precisión en la clasificación de los estados mentales. Los clasificadores elegidos para llevar a cabo los experimentos fueron: a) Support Vector Machines (SVM), b) Redes Neuronales, c) Árboles de Decisión y d) Naive Bayes. Cada uno de estos clasificadores ofrece características únicas que los hacen adecuados para el

análisis de datos complejos, como los generados por las señales de EEG.

La razón por la que se utilizan estos clasificadores radica en su capacidad para manejar la alta dimensionalidad y la variabilidad inherente de los datos EEG. Por ejemplo, las Support Vector Machines son conocidas por su eficacia en la clasificación de conjuntos de datos con un número elevado de características y en situaciones donde las clases pueden no ser linealmente separables. Su enfoque en la maximización del margen entre clases contribuye a una mayor generalización, lo que es crucial cuando se trabaja con datos de EEG que pueden contener ruido y artefactos.

Por otro lado, las Redes Neuronales, son particularmente efectivas en la identificación de patrones complejos en datos temporales y espaciales.

Los Árboles de Decisión son seleccionados debido a su interpretabilidad y a su capacidad para manejar datos con características categóricas y continuas. El clasificador Naive Bayes se incluyó por su simplicidad y rapidez en el entrenamiento, además de su capacidad para trabajar bien con grandes volúmenes de datos, lo que lo hace útil en situaciones donde la velocidad es crítica.

La combinación de estos clasificadores proporciona un enfoque diverso y robusto para la clasificación de señales de EEG, permitiendo explorar diferentes estrategias y optimizar el rendimiento de nuestro sistema de análisis.

3.3. Entrenamiento de Clasificadores

En todos los experimentos realizados, se dividió el conjunto de datos de manera estratégica para garantizar la validez y fiabilidad de los resultados obtenidos. Se utilizó la técnica de validación cruzada estratificada, una variante de la validación cruzada que tiene en cuenta la distribución de las clases en el conjunto de datos. Esto es particularmente importante cuando se trabaja con datos desbalanceados, como en el caso de muchas señales de EEG, donde ciertos estados mentales pueden estar representados con mayor frecuencia que otros. La validación cruzada estratificada asegura que cada pliegue o subconjunto de datos mantenga la misma proporción de clases que el conjunto de datos original, proporcionando una mejor estimación del rendimiento del clasificador en

escenarios reales.

Este enfoque no solo mejora la representatividad de los datos en cada iteración del proceso de validación, sino que también minimiza el riesgo de sesgo y sobreajuste, lo que permite obtener una evaluación más precisa del desempeño del modelo. Al utilizar esta técnica, se consigue que los clasificadores no se vean influenciados por desequilibrios en los datos, lo que a su vez permite que los resultados obtenidos sean más generalizables.

Adicionalmente, para optimizar el rendimiento de los clasificadores, se ajustaron parámetros específicos mediante la técnica de búsqueda de malla (grid search). Este enfoque sistemático explora exhaustivamente un espacio predefinido de hiperparámetros, evaluando múltiples combinaciones para encontrar la configuración óptima que maximice el rendimiento del clasificador. La búsqueda de malla es esencial para asegurar que cada clasificador funcione en su máximo potencial, dado que el ajuste adecuado de parámetros como el número de neuronas en una red neuronal, el valor de los parámetros C y kernel en una SVM o la profundidad de un árbol de decisión puede tener un impacto significativo en la precisión y la eficiencia del modelo.

A través de este proceso, se logra no solo mejorar el rendimiento de los clasificadores, sino también obtener una mejor comprensión de cómo se comportan bajo diferentes configuraciones, lo que es crucial para el análisis de datos EEG. De esta forma, la combinación de la validación cruzada estratificada y la búsqueda de malla garantiza una metodología rigurosa y robusta, permitiendo obtener estimaciones más fiables y modelos optimizados para la clasificación de los estados mentales.

3.3.1. Validación cruzada estratificada

Sea un conjunto de datos $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, donde $x_i \in \mathbb{R}^m$ representa una instancia de datos (con m características) y $y_i \in \{1, 2, \dots, C\}$ es la etiqueta de clase correspondiente a la instancia x_i , y C es el número total de clases en el problema de clasificación. La validación cruzada estratificada implica dividir este conjunto D en K subconjuntos o "pliegues" D_1, D_2, \dots, D_K tal que:

1. Proporción de clases constante**: Para cada clase $c \in \{1, 2, \dots, C\}$, la proporción

de instancias de la clase c en cada pliegue D_k debe ser aproximadamente la misma que la proporción de esa clase en el conjunto total D . Matemáticamente, si n_c es el número de instancias de la clase c en D , y n es el número total de instancias en D , entonces:

$$\frac{n_c}{n} \approx \frac{|D_k^c|}{|D_k|}$$

donde D_k^c es el conjunto de instancias de la clase c en el pliegue D_k , y $|D_k|$ es el número total de instancias en el pliegue D_k .

2. Entrenamiento y prueba en cada pliegue: En cada iteración i de la validación cruzada, se entrena un modelo f_i en el conjunto $D \setminus D_i$ (el conjunto total menos el pliegue i) y se evalúa en el pliegue D_i . Esto se repite para todos los pliegues $i = 1, 2, \dots, K$.

El modelo entrenado en cada iteración se puede denotar como:

$$f_i = \text{train}(D \setminus D_i)$$

La función de evaluación se calcula en el pliegue D_i , produciendo una métrica de rendimiento (como la precisión, accuracy_i , o cualquier otra métrica como F1-score, AUC, etc.) para cada pliegue:

$$\text{métrica}_i = \text{evaluate}(f_i, D_i)$$

3. Promedio de las métricas: Finalmente, se obtiene una estimación general del rendimiento del modelo al promediar las métricas obtenidas en cada uno de los K pliegues:

$$\text{métrica promedio} = \frac{1}{K} \sum_{i=1}^K \text{métrica}_i$$

Ejemplo con precisión (accuracy):

Si la métrica elegida es la precisión, la precisión en cada pliegue i se calcula como:

$$\text{accuracy}_i = \frac{\text{número de predicciones correctas en } D_i}{|D_i|}$$

Y la precisión promedio es:

$$\text{accuracy promedio} = \frac{1}{K} \sum_{i=1}^K \text{accuracy}_i$$

El procedimiento de la validación cruzada estratificada se puede resumir en los siguientes pasos:

1. Dividir D en K pliegues D_1, D_2, \dots, D_K , respetando las proporciones de clases.
2. Para cada $i = 1, 2, \dots, K$, entrenar f_i en $D \setminus D_i$ y evaluar en D_i .
3. Promediar las métricas de evaluación en los K pliegues.

