

UNIVERSIDAD DE VALLADOLID

FACULTAD DE EDUCACIÓN Y TRABAJO SOCIAL



Universidad de Valladolid

GRADO EN EDUCACIÓN PRIMARIA -MENCIÓN EN EDUCACIÓN FÍSICA

**TRABAJO DE FIN DE GRADO
2024-2025**

**“RELACIÓN ENTRE LA ACTIVIDAD CORTICAL DE
ATRACCIÓN Y RECHAZO GUSTATIVO Y LOS ESTADOS DE
ATRACCIÓN-RECHAZO HACIA EXPLICACIONES
CORPOREIZADAS: ESTUDIO A PARTIR DE CLASIFICADOR
DE SEÑALES EEG CON RANDOM FOREST”**

Autor: Daniela Mediavilla Tejeda

Tutor: Alfonso García Monge

Valladolid, Junio 2025

AGRADECIMIENTOS

Este trabajo no hubiera sido posible sin el apoyo desde el primer día de varias personas a las que me gustaría agradecer.

En primer lugar a mis compañeros, con los que he compartido este proyecto, no ha sido un proceso fácil, aunque con la dedicación de cada uno de ellos ha podido ser más llevadero. Todas las horas que hemos dedicado juntos a este trabajo, el apoyo mutuo, la ayuda constante. Compartir este camino junto a vosotros ha hecho que esta experiencia que al inicio afrontamos con un poco de incertidumbre y miedo haya sido enriquecedora y bonita.

A mi familia y amigos, este logro es de todos vosotros, con vuestras animaciones diarias, por comprender a veces mis frustraciones y por creer en mí durante todo este recorrido académico que me llevo para siempre conmigo, habéis sido un pilar fundamental.

Y por último a Alfonso, por su dedicación, por su paciencia, por habernos orientado durante todo este proceso desde el inicio hasta el final, pero sobre todo por su implicación continua y su ambición que nos ha contagiado a todos nosotros. Todo esto ha sido fundamental para poder llegar a este proyecto final, sin sus impulsos hacia la mejora, sin cada etapa de este trabajo y sin la atención que nos ha prestado en cada momento, esto no hubiera sido posible.
Infinitas gracias Alfonso.

RESUMEN

El presente Trabajo de Fin de Grado surge a partir de una propuesta de investigación entre siete estudiantes y el tutor, basada en la relación entre la actividad cortical y los estados de atracción y rechazo, utilizando los cinco sentidos como paradigma, y centrándonos cada uno de nosotros en uno de ellos, en mi caso del gusto, y explorando su posible vinculación con la aceptación o rechazo de explicaciones corporeizadas. El estudio empleó electroencefalografía (EEG) para registrar la actividad cerebral. La metodología incluyó el análisis de la comparación de espectros de frecuencia entre las condiciones de atracción y rechazo gustativo, identificando la actividad cerebral en las diferentes partes del cerebro. Posteriormente, se desarrolló y aplicó el clasificador Random Forest sobre las señales EEG, logrando discriminar entre estados de atracción y rechazo con una notable precisión.

El modelo fue validado mediante su prueba con un conjunto de datos nuevos e independientes.

Los resultados obtenidos sugieren la existencia de biomarcadores neuronales distinguibles para estos estados afectivos, que no solo contribuye al entendimiento de los estados gustativos, sino que ayuda a entender las bases para futuras investigaciones sobre la influencia de estos mecanismos, en particular aquellos de naturaleza corporeizada.

PALABRAS CLAVE

Actividad cortical, EEG, Atracción gustativa, Rechazo gustativo, Explicaciones corporeizadas, Random Forest, Neurociencia cognitiva.

ABSTRACT

This Final Degree Project originated from a research proposal involving seven students and the supervisor, focusing on the relationship between cortical activity and states of attraction and rejection, using the five senses as a paradigm. Each student focused on one sense, and in my case, taste, exploring its possible link to the acceptance or rejection of embodied explanations. The study employed electroencephalography (EEG) to record brain activity. The methodology included analyzing frequency spectrum comparisons between gustatory attraction and rejection conditions, identifying brain activity in different parts of the brain. Subsequently, a Random Forest classifier was developed and applied to the EEG signals, successfully discriminating between states of attraction and rejection with remarkable precision. The model's robustness was validated by testing it with a new and independent dataset. The results suggest the existence of distinguishable neural biomarkers for these affective states, which not only contributes to the understanding of gustatory states but also helps lay the groundwork for future research on the influence of these mechanisms, particularly those of an embodied nature.

KEY WORDS

Cortical activity, EEG, Gustatory attraction, Gustatory rejection, Embodied explanations, Random Forest, Cognitive neuroscience.

ÍNDICE

1. INTRODUCCIÓN.....	6
2. OBJETIVO.....	6
3. FUNDAMENTACIÓN TEÓRICA.....	7
4. METODOLOGÍA.....	9
4.1 Registro.....	9
4.2 Pre-procesado.....	9
4.3 Extracción de características.....	10
4.4 Modelo de Clasificación: Bosque Aleatorio (Random Forest).....	10
4.5 Entrenamiento del clasificador.....	11
4.6 Evaluación del Rendimiento del Clasificador.....	11
4.7 Identificación de características importantes.....	11
4.8 Aplicación a Nuevos Datos y Simulación de Interfaz.....	11
5. RESULTADOS.....	12
5.1. Comparación de espectros de frecuencia entre la situación de atracción y la de rechazo.....	12
5.2. Resultados clasificador random forest resultados.....	14
5.3. Prueba del modelo con nuevos datos.....	17
6. CONCLUSIONES.....	22
7. REFERENCIAS.....	23
8. ANEXOS.....	24

1. INTRODUCCIÓN

Imaginemos un plato de comida: el olor, el aspecto, la textura y el sabor se unen en el cerebro como un rompecabezas, decidiendo si te gusta o no.

Esta combinación de los sentidos es vital en nuestro día a día: nos ayuda a elegir, a evitar peligros y a relacionarnos.

Hoy en día, la tecnología nos permite asomarnos a cómo funcionan nuestros cerebros. Gracias a cascos de electroencefalografía (EEG), podemos ver en tiempo real como el cerebro responde a diferentes estímulos sensoriales. Es una herramienta sencilla, la cual nos proporciona pistas sobre cómo evaluamos las cosas y cómo tomamos decisiones condicionados por nuestra corporeidad e interacción en el entorno, mediada por los sentidos.

Este Trabajo de Fin de Grado investiga, usando un casco de electroencefalografía (EEG), cómo el cerebro humano reacciona a estímulos que generan atracción o rechazo gustativo.

Nos proponemos ver si nuestros estados corticales de atracción y rechazo hacia estímulos gustativos tienen alguna relación con los estados de atracción o rechazo en discursos académicos más o menos corporeizados.

Si un profesor gesticula, utiliza ejemplos que podemos “sentir”, o explica un ejemplo de manera expresiva, el aprendizaje es más efectivo y los alumnos lo asimilan de una manera más correcta.

Si nuestros estudios y resultados logran identificar y relacionar estas reacciones de atracción y rechazo, en el cerebro a través de los sentidos, esto confirma que el cuerpo y la sensorialidad son herramientas muy importantes y esenciales para comunicar la enseñanza, como para percibir información.

Para poder ver estos vínculos, utilizamos la clasificación de señales electroencefalográficas en estado de atracción y rechazo hacia estímulos gustativos y con ese clasificador le introducimos nuevos datos de señales encefalográficas tomadas en situaciones de discursos académicos más o menos corporeizados para poder comprobar, si de esta manera el clasificador es fiable y los resultados son los esperados y correctos, con ello podríamos decir que este clasificador podemos utilizarlo con otros nuevos datos.

