

Estudio exploratorio de modelos para la evaluación automatizada de estados mentales a partir de señales de electroencefalogramas, integrable al servicio Neuro4B

Kaled Alejandro Hernández Romo

kaledconk@gmail.com / kaled.hernandez@usm.cl

Gabriel Jara
Profesor Guía

Patricio Santander
Profesor Correferente

Resumen: Neuro4B es una empresa dedicada al análisis de *neurocompetencias* en el área laboral. Esta empresa evalúa el desempeño, rendimiento y reacciones de trabajadores usando un test proporcionado por Nesplora llamado IceCream team y un electroencefalograma portátil. Las señales de electroencefalografía (EEG) ofrecen una ventana no invasiva a la actividad cerebral, cuyo análisis es fundamental para el diagnóstico de patologías neurológicas y para el desarrollo de interfaces cerebrocomputador (BCI). Sin embargo, la complejidad y naturaleza estocástica de estas señales hacen que la identificación de patrones específicos sea una tarea desafiante. Este estudio preliminar explora y compara la eficacia de diversos algoritmos de *machine learning* para la detección automática de patrones en señales EEG descompuestas en múltiples bandas de frecuencia. Los resultados preliminares se centrarán en comparar métricas clave de rendimiento como la precisión (*accuracy*), la sensibilidad y la especificidad de cada modelo además de ser contrastadas con métricas proporcionados por Neuro4B. A partir de este trabajo se espera identificar qué algoritmos ofrecen la mayor capacidad discriminativa y la mejor especificidad diagnóstica para la clasificación de estados emocionales y de carga cognitiva.

Palabras Clave: **Electroencefalograma (EEG), Machine Learning, Detección de Patrones, Clasificación de Señales, Interfaces Cerebro-Computador (BCI)**

1 Introducción

Comprender las emociones y estado mental de una persona depende fuertemente del examen, test o cuestionario que se realiza, y dado que se busca evaluar algo perteneciente a la experiencia subjetiva de la conciencia, no es sorprendente saber que estas evaluaciones se basan en reportes subjetivos, que pueden ser imprecisos debido a sesgos o hasta inviables en algunos contextos.

La tecnología de electroencefalograma (EEG) ofrece la oportunidad de hacer estudios con evaluación a tiempo real no invasivos en una persona y obtener resultados objetivos a partir de la actividad cerebral. Sin embargo, la riqueza y complejidad de las señales



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado

Título del trabajo: Estudio exploratorio de modelos para la evaluación automatizada de estados mentales a partir de señales de electroencefalogramas, integrable al servicio Neuro4B

Nombre del candidato(a): Kaled Alejandro Hernández Romo _____

Carrera / Grado: Ingeniería en informática _____

Campus: Sede Viña del Mar _____ Departamento: Departamento de Electrotecnia e Informática _____

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Gabriel Jara Bulnes _____, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 03 de marzo 2026 Firma: _____

Estudiante o Candidato(a):

Fecha: 02-03-2026 Firma: _____

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

caracterizadas por su naturaleza no lineal y su baja relación señal-ruido hacen que su interpretación manual sea una tarea ardua y propensa a errores [1]. Por lo tanto, el desafío reside en traducir las complejas y ruidosas señales EEG en etiquetas claras y útiles, como "alta carga cognitiva" o "estado emocional negativo". Este es un problema de reconocimiento de patrones ideal para técnicas de computación avanzadas como el aprendizaje supervisado, que muestran un gran potencial para tareas de clasificación y por su capacidad de trabajar con un gran volumen de datos.

1.1 Contexto y antecedentes

Neuro4B es una empresa dedicada al análisis y evaluación de pruebas de neurocompetencias enfocada a la seguridad laboral, tiene como objetivo evaluar la reacción de un trabajador evaluado y obtener indicadores robustos que contribuyan a la estimación de su comportamiento en determinadas situaciones. Este tipo de pruebas son fundamentales en trabajos de alto riesgo los desempeñados en el área de seguridad, por ejemplo: bomberos o militares, donde la capacidad de respuesta inmediata, el manejo del estrés y la toma de decisiones bajo presión son determinantes para prevenir accidentes, salvaguardar vidas y garantizar la eficacia operativa. Por ahora, las pruebas se realizan con un interfaz cerebro-computador (BCI) en un test entregado por la empresa Nesplora llamado IceCream test, donde se evalúa la capacidad de una persona para realizar tareas bajo presión, como reaccionan a aciertos o errores y que tan rápido pueden adaptarse a nuevas instrucciones. La evaluación y resultados obtenidos a partir del BCI y el EEG son calculadas con fórmulas basadas en la transformación rápida de Fourier y permiten determinar las competencias de una persona y son procesadas a través de una herramienta llamada NeuroBit.




Figura 1: Flujo de trabajo NeuroBit

Fuente: Elaboración de Yarko Bahamonde, equipo Neurobit

1.2 Definición del problema

El análisis actual de neurocompetencias en el contexto laboral, ejemplificado por las evaluaciones de Neuro4B a través del test IceCream y EEG portátil, se basa en un procesamiento de señales mediante métodos tradicionales (e.g., transformadas rápidas de Fourier). Este enfoque proporciona métricas iniciales de desempeño y reacción y presenta una limitación fundamental: depende de un modelo lineal y estático para la extracción de características de las señales EEG. La naturaleza de las señales de un EEG es intrínsecamente no lineal y estocástico [1], y, aunque la dependencia de un análisis a través de fórmulas basadas en transformaciones rápidas de Fourier es robusta, puede

descartar información sutil pero crucial para un análisis exacto de la complejidad emocional y cerebral, limitando la capacidad discriminativa y la especificidad en la evaluación de competencias.

Debido a esto, es necesario revisar el problema de la subutilización del potencial que ofrecen modelos de *machine learning* para evaluar neurocompetencias. En este estudio se revisará el potencial que poseen algoritmos de aprendizaje supervisado en el análisis y clasificación de estados mentales en EEG. Asimismo, se discutirán los retos asociados a la variabilidad intersujeto, la necesidad de bases de datos amplias y el equilibrio entre complejidad computacional y capacidad de generalización, elementos clave para su implementación en entornos de seguridad laboral de alto riesgo.

1.3 Justificación y alcance

La industria de la neurotecnología aplicada, particularmente en el ámbito de la seguridad laboral, depende de modelos rápidos y fiables para la evaluación de estados mentales. Actualmente, el servicio Neuro4B utiliza un sistema de fórmulas heurísticas lineales para traducir la potencia de las bandas de frecuencia EEG en ratios neurocognitivos (Estrés, Carga Cognitiva, Motivación, etc.). Si bien este enfoque proporciona métricas interpretables, se enfrenta a una limitación fundamental: la naturaleza estocástica, no lineal y altamente dinámica de la actividad cerebral [2].

Esta tesis se justifica en la hipótesis de que los modelos de Aprendizaje Automático (*Machine Learning*) pueden capturar las complejas interacciones y las no linealidades presentes en el patrón de potencia espectral de los EEG, superando las restricciones de los modelos lineales. El objetivo es validar si un enfoque basado en *Machine Learning* ofrece una mayor capacidad de generalización y robustez en la clasificación de los estados mentales (Positivo, Neutro, Negativo) y en el mapeo de los constructos Neuro4B (Alto/Bajo).

