



---

# **Universidad de Valladolid**

## **TRABAJO DE FIN DE GRADO**

## **MENCIÓN DE EDUCACIÓN FÍSICA**

**RELACIÓN ENTRE ESTADOS DE ATRACCIÓN Y RECHAZO ANTE EXPLICACIONES  
DE MATEMÁTICAS Y EXPLICACIONES DE LENGUA: ESTUDIO A PARTIR DE UN  
CLASIFICADOR DE SEÑALES EEG CON RANDOM FOREST**

**FACULTAD DE EDUCACIÓN Y TRABAJO SOCIAL**

***GRADO EN MAGISTERIO DE EDUCACIÓN PRIMARIA***

**Alumno: Brais Castro González**

**Tutor UVa: Alfonso García Monge**

**CURSO 2024/25**

## ÍNDICE DE CONTENIDOS

|  |    |
|--|----|
| 1. INTRODUCCIÓN.....   | 3  |
| 2. FUNDAMENTACIÓN TEÓRICA.....                                     | 3  |
| 2.1 LA IMPORTANCIA DE LAS EMOCIONES EN EL APRENDIZAJE.....         | 3  |
| 2.2 EMBODIED EDUCATION.....  | 4  |
| 2.3 ROL DEL DOCENTE Y NARRATIVA.....                               | 5  |
| 2.4 CONEXIÓN CON EL NEUROFEEDBACK Y LOS ELECTROENFECALOGRAMAS..... | 5  |
| 3. OBJETIVO.....   | 5  |
| 4. METODOLOGÍA.....  | 6  |
| 5. RESULTADOS.....   | 9  |
| 6. CONCLUSIÓN.....   | 17 |
| 7. REFERENCIAS.....  | 19 |
| 8. ANEXOS.....   | 20 |

## **1. INTRODUCCIÓN**

Este trabajo 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.

Por otro lado, este enfoque resalta el papel del cuerpo del 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.

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. FUNDAMENTACIÓN TEÓRICA**

### **2.1. La importancia de las emociones en el aprendizaje.**

Numerosos estudios reflejan que las emociones juegan un papel fundamental en el proceso de aprendizaje, e influyen principalmente en aspectos como la atención, la memoria y la motivación. A modo de ejemplo sobre uno de estos, según Hattie (2009), desde una perspectiva en donde el alumnado experimenta emociones positivas se puede llegar a propiciar un entorno ideal para el procesamiento de información generando esto un aprendizaje significativo, sin embargo, desde un enfoque de emociones negativas, pueden derivar en este una desconexión e incluso aspectos como la ansiedad.

Esta actividad cerebral relacionada con los estados emocionales puede recogerse a través de electroencefalogramas (EEG) empleando la tecnología para evidenciar así el papel de estas durante la experiencia de aprendizaje (Zamora García, 2020).

### **2.1.1. Relación entre la atención, la motivación y las sensaciones de atracción-rechazo.**

Una vez comprendido el papel esencial de las emociones dentro del aprendizaje, necesitamos comprender como estas mismas interactúan con otros aspectos como la atención y la motivación.

Según Wimmer et al. en 2018, los términos de atención y de motivación están estrechamente ligados a las respuestas afectivas de atracción-rechazo. Cuando partimos desde un estímulo positivo, se activa un sistema de aproximación que fomenta la implicación y concentración, por el contrario, si partimos desde uno negativo o de rechazo, se activa un sistema de evitación.

Estos hechos se han estudiado en laboratorios sobre motivación y metas de logro, aquí se observaron cómo las respuestas emocionales afectan a la conducta ante situaciones académicas (Wimmer et al., 2018).

## **2.2 Embodied Education.**

### **2.2.1 Breve definición de la educación corporeizada.**

Una vez comprendemos la acción de la emoción, la atención y de la motivación, comenzamos a reflexionar sobre posibles enfoques pedagógicos en donde el cuerpo sea un agente activo dentro del propio proceso educativo.

Según lo planteado por Sainz, Rodríguez y Santonja Medina (2010) sobre la “*Embodied Education*”, también conocida como educación corporeizada, el concepto del conocimiento se construye progresivamente y mediante un papel activo del cuerpo, la experiencia sensorial y de la propia cognición (rechazando la teoría de que el conocimiento se construye exclusivamente desde lo cognitivo).

Esta definición valora los aspectos emocionales, sensoriales y gestuales como vías para adquirir conocimientos, los cuales los obtendríamos a través de la interacción con el entorno y de los propios movimientos corporales promoviendo así un aprendizaje más profundo.

## **2.3 Rol del docente y narrativa.**

### **2.3.1 Impacto del uso del cuerpo y los gestos por parte de los docentes en la transmisión de conocimientos.**

Una vez consideramos la importancia de la “*Embodied Education*”, debemos hacer hincapié en la forma de expresarse corporalmente del propio docente en el aula.

El docente, empleando el cuerpo mediante gestos o expresiones faciales, ayuda al alumnado a comprender el mensaje de una forma más clara y fortalece a su vez el vínculo emocional con estos mismos (Wimmer et al., 2018). Además de transmitir información de esta manera, se genera a la misma vez una experiencia vivencial del conocimiento, favoreciendo así una atención activa.

## **2.4 Conexión con el Neurofeedback y los Electroencefalogramas.**

### **2.4.1 Relevancia de los estados emocionales en el comportamiento humano.**

Finalmente, profundizando en esta perspectiva, las herramientas tecnológicas juegan un papel clave para realizar estudios objetivos a cerca de la cognición y de las emociones.

Según Zamora García, 2020; los estados emocionales influyen directamente en nuestras decisiones, acciones y procesos de aprendizaje. Gracias al EEG (electroencefalograma), podemos detectar porcentualmente los estímulos que provocan ciertas activaciones específicas en el cerebro, en este caso relacionadas con aspectos de atracción rechazo. Mediante estas herramientas podemos comprender de forma objetiva la relación entre cognición y estados afectivos, y han sido empleadas con éxito en el reconocimiento de emociones mediante técnicas avanzadas como el “*deep learning*” (Zamora García, 2020).

## **3. OBJETIVO**

El objetivo principal es generar un clasificador de señales a partir de datos electroencefalográficos tomados de estados de atracción y rechazo de estímulos visuales y sonoros sobre discursos de contenidos matemáticos, y comprobar si ese clasificador es útil para clasificar nuevas señales de estados de atracción y rechazo, pero observando y escuchando discursos de contenidos de lengua.

#### 4. METODOLOGÍA

**Registro:** Se grabaron señales EEG de 6 participantes de entre 20 y 30 años, que dieron su consentimiento, mientras experimentaba condiciones diseñadas para inducir "atracción" y "rechazo" (observando vídeos breves sobre una explicación de un docente en las áreas de matemáticas y lengua, primero de una forma más abstracta y posteriormente de una más concreta). Para esto, se hacía una toma de datos como protocolo con un minuto y medio previo de ojos cerrados para no verse influenciado por otros estímulos, se pusieron el gorro "*Emotiv Flex*" de 32 canales y 128 Hz. empleando sensores de cloruro de plata y conductividad facilitada por gel.

**Preprocesado de las señales:** Los datos se analizaron con "*EEG Lab*" que es una "toolbox" o herramienta del programa "*Matlab*". Se señalizaron los 32 canales y se hizo una localización espacial de estos, posteriormente le pasábamos un filtro de paso alto a 0.5 Hz. y se pasó un filtro de paso bajo a 46,8 Hz.

Se aplicó un corrector de artefactos automático con la función ASR (*artifact subspace*) de *EEG Lab*, aplicamos una "re-referenciación" promediada de la señal, se aplicó el plugin *ICA Label* en donde se quitaron los componentes que no correspondían con la actividad cortical (ICA los identificaba como actividad muscular, parpadeos u otros). Tras pasar ICA se "re-referenciaban" los datos.

A continuación, se hizo un análisis preliminar de los datos a través de la función "study" de *EEG Lab* en la que se compararon los espectros de potencia de las condiciones (visual atracción-rechazo, por ejemplo, en relación con las áreas de matemáticas y lengua).

**Extracción de Características:** Para que el ordenador pudiera analizar las señales, extrajimos de pequeños segmentos de EEG varias 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 y 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.

**Clasificación de señales:** Se utilizó un clasificador de señales supervisado con el modelo “*Random Forest*”.

### Análisis de características mediante el modelo de 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 vista 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 pruebas independientes y de 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.

## Entrenamiento del Clasificador

- **Aprendizaje:** Entrenamos el modelo de Bosque Aleatorio con una gran parte de nuestros datos de características y sus etiquetas correspondientes ("atracción" o "rechazo"). 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) y otra parte, que el modelo no vio durante el aprendizaje, se reservó para evaluarlo después (conjunto de prueba).

**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 se han identificado de una forma correcta.
- 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 esta técnica. Esto implica repetir el proceso de entrenamiento y prueba varias veces usando diferentes porciones de los datos para entrenar y probar en cada repetición. Después,

calculamos el rendimiento promedio, lo que nos da una estimación más fiable de cómo funcionaría el modelo con datos completamente nuevos.

## **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.

## **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 (lengua concreto/abstracto de los participantes: Manuel, Rubén, Daniela, Jairo...) que sabíamos que correspondía a una condición de "atracción" o "rechazo" en función de la persona. El objetivo era ver si el modelo podía generalizar y clasificar correctamente estos nuevos datos.

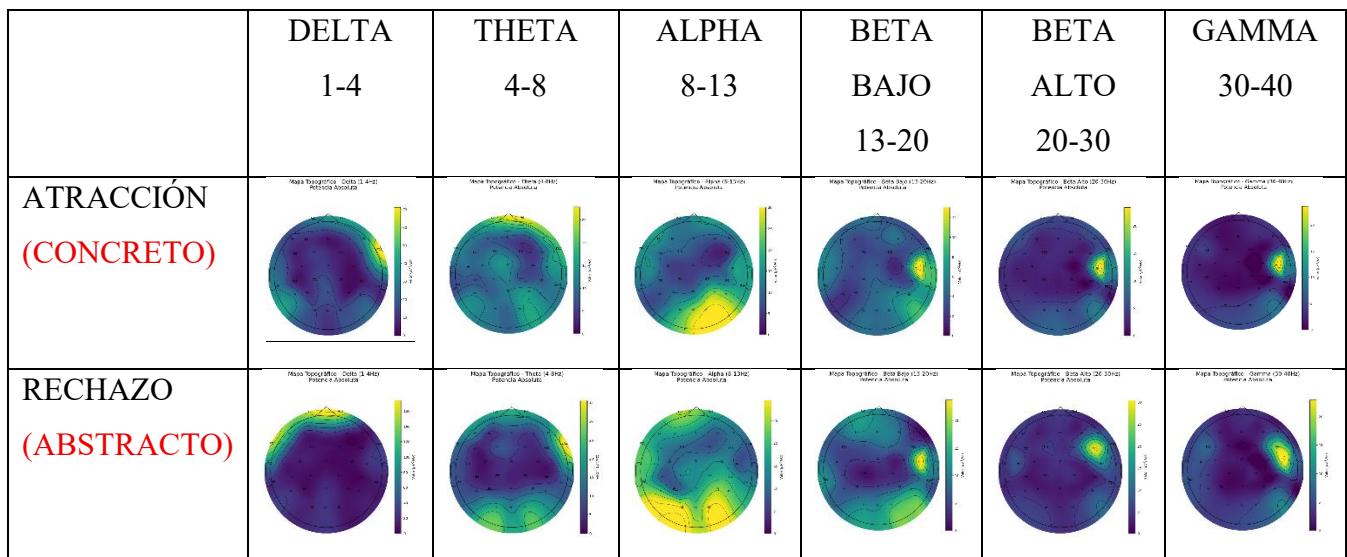
**Simulación de Interfaz:** Para ilustrar una posible aplicación práctica, desarrollamos una **demostración visual** (simulada dentro de nuestro entorno de análisis, *Google Colab*). Esta demostración cargaba el modelo entrenado, procesaba segmentos de datos nuevos (representados por sus características), y mostraba la clasificación resultante ("atracción" 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**

### **MAPAS TOPOGRÁFICOS**

A modo de introducción de los resultados comienzo introduciendo una tabla de mapas cerebrales empleando los datos de 6 personas y haciendo una media sobre estos reaccionando a una explicación más atractiva (o concreta) y a una más sobria y desinteresada (o abstracta).

Adjunto la tabla a continuación:



Con esta tabla podemos observar mapas de calor cerebrales y analizar, mediante estos, los patrones de delta, theta, alpha, beta bajo, beta alto y gamma respecto a dos estados, primero en un estado de atracción y posteriormente en un estado de rechazo.

En este caso observamos como el cerebro se activa más en las frecuencias de theta, alpha principalmente y beta bajo (aquellas zonas con los colores más claros), sobre las zonas temporales (temporal/parietal en ocasiones) y occipitales principalmente, en algún caso como en delta y theta también destaca la zona frontal. Estas bandas de frecuencias cerebrales theta, alpha y beta bajo corresponden a distintos rangos de ondas cerebrales que reflejan diferentes estados de conciencia, atención y actividad mental.

#### RANDOM FOREST

El modelo de **Random Forest (el entrenamiento)** aprende a distinguir entre dos clases: **atracción y rechazo**, en función de los datos que le has proporcionado (por ejemplo, la actividad cerebral durante un estímulo). Luego, se le pide que **prediga si nuevos datos pertenecen a una u otra clase**. Esta predicción se compara con la respuesta real para evaluar su rendimiento.

Vamos a ver qué significan los valores que nos devuelve el modelo:

“Accuracy” (precisión global): si por ejemplo nos devuelve 0.94, significa que el modelo acierta el 94% de los casos (de cada 100 predicciones 94 son correctas).

### El reporte de clasificación:

Accuracy: 0.9405940594059405

|           | Precisión | Recall | f1-score | Support |
|-----------|-----------|--------|----------|---------|
| Atracción | 0.90      | 0.98   | 0.94     | 47      |
| Rechazo   | 0.98      | 0.91   | 0.94     | 54      |

| Métrica   | ¿Qué indica?  | Atracción | Rechazo |
|-----------|---|-----------|---------|
| Precisión | De todos los casos que el modelo dijo que eran "atracción", ¿cuántos lo eran realmente? | 0.90      | 0.98    |
| Recall    | De todos los casos que realmente eran "atracción", ¿cuántos detectó bien?               | 0.98      | 0.91    |
| f1-score  | Equilibrio entre precision y recall   | 0.94      | 0.94    |
| Support   | Número de casos reales de cada clase  | 47        | 54      |

Aquí podemos observar varias cuestiones como, por ejemplo:

- En cuanto a la precisión, el modelo detecta casi perfectamente el rechazo sobre la atracción.
- En general reconoce ambos valores de atracción y rechazo con un porcentaje parejo.
- En el caso del rechazo, se equivocó en prácticamente 1 de cada 10 casos.

### Reporte de resultados de Validación Cruzada e Importancia de Características:

Resultados de Validación Cruzada (Accuracy) :

Scores: [0.92079208 0.96039604 0.92079208 0.95049505 0.95]

Media: 0.9404950495049504

Desviación Estándar: 0.016509437106609633

Importancia de las Características:

|     | característica   | importancia |                        |
|-----|------------------|-------------|------------------------|
| 149 | T8_Gamma         | 0.042859    | Brodmann area 22 right |
| 341 | T8_Gamma_ZScore  | 0.034286    | Brodmann area 22 right |
| 365 | FC2_Gamma_ZScore | 0.030958    | Brodmann area 6 right  |
| 269 | CP1_Gamma_ZScore | 0.029348    | Brodmann area 7 left   |

|     |                      |          |                        |
|-----|----------------------|----------|------------------------|
| 328 | CP6_High Beta_ZScore | 0.023854 | Brodmann area 39 right |
| ..  | ..                   | ..       | ..                     |
| 324 | CP6_Delta_ZScore     | 0.000088 |                        |
| 369 | F4_Low Beta_ZScore   | 0.000075 |                        |
| 296 | Oz_Alpha_ZScore      | 0.000019 |                        |
| 319 | CP2_Theta_ZScore     | 0.000000 |                        |
| 34  | FC1_High Beta        | 0.000000 |                        |

Tomando como referencia los trabajos de Scrivener y Reader (2021), estas posiciones se corresponderían con distintas áreas funcionales del cerebro, así tendríamos que la actividad en “x” tendrían las siguientes funciones (adjunto ejemplos):

- El área temporal derecha en la banda de frecuencia gamma (T8\_Gamma) se relaciona con el área 22 de Brodmann que se encarga de monitorear el habla, palabras que se repiten, razonamiento deductivo, generación de palabras (Ardila, Bernal, & Rosselli, 2016).
- El área fronto central derecha (o prefrontal mejor traducido) (FC2\_Gamma\_ZScore) muestra relación con el área 6 de Brodmann, la cual destaca por: la planificación de la acción, aprendizaje activo, movimientos imaginados, respiración voluntaria, palabras, idioma, comprender el habla, voces humanas, memoria de trabajo, autorreflexión, observar acciones (neuronas espejo), cálculo (Naghavi & Nyberg, 2005).
- El área centro parietal izquierda (CP1\_Gamma\_ZScore) se vincula al área 7 de Brodmann que se encarga principalmente de la autorreflexión, la capacidad de imagen, de recordar episodios, del idioma y de la literalidad (Naghavi & Nyberg, 2005).
- En cuanto al área centro parietal derecha (CP6\_High Beta\_ZScore) está relacionada con el área 39 de Brodmann que se centra en el ejecutivo, la secuencia de acción y en la atención espacial (Naghavi & Nyberg, 2005).

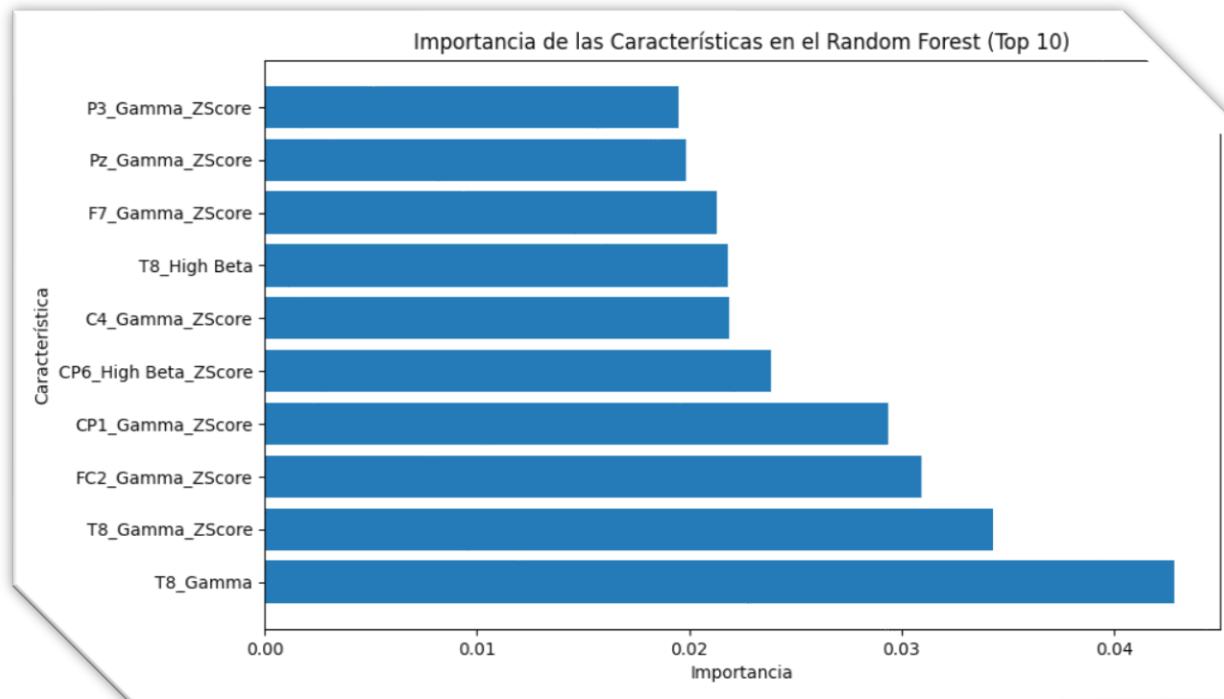


Imagen 1: *Gráfico de relevancia*

De una forma más concreta destaco en relación a mi estudio el área de Brodmann 6, el cual está implicado en los cinco dominios (lenguaje, atención, memoria, semántico, motor) y se informó de forma sistemática como central para la producción del lenguaje, la atención, la memoria y el procesamiento motor/de acción. Y otros, como el área de Brodmann 22 y el 39, que son considerados cada uno clave y central en dos dominios (procesamiento del lenguaje y procesamiento semántico).