Si los clasificadores de atracción-rechazo basados en diferentes estímulos sensoriales clasifican bien la actitud de atracción - rechazo frente a discursos teóricos o discursos más basados en narrativas corporeizadas, nos estaría indicando el papel fundamental de la narración corporeizada en la enseñanza y que el aprendizaje se basa en procesos anclados en nuestra sensorialidad.

2. OBJETIVO

El objetivo es generar un clasificador de señales, a partir de datos electroencefalográficos tomados de estados de atracción y rechazo de estímulos gustativos y comprobar si este clasificador es útil para clasificar nuevas señales de estados de atracción y rechazo, pero en situaciones académicas.

3. FUNDAMENTACIÓN TEÓRICA

Para contextualizar adecuadamente este estudio, este apartado desarrolla de manera detallada la fundamentación teórica que sustenta esta investigación. En ellos abordaremos la importancia de las emociones en el aprendizaje, la importancia de la educación corporeizada y el concepto “approach and avoidance”, tras investigar en artículos sobre estos aspectos, podemos destacar y referenciar ciertos puntos.

En cuanto a la importancia de las emociones en el aprendizaje, **las emociones** juegan un papel crucial en los procesos cognitivos, especialmente en el aprendizaje y la memoria. Según Tyng (2017), las emociones influyen significativamente en la atención, la codificación de la información, la consolidación de la memoria y su recuperación. Este estudio resalta que los estímulos emocionales tienden a ser recordados con mayor precisión y durante más tiempo que los estímulos neutros. Así, una emoción positiva puede facilitar el aprendizaje al aumentar la motivación y el interés, mientras que una emoción negativa, dependiendo de su intensidad, puede obstaculizar o, en algunos casos, reforzar el recuerdo.

Por otro lado, la integración de tecnologías emergentes como la inteligencia artificial (IA) en los entornos educativos ha permitido una evaluación más precisa y continua de los estados emocionales del alumnado. Vistorte (2024) realizó una revisión sistemática en la que se demuestra cómo el uso de herramientas de IA para el reconocimiento emocional permite adaptar la enseñanza a las necesidades afectivas de los estudiantes, promoviendo así un aprendizaje más personalizado y efectivo. Esta aproximación facilita la detección de emociones como el aburrimiento, la frustración o la confusión, permitiendo a docentes y sistemas adaptativos intervenir de manera oportuna.

En conjunto, estos estudios evidencian que comprender y gestionar las emociones en contextos educativos no solo mejora el rendimiento académico, sino que también favorece un entorno de aprendizaje más humano, sensible y centrado en el estudiante.

Este trabajo también se fundamenta en los principios de la **Educación Corporeizada** (Embodied Education), que destaca cómo el aprendizaje está intrínsecamente ligado a las experiencias corporales y sensoriales. Por un lado, las sensaciones de atracción o rechazo, evocadas mediante estímulos sensoriales (como imágenes, olores o sabores), subrayan que nuestras percepciones y emociones emergen de la interacción directa del cuerpo con el mundo. Estas experiencias sensoriales no solo influyen en cómo aprendemos, sino que también moldean nuestras actitudes hacia los conceptos presentados.

Estudios previos han demostrado que los gestos de los hablantes facilitan la comprensión del habla de los oyentes, particularmente cuando el mensaje verbal es ambiguo, altamente complejo o pronunciado en voz baja según Valenzano, Alibali y Klatzky (2003).

Un aspecto crucial de la integración sensorial y motora en la educación es la **enseñanza corporeizada o "embodied teaching"**, que reconoce el papel fundamental del cuerpo y la acción en los procesos de aprendizaje, ver al docente gesticular puede incitar a los propios estudiantes a producir gestos, lo que a su vez puede promover el aprendizaje al ayudarles a organizar sus pensamientos y a representar la información de manera más concreta, Novack y Goldin-Meadow (2015). Investigaciones han demostrado que el uso de gestos por parte de los docentes puede facilitar significativamente la comprensión y el aprendizaje de los estudiantes, Valenzano (2003).

Además, los gestos pueden añadir detalles, clarificar conceptos abstractos o proporcionar información espacial o temporal que es difícil de expresar solo con palabras, mejorando la coherencia del mensaje (Valenzeno (2003).

Otros estudios han demostrado que los estudiantes aprenden más cuando sus profesores han sido entrenados para gesticular de manera efectiva, y que la calidad y la coherencia de los gestos del docente influyen en la eficacia del aprendizaje, Alibali, (2013); Church (2024). La eficacia de los gestos se manifiesta en una mejor comprensión conceptual y en la capacidad de los estudiantes para aplicar ese conocimiento. Por lo tanto, la incorporación de la corporeidad y los gestos en la práctica docente no es solo una estrategia pedagógica intuitiva, sino que está sólidamente respaldada por la investigación neurocientífica y educativa que destaca la interconexión entre la percepción sensorial, la acción motora y la cognición.

Por otro lado, este enfoque resalta el papel del cuerpo docente en la transmisión del conocimiento. Los resultados esperados de este trabajo esperamos que muestren que los discursos narrativos, apoyados en gestos y expresiones corporales, deberían generar una mayor atracción emocional en los estudiantes. Ello reforzaría la idea de que el cuerpo es un medio poderoso para comunicar ideas abstractas, haciendo que el aprendizaje sea más accesible y significativo.

Finalmente, en cuanto al concepto de **aproximación-evitación (approach-avoidance)**, la Teoría de Sensibilidad al Refuerzo (RST), propuesta por Gray y posteriormente revisada por Corr (2008), ofrece un modelo comprensivo de los sistemas cerebrales que subyacen a la motivación y el comportamiento.

La RST revisada profundiza en tres sistemas principales:

- El **Sistema de Activación Conductual (BAS)**, asociado con la búsqueda de recompensas y la activación del comportamiento de aproximación.
- El **Sistema de Lucha-Huida-Paralización (FFFS)**, implicado en las respuestas a estímulos aversivos incondicionados, mediando las reacciones de miedo y pánico (evitación activa).
- El **Sistema de Inhibición Conductual (BIS)**, relacionado con la resolución de conflictos entre metas y la inhibición de la conducta ante señales de castigo o no recompensa (evitación pasiva).

Estos sistemas proporcionan una base neurobiológica para entender cómo los individuos responden a estímulos de valencia positiva (atracción) o negativa (rechazo), lo cual es directamente aplicable al procesamiento de los estímulos gustativos en nuestro estudio.

Complementariamente, la evidencia neurofisiológica, particularmente en el ámbito de la electroencefalografía (EEG), ha asociado patrones de actividad cerebral específicos con estas tendencias motivacionales. Coan y Allen (2003), en su revisión, consolidan la evidencia que vincula la **mayor actividad frontal izquierda** con la **aproximación motivacional y el afecto positivo** (o emociones que implican una motivación de aproximación, incluso la ira).

Por otro lado, la **mayor actividad frontal derecha** se asocia consistentemente con la **evitación motivacional y el afecto negativo**, como el miedo, la ansiedad o la tristeza (emociones que implican una motivación de retirada).

Estos hallazgos son de particular relevancia para el presente estudio, ya que la distinción entre atracción y rechazo gustativo se espera que module la actividad cerebral de manera consistente con estos principios de aproximación y evitación. La hipótesis de nuestro trabajo se fundamenta en que las diferencias en la actividad cortical observadas a través del EEG durante la experiencia de sabores atractivos y repulsivos reflejarán estos patrones de lateralización frontal, proporcionando así una base neurofisiológica medible para los estados de atracción-rechazo. Además, esta comprensión neurobiológica del "approach-avoidance" nos permite establecer un marco para explorar cómo estos mismos principios podrían operar en el dominio más abstracto de la aceptación o rechazo de las explicaciones corporeizadas.