El alcance de este trabajo es exploratorio y comparativo. Se centra en el *benchmark* de diferentes arquitecturas para identificar la solución de *Machine Learning* óptima. La investigación no solo busca un modelo con alta precisión, sino también contrastar la validez de constructo de sus predicciones con el modelo teórico de Neuro4B, asegurando que cualquier mejora tecnológica mantenga la coherencia conceptual.

1.4 Objetivos

Se tiene como objetivo general **evaluar y comparar la eficacia de diversos algoritmos de aprendizaje supervisado en la detección y clasificación automática de patrones en señales de EEG, con el fin de mejorar la capacidad discriminativa y la especificidad diagnóstica en la evaluación de neurocompetencias laborales**. Los objetivos específicos son:

- Preprocesar las señales EEG adquiridas, aplicando técnicas de limpieza y descomposición en múltiples bandas de frecuencia.
- Implementar diferentes algoritmos de *machine learning* (e.g, SVM, *Random Forest*, redes neuronales) para la clasificación de estados emocionales y de carga cognitiva.
- Comparar el rendimiento de los modelos en métricas clave como precisión, sensibilidad y especificidad, utilizando validación cruzada.
- Contrastar los resultados obtenidos por los modelos de aprendizaje supervisado con los indicadores tradicionales basados en transformada rápida de Fourier y con las métricas del test IceCream.

- Identificar los algoritmos que ofrecen la mayor capacidad discriminativa y la mejor generalización para su potencial aplicación en entornos laborales de alto riesgo.

2 Estado del arte

Desde el inicio de este milenio ha existido un interés especial en la componente física de las emociones y su impacto en la cognición de las personas [3], tal como lo muestra R. J. Dolan en su artículo *Emotion, Cognition, and Behavior* remarca como las emociones influyen en el estado interno de una persona y que además "...influyen funciones como la toma de decisiones e interacciones interpersonales" [3].

Para estudiar estos fenómenos desde una perspectiva computacional, la investigación en reconocimiento de emociones mediante EEG ha dependido históricamente de datasets generados por estímulos visuales o multimodales. Referentes como AMIGOS [4] y las versiones más recientes de SEED [5] ejemplifican esta tendencia, donde la inducción emocional mediante material audiovisual ha constituido la base para la construcción de la mayoría de los corpus disponibles. DEAP sigue siendo ampliamente usado como *benchmark* por incluir señales periféricas complementarias. El corpus SEED y sus extensiones (SEED-IV, SEEDVII, etc.) han incorporado más categorías emocionales y modalidades (p. ej. seguimiento ocular), favoreciendo estudios multimodales y transferibilidad. Además, han surgido nuevos *datasets* que buscan emociones en interacciones más naturales (por ejemplo, EEG durante interfaces por voz), ampliando la ecología de los datos disponibles.

Una vez obtenidos los datos, el desafío principal reside en la extracción de características y la selección del modelo de clasificación adecuado. Como señalan Sanei y Chambers en su compendio sobre el procesamiento de señales, el análisis moderno de EEG ha pasado de métodos puramente estadísticos a enfoques de aprendizaje automático que requieren una etapa robusta de extracción de características (como la descomposición en bandas de frecuencia o el análisis de componentes principales) para manejar la alta dimensionalidad y la naturaleza no estacionaria de las señales [1].

En el ámbito del aprendizaje supervisado clásico, las Máquinas de Vectores de Soporte (SVM) y los Bosques Aleatorios (*Random Forest*) continúan siendo estándares de referencia debido a su eficacia en conjuntos de datos con ruido. Investigaciones recientes, como el análisis profundo realizado por Jha et al. sobre los datasets DEAP y SEED, han demostrado que las SVM, cuando se combinan con una extracción de características adecuada, pueden superar a modelos más complejos en términos de especificidad y tiempos de entrenamiento, ofreciendo una línea base sólida para la clasificación de emociones [5].

De manera similar, en aplicaciones clínicas y cognitivas, como el diagnóstico de TDAH en niños, un campo que comparte la necesidad de evaluar la atención y la carga cognitiva con el entorno de seguridad laboral. Algoritmos como *Random Forest* y regresión logística han mostrado una precisión prometedora al procesar características extraídas de señales EEG multicanal [6]. Sin embargo, la tendencia actual se inclina hacia el uso de *Deep Learning* para capturar dependencias temporales y espaciales complejas que los métodos lineales podrían pasar por alto. Un avance significativo en esta dirección es la red FBSTCNet (*Spatio-Temporal Convolutional Network*), propuesta recientemente, que integra características de potencia y conectividad cerebral. Este enfoque permite

decodificar estados emocionales con una precisión superior al aprovechar la estructura topológica del cerebro y la dinámica temporal de las señales, superando las limitaciones de los métodos tradicionales de extracción manual de características [7].

Esta dicotomía entre la interpretabilidad y eficiencia de los modelos clásicos (SVM, RF), frente a la capacidad de extracción automática de características de las redes neuronales profundas (CNN/RNN), define el panorama actual de la investigación en BCI y fundamenta la metodología comparativa de este estudio.

3 Marco teórico

El desarrollo de sistemas de evaluación neurocognitiva mediante electroencefalografía (EEG) requiere la convergencia de principios neurofisiológicos, el análisis de señales y la aplicación de técnicas de aprendizaje automático. Este capítulo establece los fundamentos teóricos necesarios para comprender la metodología y los resultados de la presente investigación.

3.1 Fundamentos de la Señal de Electroencefalografía (EEG)

La señal EEG representa la actividad eléctrica cerebral, la cual se origina principalmente a partir de la sumatoria sincrónica de los potenciales postsinápticos de las neuronas corticales. Dada su naturaleza no invasiva, la EEG es una herramienta fundamental en bioingeniería para el diagnóstico y el desarrollo de interfaces cerebro-computadora (BCI) [8].

3.2 Análisis Espectral y Bandas de Frecuencia

Para el análisis cuantitativo de la EEG, la señal temporal se descompone en el dominio de la frecuencia mediante la Transformada Rápida de Fourier (FFT), revelando la distribución de la potencia en bandas específicas. La potencia relativa de cada banda se correlaciona con distintos estados cognitivos y afectivos. Hay 5 bandas principales: la onda Delta, que está relacionada con el sueño profundo, procesos inconscientes o de reparación, la onda Theta, altamente presente en memoria de trabajo, somnolencia y estados de meditación, la onda Alpha, que coordina la relajación, atención pasiva y la disminución del procesamiento visual, la onda Beta, encargada principalmente de la concentración activa, procesamiento de información y ansiedad, y por último, la onda Gamma, encargada del Procesamiento de información de alto nivel e integración de información sensorial [9].

3.3 El modelo dimensional de Lövhheim

La clasificación de emociones en categorías Positiva, Neutra y Negativa se basa en el modelo dimensional de emociones propuesto por Lövhheim [10]. Este modelo postula que las emociones pueden ser descritas en un espacio tridimensional definido por los niveles de los neurotransmisores Dopamina (D), Noradrenalina (NA) y Serotonina (S). La valencia Positiva se asocia con altos niveles de Dopamina y/o Noradrenalina (e.g., *Interés, Alegría*). La valencia Negativa se relaciona con altos niveles de Serotonina (e.g., *Angustia, Miedo*) y el estado Neutro representa una activación basal o un equilibrio entre los tres ejes, sirviendo como *baseline* para el estudio. El *Ground Truth* del *dataset* utilizado, derivado de este modelo, permite entrenar a los algoritmos de *Machine*

Learning para mapear la potencia espectral EEG hacia esta representación tridimensional de la emoción.