La validación cruzada es una forma de comprobar si el entrenamiento es fiable y generalizable. En lugar de entrenarlo y evaluarlo una sola vez, se divide el conjunto de datos en 5 partes (o “pliegues”), entrenando el modelo 5 veces y evaluando en una parte diferente cada vez.

En este ejemplo podemos observar:

| Métrica                                   | Valor                 | Interpretación  |
|---|-----------------------|---|
| <b>Puntuaciones individuales (Scores)</b> | 5 valores de accuracy | El modelo ha estado cerca de acertar en todos los casos.  |
| <b>Media (accuracy promedio)</b>          | 0.9404<br>(94.04%)    | Es muy alto. Indica que el modelo es muy preciso.   |
| <b>Desviación estándar</b>                | 0.016                 | Mide cuánto varían los resultados entre pliegues. Una desviación baja significa que el modelo es estable y consistente. |

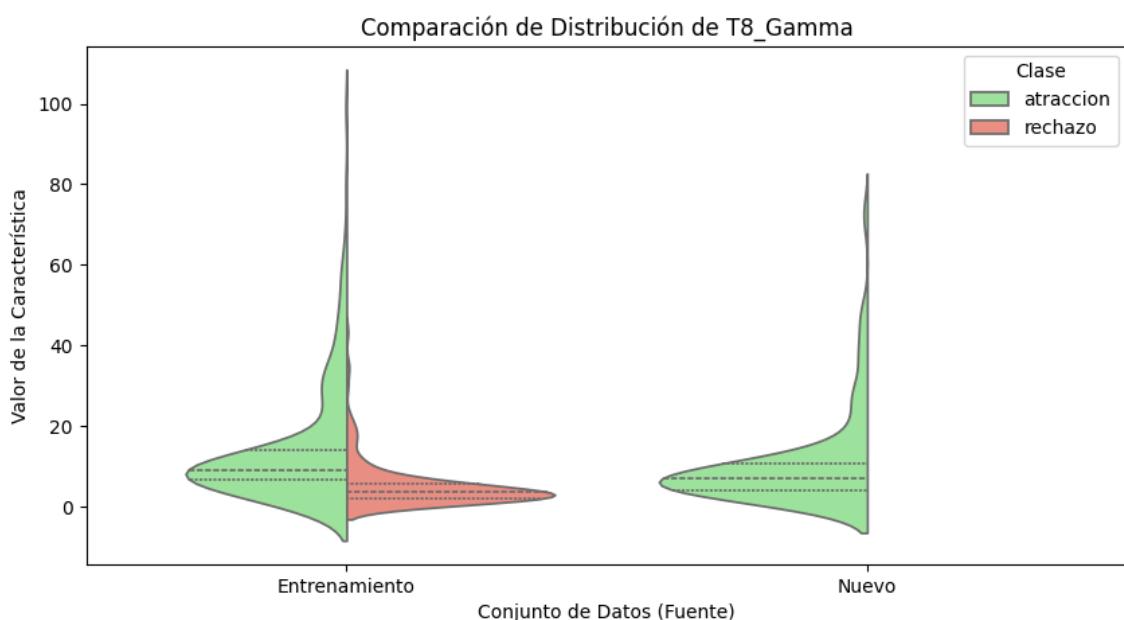
En este ejemplo, el modelo tiene un rendimiento muy bueno (quizá excesivo). Se comporta de manera muy similar en todos los subconjuntos de datos, lo que indica que probablemente no está sobre ajustado y es capaz de generalizar bien a nuevos datos.

El modelo también nos dice qué variables (características) fueron más relevantes para tomar decisiones (para discriminar entre los estados de “atracción” y “rechazo”). Estas pueden ser, por ejemplo, potencias cerebrales (bandas Gamma, Beta, etc.) en determinados electrodos. El modelo utiliza más algunas señales cerebrales que otras para decidir si hay atracción o rechazo. En este caso, señales en zonas frontales y temporales derechas (como T8, FC2) y en frecuencias Gamma o Beta han sido las más útiles.

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

Algunas características como centro parietal derecha (CP2\_Theta) o fronto central izquierda (FC1\_High Beta) no han aportado nada al modelo. Esto no significa que sean malas, sino que, para este conjunto de datos y este tipo de estímulo concreto, no han sido relevantes.

Una vez realizado el entrenamiento, debemos ponerlo a prueba con nuevos datos para verificar la fiabilidad de este. Lo probaremos con datos extraídos de las situaciones escuchando un discurso de lengua más atractivo de cara al alumnado (más concreto) o de lo contrario más insulto y sobrio (abstracto), en este caso adjunto un ejemplo de la comparación con los datos de la explicación más concreta:



## Imagen 2: Comparación con la explicación de lengua atractiva/concreta

Este gráfico compara la distribución de las 5 características que hemos visto en el *Random Forest* y que mejor diferencian los estados de atracción y de rechazo (ver anexo para los 4 ejemplos restantes). Entre ellas, pondré como ejemplo una de las más significativas que ha resultado ser la distribución del área temporal derecha en la banda gamma (T8\_Gamma) entre dos conjuntos de datos: a la izquierda podemos observar los datos del conjunto de entrenamiento (datos generales como grupo, sobre matemáticas concreto/abstracto) y a la derecha se forman los nuevos datos sobre el grupo, en una situación en donde las personas que hemos analizado escuchan una explicación del área de lengua de una forma más atractiva de cara al alumnado, más concreta, la cual se clasifica haciendo una media y según el entrenamiento como atracción finalmente.

¿Qué observamos? Diferencias claras en el entrenamiento:

En el primer conjunto del grupo (en el entreno) observamos que los valores del área temporal derecha de la frecuencia gamma (T8\_Gamma) son ligeramente más altos para la atracción que para el rechazo.

Distribución en los nuevos datos del grupo:

En los nuevos valores observamos como se ajustan más a los de la atracción que a los del rechazo, esto refuerza la decisión del modelo al clasificar las muestras del grupo en lengua concreto como atracción.

Diferencia numérica:

Mientras que la media de atracción en matemáticas del grupo se sitúa en sobre un valor de 10, el rechazo se establece sobre un valor de 6 aproximadamente. En comparación a estos datos, los nuevos de lengua concreto se sitúan sobre el medio, con un valor aproximado de 8 pero estableciendo un patrón muy similar al de atracción del entrenamiento.

En este caso, haciendo un breve resumen, los nuevos datos en la característica del área temporal derecha en la frecuencia gamma (T8\_Gamma) se parecen más a los valores típicos del estado de atracción observados durante el entrenamiento, aunque con una tendencia algo más baja. Esto apoya la clasificación del modelo, aunque también sugiere una posible respuesta fisiológica diferente frente a los estímulos presentados.

Logramos presenciar con esto, como los datos del entrenamiento del clasificador, una vez le añades nuevos datos que desconoce en un principio (en este ejemplo una explicación más concreta o llamativa en el área de lengua) es capaz de corroborar si produce en el individuo un estado de atracción o de rechazo en relación a los datos con los que ya estaba entrenada previamente.

Finalmente, a modo de síntesis visual sobre este proyecto, adjuntamos otro código al programa de *Google Colab* para generar una interfaz que muestra los datos del clasificador en tiempo real (en lapsos de tiempo cada 2 segundos) para realizar una simulación y poner de nuevo a prueba si esta muestra está más cerca del estado de atracción o del estado del rechazo, por el contrario. Adjunto un ejemplo:

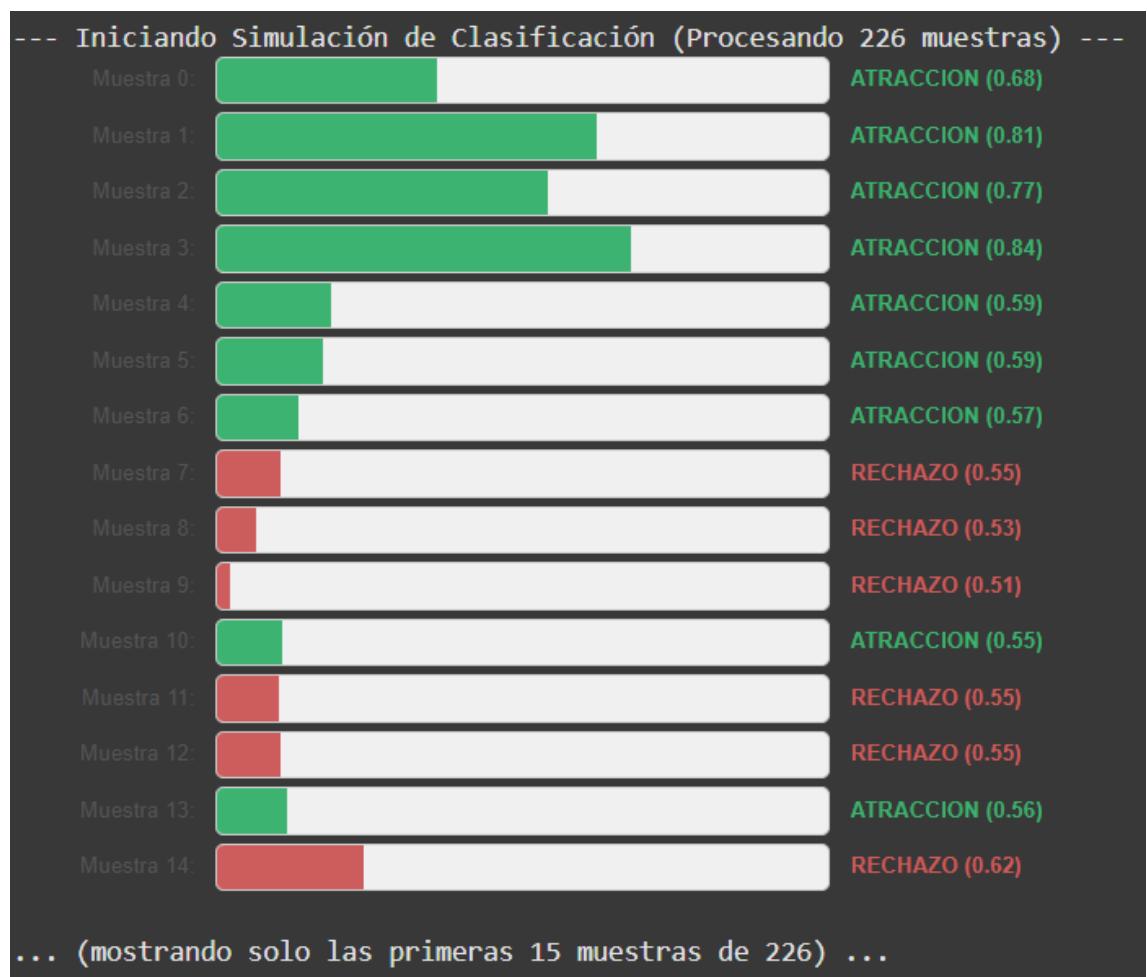


Imagen 3: *ejemplo lengua abstracto – Manu*

Aquí podemos observar un ejemplo a raíz del entreno, de cara a una posible futura aplicación, pero añadiendo ahora los datos extraídos de la prueba de lengua abstracto de Manuel. En esta prueba se extraen 226 muestras en total, 1 por cada 2

segundos (de las cuales se muestran 15 en la imagen), que se van analizando en función de si generan una atracción o un rechazo, además de esta prueba extrajimos también los siguientes datos, los cuales son interesantes de comentar:

### **Resumen General**

Total de Muestras Procesadas: **226**

Predicciones 'ATRACCION': **108 (47.8%)**

Predicciones 'RECHAZO': **118 (52.2%)**

---

Confianza Media (Prob. Atracción): **0.489**

Confianza Mín/Máx (Prob. Atracción): **0.045 / 0.980**

A pesar de que pueda parecer difuso en un principio, estos datos nos muestran el resumen total de las muestras que se han procesado. De las 226 muestras nos comenta que 108 han resultado fomentar una atracción hacia la lección de lengua abstracta y 118 han generado un sentimiento de rechazo hacia esta misma.

A continuación, vemos que el proceso no ha resultado ser demasiado preciso, ya que tenemos ejemplos de confianza mínima en valores de 0.045 hasta ejemplos de confianza máxima en 0.980, de esta franja tan extensa sacamos la media de 0.489 de confianza de probabilidad de atracción, lo cual es bastante bajo desde mi punto de vista ya que la confianza media que nos muestra no llega al 50%, aunque debemos de tener en cuenta que las muestras a estudiar se elaboran cada 2 segundos y los pensamientos del agente pueden ir cambiando.

## **6. CONCLUSIÓN**

Hay que tomar con cautela estos resultados dadas las limitaciones de este estudio en cuanto al escaso número de participantes, condiciones de muestreo y debido a la precisión del equipo empleado que puede ser mayor o menor fiable en función del estado de calidad de este.

Partiendo de que el objetivo principal era generar un clasificador de señales a partir de datos electroencefalográficos tomados de estados de atracción y rechazo de estímulos producidos durante una lección de las áreas de matemáticas o lengua, podemos observar:

- Un entrenamiento fiable mediante el clasificador modelo *Random Forest*, ya que los resultados mostraron una confianza fiable y razonable. Además, también pudimos conocer en aquellas áreas en donde se produce una mayor diferenciación entre estos estados de atracción y rechazo.

Sin embargo, un aspecto destacable de estas ha resultado ser que no concuerda a simple vista que la parte que posea una mayor diferencia entre atracción y rechazo sea (acorde con la gráfica del entrenamiento) en el área temporal derecha de la frecuencia gamma (T8\_gamma), ya que en los mapas topográficos podemos observar un patrón bastante similar entre ambos aspectos de atracción y rechazo. Pero, cabe destacar que el clasificador de *Random Forest* es mucho más fiable que los mapas topográficos ya que se basa en una mayor proporción de datos y muestras, por lo que el entrenamiento ha resultado fiable y preciso según los cálculos de la IA y de las declaraciones de las personas antes de realizar la prueba.

- Posteriormente, probamos el clasificador basado en el modelo de *Random Forest* con nuevos datos de un participante escuchando un discurso de lengua más corporeizado e incentivador (concreto).

Estos nuevos datos de lengua se mostraron (en las gráficas de violín) semejantes a los patrones de atracción del entrenamiento, por tanto, podemos concluir que los ha clasificado correctamente.

- Finalmente, a forma de resumen, comprobamos (haciendo un cómputo general sobre como logramos entrenar a la IA) como el clasificador, partiendo de un entrenamiento con datos de atracción y rechazo respecto a dos explicaciones diferentes en el área de matemáticas (una más sobria de cara al alumnado y la otra más motivadora), si le añades nuevos datos que desconoce en un principio (en este ejemplo una explicación más concreta o llamativa en el área de lengua) es capaz de corroborar si produce en el individuo un estado de atracción o de rechazo en relación a los datos con los que ya estaba entrenada previamente. En el caso del ejemplo que adjuntaba anteriormente en la gráfica del violín observamos como los nuevos datos de la lección de lengua más concreta, producían en las personas analizadas un estado de atracción con un patrón muy similar al del entrenamiento.

## 7. REFERENCIAS

- Zamora García, R. (2020). *Reconocimiento de emociones a partir de la actividad eléctrica cerebral con técnicas de deep learning* [Trabajo Fin de Máster, Universidad Nacional de Educación a Distancia (UNED)]. Repositorio Institucional UNED.
- Wimmer, S., Lackner, H. K., Papousek, I., & Paechter, M. (2018). *Goal orientations and activation of approach versus avoidance motivation while awaiting an achievement situation in the laboratory*. Frontiers in Psychology, 9, 2437.  
<https://doi.org/10.3389/fpsyg.2018.02437>
- Alfredo Ardila, Byron Bernal, Monica Rosselli (2016). *How Localized are Language Brain Areas? A Review of Brodmann Areas Involvement in Oral Language*, Archives of Clinical Neuropsychology, Volume 31, Issue 1, February 2016, Pages 112–122, <https://doi.org/10.1093/arclin/acv081>
- P. Molenberghs, R. Cunnington, J. Mattingley (2012). *Brain regions with mirror properties: A meta-analysis of 125 human fMRI studies*. Neuroscience and Biobehavioral Reviews. <https://doi.org/10.1016/j.neubiorev.2011.07.004>
- H. Naghavi, L. Nyberg (2005). *Common fronto-parietal activity in attention, memory, and consciousness: Shared demands on integration*. Consciousness and Cognition. <https://doi.org/10.1016/j.concog.2004.10.003>
- 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>
- Sainz de Baranda, P., Rodríguez García, P. L., & Santonja Medina, F. (2010). *Efectos sobre la disposición sagital del raquis de un programa de educación postural en Educación Física de Primaria*. Apunts: Educación Física y Deportes, 102, 16–21. Recuperado de <https://revista-apunts.com/wp-content/uploads/2020/11/016-021-2.pdf>.