4. METODOLOGÍA

En este apartado se presenta punto por punto, la metodología y el orden que se ha llevado a cabo desde el inicio, para la recogida de todos los datos y la aplicación de estos para obtener los resultados necesarios.

4.1. Registro: Para llevar a cabo este estudio y por lo tanto el registro de los datos e información necesaria, se grabaron, a través de señales EEG a un total de 7 participantes, mientras experimentaban condiciones diseñadas para inducir "atracción" y "rechazo", en este caso a través del gusto.

El proceso era el siguiente, en mi caso centrándonos en el GUSTO, cada participante debía de estar concentrado durante un total de 30 segundos en el cual, se le proporcionaban diferentes alimentos, tanto agradables (chocolate, hamburguesa...) como desagradables (verdura, jengibre...), en función de los gustos de cada uno.

4.2. Pre-procesado: Los datos y señales recogidas se analizaron con EEGLAB, que es un programa para MATLAB, se seleccionaron los 32 canales, se hizo una localización espacial de los canales, le pasábamos un filtro de paso alto a 0,5 Hz, se pasó un filtro de paso bajo a 46,8 Hz, se aplicó un corrector de artefactos automático con la función ASR, de EEGLAB (Artiface subspace reconstruction).

Después, aplicamos una referencia promediada de la señal, respecto al promedio de la señal. Se aplicó ICA (Análisis de componentes independientes), en el que quitaron los componentes que el plugging ICA label nos mostraba como componentes claves claros, componentes que no correspondía con actividad cortical, ICA los detectaba como actividad muscular parpadeos u otros. Tras pasar ICA se referenciaron los datos.

Finalmente, se llevó a cabo un análisis preliminar de los datos utilizando la función study de EEGLAB, comparando los espectros de potencia de las diferentes condiciones del gusto.

4.3. Extracción de Características: Para que el computador pudiera analizar las señales, extrajimos de pequeños segmentos de EEG un conjunto de características numéricas en el dominio de la frecuencia. Estas características resumen información relevante de la actividad cerebral, como la densidad de potencia espectral de diferentes ritmos cerebrales (delta, theta, alpha, beta bajo, beta alto y gamma) en 32 localizaciones del cuero cabelludo [Cz, Fz, Fp1, F7, F3, FC1, C3, FC5, FT9, T7, TP9, CP5, CP1, P3, P7, O1, Pz, Oz, O2, P8, P4, CP2, CP6, TP10, T8, FT10, FC6, C4, FC2, F4, F8, Fp2].


En total, se calcularon 250 características para cada segmento de EEG. Cada segmento fue etiquetado como "atracción" o "rechazo" según la valoración de los participantes.

4.4. Modelo de Clasificación: Bosque Aleatorio (Random Forest)

Para la tarea de clasificación, elegimos un método de aprendizaje automático llamado **Bosque Aleatorio (Random Forest)**. Imaginemos que queremos identificar un estado mental. En lugar de confiar en un solo "experto" (que sería un único árbol de decisión y podría equivocarse fácilmente), un Bosque Aleatorio consulta a un gran número de "expertos" diferentes (muchos árboles de decisión, cada uno entrenado con una visión ligeramente distinta de los datos). El modelo calcula la importancia de cada característica basada en la reducción del índice de Gini a través de los árboles. Luego, combina las opiniones de todos estos expertos para tomar una decisión final más robusta y fiable sobre si un segmento de EEG corresponde a "atracción" o "rechazo". Este enfoque es conocido por funcionar bien con muchos datos y características, ser menos propenso a errores por detalles específicos de los datos de entrenamiento, y además nos puede indicar qué características fueron más importantes para su decisión.

Utilizamos la implementación estándar de este método. Se configuró una semilla aleatoria (`random_state=42`) para garantizar la reproducibilidad de los resultados. El modelo consta de 100 árboles de decisión y emplea una técnica llamada *bootstrap* o muestreo con reemplazo, que consiste en generar múltiples subconjuntos del conjunto de datos original tomando muestras aleatorias, donde una misma observación puede aparecer varias veces. Esta técnica permite construir árboles diversos y robustos. No se ha limitado la profundidad máxima de los árboles, y se ha empleado el criterio de Gini para medir la calidad de las divisiones internas. La evaluación se ha realizado mediante un conjunto de prueba independiente y validación cruzada con cinco particiones (KFold), utilizando la precisión (accuracy) como métrica principal. Asimismo, se ha analizado la importancia relativa de las características del modelo para identificar cuáles contribuyen más a distinguir entre los estados de atracción y rechazo.

Esta imagen que podemos observar a la derecha, nos podría explicar de manera más sencilla y comprensible, cómo trabaja el clasificador Random Forest, con el que hemos realizado las clasificaciones de datos



4.5. Entrenamiento del Clasificador

-Aprendizaje: Alimentamos el modelo de Bosque Aleatorio con una gran parte de nuestros datos de características y sus etiquetas correspondientes ("atracción" o "rechazo"). A esto se le llama **entrenamiento**. Durante este paso, el modelo aprendió a identificar patrones en los valores de las características que distinguen un estado del otro.

-División de Datos: Para asegurar una evaluación justa, dividimos nuestros datos iniciales: una parte se usó para entrenar el modelo (conjunto de entrenamiento) en este caso, los datos recogidos en cuanto al gusto y otra parte, que el modelo no vio durante el aprendizaje, se reservó para evaluarlo después (conjunto de prueba).

4.6. Evaluación del Rendimiento del Clasificador.

Medimos su rendimiento usando indicadores estándar:

-Exactitud (Accuracy): El porcentaje total de veces que el modelo acertó en su clasificación (ya sea atracción o rechazo).

-Precisión y Sensibilidad (Recall): Indicadores que nos dicen qué tan bien identificó específicamente cada estado. Por ejemplo, la sensibilidad para "atracción" mide cuántos de los momentos reales de atracción fueron correctamente identificados.

-Puntuación F1: Una métrica combinada que balancea la precisión y la sensibilidad.

-Matriz de Confusión: Una tabla que visualiza cuántas veces acertó y cuántas veces confundió una clase con la otra.

-Validación Cruzada: Para confirmar que el rendimiento no fue casualidad debido a la división específica de datos, aplicamos una técnica llamada validación cruzada. Esto implica repetir el proceso de entrenamiento y prueba varias veces usando diferentes porciones de los datos para entrenar y probar en cada repetición. Luego, calculamos el rendimiento promedio, lo que nos da una estimación más fiable de cómo funcionaría el modelo con datos completamente nuevos.

4.7. Identificación de Características Importantes

El modelo de Bosque Aleatorio nos permitió identificar qué **características del EEG** (de las 250 iniciales) fueron las más útiles e informativas para diferenciar entre "atracción" y "rechazo". Esto puede dar pistas sobre los indicadores cerebrales más relevantes para estos estados.

4.8. Aplicación a Nuevos Datos y Simulación de Interfaz

-Prueba de Generalización: Aplicamos el modelo ya entrenado a un conjunto de datos completamente nuevo, correspondiente a un registro diferente [*PARTICIPANTE 1 Y PARTICIPANTE 2, habiendo visualizado unos vídeos de explicación de matemáticas concreto y abstracto*] que sabíamos que correspondía a una condición de "atracción" o "rechazo". El objetivo era ver si el modelo podía generalizar y clasificar correctamente estos nuevos datos.