3.4 Perceptrón multicapa (MLP)

El MLP es el algoritmo central en esta investigación debido a su arquitectura simple pero poderosa. Es una red neuronal artificial de tipo *feedforward* capaz de aproximar cualquier función continua gracias a sus capas ocultas y funciones de activación no lineales (como ReLU). La optimización se realiza a través del algoritmo de *backpropagation* [11]. La elección del MLP se justifica por su eficacia probada en la captura de patrones sutiles y no lineales en el dominio de la frecuencia EEG [12].

3.5 Modelos para *benchmark*

Para el análisis comparativo, se incluyeron otros tres modelos esenciales:

1. **Support Vector Machine (SVM):** Utiliza funciones *kernel* (e.g., RBF) para mapear los datos a un espacio dimensional donde la separación lineal es posible. Es un *benchmark* robusto en la clasificación de datos biomédicos [13].
2. **Random Forest (RF):** Un método de *ensemble* que combina múltiples árboles de decisión, lo que reduce la varianza y proporciona gran estabilidad. Es ideal para establecer una línea base de alto rendimiento.
3. **Redes Neuronales Convolucionales (CNN 1D):** Las CNN son modelos de *Deep Learning* diseñados para la extracción jerárquica de características de datos topológicos, su inclusión permite evaluar si pueden encontrar patrones significativos en el vector unidimensional de potencia espectral, contrastando su eficiencia con el MLP.

3.6 Regresión vs Clasificación

En el ámbito del *Machine Learning* supervisado, la naturaleza del problema de investigación queda definida por el tipo de variable objetivo que se desea predecir. En este estudio, se exploraron ambos paradigmas para determinar cuál se ajusta mejor a la volatilidad de las señales electroencefalográficas (EEG).

La clasificación tiene como objetivo asignar una instancia de entrada a una de varias categorías discretas o "clases". El modelo intenta aprender fronteras de decisión que separen los datos en grupos definidos. La regresión busca predecir un valor numérico continuo. En lugar de asignar una etiqueta, el modelo estima una cantidad en una escala real infinita o dentro de un rango específico.

Métricas de clasificación

En clasificación, el éxito se basa en si la predicción coincide exactamente con la etiqueta real, por ejemplo: la precisión (*accuracy*) mide la fracción de predicciones correctas sobre el total, el AUC evalúa la capacidad del modelo para distinguir entre clases, independientemente del umbral de decisión.

Sin embargo, No sirven para regresión porque en un valor continuo es casi imposible acertar el número exacto.

Métricas de regresión

En regresión, el éxito se mide por qué tan cerca está la predicción del valor real, el error cuadrático medio (MSE) Promedia los cuadrados de las diferencias entre la predicción y el valor real y penaliza fuertemente las desviaciones grandes. Estas métricas no sirven para la clasificación de etiquetas debido a que no se puede decir que el error entre la etiqueta A y la etiqueta B sea de n unidades

4 Métricas y neurocompetencias de Neuro4B

Neuro4B al ser una empresa dedicada la medición de neurocompetencias y emociones a través de pruebas, hace uso de fórmulas para garantizar la objetividad al catalogar datos y ofrecer resultados. Este estudio se basa en 12 formulas entregadas por la empresa que se usan a nivel comercial e internacional, además de ser formulas aceptadas en el mundo académico [13] [14] [15], la siguiente tabla muestra que variables se calculan, como se deben leer a la hora de interpretar los datos:

Tabla 1: Tabla de métricas

Fuente: Neuro4B

Variable	Bandas Cerebrales Involucradas	Fórmula
Atención	Beta baja, Beta alta, Theta, Alpha	$\frac{\beta_{baja} + \beta_{alta}}{\theta + \alpha}$
Meditación	Alpha, Beta alta, Gamma	$\frac{\alpha}{\beta_{alta} + \gamma}$
Carga Cognitiva	Theta, Beta, Alpha	$\frac{\theta + \beta}{\alpha}$
Estrés	Beta alta, Alpha, Theta	$\frac{\beta_{alta}}{\alpha + \theta}$
Activación General	Beta, Gamma, Delta, Theta	$\frac{\beta + \gamma}{\delta + \theta}$
Fatiga Mental	Theta, Beta	$\frac{\theta}{\beta}$
Alegría	Beta, Gamma, Theta, Delta, Alpha	$\frac{\beta + \gamma}{\theta + \delta}$
Tristeza	Theta, Delta, Beta	$\frac{\theta + \delta}{\beta}$
Motivación	Beta, Alpha, Theta	$\frac{\beta}{\alpha + \theta}$
Desagrado	Theta, Gamma baja, Alpha	$\frac{\theta + \gamma_{baja}}{\alpha}$
Rabia	Beta alta, Gamma, Alpha, Theta	$\frac{\beta_{alta} + \gamma}{\alpha + \theta}$

5 Metodología

La metodología propuesta se compone de cuatro fases principales, aplicadas de manera uniforme a todos los modelos de *machine learning* evaluados:

1. Preprocesamiento y generación de etiquetas,
2. Selección de modelos,
3. Entrenamiento y clasificación,
4. Evaluación final y contraste.

La metodología es independiente del origen del *dataset*, siempre que el conjunto de datos permita reconstruir información espectral suficiente para aplicar las fórmulas de Neuro4B.

5.1 Fuente de Datos y Etiquetado

Se utilizará el *dataset* "eeg-brainwave-dataset-feeling-emotions" [16] de la plataforma Kaggle. Este conjunto de datos, aunque no es un *benchmark* estándar para la cognición, provee un *Ground Truth* emocional de valencia discreta:

- Etiquetas Primarias ($Y_{emoción}$): Las 3 categorías emocionales POSITIVA, NEUTRAL y NEGATIVA. La clasificación exitosa de estas etiquetas constituye la Tarea Primaria de los modelos de Machine Learning.

5.2 Preprocesamiento estándar y etiquetado sintético

Dado que el *dataset* utilizado no contiene señales EEG crudas, sino atributos espectrales previamente calculados (principalmente coeficientes *FFT*), el preprocesamiento se basa en la reconstrucción de las bandas de frecuencia necesarias para aplicar las métricas de Neuro4B.

A partir de los atributos *fff_N_ch*, se integran los coeficientes espectrales correspondientes a las siguientes 8 bandas, descritas en la Tabla 2 del documento:

Tabla 2: Atributos creados

Fuente: Elaboración propia

ATRIBUTO	DESCRIPCIÓN
DELTA (δ)	Potencia en la banda de 0.5 – 4 Hz
THETA (θ)	Potencia en la banda de 5 – 8 Hz

ALPHA BAJA (α_{baja})	Potencia en la banda de 9 – 11 Hz
ALPHA ALTA (α_{alta})	Potencia en la banda de 12 – 13 Hz
BETA BAJA (β_{baja})	Potencia en la banda de 14 – 20 Hz
BETA ALTA (β_{alta})	Potencia en la banda de 21 – 30 Hz
GAMMA (γ_{baja})	Potencia en la banda de 31 – 70 Hz
GAMMA (γ_{alta})	Potencia en la banda > 70 Hz

Por lo tanto, el vector final de entrada queda definido como:

$$X = \{\delta, \theta, \alpha_{baja}, \alpha_{alta}, \beta_{baja}, \beta_{alta}, \gamma_{baja}, \gamma_{alta}\}$$

Este vector asegura que el trabajo de entrenamiento y clasificación simulen el entorno de Neuro4B.

i Generación de etiquetas Neuro4B (etiquetado sintético)

La meta de predecir o correlacionar las 12 Variables Cognitivas y Emocionales definidas por Neuro4B (e. g., Atención, Carga Cognitiva, Tristeza, etc.) se cumplirá mediante la generación de etiquetas sintéticas a partir del *Dataset* obtenido.