3.4. Evaluación del Desempeño

La evaluación del desempeño de los clasificadores es un paso crítico para determinar su eficacia en la tarea de clasificación de estados mentales a partir de señales EEG. Para este propósito, se emplearon diversas métricas de desempeño que ofrecen una visión integral de la capacidad predictiva de los modelos. Las métricas seleccionadas no solo permiten medir la precisión global de los clasificadores, sino que también aportan información detallada sobre el comportamiento del modelo en relación con cada clase y cómo este maneja los falsos positivos y falsos negativos.

Las principales métricas utilizadas para este análisis incluyen:

- **Matriz de Confusión:** Es una herramienta fundamental para visualizar el rendimiento de un modelo de clasificación, mostrando una tabla de doble entrada que detalla las predicciones correctas e incorrectas del modelo para cada clase. La matriz está compuesta por cuatro elementos esenciales: Verdaderos Positivos (TP), Falsos Positivos (FP), Verdaderos Negativos (TN) y Falsos Negativos (FN), que permiten

identificar no solo cuántas predicciones fueron correctas, sino también en qué medida el modelo cometió errores al confundir una clase con otra.

- Verdaderos Positivos (TP): Esta métrica indica el número de instancias correctamente clasificadas como positivas, es decir, los casos en los que el modelo predice correctamente la clase positiva (por ejemplo, cuando un estado de concentración o confusión es identificado de forma adecuada).
- Falsos Positivos (FP): Representa la cantidad de instancias que el modelo clasifica incorrectamente como positivas, cuando en realidad pertenecen a la clase negativa. Este tipo de error también es conocido como *error de tipo I* es crucial en contextos donde una falsa alarma puede tener implicaciones significativas, como en la predicción de estados mentales incorrectos.
- Verdaderos Negativos (TN): Mide el número de instancias correctamente identificadas como negativas, es decir, cuando el modelo predice que una instancia no pertenece a la clase positiva y esta predicción es correcta.
- Falsos Negativos (FN): Indica la cantidad de instancias clasificadas incorrectamente como negativas cuando en realidad pertenecen a la clase positiva. Este error también se denomina *error de tipo II* es especialmente relevante en situaciones donde el no identificar correctamente un estado mental puede tener consecuencias, como no detectar un estado de confusión en un estudiante.
- Precisión (Accuracy): Es una métrica que proporciona una visión global de la capacidad del modelo para predecir correctamente tanto las clases positivas como negativas. Se define como la proporción de predicciones correctas (tanto positivas como negativas) entre el número total de predicciones. Matemáticamente, se expresa como:

$$\text{Precisión} = \frac{TP + TN}{TP + TN + FP + FN}$$

Aunque la precisión es útil para obtener una visión general del rendimiento, puede ser engañosa en situaciones con clases desbalanceadas, lo que motiva el uso de métricas adicionales como la sensibilidad y especificidad.

- Precisión (Precision): También conocida como valor predictivo positivo, esta métrica mide la proporción de instancias correctamente clasificadas como positivas con respecto al total de instancias predichas como positivas. Es particularmente útil en escenarios donde se desea minimizar el número de falsos positivos. Se define como:

$$\text{Precision} = \frac{TP}{TP + FP}$$

- Sensibilidad (Recall o Sensitivity): También conocida como "tasa de verdaderos positivos", mide la capacidad del modelo para identificar correctamente todas las instancias positivas. Es crucial en situaciones donde el objetivo es minimizar los falsos negativos, ya que una baja sensibilidad indica que el modelo está pasando por alto muchos casos positivos. Su fórmula es:

$$\text{Sensibilidad} = \frac{TP}{TP + FN}$$

- ****Especificidad (Specificity)****: Esta métrica se enfoca en la clase negativa y mide la proporción de instancias negativas que han sido correctamente identificadas por el modelo. Es útil cuando se busca minimizar los falsos positivos. Matemáticamente, se define como:

$$\text{Especificidad} = \frac{TN}{TN + FP}$$

- Curva ROC y AUC (Area Under the Curve): La curva ROC (Receiver Operating Characteristic) es una representación gráfica que ilustra el rendimiento de un clasificador al variar su umbral de decisión, mostrando la relación entre la tasa de verdaderos positivos (sensibilidad) y la tasa de falsos positivos (1 - especificidad). El área bajo la curva (AUC) es un valor que resume el desempeño global del modelo en términos de su capacidad para distinguir entre clases positivas y negativas. Un AUC cercano a 1 indica un modelo con excelente capacidad de discriminación, mientras que un valor de 0.5 indica un desempeño similar al de un clasificador aleatorio.

Cada una de estas métricas fue descrita y detallada en el Capítulo anterior, proporcionando las fórmulas y una interpretación más profunda de cómo estas contribuyen a

la evaluación integral de los clasificadores utilizados en este estudio. El uso combinado de estas métricas asegura una evaluación equilibrada que considera tanto el rendimiento global del modelo como su comportamiento específico en cada clase, permitiendo identificar fortalezas y debilidades de los clasificadores aplicados a la clasificación de estados mentales.

Capítulo 4

Resultados experimentales

4.1. Conjunto de datos

En esta Sección, se describen los conjuntos de datos utilizados

4.1.1. Conjunto de datos 1

Los autores recopilaron datos de señales EEG de 10 estudiantes universitarios mientras observaban fragmentos de videos de cursos masivos abiertos en línea (MOOC). Se seleccionaron videos de educación en línea que, en principio, no se considerarían confusos para estudiantes universitarios, tales como introducciones a temas básicos de álgebra o geometría. También se prepararon videos que, al contrario de los primeros, se esperaba que generaran confusión en un estudiante universitario típico si no estaba familiarizado con los temas, como mecánica cuántica o investigación con células madre. Se prepararon un total de 20 videos, 10 en cada categoría. Cada video tiene una duración aproximada de 2 minutos, y se recortó el clip justo en medio del tema para incrementar el nivel de confusión.

Los estudiantes usaron un dispositivo inalámbrico de un solo canal, llamado MindSet, este dispositivo mide la actividad en el lóbulo frontal. El dispositivo registra la diferencia de voltaje entre un electrodo ubicado en la frente y dos electrodos más, uno de referencia y uno de tierra, ambos en contacto con las orejas.