## 8.ANEXOS

### 8.1 MATEMÁTICAS CONCRETO-ABSTRACTO (Random Forest)

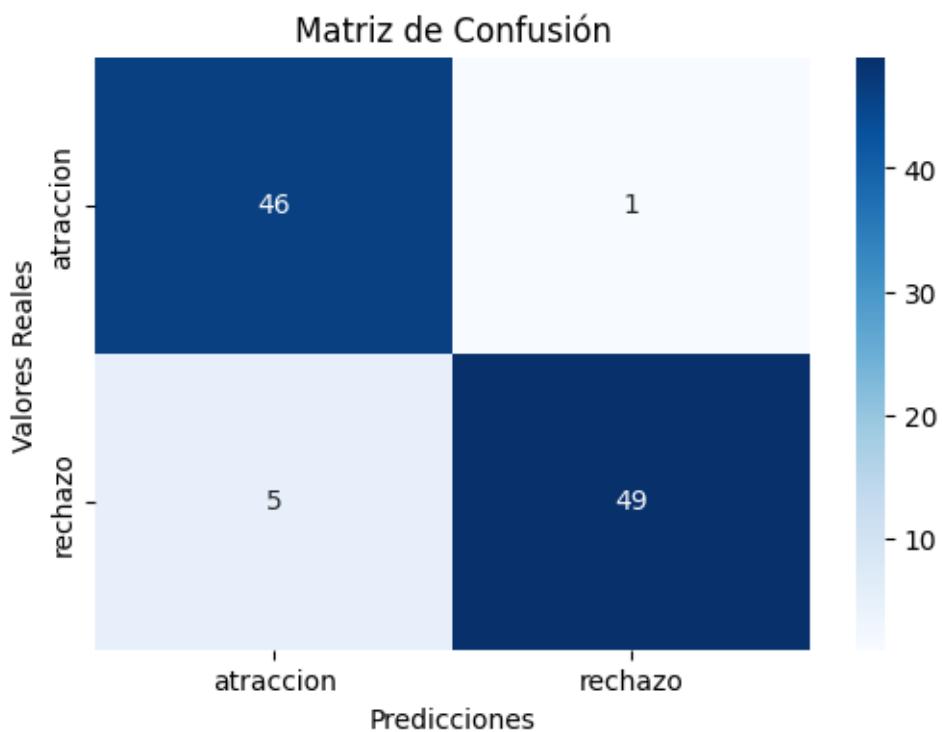
Accuracy: 0.9405940594059405

Reporte de Clasificación:

|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| atraccion    | 0.90      | 0.98   | 0.94     | 47      |
| rechazo      | 0.98      | 0.91   | 0.94     | 54      |
| accuracy     |           | 0.94   |          | 101     |
| macro avg    | 0.94      | 0.94   | 0.94     | 101     |
| weighted avg | 0.94      | 0.94   | 0.94     | 101     |

Matriz de Confusión:

```
[[46  1]
 [ 5 49]]
```



Resultados de Validación Cruzada (Accuracy):

Scores: [0.92079208 0.96039604 0.92079208 0.95049505 0.95 ]

Media: 0.9404950495049504

Desviación Estándar: 0.016509437106609633

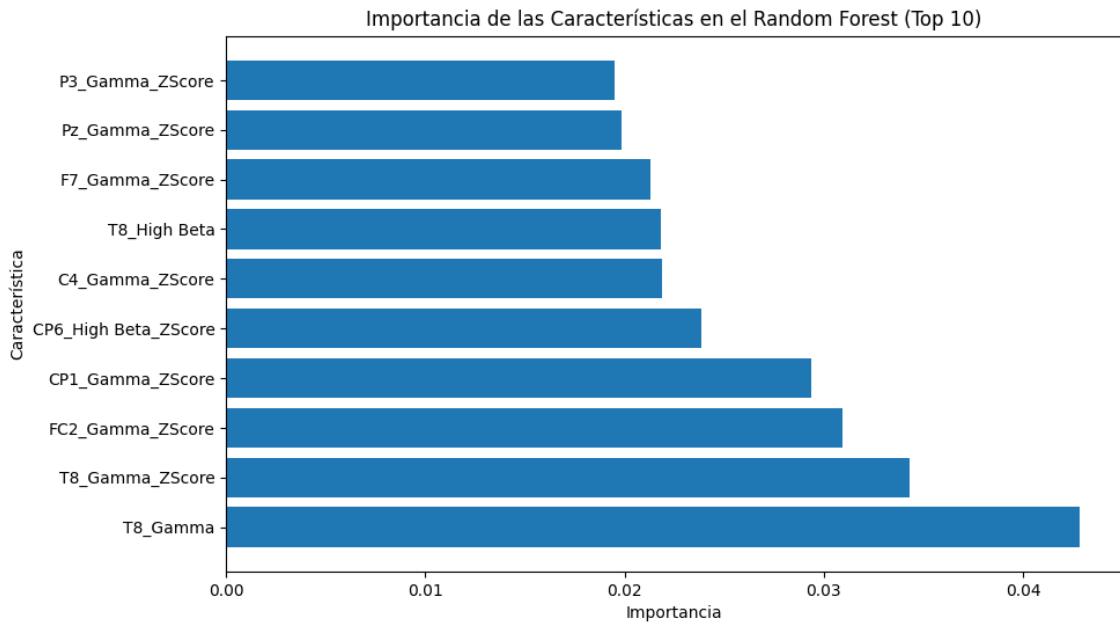
Importancia de las Características:

|     | caracteristica       | importancia |
|-----|----------------------|-------------|
| 149 | T8_Gamma             | 0.042859    |
| 341 | T8_Gamma_ZScore      | 0.034286    |
| 365 | FC2_Gamma_ZScore     | 0.030958    |
| 269 | CP1_Gamma_ZScore     | 0.029348    |
| 328 | CP6_High Beta_ZScore | 0.023854    |
| ..  | ...                  | ...         |
| 324 | CP6_Delta_ZScore     | 0.000088    |
| 369 | F4_Low Beta_ZScore   | 0.000075    |
| 296 | Oz_Alpha_ZScore      | 0.000019    |

```
319    CP2_Theta_ZScore  0.000000
```

```
34     FC1_High_Beta   0.000000
```

[434 rows x 2 columns]



## **8.2 COMPARACIÓN CON LENGUA-CONCRETO GENERAL**

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

Resumen de Predicciones:

prediccion

atraccion 149

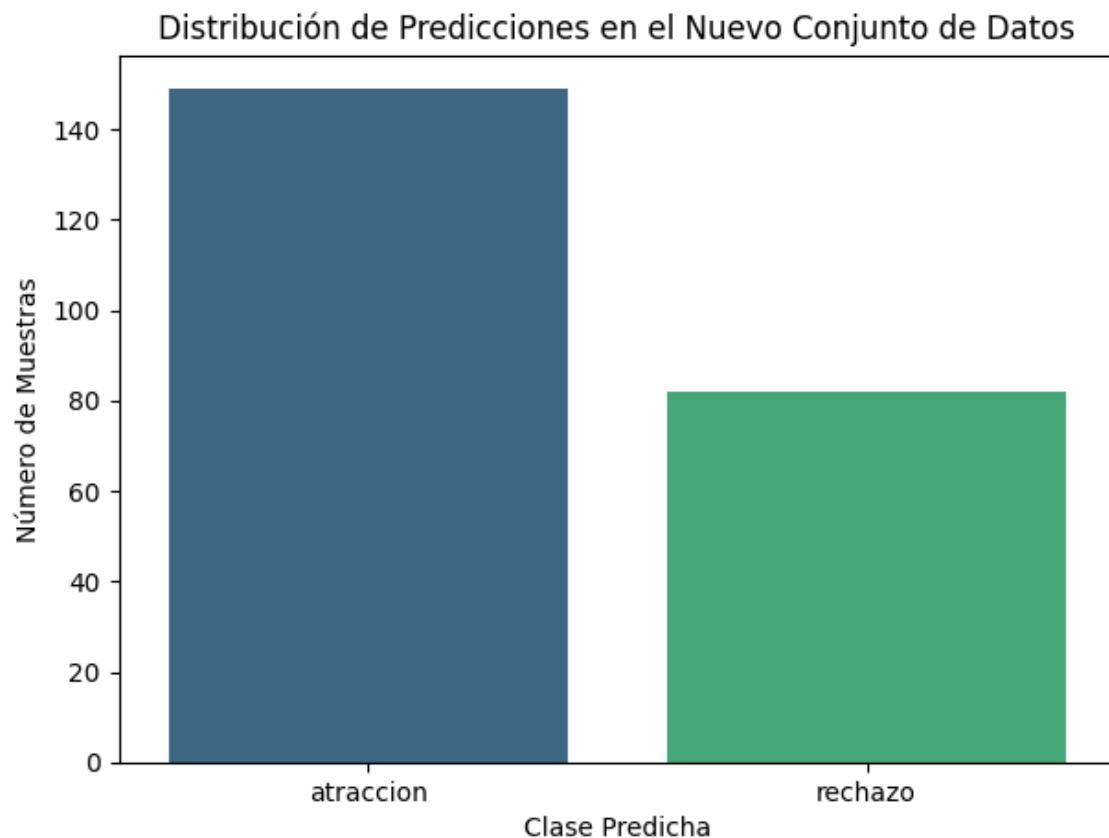
rechazo 82

Name: count, dtype: int64

<ipython-input-5-a3dbc169821c>: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)
```



75 Muestras clasificadas con baja confianza ( $\text{prob} < 0.6$ ):

|   | prediccion | prob_atraccion | prob_rechazo |
|---|------------|----------------|--------------|
| 0 | rechazo    | 0.450000       | 0.550000     |
| 1 | rechazo    | 0.460000       | 0.540000     |
| 3 | rechazo    | 0.480000       | 0.520000     |
| 4 | rechazo    | 0.470000       | 0.530000     |
| 5 | atraccion  | 0.516667       | 0.483333     |

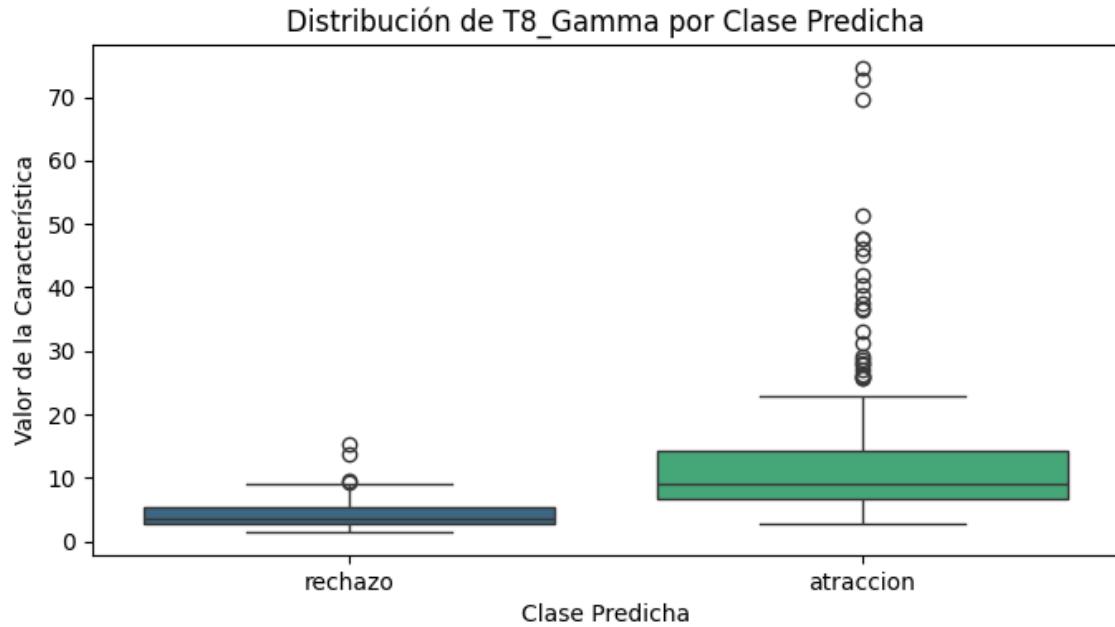
--- Análisis de Características Importantes en Nuevos Datos ---

Visualizando la distribución de las 5 características más importantes:

<ipython-input-5-a3dbc169821c>: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')
```

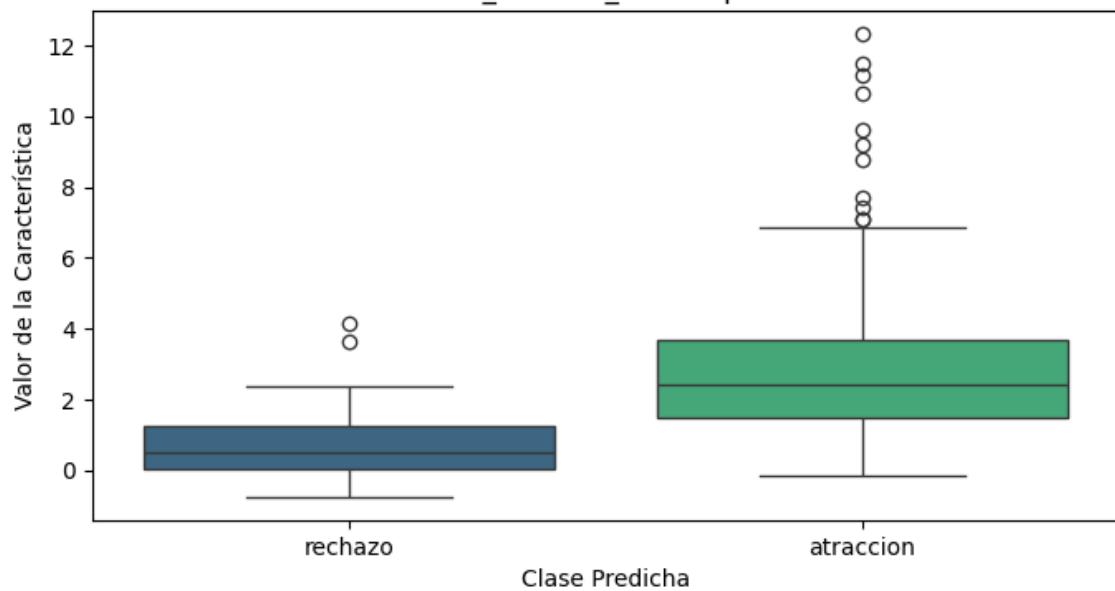


```
<ipython-input-5-a3dbc169821c>:99: FutureWarning:
```

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')
```

Distribución de T8\_Gamma\_ZScore por Clase Predicha

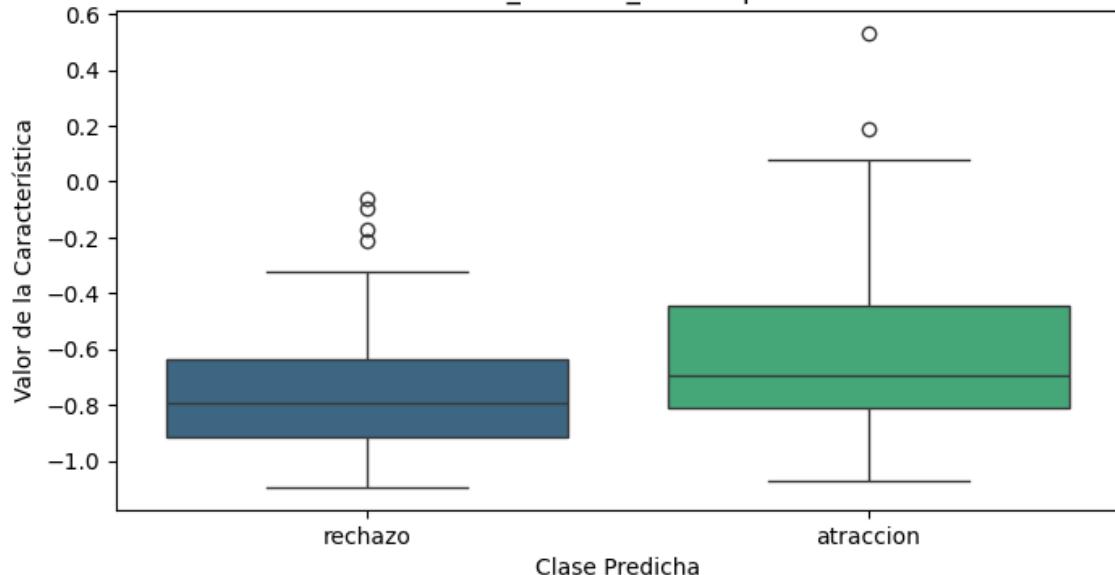


<ipython-input-5-a3dbc169821c>:99: FutureWarning:

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')
```

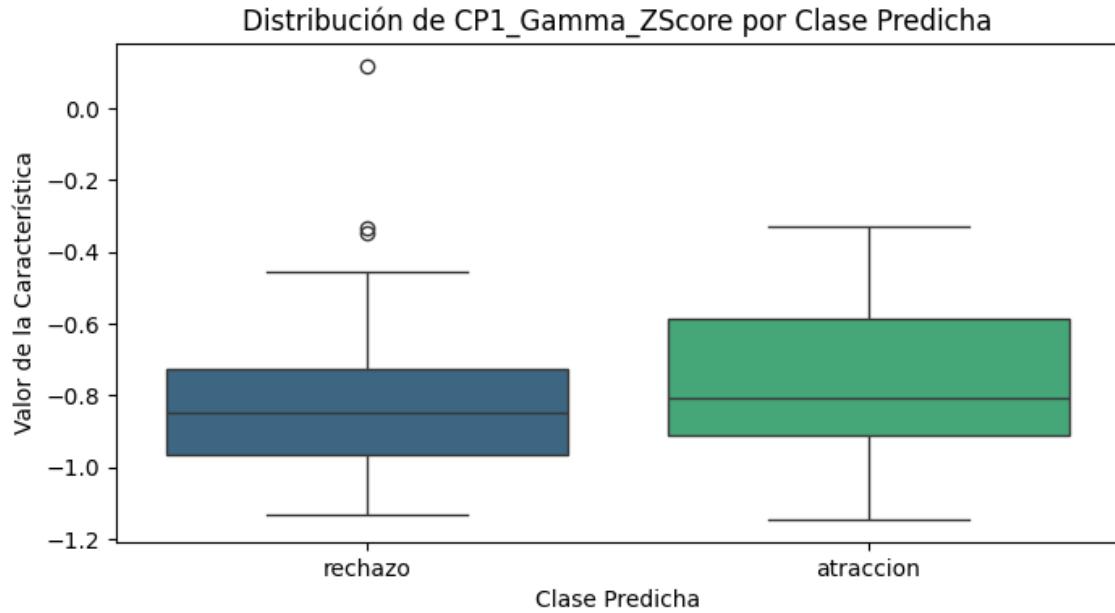
Distribución de FC2\_Gamma\_ZScore por Clase Predicha



<ipython-input-5-a3dbc169821c>: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.