- Generación de $Y_{Neuro4B}$: Una vez extraído el vector de entrada, las Fórmulas de Ratio de Neuro4B (basadas en la Transformada Rápida de Fourier) se aplicarán a las características espectrales del *Dataset*.
- Formato de Etiqueta: Esto resulta en 12 Ratios Continuos, que se utilizarán directamente en la Fase 4 para el análisis de correlación y perfilamiento. Además, estos ratios serán transformados en 12 Etiquetas Binarias mediante la aplicación de un umbral estadístico (basado en la desviación estándar o cuartiles del *dataset*), las cuales definen la Tarea Secundaria de clasificación.

5.3 Selección y preparación de modelos

Esta fase se centra en la selección rigurosa de las arquitecturas de *Machine Learning* y la formalización de las tareas experimentales, asegurando una línea base de comparación sólida antes del proceso de entrenamiento.

i Selección de arquitecturas

Se ha optado por un contraste metodológico que incluye modelos clásicos de referencia y arquitecturas de *Deep Learning*, para evaluar tanto la eficiencia de la extracción manual

de características como la capacidad de las redes profundas para aprender representaciones:

- **Modelos Clásicos Interpretables:** Se seleccionan las Máquinas de Vectores de Soporte (SVM) y los Bosques Aleatorios (Random Forest, RF). Estos servirán como línea base debido a su probada eficacia en la clasificación de datos de EEG de alta dimensión [12] y su capacidad para ofrecer cierta interpretabilidad sobre la importancia de las características espectrales [2].
- **Modelo de *Deep Learning*:** Se empleará una arquitectura basada en Redes Neuronales Convolucionales o Recurrentes (CNN/RNN). Este enfoque se incluye para explorar si la extracción automática de características espaciales o temporales supera el rendimiento logrado por la extracción manual de las 8 bandas espectrales, tal como se justifica en el Estado del Arte.

ii Definición de tareas de clasificación

El entrenamiento de los modelos se someterá a un esquema de Doble Propósito para abordar los objetivos de la tesina:

Tabla 3: Tareas de clasificación

Fuente: Elaboración propia

TAREA	OBJETIVO Y	TIPO DE CLASIFICACIÓN
PRIMARIA	$Y_{emocion}$: POSITIVA, NEUTRAL, NEGATIVA	Multiclase (3 clases)
SECUNDARIA	$Y_{Neuro4b}$: Etiquetas basadas en las fórmulas entregadas	Multi-Label (12 métricas)

iii Configuración Inicial y Esquema de Validación

El vector de entrada para todos los modelos será el vector de 8 datos, garantizando que el modelo no tenga acceso a los ratios de Neuro4B como *input* (evitando así el *data leakage*), los hiperparámetros seleccionados de cada modelo serán especificados más adelante.

5.4 Entrenamiento y clasificación final

Los modelos seleccionados serán entrenados y se guardarán resultados y métricas para su posterior evaluación.

5.5 Evaluación y contraste

Esta fase finaliza el estudio con una evaluación rigurosa del rendimiento de los modelos de *Machine Learning* y un contraste directo con los indicadores tradicionales de Neuro4B, cumpliendo el requisito de establecer una correlación de constructo/concurrente. La evaluación se centrará en la comparación directa de la Precisión de Clasificación para cada una de las 12 variables. Se comparará la precisión de las clasificaciones binarias generadas por los modelos de *Machine Learning* (SVM, RF, CNN/RNN) contra la precisión de la Clasificación Binaria basada únicamente en las Fórmulas de Neuro4B usando el mismo umbral de binarización. Dado que las variables de Neuro4B pueden ser tratadas como *ratios* continuos o estados binarios (Alto/Bajo) también se analizarán los resultados bajo un paradigma de regresión.

Se empleará el Coeficiente de Correlación de Pearson para evaluar la alineación continua de los modelos de ML con los indicadores de referencia, lo cual aborda el factor corrector por utilización y la correlación de constructo/concurrente.

Finalmente, se identificará el algoritmo (SVM, *Random Forest*, CNN/RNN o MLP) que demuestre el mejor equilibrio entre capacidad discriminativa (alta Precisión/AUC) y especificidad diagnóstica/generalización (alta Sensibilidad/Especificidad y robusto en la validación cruzada inter-sujeto) para su potencial integración en entornos laborales de alto riesgo.

6 Set de datos

El set de datos utilizado es proporcionado por Jordan J. Bird et al. con el nombre "*eeg-brainwave-dataset-feeling-emotions*", donde Jordan y sus colaboradores aplicaron su propia extracción estadística de datos y presenta sus resultados como un *dataset* de libre uso [17] [16].

Este set de datos presenta una estructura de alta dimensionalidad (2132, 2549), esto quiere decir que el set contiene 2132 instancias y 2549 atributos. Los atributos no consisten en una señal cruda de voltajes, sino que es una concatenación de atributos estadísticos y espectrales pre-calculados. Estos datos se pueden resumir en 3 categorías principales:

- *mean_X_ch*: Aproximadamente 100 atributos, son atributos estadísticos de amplitud promediada, son un complemento a características espectrales.
- *fff_N_ch*: Aproximadamente 2400 atributos, corresponden a los coeficientes de transformadas rápidas de Fourier, estas son usadas para la reconstrucción de las bandas necesarias para aplicar los cálculos de ratio de Neuro4B (ver tabla 2)
- *Label*: La variable objetivo $Y_{emoción}$, está separada en 3 categorías: POSITIVA, NEUTRAL y NEGATIVA que serán usadas como "*ground of truth*".

La clasificación de cada instancia como POSITIVA o NEGATIVA están basadas en el análisis de 4 electrodos (TP9, AF7, AF8, TP10) y son catalogadas según la clasificación de Lövheim de las emociones [10]. Las emociones consideradas y su categorización están descritas en la tabla 4. Es menester notar que en los trabajos de Jordan J. Bird las instancias definidas como NEUTRAL fueron extraídas mientras los participantes no estaban expuestos a ningún estímulo externo definido por el experimento, por lo que es

posible que instancias neutrales reflejen el comportamiento de un sistema NEGATIVO o POSITIVO.