Al finalizar cada sesión, los estudiantes calificaban su nivel de confusión en una escala del 1 al 7, donde 1 indicaba el nivel más bajo de confusión y 7 el nivel más alto. Estas calificaciones fueron posteriormente normalizadas para etiquetar si el estudiante estaba o no confundido. Además de esta autoevaluación, se proporcionó una etiqueta de confusión predefinida por los investigadores.

Estos datos se recopilaron de diez estudiantes, cada uno de los cuales observó diez videos. Por lo tanto, se pueden considerar únicamente como 100 puntos de datos para más de 12,000 filas. Si se observa de esta manera, cada punto de datos está compuesto por más de 120 filas, que se muestrean cada 0.5 segundos (de modo que cada punto de datos corresponde a un video de un minuto). Las señales de mayor frecuencia se reportan como el valor medio durante cada intervalo de 0.5 segundos.

El archivo *EEG_data.csv* contiene los datos de EEG registrados de los 10 estudiantes, mientras que el archivo *demographic.csv* incluye información demográfica de cada estudiante. En cuanto a los datos de video, cada video tiene una duración aproximada de dos minutos, de los cuales se eliminan los primeros 30 segundos y los últimos 30 segundos, recopilando únicamente los datos de EEG durante el minuto central.

4.1.2. Conjunto de datos 2

Este conjunto de datos proviene de un experimento realizado por un sujeto masculino de 20-21 años de edad, utilizando un dispositivo Muse para registrar actividad cerebral mediante electroencefalografía (EEG). El conjunto de datos fue generado a lo largo de varios meses y en distintas tareas que involucraban diferentes niveles de concentración. A continuación se detallan algunas características clave del conjunto:

1. **Dispositivo utilizado:** Muse (un casco EEG portátil).
2. **Datos recogidos:** Actividad de ondas cerebrales (alfa, beta, gamma, delta y theta) de cuatro electrodos ubicados en el cráneo, de acuerdo con las especificaciones del dispositivo Muse.
3. **Procesamiento:** Se aplicó la transformada rápida de Fourier (FFT) a las señales

EEG, dividiéndolas en 128 bins para cada tipo de onda.

4. **Duración del experimento:** El registro se hizo a lo largo de varios meses, durante diferentes actividades que implicaban diversos niveles de concentración.
5. **Tareas realizadas durante el registro:** Las tareas realizadas durante las sesiones de grabación se clasificaron en diferentes niveles de concentración:
 - **Alta concentración:** Aritmética mental.
 - **Concentración media-alta:** Leer artículos técnicos, escuchar podcasts técnicos y leer las transcripciones.
 - **Concentración baja-media:** Navegar por Internet.
 - **Baja concentración:** Sentarse con los ojos abiertos o cerrados, en estado de relajación.
6. El conjunto de datos incluye las siguientes variables:
 - **timestamp:** Marca de tiempo que indica cuándo se registró cada fila de datos.
 - **alpha0, beta0, gamma0, delta0, theta0:** Medición de las ondas cerebrales correspondientes al electrodo 0.
 - **alpha1, beta1, gamma1, delta1, theta1:** Medición de las ondas cerebrales del electrodo 1.
 - **alpha2, beta2, gamma2, delta2, theta2:** Medición de las ondas cerebrales del electrodo 2.
 - **alpha3, beta3, gamma3, delta3, theta3:** Medición de las ondas cerebrales del electrodo 3.
 - **concentration:** Un valor autoevaluado de concentración que varía entre 0 y 1. Este valor se asignó en función de la actividad que estaba realizando el sujeto en ese momento (ejemplo: valores altos para la aritmética mental o lectura técnica y valores bajos para relajación o navegación por internet).

4.1.3. Correlación de las variables del conjunto de datos 1

En esta subsección analizamos las variables del conjunto de datos 1. La matriz de correlación en la Figura 4.1 refleja las relaciones entre las variables, midiendo la intensidad y dirección de sus asociaciones. A continuación se analizan las relaciones más relevantes de las correlaciones entre las variables:



Figura 4.1: Matriz de correlación para conjunto de datos 1

1. Correlaciones fuertes

- Las variables **VideoID** y **predefinedlabel** tienen una correlación extremadamente fuerte de 0.871, lo que sugiere que ambas variables están muy relacionadas. Esto podría significar que la etiqueta predefinida está muy influenciada por el identificador de video.
- Las variables **Beta2** y **Gamma1** tienen una correlación muy fuerte de 0.808, lo que indica que estas bandas cerebrales están altamente relacionadas.
- Las variables **Gamma1** y **Gamma2** tienen una correlación de 0.740, sugiriendo que estas dos bandas cerebrales gamma tienen una fuerte relación.

2. Correlaciones moderadas

- Las variables **Attention** y **Mediation** presentan una correlación moderada de 0.549, lo que sugiere que la capacidad de atención está asociada con la mediación (posiblemente algún tipo de estado mental).
- Las variables **Theta** y **Alpha1** presentan una correlación moderada de 0.587, lo que implica que estas bandas cerebrales están asociadas, pero no completamente relacionadas.
- Las variables **Alpha2** y **Beta1** tienen una correlación moderada de 0.627, indicando que estas dos frecuencias también están relacionadas entre sí.
- Las variables **Beta1** y **Gamma2** también presentan una correlación moderada de 0.527, lo que indica una relación entre estas dos bandas cerebrales.

3. Correlaciones bajas o negativas

- Las variables **Attention** y **Beta2** presentan una correlación negativa (-0.307), lo que indica que a medida que aumenta la atención, los valores de la banda Beta2 tienden a disminuir.
- Las variables **Attention** y **Gamma2** también son negativas (-0.313), lo que sugiere que cuando aumenta la atención, la actividad en la banda Gamma2 disminuye.
- En las variables **Mediation** y **Beta2** la correlación negativa de -0.391 indica que estos dos valores disminuyen a la vez o cuando uno aumenta, el otro disminuye.
- Las variables **Attention** y **Theta** presentan una correlación de -0.258, muestra una relación inversa entre atención y la banda Theta, lo cual puede estar relacionado con niveles de concentración versus relajación.

4. Correlaciones cercanas a cero

- En las variables **SubjectID** y **VideoID** la correlación es casi nula (-0.005), lo que indica que no hay relación significativa entre el identificador del sujeto y el del video.
- Mientras que en las variables **Attention** y **predefinedlabel** la correlación también es prácticamente nula (0.001), lo que significa que la etiqueta predefinida no está relacionada con los niveles de atención.
- Las variables **Raw** y **user-definedlabeln** presentan una correlación muy baja (-0.001), lo que indica una relación prácticamente inexistente entre estas dos variables.