-Simulación de Interfaz: Para ilustrar una posible aplicación práctica, desarrollamos una **demonstración visual** (simulada dentro de nuestro entorno de análisis, Google Colab). Esta demostración cargaba el modelo entrenado, procesaba segmentos de datos nuevos (representados por sus características), y mostraba la clasificación resultante ("ATRACCION" o "RECHAZO") para cada segmento de forma visual, utilizando por ejemplo, barras de color cuya longitud indicaba la confianza del modelo en esa predicción. Esto sirve como un prototipo conceptual de cómo el clasificador podría funcionar en un escenario más aplicado.

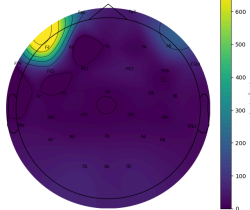
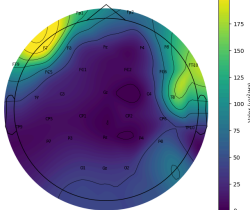
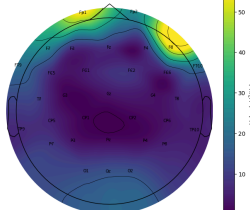
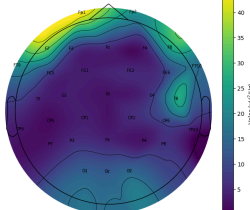
5. RESULTADOS

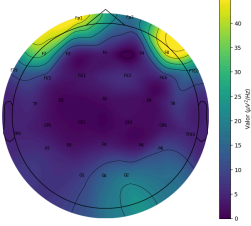
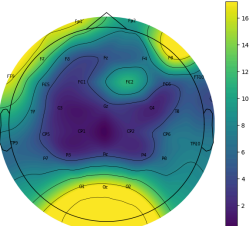
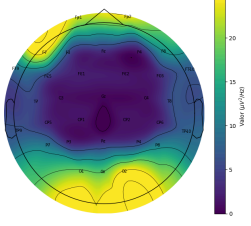
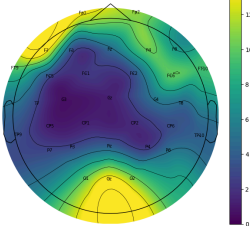
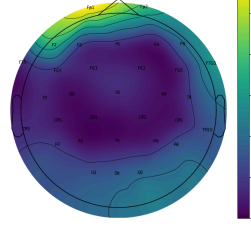
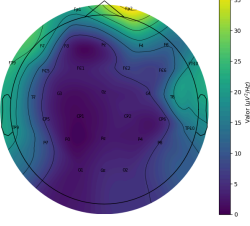
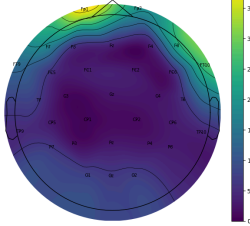
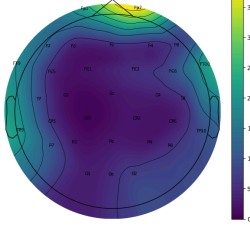
5.1 COMPARACIÓN DE ESPECTROS DE FRECUENCIA ENTRE LA SITUACIÓN DE ATRACCIÓN Y LA DE RECHAZO

Se muestran a continuación los mapas topográficos basados en las potencias espectrales en las diferentes bandas de frecuencia para las dos condiciones analizadas: “GUSTO ATRACCIÓN” y “GUSTO RECHAZO” .

Estos mapas, extraídos a través de EEG, como señalamos, nos permiten visualizar la distribución espacial de la actividad cerebral en las diferentes bandas de frecuencia, siendo de color amarillo las zonas de mayor actividad.

A continuación en la tabla podemos observar cada banda de frecuencia y sus diferencias observadas.

GUSTO RECHAZO	GUSTO ATRACCIÓN	COMENTARIO
<p>Mapa Topográfico - Delta (1-4Hz) Potencia Absoluta</p> 	<p>Mapa Topográfico - Delta (1-4Hz) Potencia Absoluta</p> 	<p>Banda Delta (1-4Hz) En este caso la condición de rechazo nos muestra una actividad superior y mayor localizada en la región fronto-prefrontal izquierda, lo que nos puede indicar una implicación más alta de atención y emociones de valencia negativa asociados al rechazo.</p>
<p>Mapa Topográfico - Theta (4-8Hz) Potencia Absoluta</p> 	<p>Mapa Topográfico - Theta (4-8Hz) Potencia Absoluta</p> 	<p>Banda Theta (4-8Hz) En este caso de nuevo la condición de rechazo se caracteriza por una potencia Theta significativamente más elevada y localizada en las áreas frontales, lo que nos sugiere una mayor activación en procesos relacionados con la memoria de trabajo, el control cognitivo.</p>

<p>Mapa Topográfico - Alpha (8-13Hz) Potencia Absoluta</p> 	<p>Mapa Topográfico - Alpha (8-13Hz) Potencia Absoluta</p> 	<p>Banda Alpha (8-13Hz) En esta banda muestra mayor potencia la atracción en las regiones posteriores, lo que podemos asociar a menudo con estados de reposo o la supresión de información no relevante.</p>
<p>Mapa Topográfico - Beta Bajo (13-20Hz) Potencia Absoluta</p> 	<p>Mapa Topográfico - Beta Bajo (13-20Hz) Potencia Absoluta</p> 	<p>Banda Beta Bajo (13-20Hz) La condición de atracción de nuevo presenta una mayor potencia en las regiones frontales, lo que nos podría indicar mayor activación de condiciones motoras, preparación a la acción.</p>
<p>Mapa Topográfico - Beta Alto (20-30Hz) Potencia Absoluta</p> 	<p>Mapa Topográfico - Beta Alto (20-30Hz) Potencia Absoluta</p> 	<p>Banda Beta Alto (20-30Hz) Al igual que en Beta baja, la condición de atracción se asocia con mayor potencia, sugiriendo una implicación más intensa en procesos cognitivos complejos, control motor y la integración multisensorial.</p>
<p>Mapa Topográfico - Gamma (30-40Hz) Potencia Absoluta</p> 	<p>Mapa Topográfico - Gamma (30-40Hz) Potencia Absoluta</p> 	<p>Banda Gamma (30-40Hz) En el caso de la banda Gamma, muestra mayor potencia en atracción, lo que nos puede indicar, una mayor coordinación neuronal, integración de forma sensorial y procesamiento de alto nivel asociado a la percepción de estímulos placenteros o atractivos.</p>

En resumen, los resultados obtenidos nos muestran una diferenciación clara en la actividad cerebral en función de la valencia afectiva de los estímulos gustativos.

La condición de **GUSTO RECHAZO** parece obtener una mayor potencia en las bandas de baja frecuencia (Delta y Theta), particularmente en las regiones frontales, lo que puede estar vinculado a una mayor demanda de recursos cognitivos para el procesamiento de estímulos aversivos, la detección de la saliencia negativa o la respuesta de evitación.

Por otro lado, en la condición de **GUSTO ATRACCIÓN**, se asocia con mayor potencia las bandas de alta frecuencia (Alpha, Beta y Gamma), que nos muestra mayormente en las regiones frontales y posteriores, lo que nos puede estar mostrando un procesamiento más integrado, la activación de sistemas de recompensa, la preparación para la aproximación y mayor demanda cognitiva en el procesamiento de estímulos placenteros.

5.2 RANDOM FOREST RESULTADOS→ GUSTO ATRACCIÓN-RECHAZO

→ REPORTE DE CLASIFICACIÓN

Accuracy: 0.9629629629629629

Reporte de Clasificación:

	precision	recall	F1-score	support
ATRACCIÓN	0.96	0.98	0.97	44
RECHAZO	0.97	0.95	0.96	37

En este caso en la precisión global, nos devuelve 0.96, por esto significa que el modelo acierta en 96% de los casos(de cada 100 predicciones 96 son correctas), y que por ello al ser un porcentaje muy alto, nos indica la gran precisión del clasificador.