Tabla 4: Tabla de categorías Lövheim, con categorización

Fuente: Jordan J. Bird et al., traducción propia

CATEGORÍA EMOCIONAL	EMOCIÓN/TIPO
A	Vergüenza (Negativa), Humillación (Negativa)
B	Desprecio (Negativa), Disgusto (Negativa)
C	Miedo (Negativa), Terror (Negativa)
D	Gozo (Positiva), Felicidad (Positiva)
E	Angustia (Negativa), Sufrimiento (Negativa)
F	Sorpresa (Falta de dopamina) (Negativa)
G	Furia (Negativa), Rabia (Negativa)
H	Interés (Positiva), Emoción (Positiva)

A partir de este conjunto de datos se construye el vector de entrada X utilizado para el entrenamiento de los algoritmos de aprendizaje. Este vector se obtiene mediante la interpretación y combinación de los atributos fff_N_ch , lo que produce un total de ocho características que corresponden a las bandas de frecuencia definidas en las fórmulas proporcionadas por Neuro4B.

6.1 Binarización

El objetivo es crear un conjunto de etiquetas binarias que simulen la decisión de si un estado mental se encuentra en un nivel Alto o Bajo. Un valor continuo (e.g., Activación General = 1.5) no es una etiqueta directa para un clasificador; por lo tanto, se requiere la definición de un umbral heurístico.

La mediana, o el percentil 50, es un estimador de tendencia central robusto, ya que un valor extremo no altera su valor: Al usar la mediana para binarizar en este caso aprovechamos las siguientes ventajas:

1. Definición de Etiquetas: Las etiquetas son fácilmente identificadas en Alto y Bajo con este método.
2. Balanceo del *dataset*: Usar la mediana asegura que haya aproximadamente igual cantidad de datos Altos y Bajos para cada indicador.
3. Incertidumbre en la distribución: En la ausencia de un análisis exhaustivo que demuestre que los ratios de Neuro4B siguen una distribución normal (gaussiana), la mediana es la elección metodológica más segura.
4. No se asume normalidad: El supuesto de que la media es el centro ideal solo se cumple perfectamente en distribuciones simétricas como la Normal, pero en sistemas biológicos (como la naturaleza de estudio) rara vez se cumple [8].

Como mecanismo de etiquetado, se sigue la siguiente regla: Para cada instancia i y cada una de las 12 variables de Neuro4B, la etiqueta binaria $Y_{neuro4b}^{(i)}$ se define como:

$$Y_{neuro4b}^{(i)} = \begin{cases} 1 & \text{si } ratio_i > mediana(ratio) \\ 0 & \text{si } ratio_i \leq mediana(ratio) \end{cases}$$

7 Resultados experimentales

Este estudio evaluó la capacidad de diversos algoritmos de aprendizaje automático para mapear señales EEG procesadas en ocho bandas de frecuencia hacia dos tipos de objetivos: la clasificación emocional primaria ($Y_{emocion}$) y predicciones secundarias asociadas a las doce métricas Neuro4B, tanto en formato binario como en formato continuo.

Para ello se configuró un pipeline metodológico que incluyó ingeniería espectral de características, etiquetado sintético de las métricas Neuro4B, validación cruzada estratificada y análisis detallado del constructo. Los resultados muestran un desempeño notablemente alto en tareas de clasificación emocional y clasificación binaria de las métricas Neuro4B, especialmente en redes neuronales y modelos SVM. Sin embargo, los resultados de regresión continua revelan una alta complejidad para ajustar los valores exactos de los ratios, lo que sugiere que dichas métricas son más adecuadas como constructos discretizados.

7.1 Configuración experimental

Cada algoritmo evaluado fue configurado con hiperparámetros cuidadosamente seleccionados, optimizados para garantizar estabilidad en validación cruzada:

Tabla 5: Hiperparametros definidos

Fuente: Elaboración propia

ALGORITMO	CONFIGURACIÓN	COMENTARIO
RANDOM FOREST	<code>n_estimators = 100</code>	Permite robustez y baja varianza

SUPPORT VECTOR MACHINE	<pre>kernel = 'rbf' C = 1.0 probability = True #Regresión epsilon = 0.1 #Regresión</pre>	Buen equilibrio entre margen y flexibilidad
MLP NEURONAL	<pre>hidden_layer_sizes = (100, 50) activation = 'relu' max_iter = 800 solver = 'adam'</pre>	Arquitectura útil para patrones no lineales
CNN 1D	Descrito en la siguiente tabla para mayor claridad	Buena con señales estructuradas

Tabla 6: Hiperparámetros CNN 1D

Fuente: Elaboración propia

TIPO DE CAPA	FORMA DEL RETORNO	PARÁMETROS
CONV1D_7 (CONV1D)	(None, 6, 32)	128
MAX_POOLING1D_7 (MAXPOOLING1D)	(None, 6, 32)	0
DROPOUT_7 (DROPOUT)	(None, 6, 32)	0
FLATTEN_7 (FLATTEN)	(None, 192)	0
DENSE_14 (DENSE)	(None, 50)	9650
DENSE_15 (DENSE)	(None, 12)	612

A continuación, se presentan y discuten los resultados obtenidos tras la ejecución de la metodología propuesta, utilizando un esquema de validación cruzada estratificada de 5 pliegues (*Stratified 5-fold Cross-Validation*) para garantizar la robustez estadística de las métricas.

7.2 Resultados de la Tarea Primaria

Los modelos evaluados bajo un esquema *5-fold Stratified Cross-Validation* demostraron desempeños consistentemente altos. El modelo con mejor rendimiento fue MLP Neuronal, alcanzando una precisión máxima de 0.965 en su mejor *fold*, seguido de *Random Forest*, SVM y CNN 1D. Los modelos evaluados bajo un esquema *5-fold Stratified Cross-Validation* demostraron desempeños consistentemente altos. El modelo con mejor rendimiento fue MLP Neuronal, alcanzando una precisión máxima de 0.965 en su mejor *fold*, seguido de *Random Forest*, SVM y CNN 1D. La siguiente tabla resume el rendimiento de cada algoritmo, mostrando el promedio y desviación estándar de sus métricas.

Tabla 7: Resultados (P/N/N)

Fuente: Elaboración propia

	ACCURACY	F1-SCORE	JACCARD
RANDOM FOREST	0.946 ± 0.011	0.946 ± 0.010	0.899
SVM	0.941 ± 0.007	0.941 ± 0.007	0.891
MLP NEURONAL	0.956 ± 0.012	0.956 ± 0.012	0.917
CNN 1D	0.944 ± 0.010	0.944 ± 0.010	0.896

En general, la estabilidad de los modelos es alta, con desviaciones estándar bajas que indican consistencia entre pliegues. Se muestra que el mejor modelo MLP Neuronal (que presentó el mejor rendimiento, alrededor del 97%) no solo acierta, sino que lo hace de forma robusta entre clases emocionales, y es seguido muy de cerca por los demás algoritmos.

Este margen de diferencia, aunque sutil, es estadísticamente relevante. Sugiere que la arquitectura de red neuronal densa posee una capacidad superior para modelar las interacciones no lineales complejas existentes entre las 8 bandas de frecuencia espectral. A diferencia de las SVM (especialmente con *kernels* lineales o RBF estándar) que buscan hiperplanos de separación, el MLP logra construir una representación interna de las características que captura mejor la naturaleza estocástica de la señal EEG procesada. Es importante notar que la CNN 1D obtuvo un rendimiento ligeramente inferior al del MLP (93.9%). Esto podría atribuirse a que el vector de entrada ya consiste en características espectrales pre-procesadas (potencia por banda), lo que limita la capacidad de la red convolucional para extraer nuevos patrones espaciales o temporales locales, una ventaja que suele explotar mejor sobre señales crudas.