5. Otras relaciones

- Correlaciones entre bandas cerebrales: Las bandas cerebrales tienden a tener correlaciones positivas entre ellas, lo que es común dado que suelen estar relacionadas en términos de la actividad cerebral.
- Variables de etiquetas y otras variables: En general, las variables **predefinedlabel** y **user-definedlabeln** tienen correlaciones bajas con otras variables, lo que sugiere que no tienen una relación muy fuerte con los datos de atención, mediación o señales EEG.

La matriz muestra que VideoID está muy relacionado con predefinedlabel, lo que podría significar que los videos influyen mucho en las etiquetas predefinidas. Las variables Attention y Mediation tienen correlaciones significativas con bandas cerebrales, lo que podría ser útil para interpretar estados cognitivos. Las correlaciones negativas en las bandas Beta y Gamma con Attention podrían indicar que estas frecuencias disminuyen con una mayor concentración.

4.1.4. Correlación de las variables del conjunto de datos 2

En esta subsección analizamos las variables del conjunto de datos 2. La matriz de correlación en la Figura [4.2](#) muestra las relaciones entre las variables, midiendo la intensidad

y dirección de sus asociaciones. A continuación se analizan las relaciones más relevantes de las correlaciones entre las variables:

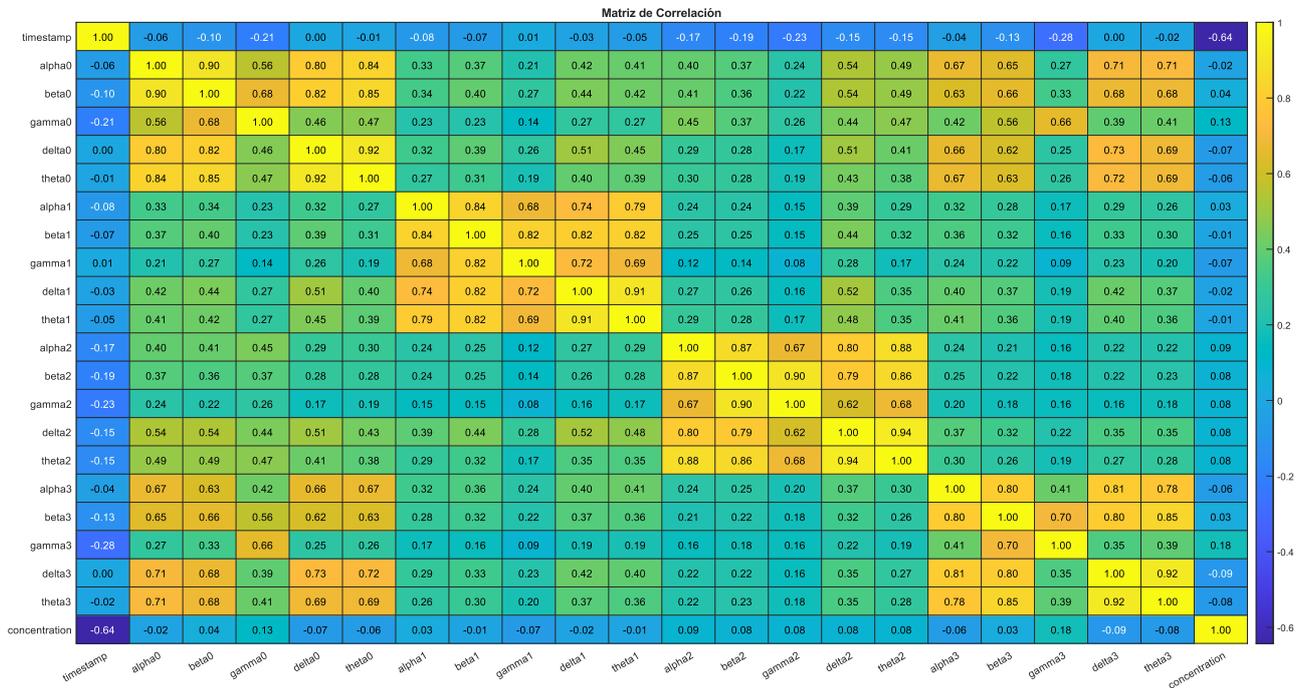


Figura 4.2: Matriz de correlación para conjunto de datos 2

La matriz de correlación de la Figura 4.2 tiene varias variables, incluyendo medidas de diferentes ondas cerebrales (alpha, beta, gamma, delta, theta) en distintos canales (0, 1, 2, 3), un registro temporal (timestamp), y una variable de concentración (concentration). En esta Sección se describen algunos patrones relevantes observados

1. **Timestamp (timestamp).** La correlación entre timestamp y la mayoría de las variables de ondas cerebrales es negativa, lo que podría indicar que las características de las señales cerebrales tienden a cambiar en el tiempo. Especialmente, hay una correlación negativa fuerte con la variable de concentración (concentration), con un valor de -0.6425, lo que sugiere que a medida que avanza el tiempo, la concentración disminuye significativamente.
2. **Ondas cerebrales en diferentes canales.** Las variables de las diferentes bandas (alpha, beta, gamma, delta, theta) de un mismo canal (ej., alpha0, beta0, etc.)

suelen tener correlaciones positivas entre ellas. Por ejemplo, β_0 y α_0 tienen una correlación de 0.8980, lo que significa que hay una relación lineal fuerte entre estas dos ondas en el mismo canal. Lo mismo sucede para otros canales, como las correlaciones entre α_1 , β_1 , γ_1 , etc. También se observa una alta correlación entre las mismas ondas en diferentes canales, por ejemplo, α_0 está correlacionada con α_1 con un valor de 0.7951.