Esto podemos observarlo en una tabla más visual que encontramos en el (*Anexo 2*).

El modelo detecta el rechazo con un porcentaje de 96% y la atracción con un 97%, lo cual nos puede estar indicando que hay un sobreentrenamiento debido a que hemos utilizado una muestra muy baja para el entrenamiento del modelo.

En general, reconoce mejor la atracción que el rechazo, estos resultados nos sugieren que las señales cerebrales durante la atracción están más marcadas o diferenciadas que las del rechazo.

→ Reporte de resultados de Validación Cruzada e Importancia de Características

-Resultados de Validación Cruzada (Accuracy):

Scores: [0.9382716 0.98765432 0.95 0.9375 0.925]

Media: 0.94

Desviación Estándar: 0.021

-Importancia de las Características:

	característica	importancia
154	FT10_High Beta	0.047498
155	FT10_Gamma	0.040026
268	CP1_High Beta_ZScore	0.031432
185	F8_Gamma	0.020073
59	T7_Gamma	0.017390
.....
397	FAA_Avg_Theta	0.000000
210	F7_Delta_ZScore	0.000000
279	P7_Low Beta_ZScore	0.000000
415	Engagement_P3	0.000000
234	FC5_Delta_ZScore	0.000000

De más importancia a menos.

En cuanto a las características de más importancia que nos seleccionó Random Forest, ha sacado 5 muestras, y podemos decir que tiene un rendimiento muy bueno.


Muestra una precisión muy alta y estable en la validación cruzada.

Se comporta de manera similar en todos los subconjuntos de datos, lo que nos indica que probablemente no está sobreajustado.

En este caso, nos muestra qué variables o características son más relevantes para tomar decisiones, siendo las más alta con un 4.7 %, la zona fronto temporal derecho en Beta alto.

El modelo por lo tanto, utiliza más unas señales cerebrales que otras para decidir si hay atracción o rechazo, como bien hemos dicho anteriormente, en este caso, señales en zonas frontales y temporales derechas como, FT10, F8 Y T7, y en frecuencias Gamma y Beta han sido las más útiles.

Esto puede estar relacionado con la **atención, el procesamiento emocional o el juicio sensorial.**



Esta gráfica muestra de manera algo más clara, los datos comentados anteriormente, y con ello las características más importantes que ayudan a diferenciar entre el estado de atracción y el de rechazo, en este caso del gusto, como señalamos anteriormente.

Por un lado, observamos que sobresale y destaca en mayor parte la actividad Beta Alto en la posición Fronto Temporal Izquierda (FT10), lo cual nos dice que esta característica es la más utilizada en el clasificador.

En el caso de Beta Alto también vemos que destaca la posición Centro Parietal izquierda (CP1), aunque su magnitud no es tan alta.

Y en cuanto a la banda de frecuencia Gamma, es la otra que más destaca, en las posiciones Fronto Temporal izquierda (FT10), Frontal derecha (F8) y Temporal izquierda (T7).

Las otras cinco restantes, no han aportado nada al modelo, lo cual no significa que sean malas, sino que para este conjunto de datos y este tipo de estímulo concreto, no han sido relevantes.

Tomando como referencia el trabajo de (Scrivener y Reader. 2021), estas posiciones se corresponderá con distintas áreas funcionales del cerebro, así tendríamos que la actividad en:

- **FT10_Hight Beta y FT10_Gamma**, corresponden al área 21 derecho de Brodman, estos nos podrían estar indicando la implicación de funciones relacionadas con categorización y observación de movimiento.
- **CP1_High Beta_ZScore**, que corresponde al área 7 izquierdo de Brodmann, nos podría estar indicando la implicación de funciones relacionadas con autorreflexión , metas, recordar episodios y cambiar la atención.
- **F8_Gamma**, que corresponde al área 45 de Brodmann, nos podría estar indicando la implicación de funciones relacionadas con lenguaje de señas, memoria episódica, neuronas de movimiento espejo, codificación de palabras y rostros, modular emociones, monitorear la conducta y comportamiento cronometrado.

Consultada la base de datos de los estudios de **PubMed** revelan que:

-El **área de Brodmann 21** derecho, ubicada en el giro temporal medio, es una región clave del lóbulo temporal que ha sido consistentemente asociada con el procesamiento auditivo de alto nivel y la comprensión del lenguaje. Si bien su función lingüística es a menudo lateralizada al hemisferio izquierdo en la mayoría de los individuos, se reconoce su papel en el procesamiento semántico y la integración de información auditiva. Este procesa el lenguaje receptivo, según Precio (2012) se centra en la implicación de esta en el procesamiento del lenguaje, específicamente en el procesamiento de palabras y significado, lo que es fundamental para el lenguaje receptivo.

-El **área de Brodmann 7** izquierdo, ubicada en el lóbulo parietal superior y precúneo, es parte de la corteza de asociación somatosensorial. Juega un papel crucial en la integración visuomotora, la coordinación de movimientos (alcanzar y agarrar objetos), y la navegación espacial. Además, se ha vinculado con procesos cognitivos de alto nivel que pueden integrar información sensorial y motora relevante para el lenguaje, como la comprensión de gestos o la representación espacial de conceptos.

Controla las funciones motoras y la integración del lenguaje.

Andersen y Bueno (2002), nos indican la importancia de esta área a la hora de transformar información sensorial de acción y movimientos dirigidos, lo que es fundamental para la integración motora.

-El **área de Brodmann 45** derecho, forma parte del área de Broca en el giro frontal inferior, tradicionalmente asociada con la producción del lenguaje y el procesamiento sintáctico. Sin embargo, la investigación ha revelado su rol en el procesamiento semántico y la memoria de trabajo verbal.

Según Friederici (2011), nos dice que las redes neuronales del lenguaje, incluyendo las contribuciones del hemisferio derecho a la integración contextual y la prosodia, el área 45 de Brodmann derecha puede jugar un rol.

5.3 PRUEBA DEL MODELO CON NUEVOS DATOS

→ MAPAS DE VIOLÍN COMPARANDO LOS DATOS DE ENTRENAMIENTO Y LOS NUEVOS


Una vez obtenidos todos los resultados, decidimos hacer la prueba con nuevos datos, para comprobar si este clasificador sirve para clasificar bien nueva información.

Introducimos datos tomados de una situación en la que los oyentes escuchaban un discurso sobre matemáticas, uno de los participantes escuchaba un discurso abstracto, es decir, de una forma más teórica y compleja (PARTICIPANTE 1) y también los intentamos probar con datos tomados de otra participante escuchando un discurso más concreto, corporeizado con mayor narrativa (PARTICIPANTE 2), y probamos el modelo con ello, obteniendo como resultado los siguientes mapas de violín.

Miramos algunas características que nos proporcionaba el modelo de Random forest como más significativas, en este caso la potencia de **Beta Alto en la zona Centro Parietal izquierda (CP1)** en el **participante 1** y la potencia de **Gamma en la zona Frontal derecha** concretamente (F8) en el **participante 2**.

Estos los podemos observar de forma gráfica a continuación.

1. RESULTADOS PARTICIPANTE 1 (mates abstracto)



Este primer mapa de violín en referencia al primer participante, de las características que nos proporcionó Random Forest, escogimos la potencia Beta Alto en la zona Centro Parietal izquierda (CP1), se podrán observar las gráficas de las demás potencias en el *Anexo 3*.