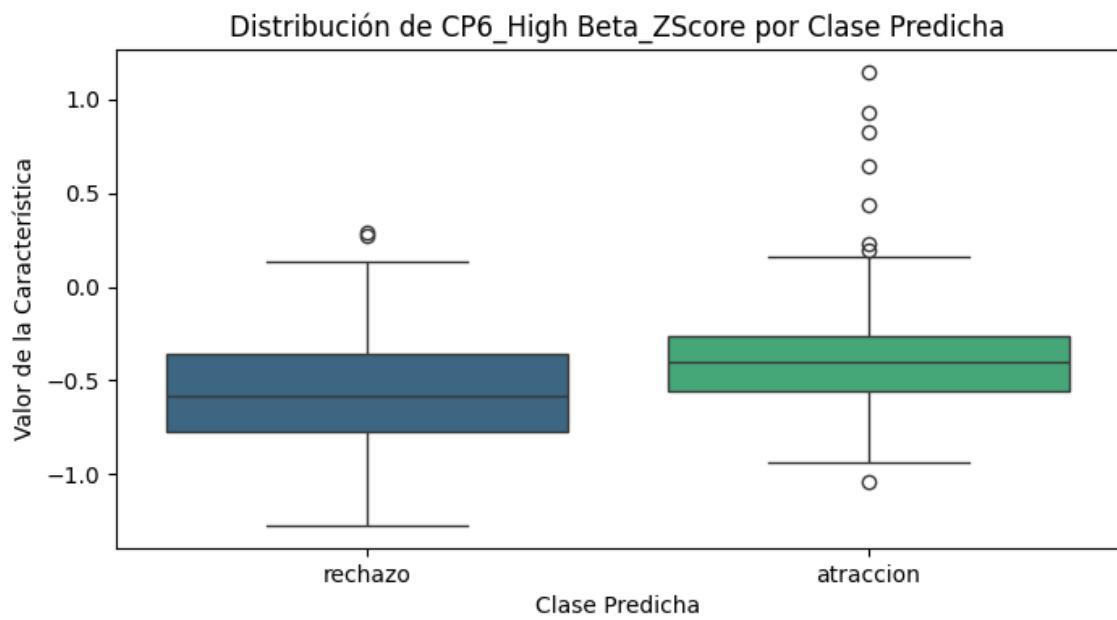
```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



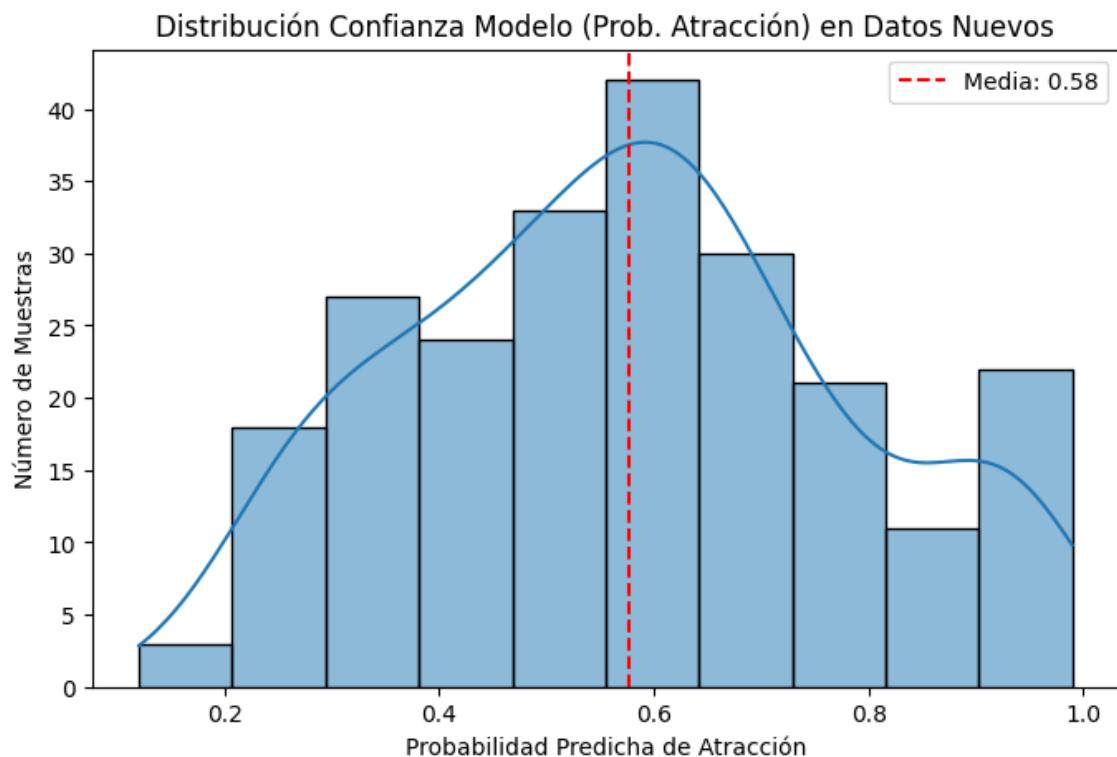
```
<ipython-input-5-a3dbc169821c>:99: FutureWarning:
```

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: 0.576

Mediana: 0.580

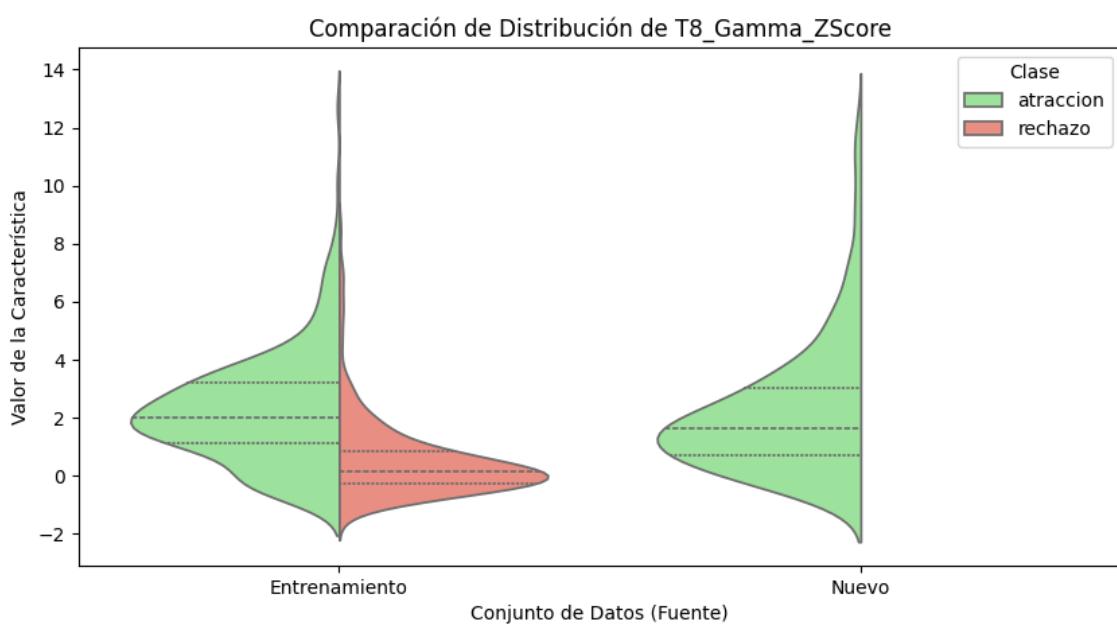
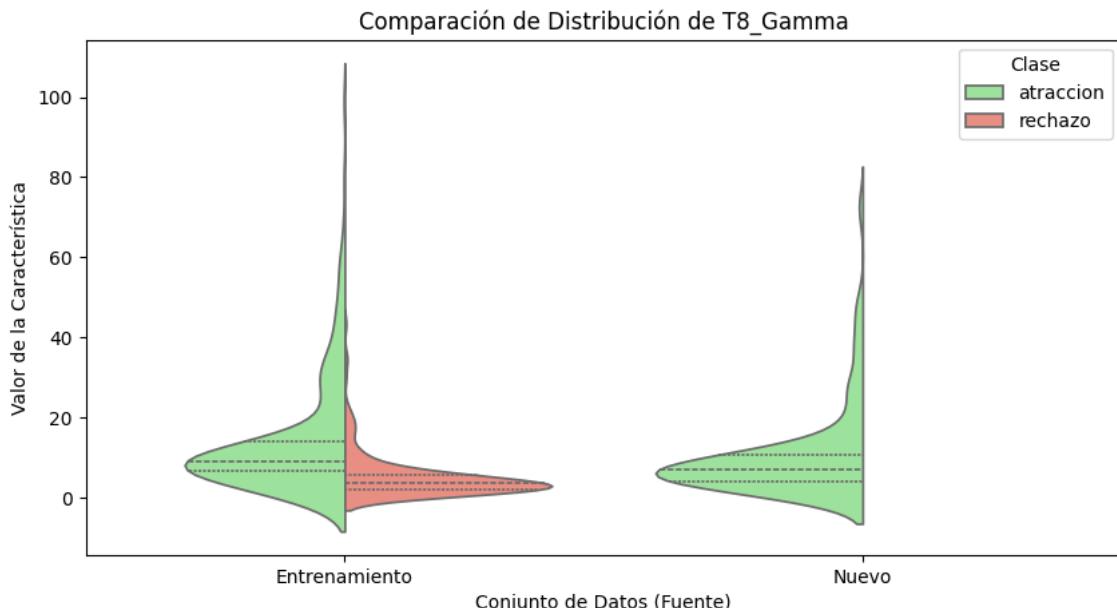
Mínima: 0.120

Máxima: 0.990

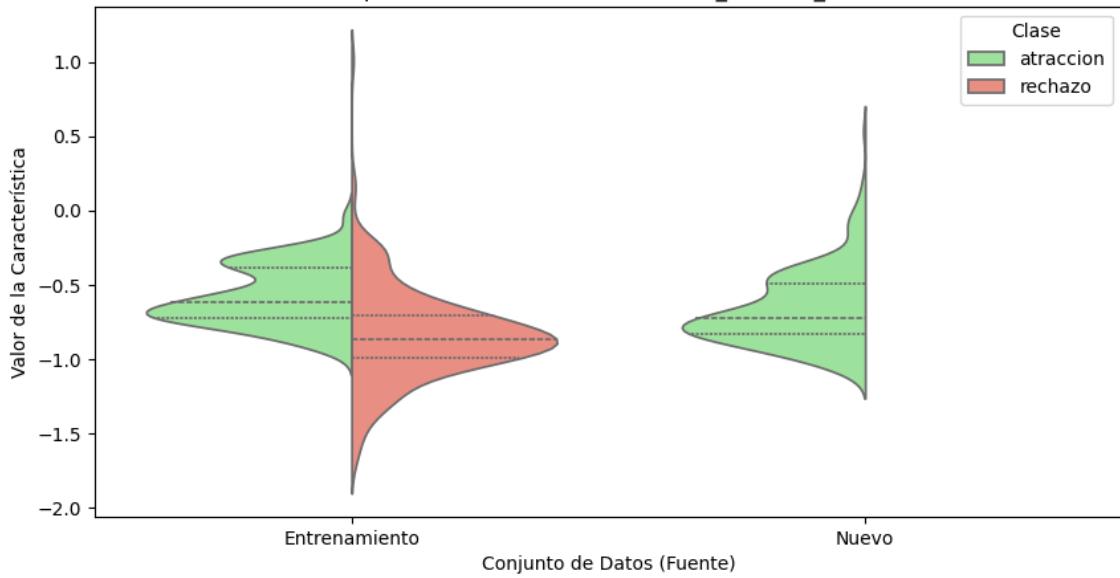
Desv. Estándar: 0.204

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

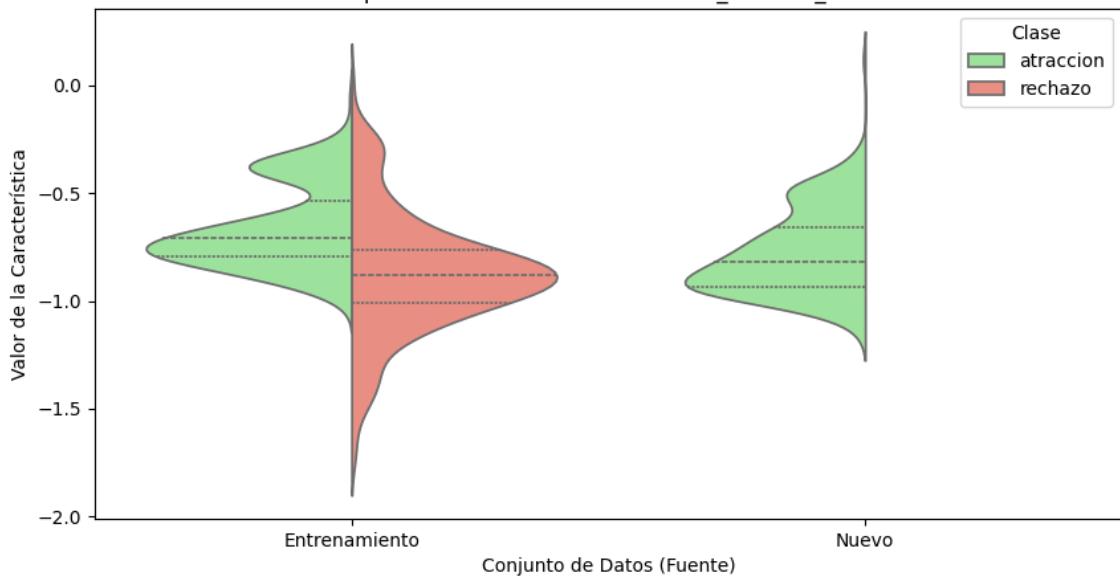
Comparando: Datos Entrenamiento vs Datos Nuevos

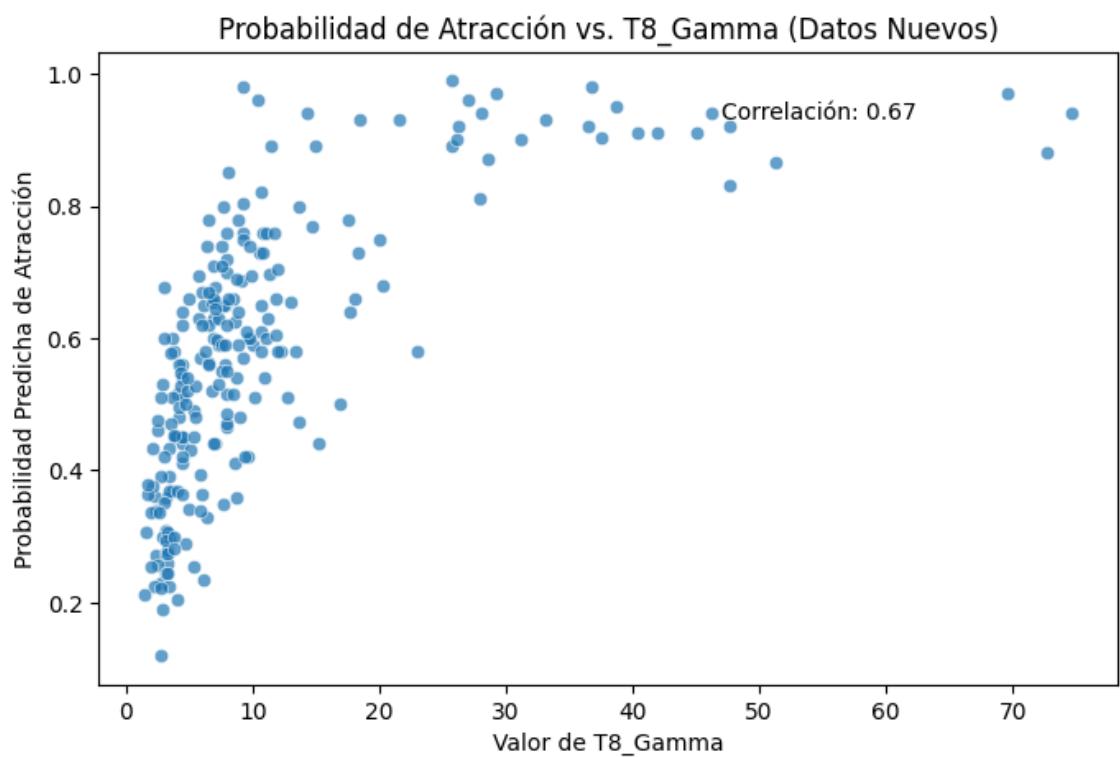
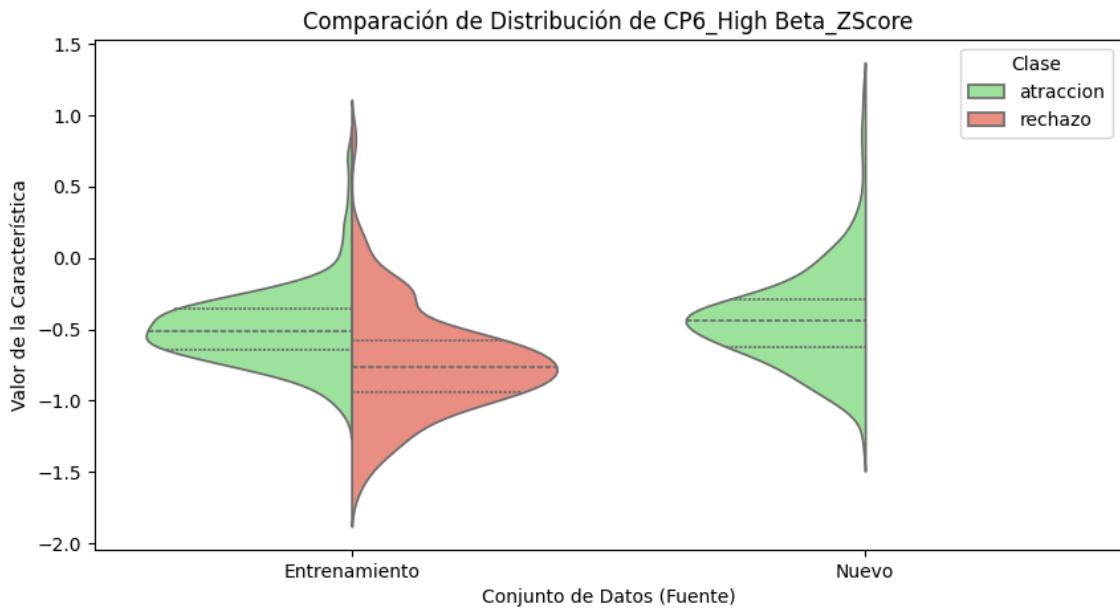


Comparación de Distribución de FC2\_Gamma\_ZScore



Comparación de Distribución de CP1\_Gamma\_ZScore





--- 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   | 0.941 | 0.940 | 0.017 |
| Precisión       | Atraccion | 0.902 | -     | -     |
| Precisión       | Rechazo   | 0.980 | -     | -     |
| Recall          | Atraccion | 0.979 | -     | -     |
| Recall          | Rechazo   | 0.907 | -     | -     |
| F1-Score        | Atraccion | 0.939 | -     | -     |
| F1-Score        | Rechazo   | 0.942 | -     | -     |
| F1 Macro Avg    | General   | 0.941 | -     | -     |
| F1 Weighted Avg | General   | 0.941 | -     | -     |

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

| Ranking | Característica       | Puntuación de Importancia |
|---------|----------------------|---------------------------|
| 1       | T8_Gamma             | 0.0429                    |
| 2       | T8_Gamma_ZScore      | 0.0343                    |
| 3       | FC2_Gamma_ZScore     | 0.0310                    |
| 4       | CP1_Gamma_ZScore     | 0.0293                    |
| 5       | CP6_High Beta_ZScore | 0.0239                    |
| 6       | C4_Gamma_ZScore      | 0.0219                    |
| 7       | T8_High Beta         | 0.0218                    |
| 8       | F7_Gamma_ZScore      | 0.0213                    |
| 9       | Pz_Gamma_ZScore      | 0.0199                    |
| 10      | P3_Gamma_ZScore      | 0.0195                    |

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

Número de Muestras 231  
Media Prob. Atracción 0.576  
Mediana Prob. Atracción 0.580  
Desv. Est. Prob. Atracción 0.204  
Mínima Prob. Atracción 0.120

Máxima Prob. Atracción 0.990

% Muestras Confianza > 0.9 9.5%

% Muestras Confianza < 0.6 54.5%

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

| Característica                                 | Grupo | Media ( $\pm$ Desv. Est.) | Mediana [IQR]  |
|--|-------|---------------------------|----------------|
| T8_Gamma Entrenamiento - Atraccion             |       | 14.441 ( $\pm$ 14.619)    | 9.169 [7.516]  |
| T8_Gamma Entrenamiento - Rechazo               |       | 5.187 ( $\pm$ 5.691)      | 3.521 [3.627]  |
| T8_Gamma Nuevo - Atraccion                     |       | 10.691 ( $\pm$ 11.880)    | 7.080 [6.588]  |
| T8_Gamma_ZScore Entrenamiento - Atraccion      |       | 2.274 ( $\pm$ 1.944)      | 2.003 [2.096]  |
| T8_Gamma_ZScore Entrenamiento - Rechazo        |       | 0.540 ( $\pm$ 1.380)      | 0.154 [1.111]  |
| T8_Gamma_ZScore Nuevo - Atraccion              |       | 2.201 ( $\pm$ 2.274)      | 1.631 [2.314]  |
| FC2_Gamma_ZScore Entrenamiento - Atraccion     |       | -0.575 ( $\pm$ 0.200)     | -0.619 [0.341] |
| FC2_Gamma_ZScore Entrenamiento - Rechazo       |       | -0.837 ( $\pm$ 0.310)     | -0.866 [0.288] |
| FC2_Gamma_ZScore Nuevo - Atraccion             |       | -0.663 ( $\pm$ 0.253)     | -0.727 [0.340] |
| CP1_Gamma_ZScore Entrenamiento - Atraccion     |       | -0.660 ( $\pm$ 0.192)     | -0.708 [0.262] |
| CP1_Gamma_ZScore Entrenamiento - Rechazo       |       | -0.873 ( $\pm$ 0.274)     | -0.881 [0.246] |
| CP1_Gamma_ZScore Nuevo - Atraccion             |       | -0.776 ( $\pm$ 0.194)     | -0.820 [0.277] |
| CP6_High Beta_ZScore Entrenamiento - Atraccion |       | -0.488 ( $\pm$ 0.259)     | -0.512 [0.285] |
| CP6_High Beta_ZScore Entrenamiento - Rechazo   |       | -0.739 ( $\pm$ 0.364)     | -0.762 [0.367] |
| CP6_High Beta_ZScore Nuevo - Atraccion         |       | -0.434 ( $\pm$ 0.331)     | -0.440 [0.333] |
| C4_Gamma_ZScore Entrenamiento - Atraccion      |       | -0.481 ( $\pm$ 0.234)     | -0.460 [0.347] |
| C4_Gamma_ZScore Entrenamiento - Rechazo        |       | -0.791 ( $\pm$ 0.400)     | -0.798 [0.384] |
| C4_Gamma_ZScore Nuevo - Atraccion              |       | -0.510 ( $\pm$ 0.501)     | -0.568 [0.470] |
| T8_High Beta Entrenamiento - Atraccion         |       | 19.104 ( $\pm$ 22.263)    | 10.172 [8.582] |
| T8_High Beta Entrenamiento - Rechazo           |       | 6.641 ( $\pm$ 6.813)      | 4.770 [3.913]  |
| T8_High Beta Nuevo - Atraccion                 |       | 13.675 ( $\pm$ 14.428)    | 9.592 [10.484] |
| F7_Gamma_ZScore Entrenamiento - Atraccion      |       | 0.111 ( $\pm$ 0.666)      | -0.088 [0.424] |
| F7_Gamma_ZScore Entrenamiento - Rechazo        |       | 1.292 ( $\pm$ 2.383)      | 0.636 [1.761]  |

|                 |                           |                        |                |
|-----------------|---------------------------|------------------------|----------------|
| F7_Gamma_ZScore | Nuevo - Atraccion         | 0.376 ( $\pm 1.381$ )  | -0.004 [0.669] |
| Pz_Gamma_ZScore | Entrenamiento - Atraccion | -0.584 ( $\pm 0.193$ ) | -0.612 [0.347] |
| Pz_Gamma_ZScore | Entrenamiento - Rechazo   | -0.795 ( $\pm 0.290$ ) | -0.846 [0.256] |
| Pz_Gamma_ZScore | Nuevo - Atraccion         | -0.725 ( $\pm 0.218$ ) | -0.750 [0.268] |
| P3_Gamma_ZScore | Entrenamiento - Atraccion | -0.612 ( $\pm 0.190$ ) | -0.641 [0.292] |
| P3_Gamma_ZScore | Entrenamiento - Rechazo   | -0.809 ( $\pm 0.286$ ) | -0.833 [0.270] |
| P3_Gamma_ZScore | Nuevo - Atraccion         | -0.712 ( $\pm 0.230$ ) | -0.761 [0.366] |

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

### **8.3 COMPARACIÓN CON LENGUA-ABSTRACTO GENERAL**

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

Resumen de Predicciones:

prediccion

rechazo 118

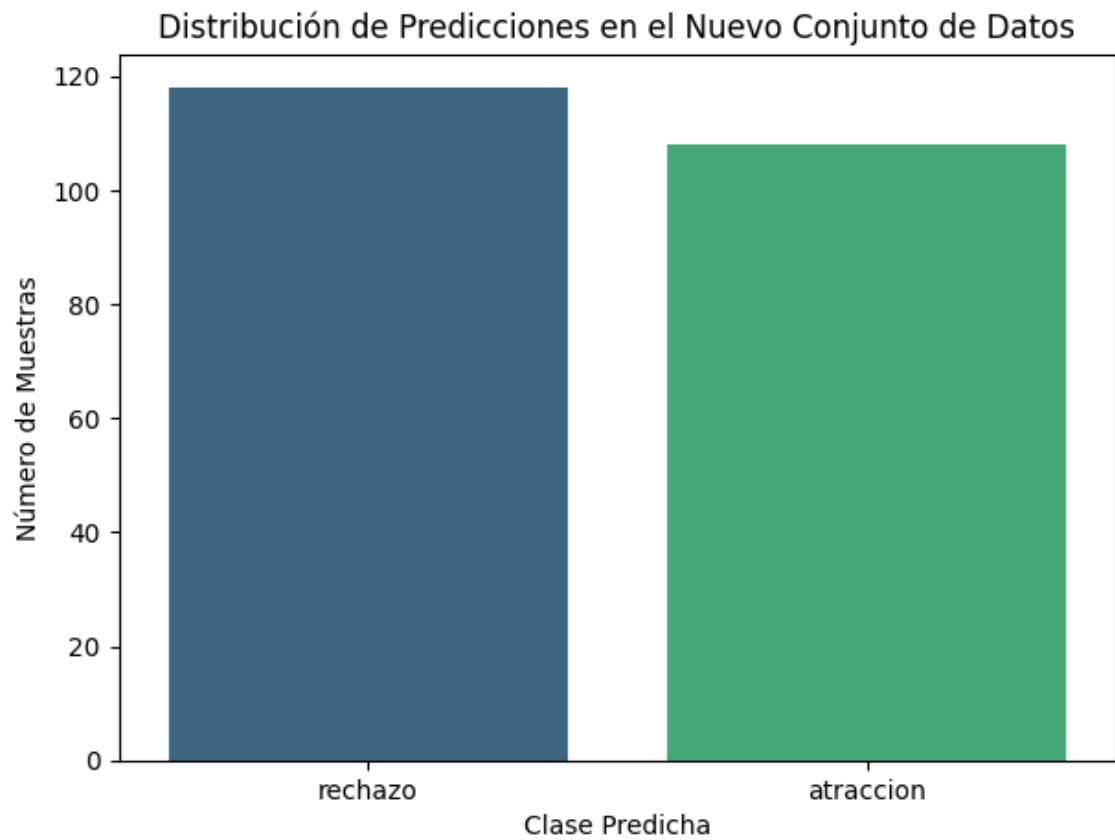
atraccion 108

Name: count, dtype: int64

<ipython-input-6-588bc1e99da0>: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)
```