3. **Concentración (concentration).** La variable *concentration* presenta una fuerte correlación negativa con la mayoría de las variables de ondas cerebrales, especialmente con β_0 (-0.6425), lo que podría indicar que cuando las ondas beta del canal 0 aumentan, la concentración disminuye. Esto es consistente con investigaciones que sugieren que las ondas beta a menudo están asociadas con procesos mentales activos, pero no necesariamente con concentración. Sin embargo, con algunas variables, como α_2 y α_3 , la correlación es más baja (en magnitud), lo que podría significar que la concentración tiene una relación más débil con estas ondas en comparación con otras.
4. **Correlaciones entre diferentes ondas cerebrales.** Existe una alta correlación entre las mismas ondas en diferentes canales. Por ejemplo, θ_0 y θ_1 tienen una correlación de 0.8392, y lo mismo sucede con otros tipos de ondas. Esto sugiere que las diferentes bandas de frecuencia mantienen comportamientos similares en todos los canales. Las correlaciones cruzadas entre ondas distintas son también significativas. Por ejemplo, α_0 y β_0 tienen correlaciones altas en todos los canales, lo que podría sugerir una relación entre las actividades de esas ondas en diferentes partes del cerebro.
5. **Correlaciones destacadas.** Ondas beta: las variables β_0 , β_1 , β_2 , y β_3 están altamente correlacionadas entre sí, con valores superiores a 0.8, lo que indica una relación muy fuerte entre las ondas beta de los diferentes canales. Theta y concentración: existe una correlación más baja entre θ_0 , θ_1 , θ_2 , θ_3 y la concentración, con valores cercanos a cero, lo que sugiere que la actividad de

las ondas theta puede no estar tan fuertemente relacionada con la concentración en este caso.

- 6. Relación negativa con la concentración.** La variable concentration muestra una correlación negativa con muchas variables cerebrales, como beta0, beta1, beta2, lo que indica que, en este conjunto de datos, a medida que ciertas ondas aumentan en intensidad, la concentración tiende a disminuir.

En general, el conjunto de datos muestra fuertes correlaciones entre las mismas bandas de frecuencia en diferentes canales y, en general, una tendencia negativa en las correlaciones entre las ondas cerebrales y la concentración. Las ondas beta, en particular, parecen tener una relación inversa significativa con la concentración.

4.2. Evaluación de los Clasificadores

4.2.1. Resultados conjunto de datos 1

La tabla 4.1 presenta el rendimiento de diferentes tipos de modelos de clasificación, medido en términos de su Accuracy (Validación). Esta métrica refleja el porcentaje de predicciones correctas que realiza cada modelo durante la fase de validación.

Los modelos Ensemble y Neural Network sobresalen por su precisión extremadamente alta, con casi el 99% de aciertos. Esto los hace opciones ideales en escenarios donde se busca maximizar la precisión, aunque es importante recordar que estos modelos suelen ser más complejos y pueden requerir mayor poder computacional y tiempo de entrenamiento. El Árbol de Decisión (Tree) también tiene un rendimiento alto con un 92,56%, lo que lo convierte en una opción más sencilla pero efectiva para tareas donde la interpretabilidad es importante.

Cuadro 4.1: Resultados utilizando todas las características

Tipo de modelo	Accuracy % (Validación)
Tree	92.56108032
Discriminant	59.81578331
Binary GLM Logistic Regression	59.96409336
Efficient Logistic Regression	51.26063539
Efficient Linear SVM	53.57895559
Naive Bayes	60.78370151
SVM	84.20888299
KNN	83.1394895
Ensemble	98.99305285
Neural Network	98.64179221
Kernel	69.08125829

SVM y KNN ofrecen precisiones competitivas (alrededor del 83-84%), lo que los convierte en opciones viables en muchos casos. La SVM, en particular, es conocida por su capacidad para manejar problemas de clasificación en espacios de alta dimensionalidad, mientras que KNN es un modelo simple pero efectivo en ciertos contextos.

En general, mientras que Ensemble y Neural Network ofrecen el mayor rendimiento en términos de precisión, el Árbol de Decisión destaca como un modelo robusto y sencillo, mientras que modelos como Efficient Logistic Regression y Efficient Linear SVM no parecen ser las mejores opciones en este caso particular.

Los resultados presentados en la tabla [4.2](#) muestran una comparación del rendimiento de diferentes modelos de clasificación (Ensemble, Árbol de Decisión, SVM, KNN y Redes Neuronales) usando varias métricas clave como Precisión (Precision), Recall, F1-Score, Tasa de Falsos Positivos (FP Rate), Coeficiente de Correlación de Matthews (MCC) y Área bajo la curva (AUC).

En la Tabla es posible ver que el modelo Ensemble tiene el rendimiento más alto en todas las métricas, con valores de precisión y recall cercanos al 99%, tanto para la clase 0

como para la clase 1. El valor de AUC es casi 1, lo que significa que el modelo es excelente para distinguir entre las clases. El modelo Ensemble es el mejor de todos en cuanto a métricas generales de rendimiento.

Por otro lado, aunque los árboles de decisión no alcanzan el nivel del Ensemble, el árbol de decisión tiene valores de precisión y recall superiores al 90 % para ambas clases. El AUC sigue siendo alto (0.9841), lo que demuestra que es un buen modelo para la clasificación en general.

Las SVM para la clase 0 tiene un rendimiento moderado, con una precisión del 89 %, pero el recall es solo del 76 %, lo que sugiere que el modelo puede estar perdiendo algunos ejemplos positivos. La clase 1, por otro lado, tiene un mejor recall (91 %) pero una precisión más baja (80 %). Aunque el AUC es aceptable (0.9234), es inferior al de los modelos Ensemble y Árbol de Decisión.

Para KNN, las métricas son bastante similares para ambas clases, con precisiones y recall alrededor del 83 %. Esto indica un buen desempeño, aunque es inferior al de los modelos Ensemble y Árbol de Decisión. El valor de AUC de 0.9123 es bueno, pero nuevamente inferior a los modelos más robustos.

Por su parte, para las Redes neuronales, las métricas de precisión, recall y F1-Score son casi perfectas, cercanas al 98 %, lo que lo coloca como uno de los mejores modelos junto con el Ensemble. El AUC de 0.994 es casi perfecta, lo que significa que la red neuronal distingue bien entre las clases. La Red Neuronal es una de las mejores opciones, comparable con Ensemble, aunque podría ser más compleja y costosa en términos de recursos computacionales.