Figura 2: Matriz de confusión emocional

Fuente: Elaboración propia

La robustez del modelo MLP se confirma al observar su Matriz de Confusión en el mejor pliegue, donde demostró una capacidad casi simétrica para distinguir entre estados, minimizando los falsos positivos entre clases opuestas (Positivo vs. Negativo).

7.3 Resultados de la Tarea Secundaria

Al evaluar la capacidad de los modelos para predecir los 12 constructos de Neuro4B (e.g., Atención, Estrés, Carga Cognitiva) bajo un esquema de clasificación binaria, los resultados fueron contundentes. Nuevamente, el MLP Neuronal lideró el desempeño con un Mean AUC (Área Bajo la Curva) casi perfecto de 0.997 (± 0.001) y una precisión global del 97.3%. Los resultados binarios indican que, aunque los ratios continuos pudieran ser difíciles de predecir exactamente, sus versiones discretizadas con la mediana contienen señales más estables y cognitivamente significativas para los modelos. En otras palabras, el modelo logra mapear adecuadamente los constructos teóricos hacia patrones empíricos aprendidos.

Tabla 8: Resultados (Etiquetas binarias)

Fuente: Elaboración propia

MODELO	MEAN ACCURACY	JACCARD	MEAN AUC
RANDOM FOREST	0.917 ± 0.005	0.765 ± 0.016	0.975 ± 0.003
SVM RBF	0.895 ± 0.006	0.728 ± 0.015	0.965 ± 0.003
MLP NEURONAL	0.973 ± 0.002	0.896 ± 0.011	0.997 ± 0.001
CNN 1D	0.932 ± 0.005	0.798 ± 0.010	0.985 ± 0.002

Este hallazgo es crítico para la validación de la metodología propuesta. Un AUC tan cercano a 1.0 indica que, si bien las señales EEG son ruidosas, la información espectral contenida en las bandas de frecuencia es suficiente para discriminar con altísima fiabilidad si un sujeto se encuentra por encima o por debajo de la mediana poblacional en cada constructo.

Comparativamente, modelos como Random Forest (AUC 0.975) y SVM (AUC 0.965), aunque efectivos, mostraron una mayor dispersión en sus predicciones. El éxito rotundo del MLP en esta tarea confirma que los ratios definidos por Neuro4B poseen una estructura latente que es altamente predecible mediante aprendizaje supervisado, siempre y cuando el problema se plantee como una clasificación dicotómica, los diagramas de matriz de confusión correspondientes a cada etiqueta binaria, clasificados por el mejor algoritmo (MLP), se presentan en la sección de Anexos. No obstante, el escenario cambia drásticamente cuando los modelos intentan predecir los valores continuos de los mismos indicadores. Los modelos clásicos muestran inestabilidad sustancial y valores negativos de la métrica R^2 , lo cual indica que no generalizan adecuadamente debido a la naturaleza no lineal y altamente ruidosa de las métricas [8]. El único modelo con un desempeño marginalmente aceptable fue SVM, aunque con valores aún reducidos:

Tabla 9: Resultados (Ratios Neuro4B)

Fuente: Elaboración propia

MODELO	R2 SCORE	MSE
RANDOM FOREST REG.	-19.702 ± 29.955	2108.486 ± 2185.386
SVM REG. (SVR)	0.041 ± 0.029	1186.185 ± 2005.480
MLP REGRESSOR	-17.385 ± 27.989	1583.603 ± 1893.666
CNN 1D REG.	-0.588 ± 0.950	1194.113 ± 2002.856

El análisis separado por ratio muestra que algunos indicadores aislados, como alegría o activación general, pueden modelarse con mayor precisión, pero en general los 12 constructos presentan no linealidades y distribuciones altamente irregulares que dificultan su regresión directa.

Tabla 10: Análisis predicción SVM

Fuente: Elaboración propia

VARIABLE	R ² SCORE	MSE
ATENCIÓN	0.039	1.871
MEDITACIÓN	-0.001	6044.991
CARGA COGNITIVA	0.002	421.105
ESTRÉS	0.097	0.441
ACTIVACIÓN GENERAL	0.328	4.640
FATIGA MENTAL	-0.003	594.358
ALEGRIA_RATIO	0.328	4.640
TRISTEZA_RATIO	-0.005	503.346
MOTIVACION_RATIO	0.039	1.871
DESAGRADO_RATIO	0.004	152.903
RABIA_RATIO	0.102	1.662
COMPROMISO_COGNITIVO_RATIO	0.039	1.871

7.4 Correlación de etiquetas originales y métricas de Neuro4B

El análisis de constructo contrastó los perfiles teóricos (heurísticos) con los perfiles generados por el modelo MLP para las predicciones correctas del mejor fold, el contraste está basado en la correlación de Pearson ya que evalúa relación lineal entre dos mediciones y ve si son coherentes entre sí y es un estándar de medición en psicometrías y neurociencias [18].

Tabla 11: Correlación de pearson Lövheim vs Neuro4B

Fuente: Elaboración propia

EMOCIÓN	CORRELACIÓN DE PEARSON
NEGATIVE	0.737
NEUTRAL	0.995
POSITIVE	0.340

El análisis de correlación de Pearson (ρ) entre los perfiles teóricos (heurísticos) y los perfiles aprendidos por el modelo MLP arrojó luz sobre la validez interna de las fórmulas de Neuro4B.

Se encontró una correlación casi perfecta ($\rho = 0.995$) para el estado NEUTRAL y una correlación fuerte ($\rho = 0.737$) para el estado NEGATIVE. Esto valida que el modelo de aprendizaje automático y las fórmulas teóricas están buscando lo mismo: los patrones de activación cerebral asociados a la calma o al estrés negativo son consistentes y robustos en ambas aproximaciones.

Sin embargo, se detectó una anomalía significativa en la categoría POSITIVE, donde la correlación cayó drásticamente a $\rho = 0.340$. Este desacoplamiento sugiere que el perfil de ratios que Neuro4B asocia teóricamente con la "Alegría" o "Positividad" difiere de los

patrones que el modelo identifica empíricamente en sujetos que reportan emociones positivas (basado en el *Ground Truth* presentado por Jordan J. Bird).

Esta baja correlación podría explicarse por la naturaleza difusa de la valencia positiva en señales fisiológicas [19], la cual a menudo se solapa con estados de baja activación [20], o bien podría indicar la necesidad de recalibrar las fórmulas de ratios asociadas a emociones positivas para mejorar su especificidad en futuras versiones del sistema NeuroBit. Los siguientes tres diagramas muestran la comparación de presencia de cada métrica dentro de las etiquetas POSITIVE, NEUTRAL y NEGATIVE respectivamente.




Figura 3: Comparación de perfiles POSITIVE

Fuente: Elaboración propia




Figura 4: Comparación de perfiles NEUTRAL

Fuente: Elaboración propia




Figura 5: Comparación de perfiles NEGATIVE

Fuente: Elaboración propia

8 Discusión

Los resultados del estudio destacan varias observaciones clave. En primer lugar, las emociones pueden clasificarse con notable precisión a partir de solo ocho bandas espectrales reconstruidas. Este hallazgo confirma que la información espectral contenida en transformadas rápidas de Fourier es suficiente para capturar patrones afectivos robustos.