91 Muestras clasificadas con baja confianza ( $\text{prob} < 0.6$ ):

|   | <code>prediccion</code> | <code>prob_atraccion</code> | <code>prob_rechazo</code> |
|---|-------------------------|-----------------------------|---------------------------|
| 4 | atraccion               | 0.595000                    | 0.405000                  |
| 5 | atraccion               | 0.586667                    | 0.413333                  |
| 6 | atraccion               | 0.566667                    | 0.433333                  |
| 7 | rechazo                 | 0.446667                    | 0.553333                  |
| 8 | rechazo                 | 0.466667                    | 0.533333                  |

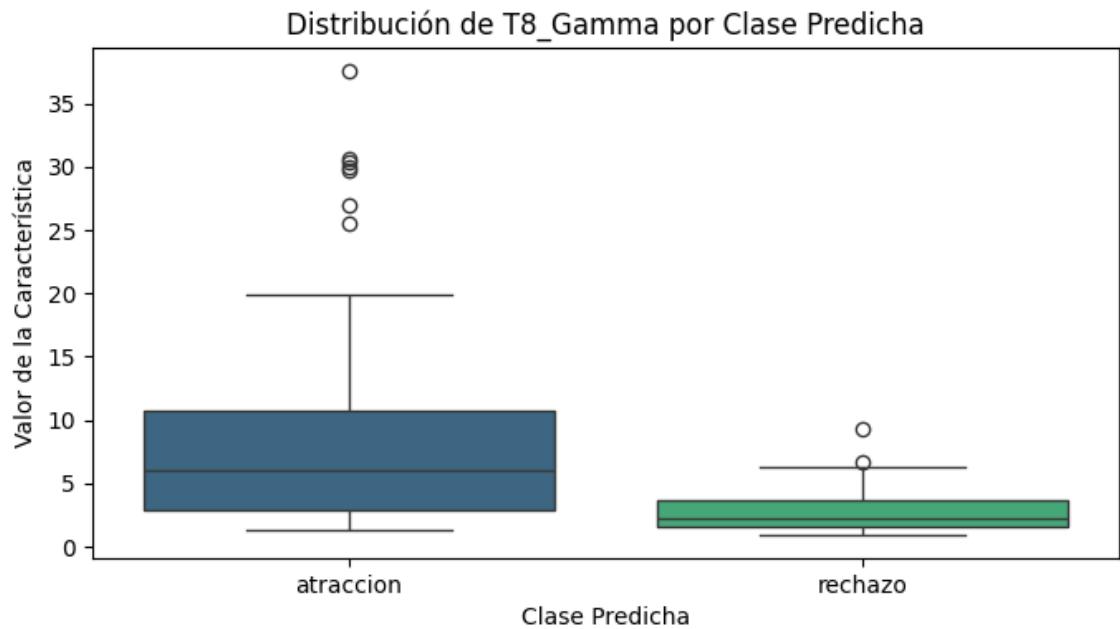
--- Análisis de Características Importantes en Nuevos Datos ---

Visualizando la distribución de las 5 características más importantes:

<ipython-input-6-588bc1e99da0>: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.

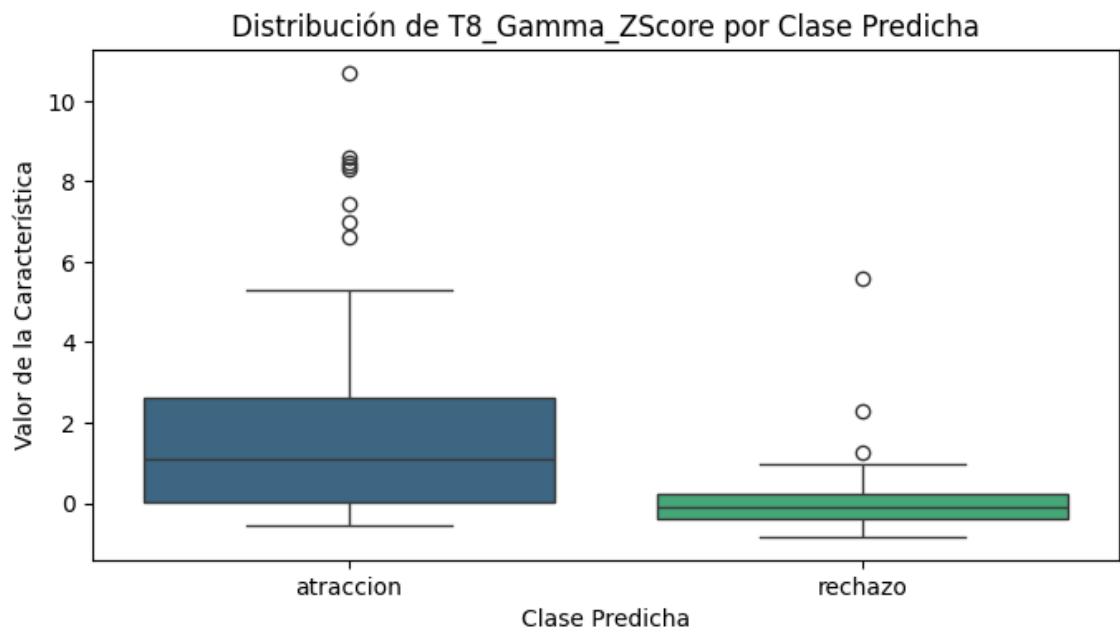
```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



```
<ipython-input-6-588bc1e99da0>: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.

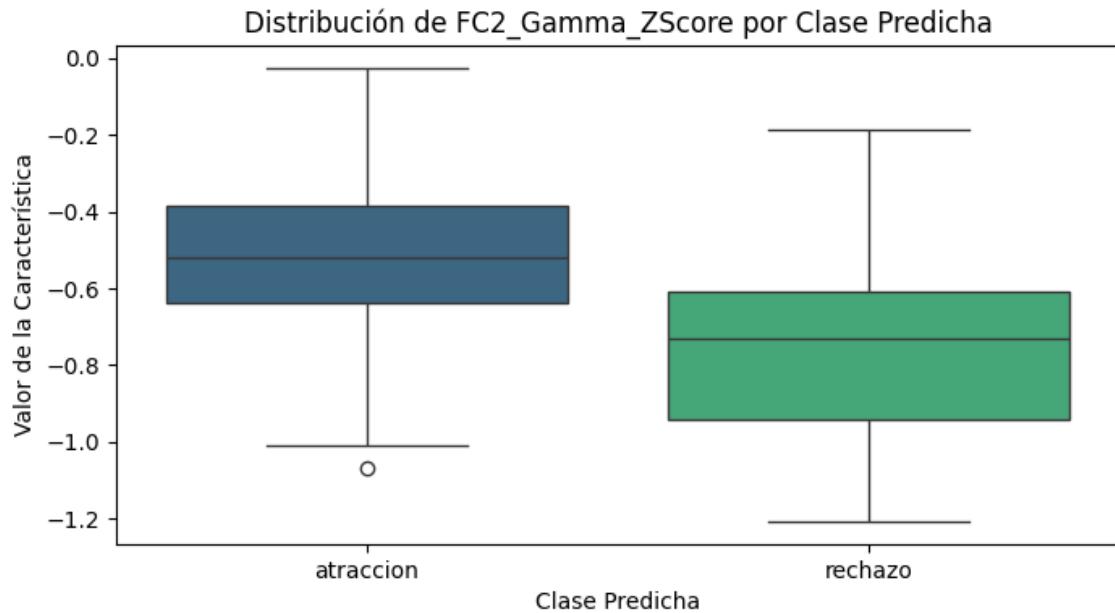
```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



```
<ipython-input-6-588bc1e99da0>: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.

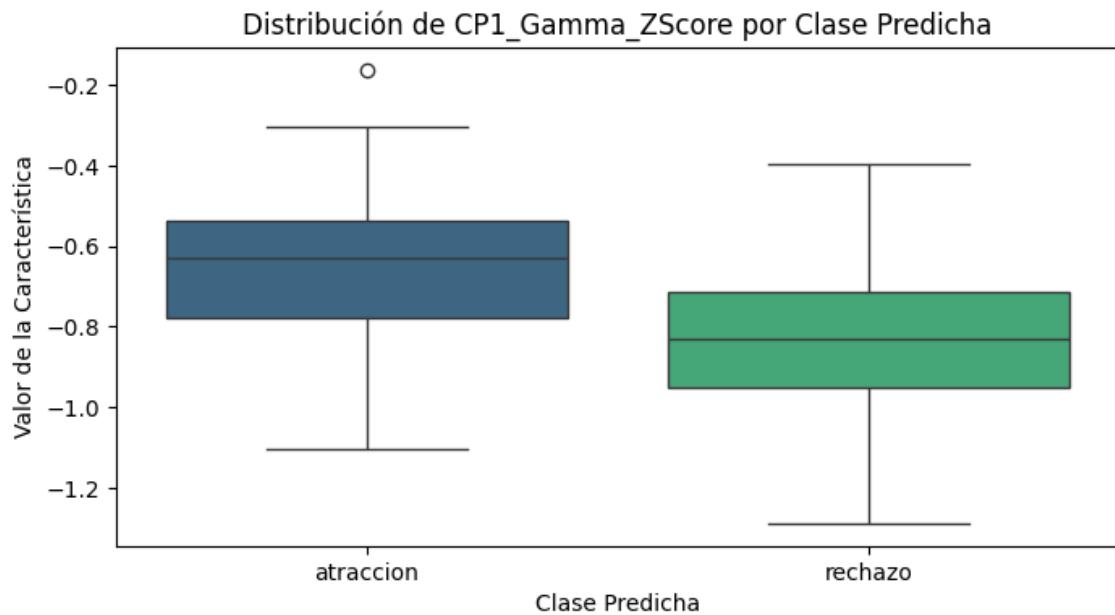
```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



```
<ipython-input-6-588bc1e99da0>: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.