Este gráfico compara la distribución de la característica CP1 High Beta entre dos conjuntos de datos: A la izquierda los datos del conjunto de entrenamiento (gusto), separados por “atracción” de color verde y “rechazo” de color rojo.


A la derecha, los nuevos datos del participante, todos clasificados o asumidos como atracción.

A la izquierda, los datos de entrenamiento del gusto, nos muestra valores más bajos para atracción que para rechazo, lo que nos sugiere que esta característica es útil para distinguir entre ambos estados. Por ello, este modelo probablemente le ha asignado una gran importancia.

La distribución de los nuevos datos es más parecida a los valores bajos de atracción que obtenemos en el entrenamiento del gusto, más que del rechazo.

Se le preguntó al participante al terminar de tomar los datos, si al observar el vídeo de matemáticas abstracto había sentido rechazo o atracción, siendo su respuesta “atracción”, por lo tanto, posicionándonos en la gráfica, podemos confirmar que es correcto y coincide.

2. RESULTADOS , PARTICIPANTE 2 (mates concreto)



Esta segunda gráfica, la obtuvimos con el mismo proceso que del participante 1, pero decidimos hacerla con nuevos datos, para así proporcionar más fiabilidad e información a este estudio.

Esta presenta una gran similitud a la anterior, presentándonos a la izquierda los datos de entrenamiento de gusto y a la derecha los datos nuevos del participante 2.

En este caso escogimos la potencia Gamma en la zona Frontal derecha (F8), se podrán observar las gráficas de las demás potencias en el *Anexo 4*.

A la izquierda los datos del conjunto de entrenamiento (gusto), separados por “atracción” de color verde y “rechazo” de color rojo.

A la derecha, los nuevos datos del participante, todos clasificados o asumidos como atracción.

Los datos son muy similares en el caso de la atracción, como señalamos en el anterior, se le preguntó al participante al terminar de tomar los datos, si al observar el vídeo de matemáticas concreto había sentido rechazo o atracción, siendo su respuesta “atracción”, por lo tanto, posicionándonos en la gráfica, podemos confirmar que es correcto y coincide.

Finalmente, para concretar, ambas gráficas y ambos datos se parecen más a los valores típicos del estado de atracción observados durante el entrenamiento. Esto por lo tanto, apoya la clasificación del modelo, aunque también sugiere una posible respuesta fisiológica más intensa o distinta frente a los estímulos presentados.


→ SIMULACIÓN DE INTERFAZ

Intento de una aplicación de prueba de este modelo, como un prototipo conceptual de cómo el clasificador podría funcionar en un escenario más aplicado.

Se puede encontrar otra posible aplicación en el *Anexo 5*.

Los datos que se han tomado para llevar a cabo esta simulación de interface, en este caso han sido de un nuevo participante, (PARTICIPANTE 3), con los datos tomados a raíz de la visualización de un vídeo donde se le explicaban las matemáticas de una manera abstracta.

--- Iniciando Simulación de Clasificación (Procesando 50 muestras) ---



... (mostrando solo las primeras 15 muestras de 50) ...

Finalmente, quisimos poner toda la información y los datos a prueba para una posible aplicación en el futuro a través de una aplicación en la que puedan introducir sus datos y comprobar de una manera más sencilla y comprensible para todo tipo de personas, qué confianza de datos existe.

Los datos y porcentajes que se observan, se han tomado a través de muestras las cuales tienen una duración de dos segundos cada una. De esas 50 muestras, posteriormente nos ha seleccionado 15 de ellas, las cuales nos indican un 100% de atracción, con una confianza del 78%, lo cual podría indicarnos que para una posible aplicación futura, con otros nuevos datos, podríamos confiar en esta, ya que a mayores, el supuesto del que sacamos las muestras y los datos, nos afirmó que sentía

atracción al visualizar un vídeo sobre una explicación de matemáticas, en este caso con una mayor precisión teórica y explicaciones más complejas.

Como podemos observar en esta clasificación de muestras, estas han sido sacadas a partir de la unión de los datos de entrenamiento y los datos extraídos de la prueba de mates abstracto del participante 3.

A continuación comentamos otros datos en cuanto a la confianza que nos muestra este proceso:

Total de Muestras Procesadas: **50**

Predicciones 'ATRACCION': **50 (100.0%)**

Predicciones 'RECHAZO': **0 (0.0%)**

Confianza Media (Prob. Atracción): **0.781**

Confianza Mín/Máx (Prob. Atracción): **0.605 / 0.937**

Con estos datos podemos ver que el 100% de las pruebas nos indican atracción, y estas se muestran con una confianza del 78%, por lo que podríamos decir que sí podríamos fiarnos y utilizarlo con otros nuevos datos, para poder ver los resultados de una manera más visual y comprensiva.

6. CONCLUSIONES

Para finalizar y concluir con este presente trabajo de fin de grado, tras todo el proceso y la obtención de todos los datos y resultados finales, he podido llegar a ciertas conclusiones y ciertos aspectos a destacar.

En todo caso e inicialmente, destacar que hay que tomar con cautela estos resultados dadas las limitaciones de este estudio en cuanto número de participantes, condiciones de muestreo o precisión del equipo utilizado.

En primer lugar, la comparación de espectros de frecuencia entre las situaciones de atracción y de rechazo gustativo nos ha revelado patrones distintivos en la actividad cerebral. En cada banda de frecuencia se han observado diferentes actividades cerebrales, lo que nos respalda la conclusión de que el cerebro procesa de manera diferente las experiencias placenteras y no tan placenteras a nivel gustativo, que se refleja a partir de los datos encefalográficos extraídos.

En segundo lugar, en cuanto al clasificador Random Forest, nos ha demostrado ser una herramienta eficaz a la hora de discriminar entre estados de atracción y rechazo. Los resultados obtenidos, nos han mostrado que para futuras aplicaciones prácticas, este clasificador podría ser una buena opción, para trabajar en la creación o personalización de contenidos.

Además la prueba con los nuevos datos nos demuestra la capacidad del modelo para utilizar y extender los datos específicos del entrenamiento y aplicar esos aprendizajes a nuevas situaciones, en este caso lo hemos aplicado a dos nuevas situaciones, y ambas nos han demostrado su alta fiabilidad para poder introducir nuevos datos.

Por lo tanto, toda esta información y hallazgos tras aplicar la metodología requerida, tienen una implicación importante para comprender la relación entre la actividad cortical de atracción y rechazo gustativo y los estados de atracción-rechazo hacia explicaciones corporeizadas.

Este trabajo ha demostrado la capacidad que tienen las señales EEG para reflejar y clasificar el estado de atracción y rechazo gustativo.