En segundo lugar, las métricas Neuro4B funcionan significativamente mejor cuando se discretizan en etiquetas binarias. En formato continuo, las métricas exhiben alta variabilidad, lo que dificulta la regresión precisa. No obstante, su estructura dicotómica (alto/bajo) revela una codificación más estable que puede ser explotada eficazmente por algoritmos de clasificación.

En tercer lugar, el análisis de constructo demuestra que los modelos no solo clasifican correctamente, sino que reconstruyen patrones funcionales coherentes con las competencias neurocognitivas esperadas. Esto fortalece la validez interpretativa del enfoque Neuro4B.

Finalmente, aunque los modelos avanzados como CNN o MLP destacan en tareas de clasificación, su ventaja se reduce en la regresión. Esto sugiere que las métricas Neuro4B, por diseño, no están optimizadas para ser tratadas como variables continuas precisas, sino como indicadores discretos de estados cognitivos. En conjunto, los resultados indican que el enfoque y metodología propuestas no solo replican los patrones Neuro4B, sino que además permite evaluar la coherencia interna de dichos constructos en un escenario empírico.

En la regresión y clasificación de alegría y activación general

En los resultados obtenidos se observa un fenómeno paradójico que requiere un análisis detallado: los constructos de Alegría y Activación General presentan la mayor capacidad de modelamiento matemático, pero al mismo tiempo se asocian con el estado mental que exhibe la mayor dificultad de clasificación y la menor validez de constructo.

Se postula que la raíz de esta paradoja reside en que la Activación no es exclusiva del estado Positivo. Es altamente probable que el estado Neutral y contenga niveles significativos de activación cerebral debido a procesos cognitivos internos, ansiedad situacional o ruido biológico. En consecuencia, si la activación está presente tanto en el estado Neutral como en el Positivo, los perfiles neurofisiológicos de ambas etiquetas se vuelven indistinguibles para el algoritmo.

Asimismo, se considera que la metodología de binarización por mediana desempeña un papel crítico en la generación de esta paradoja. Al utilizar el percentil 50 como umbral, se eliminan las incertidumbres propias de la distribución biológica y se fuerza la construcción de un dataset perfectamente balanceado. La contradicción emerge al contrastar este éxito matemático con la validez de las categorías emocionales evaluadas en la Tarea Primaria. Mientras que el estado Neutral presenta una correlación de Pearson casi perfecta entre el perfil teórico y el perfil aprendido, el estado Positivo (al que pertenecen los constructos de Alegría y Activación) muestra un desacoplamiento drástico, con una correlación que desciende hasta 0.340.

En definitiva, la excelente capacidad del modelo para modelar los constructos de Alegría y Activación es una "ilusión de precisión" generada por la consistencia de la fórmula matemática y la binarización forzada. El error de clasificación en el estado Neutral confirma que estos ratios no son selectivos: la presencia de activación en estados basales contamina la muestra, impidiendo que el modelo encuentre una frontera clara entre la neutralidad y la positividad emocional.

9 Limitaciones del trabajo encontradas

La tercera fase experimental reveló una gran limitación. Al intentar predecir el valor numérico exacto y continuo de los ratios Neuro4B, todos los modelos evaluados fracasaron en generalizar patrones útiles. El modelo SVM, que obtuvo el "mejor" desempeño, apenas alcanzó un coeficiente de determinación (R^2) promedio de 0.041, lo que implica que el modelo solo es capaz de explicar un 4.1% de la varianza de los datos. Más revelador aún es el rendimiento negativo de modelos complejos como el MLP Neuronal y *Random Forest* ($R^2 < 0$). Un R^2 negativo indica que estos modelos, al intentar ajustarse al ruido de entrenamiento, terminan realizando predicciones peores que una simple línea horizontal en la media de los datos.

Este colapso en la regresión no debe interpretarse como un fallo de los algoritmos, sino como una característica de los datos: sugiere que los valores continuos de los ratios Neuro4B contienen una cantidad significativa de ruido de alta frecuencia o variabilidad estocástica que no tiene correlación biológica directa con las bandas de potencia de entrada. Esto refuerza la conclusión de que la binarización no es solo una simplificación útil, sino un paso de filtrado necesario para eliminar el ruido y extraer la señal cognitiva real subyacente.

Debido a que el *dataset* utilizado en este trabajo presenta cada instancia de forma aleatoria o sin correlación temporal, se descartó usar arquitecturas de *machine learning* avanzadas más profundas como CNN 2D o arquitecturas recurrentes con modelos híbridos espectro-temporales (como *transformers*) [7], limitando el alcance comparativos de las técnicas de aprendizaje seleccionadas. Además, la validación de los resultados, al estar basados en un solo *dataset*, no evalúa una generalización inter-sujeto real.

10 Conclusiones y trabajo futuro

Este trabajo exploratorio evaluó la eficacia y estabilidad de diversos modelos de aprendizaje supervisado en el mapeo de patrones espectrales EEG hacia las métricas neurocognitivas y emocionales definidas por la empresa Neuro4B. Los resultados obtenidos a través de la validación cruzada estratificada permitieron cumplir con el objetivo general y la totalidad de los objetivos específicos planteados mientras que aseguraba una robustez estadística de los resultados.

El análisis comparativo, reforzado por el uso de *k-fold Cross-Validation*, arrojó una serie de hallazgos que reafirman la viabilidad de utilizar modelos de *Machine Learning* para la evaluación automatizada de estados mentales. A continuación, se resumen las principales conclusiones, alineadas con los objetivos específicos del estudio:

1. Se confirmó la eficacia de la ingeniería de características espectrales (las 8 bandas de potencia) como vector de entrada robusto para tareas de clasificación de estados mentales.
2. El MLP Neuronal fue identificado como el algoritmo con la mayor capacidad discriminativa y estabilidad, superando a las SVM, Random Forest y la arquitectura CNN 1D.
3. La comparación de rendimiento demostró que las métricas Neuro4B son altamente predecibles si se tratan como variables discretas (Alto/Bajo), validando la metodología de binarización para fines de seguridad laboral y alerta.
4. Se logró contrastar los resultados del *Machine Learning* con los indicadores tradicionales de Neuro4B (Correlación de Constructo), lo que confirmó la alta validez de constructo para los estados NEUTRAL ($\rho = 0.995$) y NEGATIVE ($\rho = 0.737$).
5. El estudio identificó una limitación crítica en la predicción continua de los ratios, donde todos los modelos de regresión fracasaron sistemáticamente (R^2 negativos para la mayoría), lo que sugiere que los valores continuos de Neuro4B están sujetos a un ruido estocástico intrínseco que solo la binarización logra mitigar.

En resumen, este estudio valida la implementación de modelos de *Machine Learning* basados en MLP como una alternativa robusta y más precisa a las fórmulas heurísticas tradicionales para la clasificación de estados mentales en el contexto de Neuro4B, cumpliendo con el objetivo de identificar algoritmos con el mejor equilibrio entre precisión y generalización.

Con base en las limitaciones metodológicas y los hallazgos críticos del estudio, se proponen las siguientes líneas de investigación para consolidar y expandir la aplicación de *Machine Learning* en la evaluación de neurocompetencias incluyendo los siguientes flujos de trabajo.