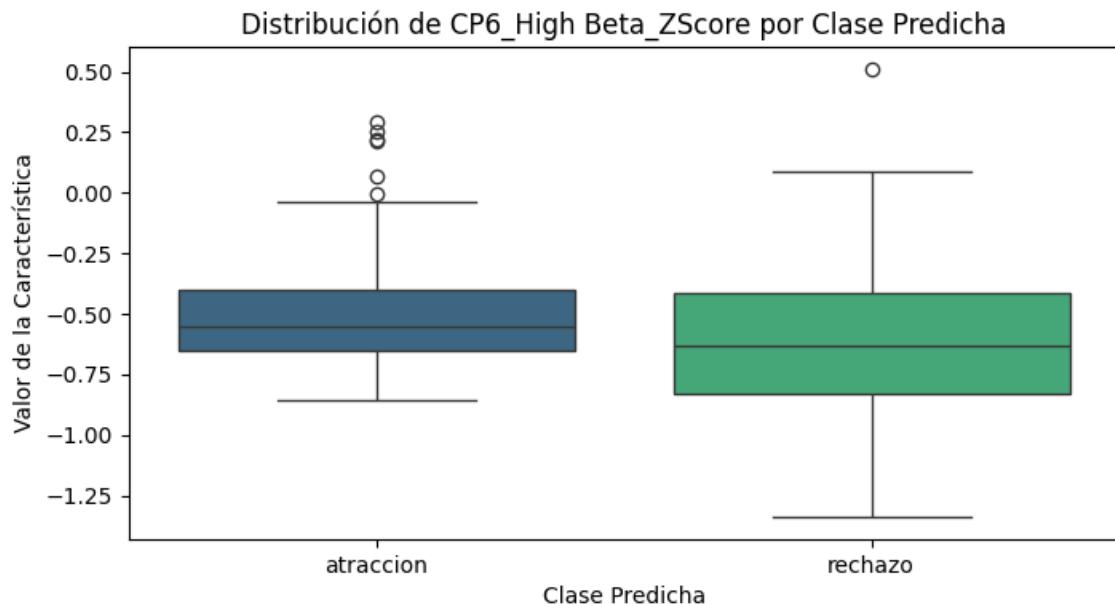
```
sns.boxplot(x='prediccion', y=feature, data=df_visualizacion, palette='viridis')
```



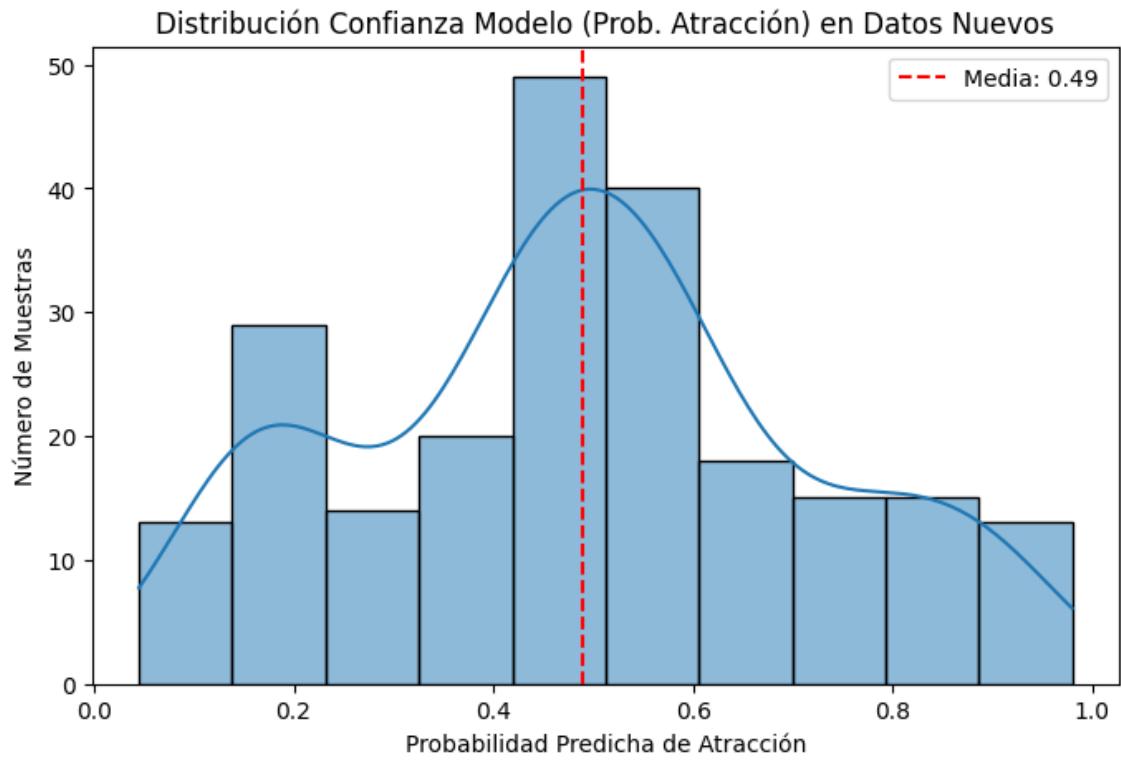
```
<ipython-input-6-588bc1e99da0>:99: FutureWarning:
```

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: 0.489

Mediana: 0.490

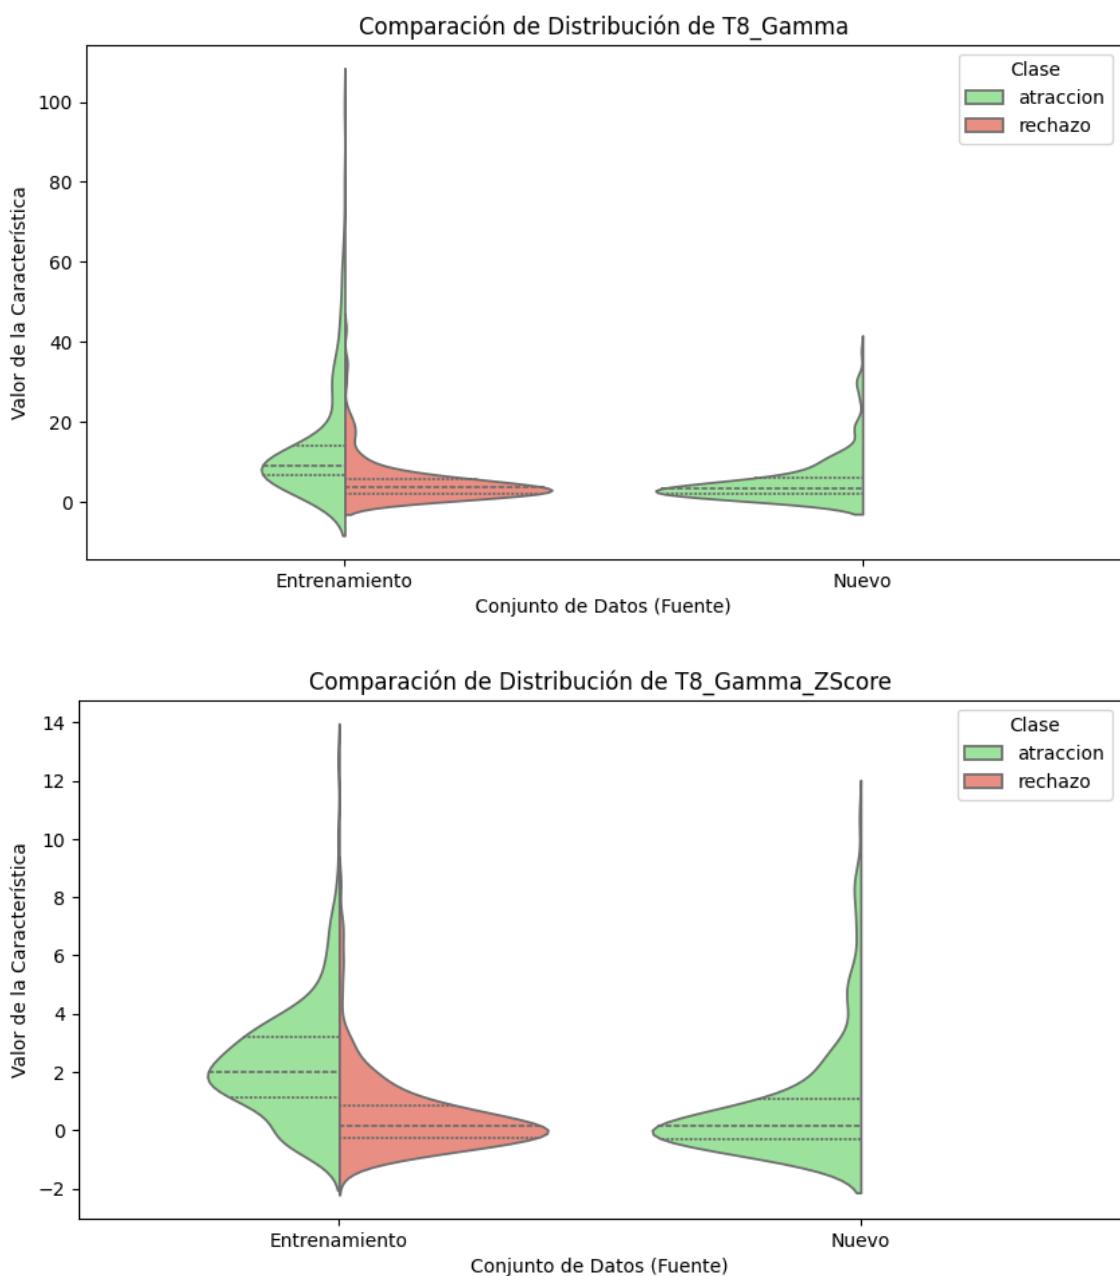
Mínima: 0.045

Máxima: 0.980

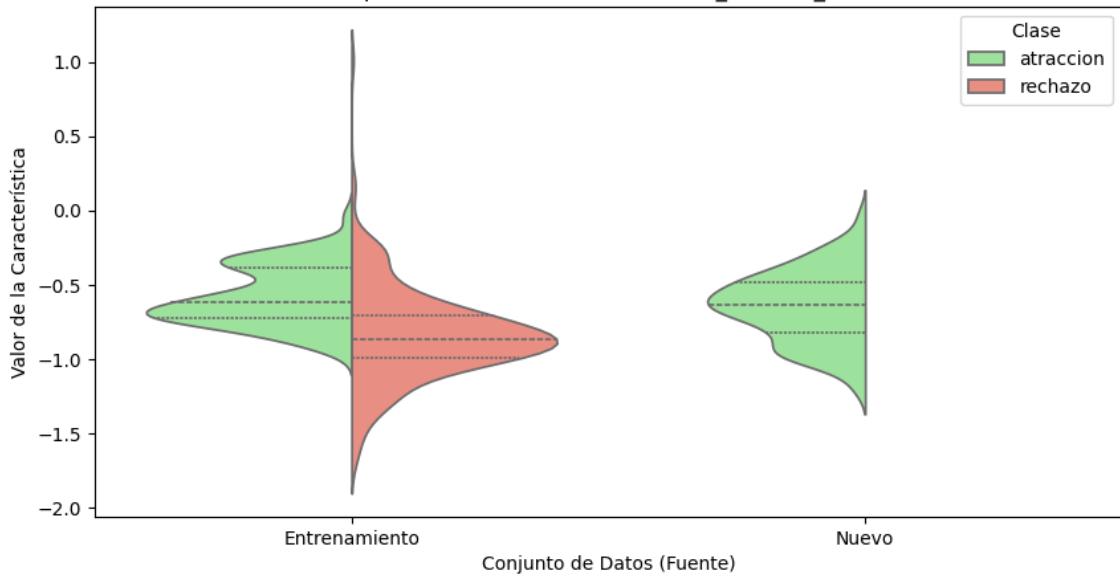
Desv. Estándar: 0.226

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

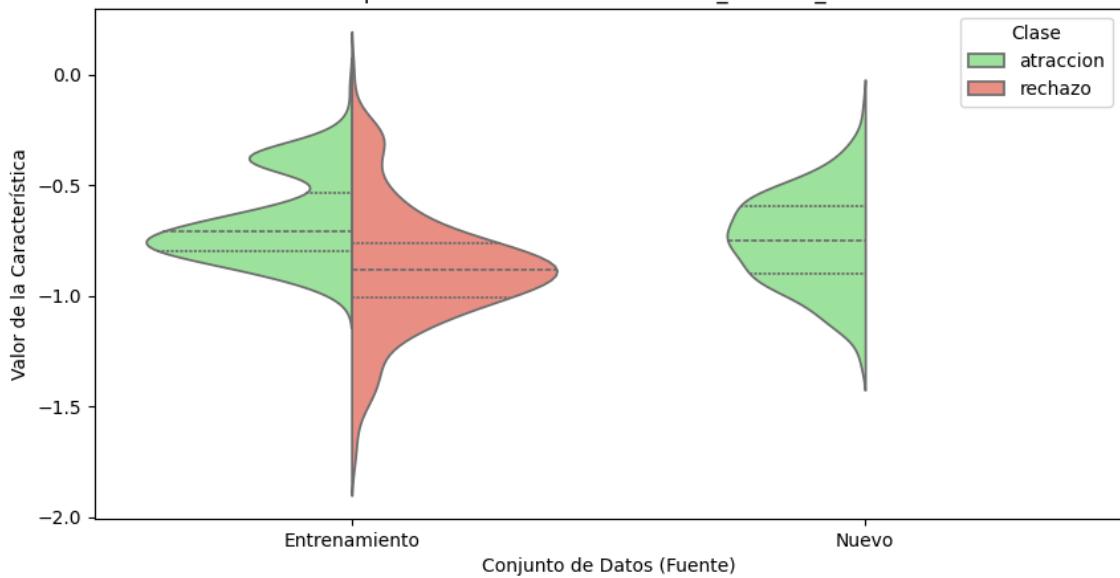
Comparando: Datos Entrenamiento vs Datos Nuevos

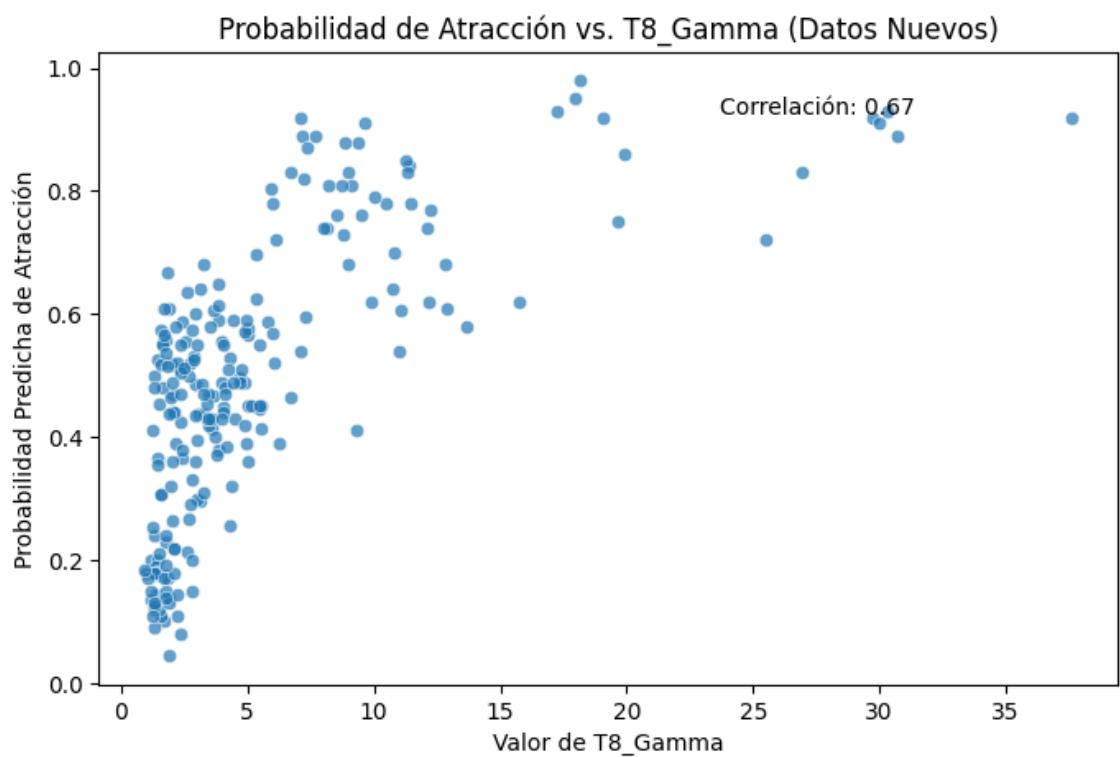
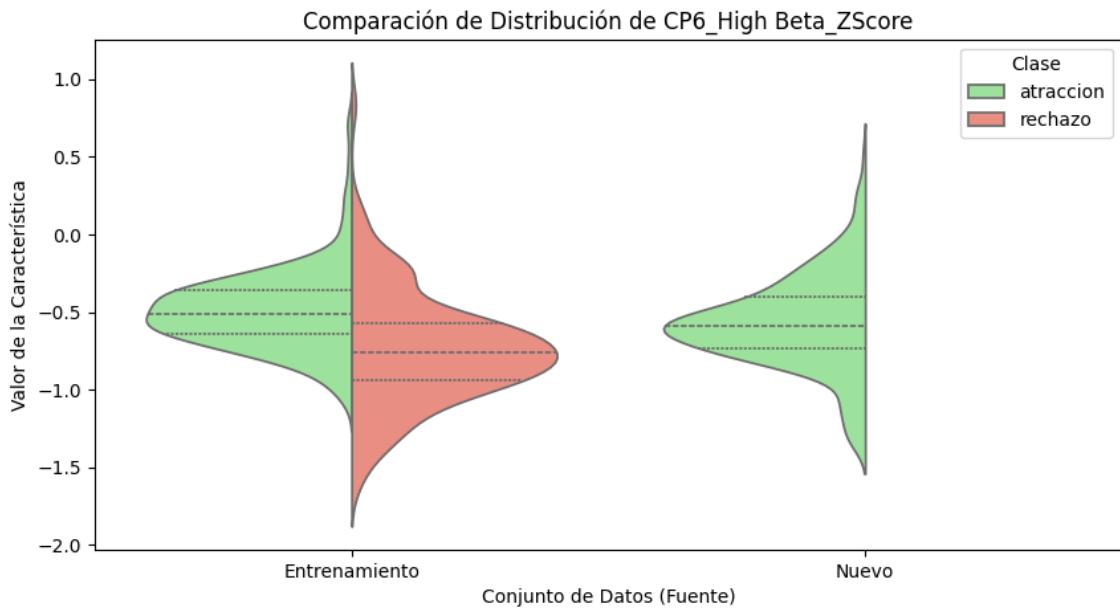


Comparación de Distribución de FC2\_Gamma\_ZScore



Comparación de Distribución de CP1\_Gamma\_ZScore





--- 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   | 0.941 | 0.940 | 0.017 |
| Precisión       | Atraccion | 0.902 | -     | -     |
| Precisión       | Rechazo   | 0.980 | -     | -     |
| Recall          | Atraccion | 0.979 | -     | -     |
| Recall          | Rechazo   | 0.907 | -     | -     |
| F1-Score        | Atraccion | 0.939 | -     | -     |
| F1-Score        | Rechazo   | 0.942 | -     | -     |
| F1 Macro Avg    | General   | 0.941 | -     | -     |
| F1 Weighted Avg | General   | 0.941 | -     | -     |

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

| Ranking | Característica       | Puntuación de Importancia |
|---------|----------------------|---------------------------|
| 1       | T8_Gamma             | 0.0429                    |
| 2       | T8_Gamma_ZScore      | 0.0343                    |
| 3       | FC2_Gamma_ZScore     | 0.0310                    |
| 4       | CP1_Gamma_ZScore     | 0.0293                    |
| 5       | CP6_High Beta_ZScore | 0.0239                    |
| 6       | C4_Gamma_ZScore      | 0.0219                    |
| 7       | T8_High Beta         | 0.0218                    |
| 8       | F7_Gamma_ZScore      | 0.0213                    |
| 9       | Pz_Gamma_ZScore      | 0.0199                    |
| 10      | P3_Gamma_ZScore      | 0.0195                    |

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

Número de Muestras 226  
Media Prob. Atracción 0.489  
Mediana Prob. Atracción 0.490  
Desv. Est. Prob. Atracción 0.226  
Mínima Prob. Atracción 0.045