Cuadro 4.2: Resultados utilizando varias métricas de desempeño

Modelo	Clase	Precision	Recall	F1-Score	FP Rate	MCC	AUC
Ensemble	0	0.98837	0.99343	0.99089	0.011116	0.98221	0.9996
	1	0.99373	0.98888	0.99130	0.0065663	0.98221	0.9996
Tree	0	0.91247	0.92825	0.92029	0.084666	0.84335	0.9841
	1	0.93064	0.91533	0.92292	0.071749	0.84335	0.9841
SVM	0	0.89146	0.76553	0.82371	0.088625	0.68586	0.9234
	1	0.80346	0.91138	0.85402	0.23447	0.68586	0.9234
KNN	0	0.83382	0.81566	0.82464	0.15456	0.66161	0.9123
	1	0.82829	0.84544	0.83677	0.18434	0.66161	0.9123
Neural Network	0	0.98317	0.98222	0.98270	0.015989	0.96626	0.994
	1	0.98311	0.98401	0.98356	0.017777	0.96626	0.994

Por su parte la Figura [4.3](#) muestra las matrices de confusión obtenidas con los algoritmos más destacados. Los modelos Ensemble y Red Neuronal tienen el mejor desempeño con tasas mínimas de falsos positivos y falsos negativos, lo que refleja una gran precisión. El Árbol de Decisión también tiene un buen desempeño, aunque ligeramente inferior a los anteriores en términos de falsos negativos y positivos. El modelo KNN tiene un rendimiento razonable, pero tiene una cantidad significativa de errores en ambas categorías (FP y FN). Finalmente, modelo SVM presenta una alta tasa de falsos positivos, lo que sugiere que no distingue bien entre las clases negativas y positivas en comparación con los otros modelos.

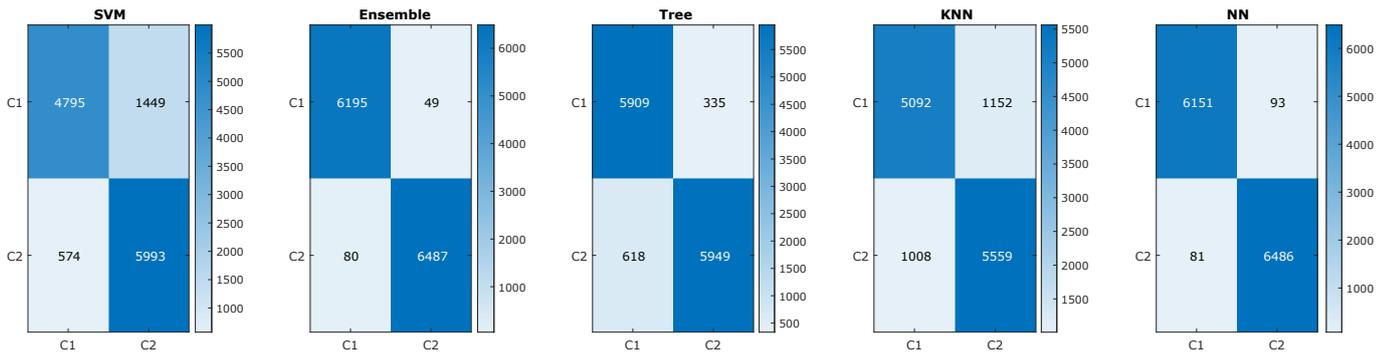


Figura 4.3: Matrices de confusion de varios modelos

4.2.2. Resultados conjunto de datos 2

En esta Sección se muestran los resultados obtenidos con el conjunto de datos 2. La Tabla 4.3 resume las métricas clave de desempeño para los mejores 3 modelos de clasificación encontrados: Redes Neuronales (NN), Árboles de Decisión y Ensemble.

Los resultados de la tabla 4.3 presentan un análisis de tres modelos de clasificación: Árbol de Decisión (Tree), Ensamble (Ensemble), y Red Neuronal (Neural Network), evaluados utilizando varias métricas de rendimiento como Precision, Recall, F1-Score, Tasa de Falsos Positivos (FP Rate), Matriz de Correlación de Matthews (MCC), y Área Bajo la Curva (AUC).

El modelo de Árboles de decisión muestra un desempeño robusto con valores altos de Precision, Recall y F1-Score, especialmente en las primeras clases (valores cercanos al 99%), lo que indica que el modelo es bastante confiable en cuanto a la correcta clasificación. La tasa de falsos positivos (FP Rate) es extremadamente baja (menor al 0.001 en la mayoría de los casos), lo que refleja que el modelo rara vez clasifica erróneamente ejemplos negativos. El AUC es superior a 0.995 en todos los casos, lo que indica que el modelo tiene un excelente rendimiento para distinguir entre las clases.

Cuadro 4.3: Resultados obtenidos con los tres mejores modelos de clasificación

Modelo	Precision	Recall	F1-Score	FP Rate	MCC	AUC
Tree						
1	0.9979	0.98347	0.99063	0.00014795	0.99	0.9956
2	0.9922	0.9922	0.9922	0.00059435	0.99161	0.9959
3	0.9916	0.99299	0.99229	0.0020629	0.9904	0.9976
4	0.99338	0.9912	0.99229	0.00094727	0.99119	0.996
5	0.99404	0.998	0.99602	0.00044497	0.99572	0.9968
6	0.98291	0.98367	0.98329	0.0036931	0.97968	0.9967
7	1	1	1	0	1	0.9975
8	0.98493	0.98698	0.98595	0.0054481	0.98088	0.997
Ensemble						
1	1	0.99587	0.99793	0	0.99778	1
2	1	1	1	0	1	1
3	1	1	1	0	1	1
4	1	1	1	0	1	1
5	1	1	1	0	1	1
6	1	1	1	0	1	1
7	1	1	1	0	1	1
8	0.99896	1	0.99948	0.00037573	0.99929	1
Neural Network						
1	0.79184	0.80165	0.79671	0.015091	0.78208	0.9342
2	0.59833	0.5575	0.57719	0.028529	0.54658	0.9065
3	0.73864	0.74123	0.73994	0.064294	0.67605	0.9363
4	0.61105	0.63256	0.62162	0.057783	0.56635	0.9333
5	0.51959	0.50299	0.51116	0.034559	0.47553	0.8932
6	0.74038	0.71851	0.72928	0.05439	0.67201	0.9173
7	0.81221	0.84804	0.82974	0.0056826	0.8249	0.9628
8	0.81451	0.83021	0.82229	0.068195	0.75741	0.9392

Por otro lado, El modelo Ensemble tiene el mejor rendimiento general, con Precision, Recall y F1-Score perfectos (valores de 1 en casi todas las clases). Esto significa que el modelo clasifica correctamente casi todas las instancias sin errores. La tasa de falsos positivos es prácticamente cero, lo que es ideal para aplicaciones que requieren alta precisión. El AUC es perfecto (1.0), lo que implica que el modelo es excelente en la clasificación sin cometer errores.