Se ve como trabajo futuro inmediato explorar una metodología de binarización basada en aprendizaje no supervisado mediante *k-means* para cada métrica Neuro4B permitiendo que la frontera entre ALTO y BAJO emergiera directamente de la estructura de los datos. Este enfoque evita imponer un umbral rígido y puede capturar distribuciones multimodales propias de la actividad EEG y es posible que permita una mejor evaluación y generalización inter-sujeto, debido a que no todas las personas tienen el mismo umbral para decidir si se alguna métrica es alta o baja en determinado momento.

Además, se espera poder tener acceso a mejores *dataset* como AMIGOS [4] o DEAP [5] que contienen la "señal cruda" de EEG y están ordenados de forma continua temporalmente, permitiendo el uso de técnicas de aprendizaje recurrentes como LSMT o una reinterpretación de FBSTCnet para realizar análisis más complejos y que puedan arrojar más luz sobre ciertas métricas o temas, sin olvidar que es imperativo probar estos resultados en un set de datos creados por Neuro4B basados en la prueba IceCream de Nesplora, lo que permitirá la integración de *machine learning* en el sistema NeuroBit y permitirá una validación de facto inter-sujeto y así lograr medir su impacto directo en la especificidad diagnóstica en pruebas de campo.

Agradecimientos. Quiero agradecer a todas las personas que son parte de mi vida, especialmente a mi familia, que siempre estuvieron ahí para apoyarme, a mis amigos por escuchar cuando arrojaba un río de ideas sin coherencia y no desecharlas sin escucharlas. Este trabajo no podría ser posible sin la ayuda de PhD. Alfredo Sherrington que me ha ayudado a validar las métricas de Neuro4B y seguir el estándar académico en el área psicológica.

11 Referencias

- [1] S. Sanei y J. A. Chambers, «Machine Learning for EEG Analysis,» de *EEG Signal Processing and Machine Learning*, 2021, pp. 177-233.
- [2] M.-P. Hosseini, A. Hosseini y K. Ahi, «A Review on Machine Learning for EEG Signal Processing in Bioengineering,» *IEEE reviews in biomedical engineering*, vol. 14, pp. 204-218, 2021.
- [3] R. J. Dolan, «Emotion, Cognition, and Behavior,» *ResearchGate*, pp. 1191-1194, 2002.
- [4] M. Correa, «AMIGOS: A Dataset for Affect, Personality and Mood Research on Individuals and Groups,» *IEEE Transactions on Affective Computing*, vol. 12, nº 2, pp. 479-493, 2021.
- [5] S. K. Jha, S. Suyyari y M. Kumar , «EEG-based Emotion Recognition: An In-Depth Analysis using DEAP and SEED datasets,» de *2024 11th International Conference on Computing for Sustainable Global Development*, INDIACom, 2024, pp. 1816-1821.
- [6] A. M. Balamurugan, V. S y V. N. M, «Machine Learning Approach for ADHD Diagnosis in Children using EEG,» de *2025 International Conference on Intelligent Systems and Computational Networks (ICISCN)*, 2025, p. 17.
- [7] W. Huang, W. Wang, Y. Li y W. Wu, «FBSTCNet: A Spatio-Temporal Covolutional Network Integrating Power and Connectivity Features for EEG-Based Emotion Decoding,» *IEEE Transactions on Affective Computing*, vol. 15, nº 4, pp. 1906-1918, 2024.
- [8] A. Delorme y S. Makeig, «EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis.,» *Journal of neuroscience methods*, Vols. %1 de %2134,1, pp. 9-21, 2004.
- [9] S. Sanei y J. A. Chambers, «Fundamentals of EEG Signal Processing,» de *EEG Signal Processing and Machine Learning*, Wiley AI, 2021, pp. 77-113.
- [10] H. Lövhheim, «A new three-dimensional model for emotions and monoamine neurotransmitters,» *Medical hypotheses*, vol. 2, nº 78, p. 341–348, 2012.
- [11] D. E. Rumelhart, G. E. Hinton y R. J. Williams, «Learning representations by back-propagating errors,» *Nature*, vol. 323, p. 533–536, 1986.

- [12] M. Bilucaglia, G. M. Duma, G. Mento, L. Semenzato y P. E. Tressoldi, «Applying machine learning EEG signal classification to emotion-related brain anticipatory activity,» *F1000Research*, 2021.
- [13] H. Wei, L. Chen y L. Zhao, «Can the Spontaneous Electroencephalography Theta/Beta Power Ratio and Alpha Oscillation Measure Individuals' Attentional Control?,» *Behavioral Sciences*, vol. 14, nº 3, 2024.
- [14] J. F. Lubar y M. N. Shouse, «Use of Biofeedback in the Treatment of Seizure Disorders and Hyperactivity,» de *Advances in Clinical Child Psychology: Volume 1*, Boston, Springer, 1977, pp. 203-265.
- [15] S. M. Snyder y J. R. Hall, «A meta-analysis of quantitative EEG power associated with attention-deficit hyperactivity disorder,» *Journal of clinical neurophysiology : official publication of the American Electroencephalographic Society*, vol. 23, nº 5, pp. 44-55, 2006.
- [16] J. J. Bird, D. R. Faria, L. J. Manso y A. Ekárt, «A Deep Evolutionary Approach to Bioinspired Classifier Optimisation for Brain-Machine Interaction,» *ResearchGate*, 2019.
- [17] J. Bird, A. Ekart, C. Buckingham y R. Faria, «Mental Emotional Sentiment Classification with an EEG-based Brain-machine Interface,» de *The International Conference on Digital Image & Signal Processing (DISP'19)*, Oxford University, UK., 2019.
- [18] L. A. Schmidt y L. Trainor, «Frontal brain electrical activity (EEG) distinguishes valence and intensity of musical emotions,» *Cognition and Emotion*, vol. 15, pp. 487-500, 2001.
- [19] X.-W. Wang, D. Nie y B.-L. Lu, «EEG-Based Emotion Recognition Using Frequency Domain Features and Support Vector Machines,» *Neural Information Processing*, vol. 7062, p. 734–743, 2011.
- [20] R. J. Davidson, «Anterior cerebral asymmetry and the nature of emotion,» *Brain and Cognition*, vol. 20, nº 1, pp. 125-51, 1992.

12 Anexos

12.1 Matrices de confusión para etiquetas binarias (MLP)




Figura 6: Matriz de confusión Motivación

Fuente: Elaboración propia




Figura 7: Matriz de confusión Rabia

Fuente: Elaboración propia




Figura 8: Matriz de confusión Meditación

Fuente: Elaboración propia




Figura 9: Matriz de confusión fatiga mental

Fuente: Elaboración propia




Figura 10: Matriz de confusión estrés

Fuente: Elaboración propia




Figura 11: Matriz de confusión Desagrado

Fuente: Elaboración propia




Figura 12: Matriz de confusión compromiso cognitivo

Fuente: Elaboración propia




Figura 13: Matriz de confusión carga cognitiva

Fuente: Elaboración propia




Figura 14: Matriz de confusión atención

Fuente: Elaboración propia




Figura 15: Matriz de confusión alegría

Fuente: Elaboración propia




Figura 16: Matriz de confusión activación general

Fuente: Elaboración propia




Figura 17: Matriz de confusión tristeza

Fuente: Elaboración propia