Máxima Prob. Atracción 0.980

% Muestras Confianza > 0.9 4.4%

% Muestras Confianza < 0.6 72.1%

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

| Característica                                 | Grupo | Media ( $\pm$ Desv. Est.) | Mediana [IQR]  |
|--|-------|---------------------------|----------------|
| T8_Gamma Entrenamiento - Atraccion             |       | 14.441 ( $\pm$ 14.619)    | 9.169 [7.516]  |
| T8_Gamma Entrenamiento - Rechazo               |       | 5.187 ( $\pm$ 5.691)      | 3.521 [3.627]  |
| T8_Gamma Nuevo - Atraccion                     |       | 5.396 ( $\pm$ 5.882)      | 3.316 [4.148]  |
| T8_Gamma_ZScore Entrenamiento - Atraccion      |       | 2.274 ( $\pm$ 1.944)      | 2.003 [2.096]  |
| T8_Gamma_ZScore Entrenamiento - Rechazo        |       | 0.540 ( $\pm$ 1.380)      | 0.154 [1.111]  |
| T8_Gamma_ZScore Nuevo - Atraccion              |       | 0.861 ( $\pm$ 1.943)      | 0.146 [1.405]  |
| FC2_Gamma_ZScore Entrenamiento - Atraccion     |       | -0.575 ( $\pm$ 0.200)     | -0.619 [0.341] |
| FC2_Gamma_ZScore Entrenamiento - Rechazo       |       | -0.837 ( $\pm$ 0.310)     | -0.866 [0.288] |
| FC2_Gamma_ZScore Nuevo - Atraccion             |       | -0.647 ( $\pm$ 0.241)     | -0.632 [0.340] |
| CP1_Gamma_ZScore Entrenamiento - Atraccion     |       | -0.660 ( $\pm$ 0.192)     | -0.708 [0.262] |
| CP1_Gamma_ZScore Entrenamiento - Rechazo       |       | -0.873 ( $\pm$ 0.274)     | -0.881 [0.246] |
| CP1_Gamma_ZScore Nuevo - Atraccion             |       | -0.750 ( $\pm$ 0.204)     | -0.748 [0.306] |
| CP6_High Beta_ZScore Entrenamiento - Atraccion |       | -0.488 ( $\pm$ 0.259)     | -0.512 [0.285] |
| CP6_High Beta_ZScore Entrenamiento - Rechazo   |       | -0.739 ( $\pm$ 0.364)     | -0.762 [0.367] |
| CP6_High Beta_ZScore Nuevo - Atraccion         |       | -0.571 ( $\pm$ 0.300)     | -0.587 [0.325] |
| C4_Gamma_ZScore Entrenamiento - Atraccion      |       | -0.481 ( $\pm$ 0.234)     | -0.460 [0.347] |
| C4_Gamma_ZScore Entrenamiento - Rechazo        |       | -0.791 ( $\pm$ 0.400)     | -0.798 [0.384] |
| C4_Gamma_ZScore Nuevo - Atraccion              |       | -0.627 ( $\pm$ 0.241)     | -0.600 [0.329] |
| T8_High Beta Entrenamiento - Atraccion         |       | 19.104 ( $\pm$ 22.263)    | 10.172 [8.582] |
| T8_High Beta Entrenamiento - Rechazo           |       | 6.641 ( $\pm$ 6.813)      | 4.770 [3.913]  |
| T8_High Beta Nuevo - Atraccion                 |       | 6.725 ( $\pm$ 6.258)      | 4.575 [5.590]  |
| F7_Gamma_ZScore Entrenamiento - Atraccion      |       | 0.111 ( $\pm$ 0.666)      | -0.088 [0.424] |
| F7_Gamma_ZScore Entrenamiento - Rechazo        |       | 1.292 ( $\pm$ 2.383)      | 0.636 [1.761]  |

|                 |                           |                        |                |
|-----------------|---------------------------|------------------------|----------------|
| F7_Gamma_ZScore | Nuevo - Atraccion         | 0.451 ( $\pm 0.897$ )  | 0.217 [0.769]  |
| Pz_Gamma_ZScore | Entrenamiento - Atraccion | -0.584 ( $\pm 0.193$ ) | -0.612 [0.347] |
| Pz_Gamma_ZScore | Entrenamiento - Rechazo   | -0.795 ( $\pm 0.290$ ) | -0.846 [0.256] |
| Pz_Gamma_ZScore | Nuevo - Atraccion         | -0.633 ( $\pm 0.227$ ) | -0.612 [0.277] |
| P3_Gamma_ZScore | Entrenamiento - Atraccion | -0.612 ( $\pm 0.190$ ) | -0.641 [0.292] |
| P3_Gamma_ZScore | Entrenamiento - Rechazo   | -0.809 ( $\pm 0.286$ ) | -0.833 [0.270] |
| P3_Gamma_ZScore | Nuevo - Atraccion         | -0.645 ( $\pm 0.209$ ) | -0.633 [0.283] |

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

#### **8.4 EJEMPLO FINAL MATES CONCRETO (Gráfica de futura aplicación)**

Modelo cargado desde 'clasificador\_atraccion\_rechazo.joblib'.

Nombres de características cargados desde 'feature\_names.joblib'. El modelo espera 434 características.

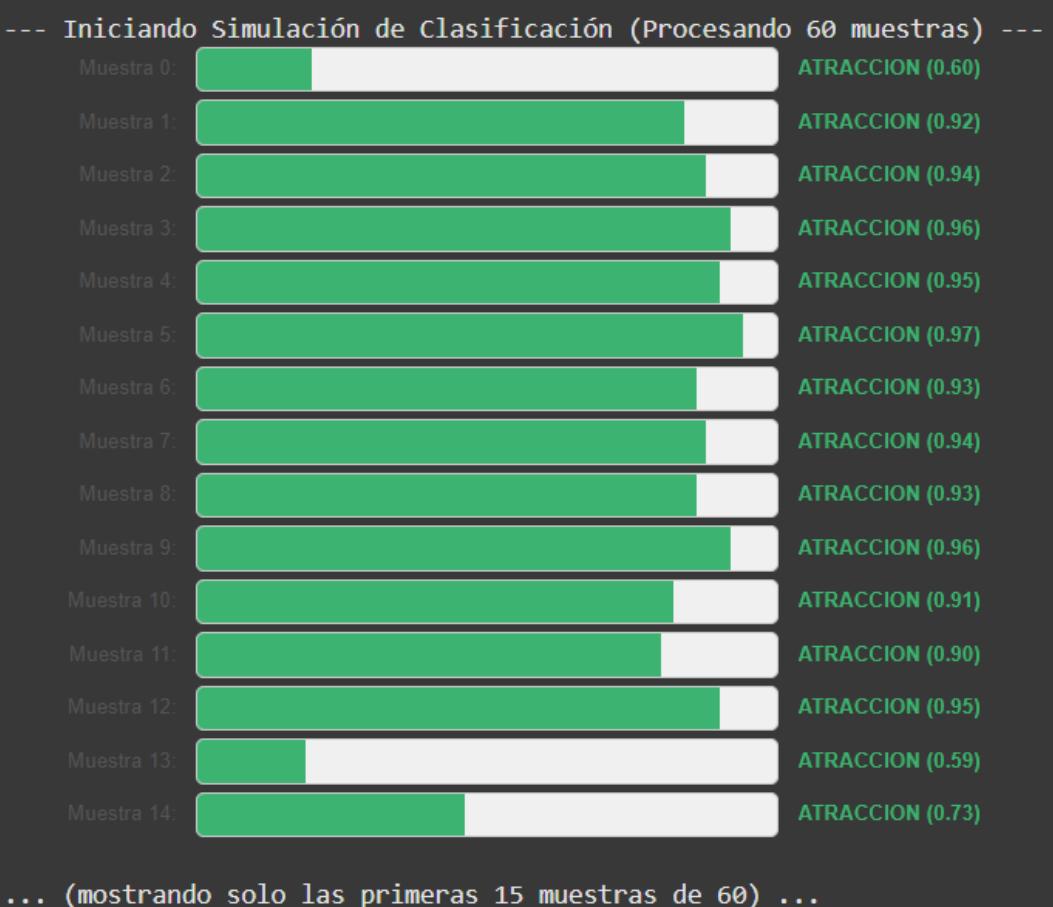
Datos nuevos cargados desde:

/content/drive/MyDrive/TFG/matesconcretobrais\_PSD\_Zscores\_FAEngagement.xls  
x (60 muestras)

Alineando columnas del nuevo archivo con las esperadas por el modelo...

Columnas alineadas correctamente.

--- Iniciando Simulación de Clasificación (Procesando 60 muestras) ---



--- Resumen de Clasificación para el Archivo Completo ---

### Resumen General

Total de Muestras Procesadas: **60**

Predicciones 'ATRACCION': **60 (100.0%)**

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

Confianza Media (Prob. Atracción): **0.898**

Confianza Mín/Máx (Prob. Atracción): **0.590 / 0.990**

--- Fin de la Simulación ---

### 8.5 EJEMPLO LENGUA ABSTRACTO – MANU (Gráfica de futura aplicación)

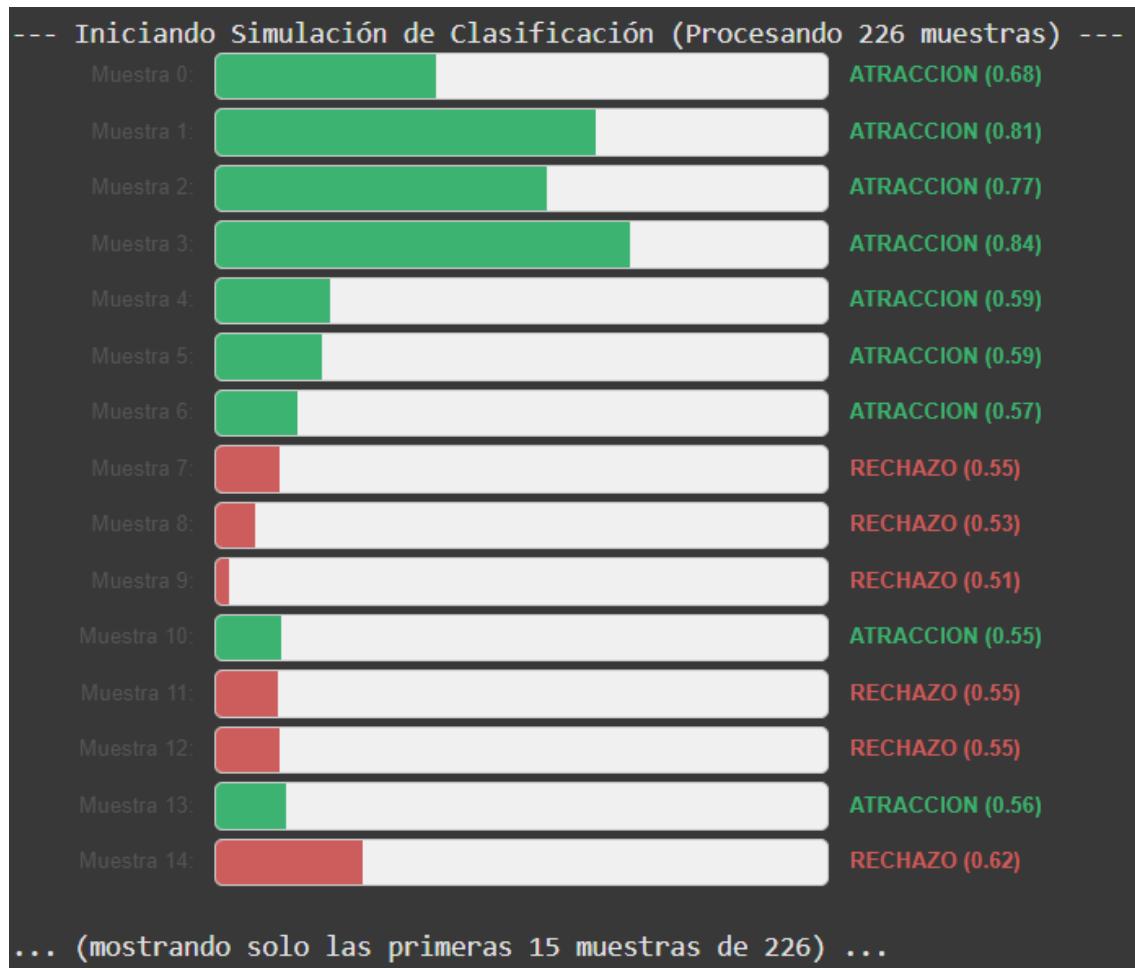
Modelo cargado desde 'clasificador\_atraccion\_rechazo.joblib'.

Nombres de características cargados desde 'feature\_names.joblib'. El modelo espera 434 características.

Datos nuevos cargados desde: /content/drive/MyDrive/TFG/Lengua concreto-abstracto/lenguabstractoPSD\_Zscores\_FAEngagement.xlsx (226 muestras)

Alineando columnas del nuevo archivo con las esperadas por el modelo...

Columnas alineadas correctamente.



--- Resumen de Clasificación para el Archivo Completo ---

## Resumen General

Total de Muestras Procesadas: **226**

Predicciones 'ATRACCION': **108 (47.8%)**

Predicciones 'RECHAZO': **118 (52.2%)**

---

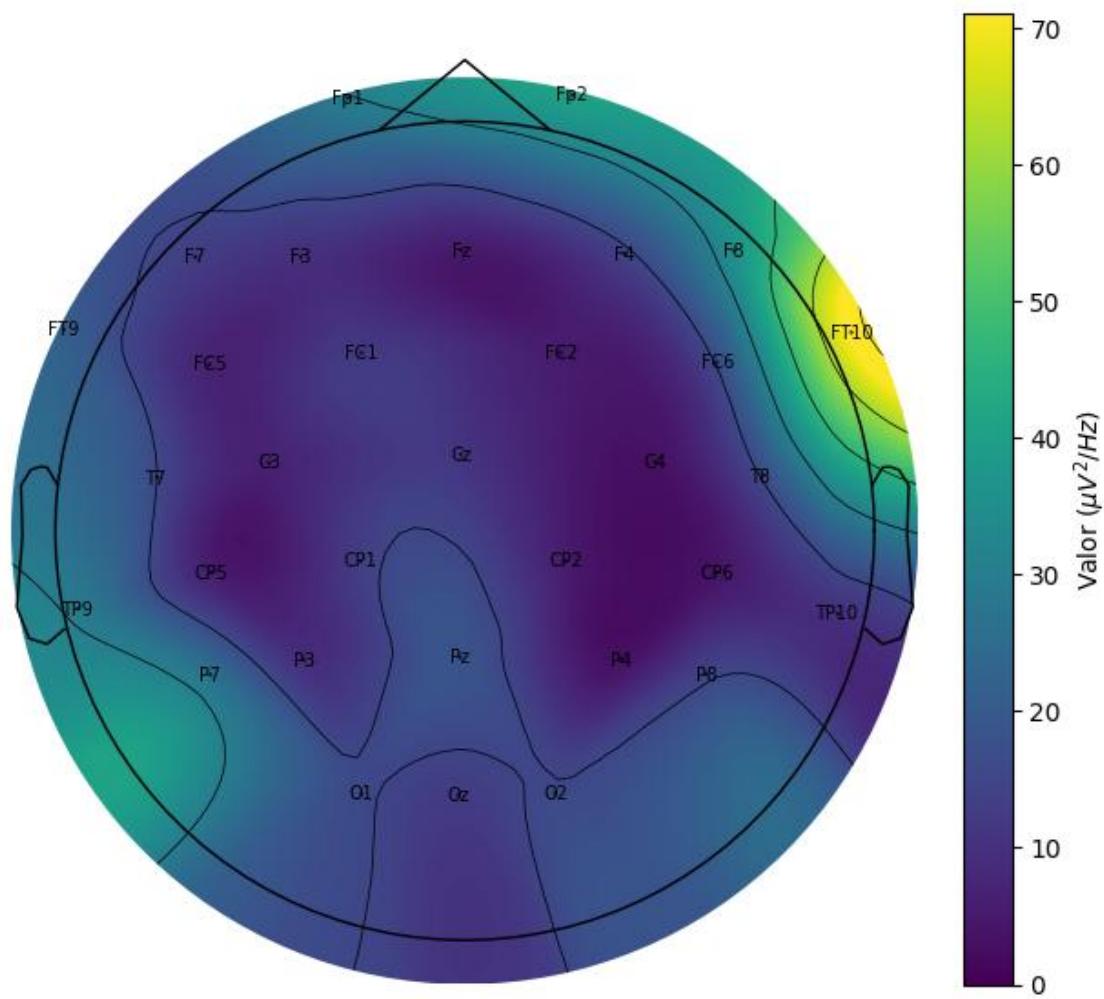
Confianza Media (Prob. Atracción): **0.489**