Finalmente, para las redes neuronales, la precisión y el recall varían más en comparación con los otros modelos. Si bien en algunas clases la precisión y el F1-Score son altos (por ejemplo, en la clase 7 con valores alrededor de 0.83), en otras clases los valores son más bajos (alrededor de 0.51 en la clase 5). El AUC se mantiene alrededor de 0.93 a 0.94, lo que aún indica una buena capacidad para diferenciar entre las clases, pero con algunas áreas de mejora.

Los resultados obtenidos de los tres mejores modelos de clasificación en la investigación, presentados en la Tabla [4.3](#), mostraron rendimientos excepcionales, con precisiones y F1-scores que superaron el 99 % en muchos casos. Esto sugiere que estos enfoques son altamente efectivos para detectar la confusión en estudiantes universitarios durante la visualización de materiales educativos. La alta tasa de verdadero positivo (Recall) indica que los modelos son capaces de identificar correctamente a los estudiantes que experimentan confusión, lo que es crucial para implementar intervenciones educativas personalizadas.

Por otro lado, los modelos de redes neuronales presentaron un rendimiento inferior, lo que sugiere que, aunque son herramientas poderosas, su configuración actual no es óptima para este tipo de datos. Esta diferencia en el desempeño podría indicar la necesidad de más datos de entrenamiento, un mejor ajuste de los hiperparámetros o la utilización de arquitecturas más complejas.

4.3. Discusión de Resultados

La detección de estados de confusión en estudiantes universitarios mediante clasificadores representa un avance importante tanto en el ámbito de la educación como en el estudio de los procesos de aprendizaje. Este tipo de tecnología abre nuevas posibilidades

para personalizar la enseñanza, permitiendo una aproximación más intuitiva y reactiva hacia las necesidades individuales de los estudiantes. Los resultados de esta investigación han demostrado que ciertos modelos, especialmente los basados en árboles de decisión y métodos de ensemble, alcanzan niveles de precisión notablemente altos al identificar momentos críticos de confusión. Esto sugiere que estos modelos pueden ser herramientas valiosas en entornos educativos, ya que logran captar indicios tempranos de dificultades, lo cual es crucial para una intervención efectiva. La detección oportuna de estados de confusión no solo permite que los educadores ajusten sus métodos en función del estado cognitivo del estudiante, sino que también capacita a los propios estudiantes para tomar decisiones informadas sobre su proceso de aprendizaje. Identificar cuándo una persona experimenta dificultades permite que tanto el estudiante como el profesor sean conscientes de los momentos en los que es necesario un enfoque diferente o un apoyo adicional, fomentando una experiencia educativa más comprensiva e inclusiva.

A pesar del optimismo que generan estos avances, es necesario adoptar una perspectiva crítica respecto a las limitaciones de estos modelos. La precisión de los clasificadores no debe considerarse una solución definitiva, pues los procesos de aprendizaje y los factores que generan confusión son increíblemente complejos. La confusión en un aula puede ser causada por una variedad de factores, desde la falta de familiaridad con el tema hasta cuestiones de presentación y pedagogía, e incluso elementos externos como el estado emocional del estudiante o las condiciones ambientales. Por ejemplo, un estudiante podría mostrar signos de confusión en sus patrones EEG no necesariamente por no entender el contenido, sino debido a fatiga, estrés u otros factores personales. Por lo tanto, aunque los clasificadores ofrecen una herramienta innovadora para señalar momentos de confusión, los educadores y analistas deben interpretarlos con cautela, siempre considerando el contexto completo en el que el estudiante se encuentra.

La metodología de esta investigación se enfocó en recopilar datos de EEG de estudiantes mientras veían videos educativos, un contexto específico que busca relacionar directamente la actividad cerebral con la confusión durante el aprendizaje. Los datos de EEG, obtenidos mediante electrodos colocados en el cuero cabelludo, captan distintos tipos de ondas cerebrales que corresponden a diversos estados cognitivos y emocionales,

como la atención, el estrés y, en este caso, la confusión. A través del análisis de estos patrones, el modelo logra identificar momentos en los que los estudiantes podrían estar enfrentando dificultades. Esto podría abrir puertas a futuras aplicaciones en las que el contenido educativo se ajusta en tiempo real, adaptándose al estado cognitivo del estudiante y brindándole un apoyo inmediato. Tal implementación permitiría, por ejemplo, que un estudiante visualizara explicaciones adicionales o recursos interactivos si el sistema detecta que se encuentra en un estado de confusión, fomentando una experiencia de aprendizaje más adaptativa y, potencialmente, más efectiva.

Los resultados obtenidos en este estudio ofrecen además diversas posibilidades para investigaciones futuras. En primer lugar, sería valioso ampliar el análisis de las características del EEG, explorando la correlación entre distintos tipos de ondas cerebrales (como alfa, beta, theta y gamma) y niveles de confusión. Profundizar en estos patrones podría ofrecer un entendimiento más detallado de cómo se manifiestan diferentes estados emocionales y cognitivos en el cerebro, enriqueciendo la precisión de los clasificadores. Además, un estudio con una muestra más amplia y variada, que incluya estudiantes de diferentes edades, disciplinas y contextos culturales, permitiría obtener una perspectiva más generalizada sobre el papel de la confusión en el aprendizaje. Tal enfoque ayudaría a verificar si los mismos patrones EEG de confusión observados en un contexto específico se replican en otros entornos, contribuyendo así a la robustez y aplicabilidad de los modelos desarrollados.

Otro aspecto relevante en la discusión de estos resultados radica en el potencial de estas herramientas para proporcionar retroalimentación a los diseñadores de contenido educativo. Al analizar los momentos específicos en los que los estudiantes experimentan confusión, los desarrolladores de material didáctico podrían identificar patrones comunes y ajustar el diseño de los recursos para minimizar posibles puntos de dificultad. Por ejemplo, si ciertos temas o presentaciones visuales tienden a generar confusión, se podrían revisar para asegurar una mayor claridad y accesibilidad del contenido. Además, los datos recogidos a través de estos clasificadores podrían ofrecer información valiosa sobre cómo se perciben diferentes métodos pedagógicos, ayudando a optimizar no solo la presentación de la información, sino también la estructura de los planes de estudio. Esta retroalimentación

constante y en tiempo real tiene el potencial de cerrar el ciclo entre la producción de contenido y la experiencia de aprendizaje, promoviendo un proceso educativo más dinámico y alineado con las necesidades cognitivas y emocionales de los estudiantes.