7. REFERENCIAS

- Tyng, C. M., Amin, H. U., Saad, M. N. M., & Malik, A. S. (2017). The Influences of Emotion on Learning and Memory. *Frontiers in Psychology*, 8, 1454. <https://doi.org/10.3389/fpsyg.2017.01454>
- Vistorte, A. O. R., Deroncele-Acosta, A., Ayala, J. L. M., Barrasa, A., López-Granero, C., & Martí-González, M. (2024). Integrating artificial intelligence to assess emotions in learning environments: a systematic literature review. *Frontiers in Psychology*, 15, 1387089. <https://doi.org/10.3389/fpsyg.2024.1387089>
- Alibali, M. W., Young, A. G., Crooks, N. M., Yeo, A., Wolfgram, M. S., Ledesma, I. M., Nathan, M. J., Church, R. B., & Knuth, E. J. (2013). Students learn more when their teacher has learned to gesture effectively. *Gesture*, 13(2), 210–233. <https://doi.org/10.1075/gest.13.2.05ali>
- Church, R. B., Perry, M., Singer, M. A., Cook, S. W., & Alibali, M. W. (2024). Teachers' Gestures and How They Matter. *Topics in Cognitive Science*. Advance online publication. <https://doi.org/10.1111/tops.12755>
- Novack, M., & Goldin-Meadow, S. (2015). Learning from gesture: How our hands change our minds. *Educational Psychology Review*, 27(3), 405–412. <https://doi.org/10.1007/s10648-015-9325-3>
- Valenzeno, L., Alibali, M. W., & Klatzky, R. (2003). Teachers' gestures facilitate students' learning: A lesson in symmetry. *Contemporary Educational Psychology*, 28(2), 187–204. [https://doi.org/10.1016/S0361-476X\(02\)00007-3](https://doi.org/10.1016/S0361-476X(02)00007-3)
- Corr, P. J. (2008). *The reinforcement sensitivity theory of personality*. Cambridge University Press.
- Coan, J. A., & Allen, J. J. B. (2003). The state and trait nature of frontal EEG asymmetry in emotion. En K. Hugdahl & R. J. Davidson (Eds.), *The asymmetrical brain* (pp. 565–615). MIT Press.
- Friederici, A. D. (2011). The Brain Basis of Language Processing: From Structure to Function. *Physiological Reviews*, 91(4), 1357-1392. <https://doi.org/10.1152/physrev.00006.2011>


→GUSTO ATRACCIÓN

ANEXO 2

(RANDOM FOREST)

Matriz de Confusión:

```
[[43  1]
 [ 2 35]]
```



ANEXO 3

(OTROS DATOS MATES ABSTRACTO BRAIS)

--- Resultados de Clasificación para el Nuevo Archivo ---

Resumen de Predicciones:

prediccion


atraccion 54

Name: count, dtype: int64

<ipython-input-8-4e78c547075a>:65: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.

```
sns.countplot(x='prediccion', data=nuevo_archivo, palette='viridis',
order=conteo_predicciones.index)
```



Todas las muestras clasificadas con confianza ≥ 0.6 .


--- Análisis de Características Importantes en Nuevos Datos ---

Visualizando la distribución de las 5 características más importantes:

<ipython-input-8-4e78c547075a>:99: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.


```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



<ipython-input-8-4e78c547075a>:99: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.


```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



<ipython-input-8-4e78c547075a>:99: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.


```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



<ipython-input-8-4e78c547075a>:99: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.


```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```




<ipython-input-8-4e78c547075a>:99: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.

```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



--- Iniciando Visualizaciones Genéricas ---



Estadísticas de la Probabilidad de Atracción (Datos Nuevos):

Media: 0.879

Mediana: 0.890



Mínima: 0.670



Máxima: 0.932



Desv. Estándar: 0.049

--- Comparando Distribución de las 5 Características Más Importantes ---

Comparando: Datos Entrenamiento vs Datos Nuevos







--- Fin de Visualizaciones Genéricas ---

--- Generando Datos para Tablas Cuantitativas ---

--- Tabla 1: Datos de Rendimiento del Modelo ---

Métrica	Clase	Valor (Conjunto Prueba)	Valor Medio (CV)	Desv. Est. (CV)
Accuracy	General	0.963	0.948	0.021
Precisión	Atraccion	0.956	-	-
Precisión	Rechazo	0.972	-	-
Recall	Atraccion	0.977	-	-

Recall Rechazo	0.946	-	-
F1-Score Atraccion	0.966	-	-
F1-Score Rechazo	0.959	-	-
F1 Macro Avg General	0.963	-	-
F1 Weighted Avg General	0.963	-	-

--- Tabla 2: Top 10 Características Más Importantes ---

Ranking	Característica	Puntuación de Importancia
1	FT10_High Beta	0.0475
2	FT10_Gamma	0.0400
3	CP1_High Beta_ZScore	0.0314
4	F8_Gamma	0.0201
5	T7_Gamma	0.0174
6	F7_High Beta	0.0170
7	Fp1_High Beta	0.0167
8	T7_High Beta	0.0140
9	C3_High Beta_ZScore	0.0138
10	Engagement_T7	0.0134

--- Tabla 3: Resumen de Confianza de Predicción en Datos Nuevos ---

Número de Muestras	54
Media Prob. Atracción	0.879
Mediana Prob. Atracción	0.890
Desv. Est. Prob. Atracción	0.049
Mínima Prob. Atracción	0.670
Máxima Prob. Atracción	0.932
% Muestras Confianza > 0.9	37.0%
% Muestras Confianza < 0.6	0.0%

--- Tabla 4: Comparación Estadística de Top 10 Características ---

Característica	Grupo	Media (\pm Desv. Est.)	Mediana [IQR]
FT10_High Beta	Entrenamiento - Atraccion	16.128 (\pm 9.303)	14.448 [11.322]
FT10_High Beta	Entrenamiento - Rechazo	34.919 (\pm 15.061)	32.565 [19.218]
FT10_High Beta	Nuevo - Atraccion	5.587 (\pm 2.296)	5.357 [2.830]
FT10_Gamma	Entrenamiento - Atraccion	15.269 (\pm 9.376)	13.205 [12.073]
FT10_Gamma	Entrenamiento - Rechazo	35.925 (\pm 18.120)	32.272 [21.252]
FT10_Gamma	Nuevo - Atraccion	2.553 (\pm 0.844)	2.373 [1.244]
CP1_High Beta_ZScore	Entrenamiento - Atraccion	-1.050 (\pm 0.218)	-1.108 [0.209]
CP1_High Beta_ZScore	Entrenamiento - Rechazo	-0.877 (\pm 0.136)	-0.878 [0.149]
CP1_High Beta_ZScore	Nuevo - Atraccion	-1.042 (\pm 0.415)	-1.165 [0.317]
F8_Gamma	Entrenamiento - Atraccion	7.281 (\pm 6.833)	5.586 [4.300]
F8_Gamma	Entrenamiento - Rechazo	17.074 (\pm 14.318)	11.017 [15.926]
F8_Gamma	Nuevo - Atraccion	2.669 (\pm 0.966)	2.506 [1.225]
T7_Gamma	Entrenamiento - Atraccion	13.253 (\pm 14.310)	7.278 [12.254]
T7_Gamma	Entrenamiento - Rechazo	29.233 (\pm 22.296)	24.861 [29.935]
T7_Gamma	Nuevo - Atraccion	1.662 (\pm 0.620)	1.592 [0.694]
F7_High Beta	Entrenamiento - Atraccion	11.415 (\pm 10.878)	8.222 [7.969]
F7_High Beta	Entrenamiento - Rechazo	21.354 (\pm 15.632)	16.744 [16.046]

F7_High Beta	Nuevo - Atraccion	5.252 (\pm 1.730)	5.128 [1.518]
Fp1_High Beta	Entrenamiento - Atraccion	8.873 (\pm 4.689)	7.974 [5.639]
Fp1_High Beta	Entrenamiento - Rechazo	19.865 (\pm 15.104)	14.537 [16.402]
Fp1_High Beta	Nuevo - Atraccion	4.493 (\pm 1.446)	4.387 [1.611]
T7_High Beta	Entrenamiento - Atraccion	13.728 (\pm 13.308)	8.732 [12.164]
T7_High Beta	Entrenamiento - Rechazo	30.268 (\pm 21.081)	28.071 [37.064]
T7_High Beta	Nuevo - Atraccion	2.730 (\pm 0.757)	2.642 [1.131]
C3_High Beta_ZScore	Entrenamiento - Atraccion	-0.727 (\pm 0.874)	-0.918 [0.344]
C3_High Beta_ZScore	Entrenamiento - Rechazo	-0.683 (\pm 0.340)	-0.774 [0.210]
C3_High Beta_ZScore	Nuevo - Atraccion	-0.918 (\pm 0.349)	-0.959 [0.461]
Engagement_T7	Entrenamiento - Atraccion	0.718 (\pm 0.612)	0.487 [0.585]
Engagement_T7	Entrenamiento - Rechazo	1.179 (\pm 0.737)	0.963 [0.898]
Engagement_T7	Nuevo - Atraccion	0.424 (\pm 0.239)	0.357 [0.189]

--- Fin de la Generación de Datos para Tablas ---

ANEXO 4

(OTROS DATOS **MATES CONCRETO MIREYA**)

--- Resultados de Clasificación para el Nuevo Archivo ---

Resumen de Predicciones:

prediccion


atraccion 39

Name: count, dtype: int64

<ipython-input-9-07ecf548a451>:65: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.