En conclusión, los resultados de esta investigación no solo revelan el potencial de los clasificadores en la identificación de estados de confusión, sino que también abren el camino para un cambio fundamental en el diseño de experiencias educativas. La capacidad de adaptar la enseñanza a las necesidades cognitivas y emocionales de cada estudiante podría transformar el enfoque educativo hacia un modelo más inclusivo y efectivo, en el que se atienda de manera personalizada cada fase del proceso de aprendizaje. De esta manera, se avanza hacia una educación más accesible, que prioriza el bienestar y la efectividad del aprendizaje, no solo como una acumulación de conocimientos, sino como una experiencia enriquecedora y de crecimiento constante para todos los estudiantes.

Capítulo 5

Conclusiones

Los clasificadores demostraron ser herramientas prometedoras para la detección de estados de confusión en estudiantes universitarios, con implicaciones significativas para la práctica educativa. Sin embargo, es crucial abordar las limitaciones identificadas y continuar explorando el desarrollo de modelos más robustos y contextualizados. A medida que avancemos en esta investigación, es fundamental no perder de vista la complejidad del aprendizaje humano y la importancia de adoptar un enfoque holístico que considere tanto los aspectos técnicos como los contextuales del proceso educativo.

A pesar de la efectividad observada en algunos modelos, también se identificaron limitaciones que merecen atención:

Desempeño de Redes Neuronales: Los modelos de redes neuronales mostraron un rendimiento inferior en comparación con los enfoques de ensemble y árboles de decisión. Esta discrepancia podría indicar que la arquitectura o el conjunto de datos utilizados no eran los más adecuados. Es posible que una mayor diversidad en el conjunto de datos o un ajuste más fino de los hiperparámetros puedan mejorar su rendimiento.

Generalización: La investigación se basa en un conjunto relativamente pequeño de datos recopilados de 10 estudiantes. Esto limita la capacidad de generalizar los resultados a poblaciones más amplias. La diversidad de los estudiantes, sus estilos de aprendizaje y las diferentes áreas temáticas podrían influir en la eficacia de los modelos. La ampliación del conjunto de datos para incluir una variedad más amplia de contextos y sujetos es

crucial para validar estos hallazgos.

Interpretación de Resultados: Si bien los modelos lograron una alta precisión, es esencial tener en cuenta que la confusión no siempre se traduce en una mala comprensión. Existen diferentes tipos de confusión, y algunos pueden ser incluso beneficiosos en el proceso de aprendizaje. Por lo tanto, una clasificación simplista de los estados de confusión podría ser engañosa. Es fundamental desarrollar un marco conceptual que permita entender mejor estos estados en el contexto del aprendizaje.

Factores Externos: Finalmente, los modelos pueden no haber considerado factores externos que influyen en la confusión, como el estado emocional del estudiante, el ambiente de aprendizaje, o la calidad del material educativo. Integrar estos factores podría enriquecer la detección y el análisis de los estados de confusión, llevando a una mejor personalización de la enseñanza.

Bibliografía

- [1] Ivana Di Leo et al. “Curiosity... Confusion? Frustration! The role and sequencing of emotions during mathematics problem solving”. En: *Contemporary Educational Psychology* 58 (jul. de 2019), págs. 121-137. ISSN: 0361-476X. DOI: [10.1016/j.cedpsych.2019.03.001](https://doi.org/10.1016/j.cedpsych.2019.03.001).
- [2] Sidney D’Mello et al. “Confusion can be beneficial for learning”. En: *Learning and Instruction* 29 (feb. de 2014), págs. 153-170. ISSN: 0959-4752. DOI: [10.1016/j.learninstruc.2012.05.003](https://doi.org/10.1016/j.learninstruc.2012.05.003).
- [3] Brooke B. Eisenbach y Jason S. Frydman. ““What are we doing?”: Teacher role confusion in mental health literacy instruction”. En: *Teaching and Teacher Education* 132 (oct. de 2023), pág. 104236. ISSN: 0742-051X. DOI: [10.1016/j.tate.2023.104236](https://doi.org/10.1016/j.tate.2023.104236).
- [4] Crystal Kalinec-Craig y Anthony Rios. “An exploratory mixed methods study about teacher candidates’ descriptions of children’s confusion, productive struggle, and mistakes in an elementary mathematics methods course”. En: *The Journal of Mathematical Behavior* 73 (mar. de 2024), pág. 101103. ISSN: 0732-3123. DOI: [10.1016/j.jmathb.2023.101103](https://doi.org/10.1016/j.jmathb.2023.101103).
- [5] Blair Lehman, Sidney D’Mello y Art Graesser. “Confusion and complex learning during interactions with computer learning environments”. En: *The Internet and Higher Education* 15.3 (jun. de 2012), págs. 184-194. ISSN: 1096-7516. DOI: [10.1016/j.iheduc.2012.01.002](https://doi.org/10.1016/j.iheduc.2012.01.002).
- [6] Célia Loriette, Julian L. Amengual y Suliann Ben Hamed. “Beyond the brain-computer interface: Decoding brain activity as a tool to understand neuronal mechanisms sub-

- tending cognition and behavior”. En: *Frontiers in Neuroscience* 16 (sep. de 2022). ISSN: 1662-453X. DOI: [10.3389/fnins.2022.811736](https://doi.org/10.3389/fnins.2022.811736).
- [7] Xiuping Men y Xia Li. “Detecting the Confusion of Students in Massive Open Online Courses Using EEG”. En: *International Journal of Education and Humanities* 4.2 (sep. de 2022), págs. 72-77. ISSN: 2770-6702. DOI: [10.54097/ijeh.v4i2.1509](https://doi.org/10.54097/ijeh.v4i2.1509).
- [8] J. Elizabeth Richey et al. “More confusion and frustration, better learning: The impact of erroneous examples”. En: *Computers amp; Education* 139 (oct. de 2019), págs. 173-190. ISSN: 0360-1315. DOI: [10.1016/j.compedu.2019.05.012](https://doi.org/10.1016/j.compedu.2019.05.012).
- [9] Tao Xu et al. “Confused or not: decoding brain activity and recognizing confusion in reasoning learning using EEG”. En: *Journal of Neural Engineering* 20.2 (mar. de 2023), pág. 026018. ISSN: 1741-2552. DOI: [10.1088/1741-2552/acbfe0](https://doi.org/10.1088/1741-2552/acbfe0).