```
sns.countplot(x='prediccion', data=nuevo_archivo, palette='viridis',
order=conteo_predicciones.index)
```



Todas las muestras clasificadas con confianza ≥ 0.6 .


--- Análisis de Características Importantes en Nuevos Datos ---

Visualizando la distribución de las 5 características más importantes:

<ipython-input-9-07ecf548a451>:99: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.


```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



<ipython-input-9-07ecf548a451>:99: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.


```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



<ipython-input-9-07ecf548a451>:99: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.


```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



<ipython-input-9-07ecf548a451>:99: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.


```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```




<ipython-input-9-07ecf548a451>:99: FutureWarning:

Passing `palette` without assigning `hue` is deprecated and will be removed in v0.14.0. Assign the `x` variable to `hue` and set `legend=False` for the same effect.

```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



--- Iniciando Visualizaciones Genéricas ---



Estadísticas de la Probabilidad de Atracción (Datos Nuevos):

Media: 0.769

Mediana: 0.760



Mínima: 0.673



Máxima: 0.860



Desv. Estándar: 0.048

--- Comparando Distribución de las 5 Características Más Importantes ---

Comparando: Datos Entrenamiento vs Datos Nuevos







--- Fin de Visualizaciones Genéricas ---

--- Generando Datos para Tablas Cuantitativas ---

--- Tabla 1: Datos de Rendimiento del Modelo ---

Métrica	Clase	Valor (Conjunto Prueba)	Valor Medio (CV)	Desv. Est. (CV)
Accuracy	General	0.963	0.948	0.021
Precisión	Atraccion	0.956	-	-
Precisión	Rechazo	0.972	-	-
Recall	Atraccion	0.977	-	-

Recall Rechazo	0.946	-	-
F1-Score Atraccion	0.966	-	-
F1-Score Rechazo	0.959	-	-
F1 Macro Avg General	0.963	-	-
F1 Weighted Avg General	0.963	-	-

--- Tabla 2: Top 10 Características Más Importantes ---

Ranking	Característica	Puntuación de Importancia
1	FT10_High Beta	0.0475
2	FT10_Gamma	0.0400
3	CP1_High Beta_ZScore	0.0314
4	F8_Gamma	0.0201
5	T7_Gamma	0.0174
6	F7_High Beta	0.0170
7	Fp1_High Beta	0.0167
8	T7_High Beta	0.0140
9	C3_High Beta_ZScore	0.0138
10	Engagement_T7	0.0134

--- Tabla 3: Resumen de Confianza de Predicción en Datos Nuevos ---

Número de Muestras	39
Media Prob. Atracción	0.769
Mediana Prob. Atracción	0.760
Desv. Est. Prob. Atracción	0.048
Mínima Prob. Atracción	0.673
Máxima Prob. Atracción	0.860
% Muestras Confianza > 0.9	0.0%
% Muestras Confianza < 0.6	0.0%

--- Tabla 4: Comparación Estadística de Top 10 Características ---

Característica	Grupo	Media (\pm Desv. Est.)	Mediana [IQR]
FT10_High Beta	Entrenamiento - Atraccion	16.128 (\pm 9.303)	14.448 [11.322]
FT10_High Beta	Entrenamiento - Rechazo	34.919 (\pm 15.061)	32.565 [19.218]
FT10_High Beta	Nuevo - Atraccion	4.752 (\pm 1.374)	4.885 [2.058]
FT10_Gamma	Entrenamiento - Atraccion	15.269 (\pm 9.376)	13.205 [12.073]
FT10_Gamma	Entrenamiento - Rechazo	35.925 (\pm 18.120)	32.272 [21.252]
FT10_Gamma	Nuevo - Atraccion	2.770 (\pm 0.932)	2.815 [1.229]
CP1_High Beta_ZScore	Entrenamiento - Atraccion	-1.050 (\pm 0.218)	-1.108 [0.209]
CP1_High Beta_ZScore	Entrenamiento - Rechazo	-0.877 (\pm 0.136)	-0.878 [0.149]
CP1_High Beta_ZScore	Nuevo - Atraccion	-0.639 (\pm 0.272)	-0.673 [0.351]
F8_Gamma	Entrenamiento - Atraccion	7.281 (\pm 6.833)	5.586 [4.300]
F8_Gamma	Entrenamiento - Rechazo	17.074 (\pm 14.318)	11.017 [15.926]
F8_Gamma	Nuevo - Atraccion	5.011 (\pm 2.265)	5.138 [3.694]
T7_Gamma	Entrenamiento - Atraccion	13.253 (\pm 14.310)	7.278 [12.254]
T7_Gamma	Entrenamiento - Rechazo	29.233 (\pm 22.296)	24.861 [29.935]
T7_Gamma	Nuevo - Atraccion	1.994 (\pm 0.802)	1.833 [0.941]
F7_High Beta	Entrenamiento - Atraccion	11.415 (\pm 10.878)	8.222 [7.969]
F7_High Beta	Entrenamiento - Rechazo	21.354 (\pm 15.632)	16.744 [16.046]

F7_High Beta	Nuevo - Atraccion	9.435 (\pm 3.754)	8.932 [3.945]
Fp1_High Beta	Entrenamiento - Atraccion	8.873 (\pm 4.689)	7.974 [5.639]
Fp1_High Beta	Entrenamiento - Rechazo	19.865 (\pm 15.104)	14.537 [16.402]
Fp1_High Beta	Nuevo - Atraccion	14.946 (\pm 6.326)	14.426 [6.559]
T7_High Beta	Entrenamiento - Atraccion	13.728 (\pm 13.308)	8.732 [12.164]
T7_High Beta	Entrenamiento - Rechazo	30.268 (\pm 21.081)	28.071 [37.064]
T7_High Beta	Nuevo - Atraccion	3.162 (\pm 1.286)	3.172 [1.910]
C3_High Beta_ZScore	Entrenamiento - Atraccion	-0.727 (\pm 0.874)	-0.918 [0.344]
C3_High Beta_ZScore	Entrenamiento - Rechazo	-0.683 (\pm 0.340)	-0.774 [0.210]
C3_High Beta_ZScore	Nuevo - Atraccion	-0.856 (\pm 0.312)	-0.935 [0.373]
Engagement_T7	Entrenamiento - Atraccion	0.718 (\pm 0.612)	0.487 [0.585]
Engagement_T7	Entrenamiento - Rechazo	1.179 (\pm 0.737)	0.963 [0.898]
Engagement_T7	Nuevo - Atraccion	0.358 (\pm 0.131)	0.367 [0.186]

--- Fin de la Generación de Datos para Tablas ---

ANEXO 5

(OTRO TIPO DE APLICACIÓN)

--- Iniciando Simulación de Clasificación (Procesando 39 muestras) ---