Confianza Mín/Máx (Prob. Atracción): **0.045 / 0.980**

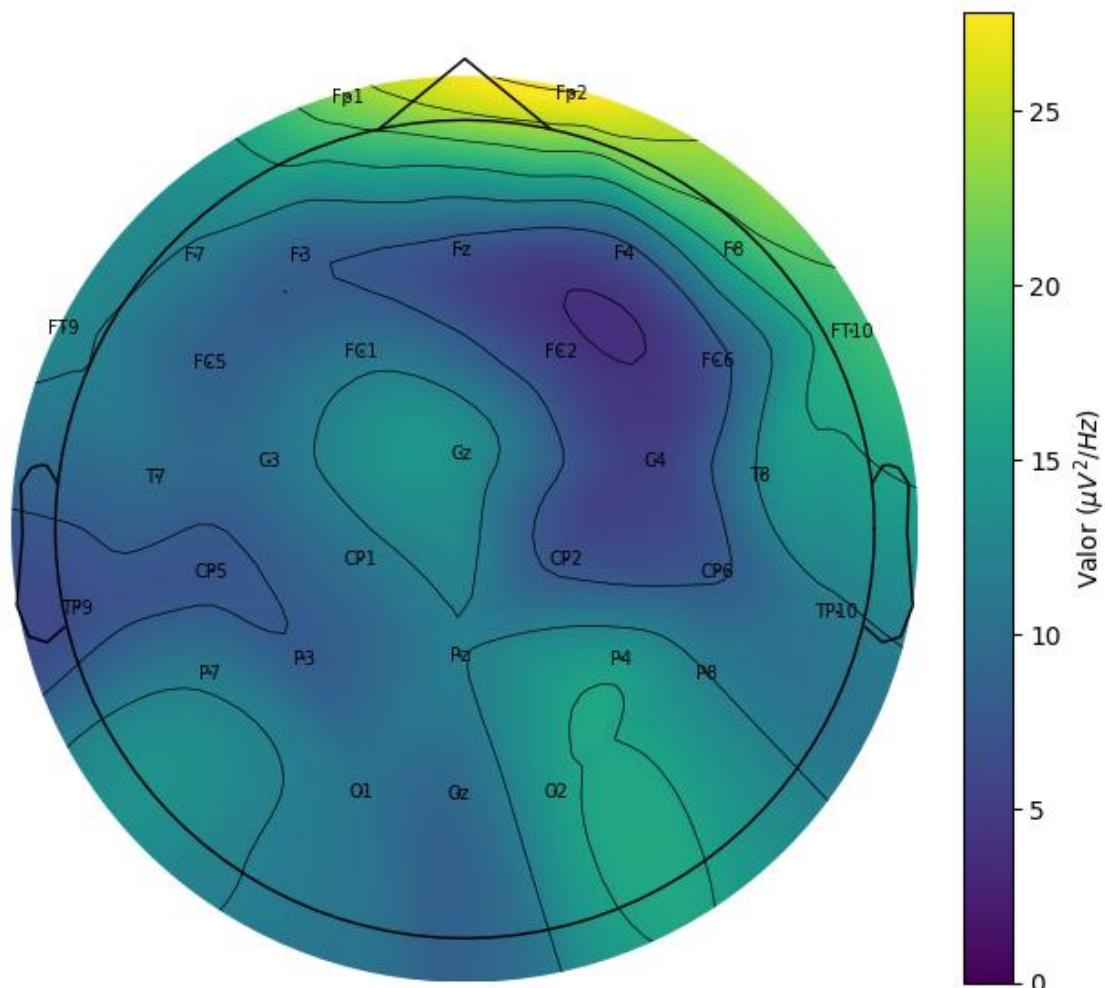
--- Fin de la Simulación ---

## **8.6 MAPAS TOPOGRÁFICOS - MATE CONCRETO**

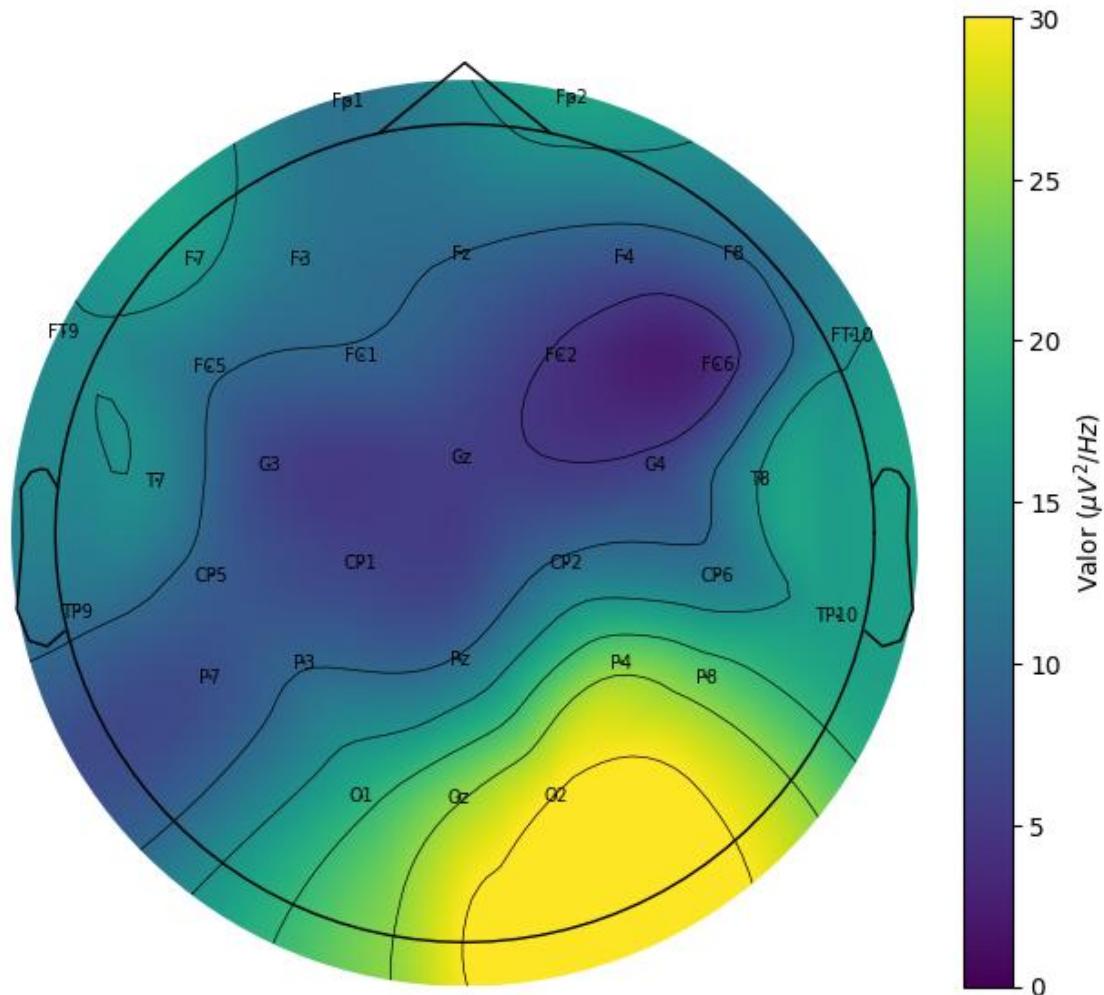
**Mapa Topográfico - Delta (1-4Hz)  
Potencia Absoluta**



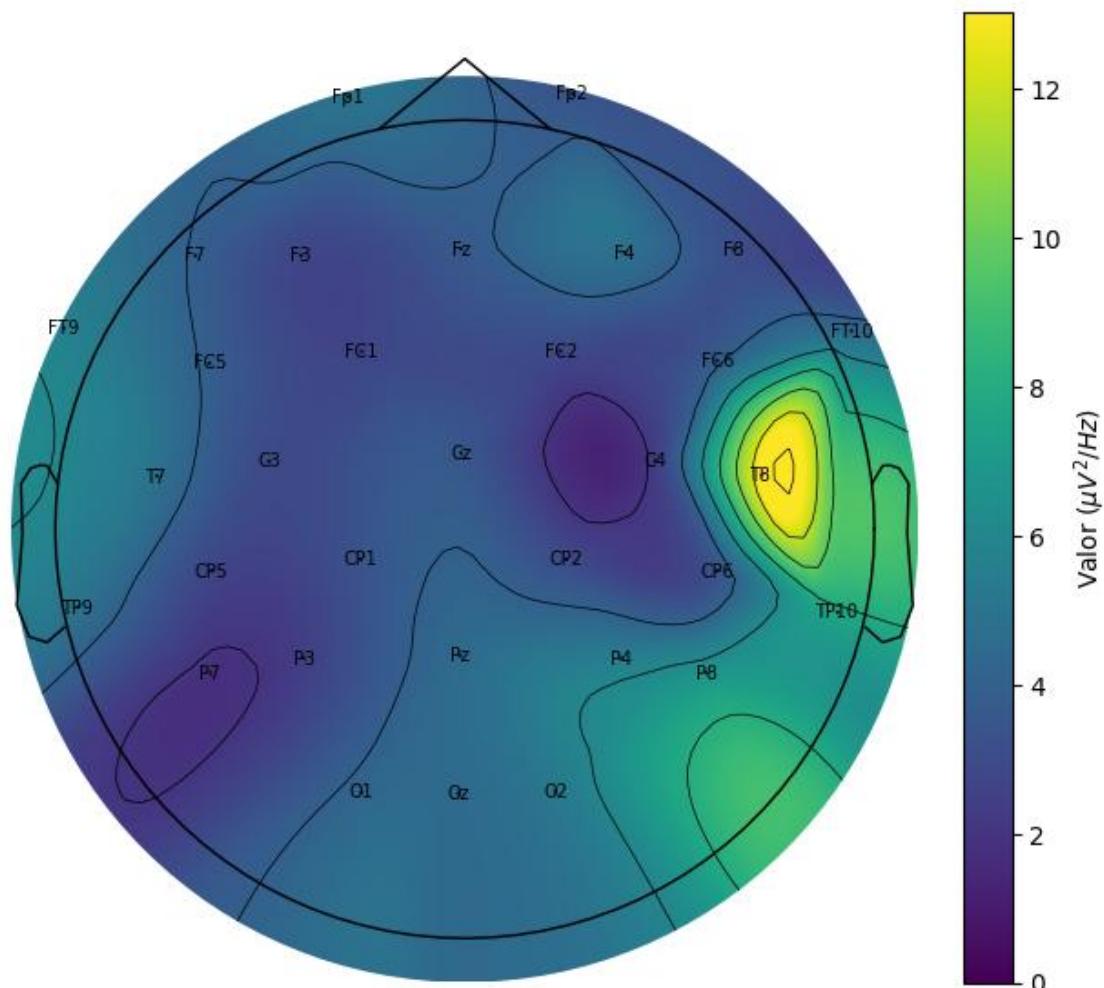
## Mapa Topográfico - Theta (4-8Hz) Potencia Absoluta



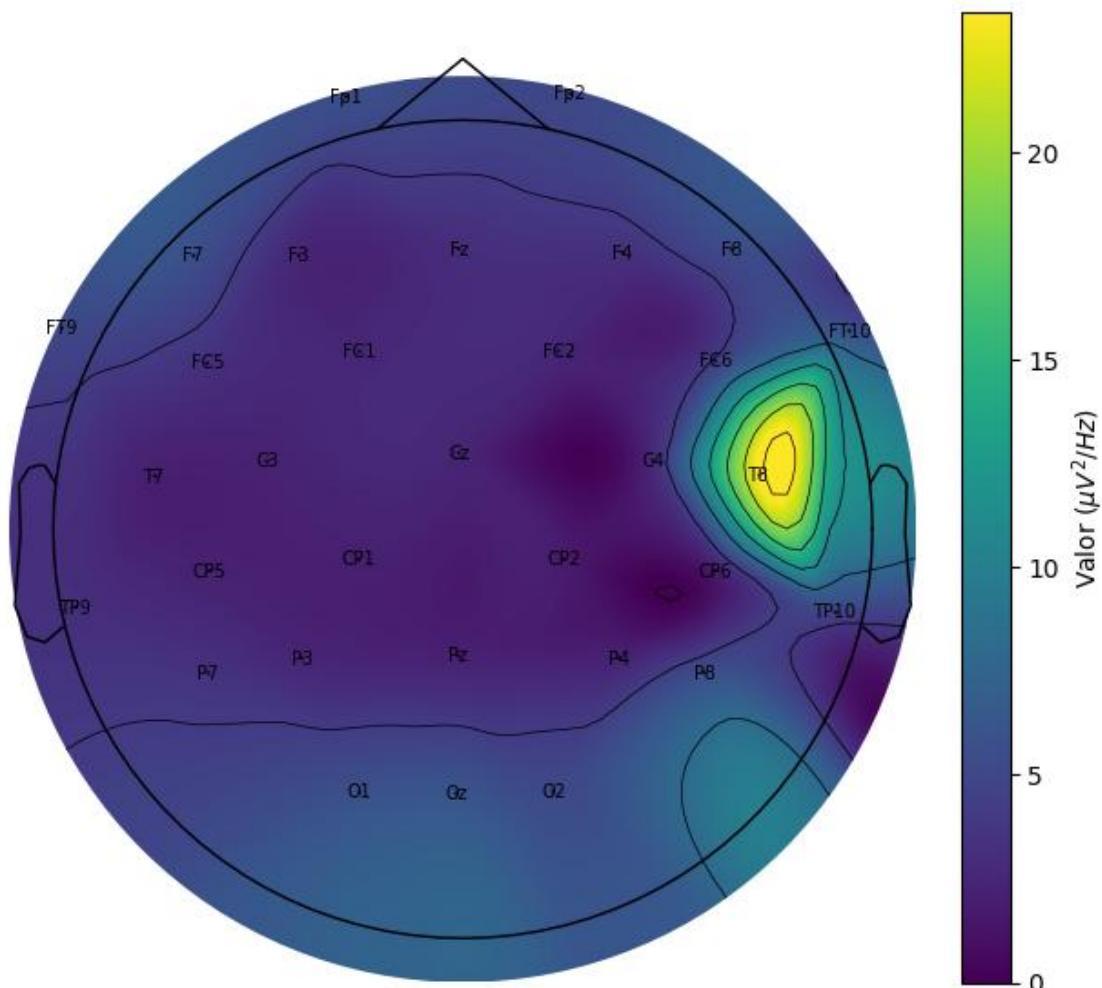
## Mapa Topográfico - Alpha (8-13Hz) Potencia Absoluta



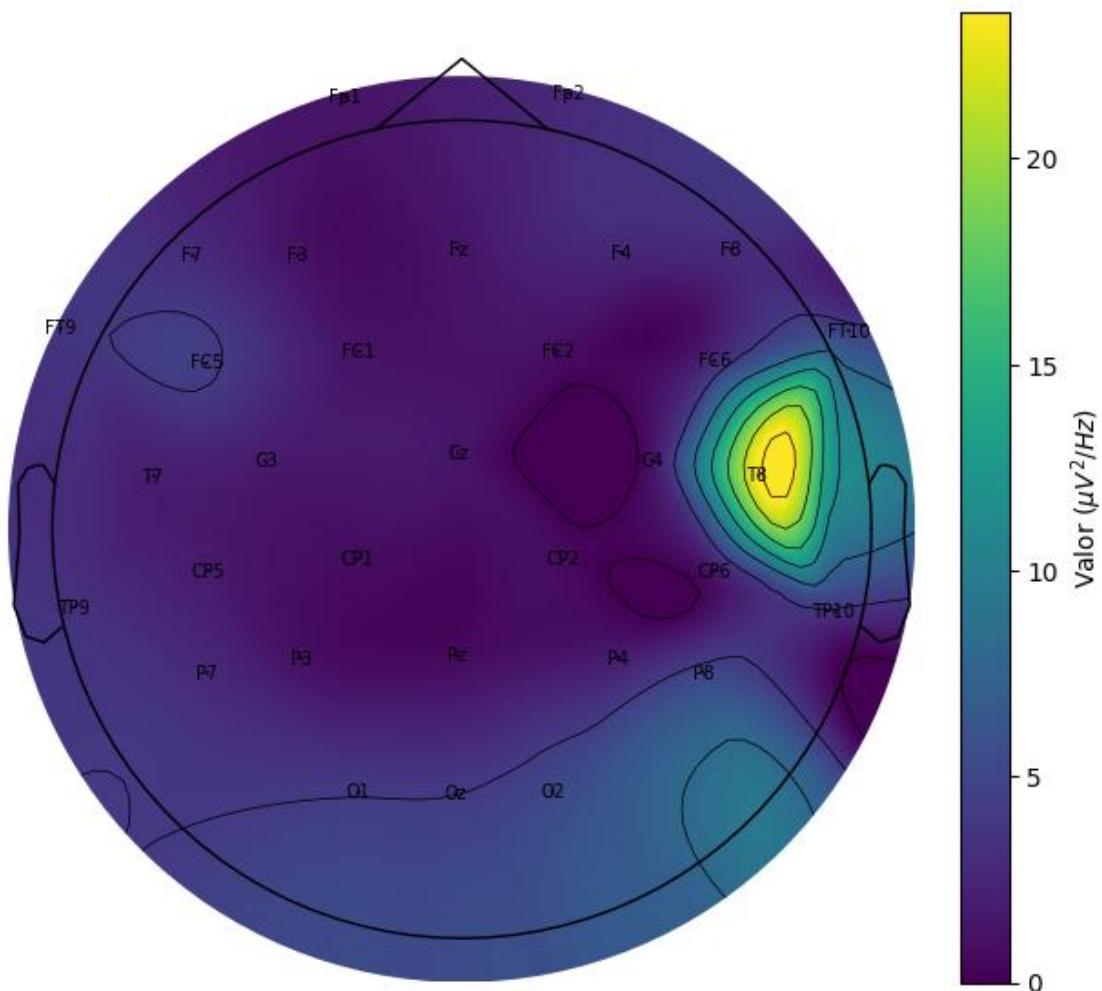
## Mapa Topográfico - Beta Bajo (13-20Hz) Potencia Absoluta



## Mapa Topográfico - Beta Alto (20-30Hz) Potencia Absoluta

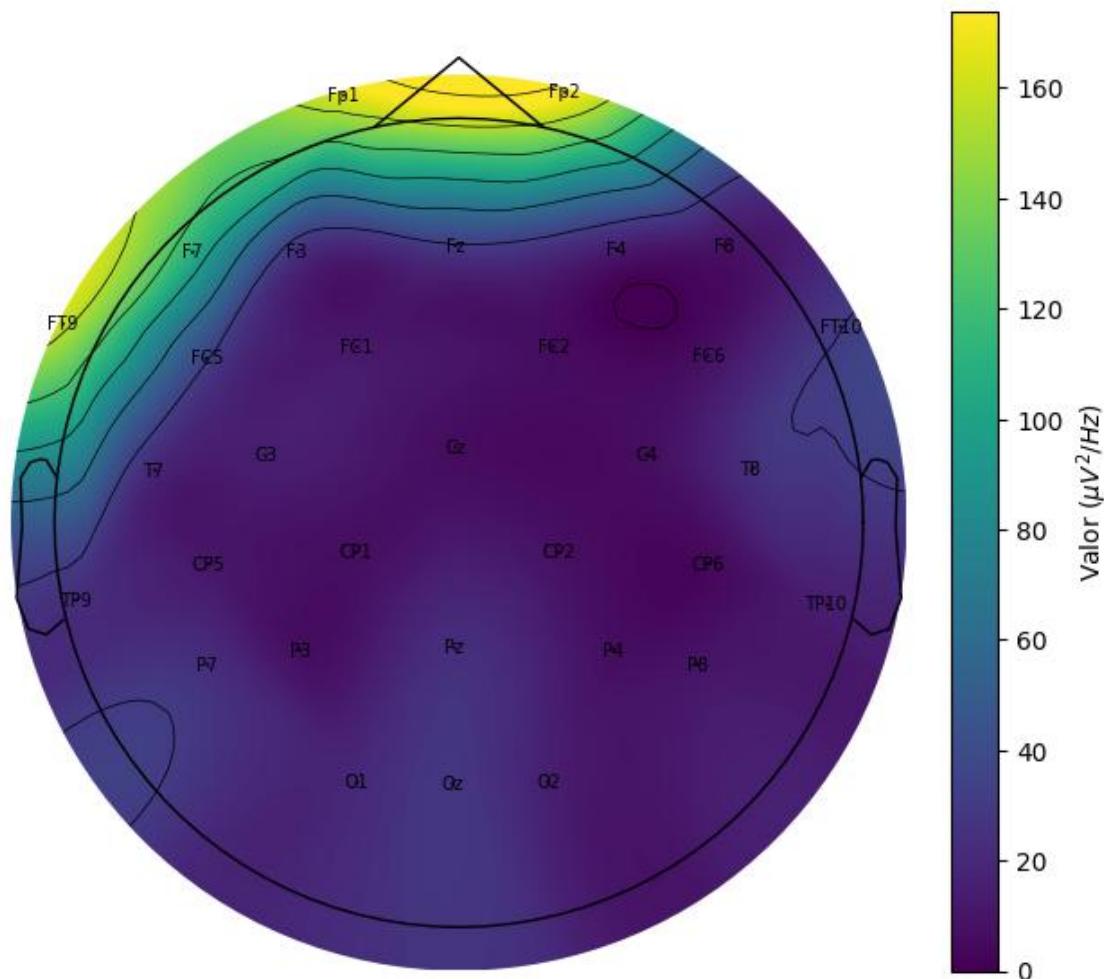


## Mapa Topográfico - Gamma (30-40Hz) Potencia Absoluta

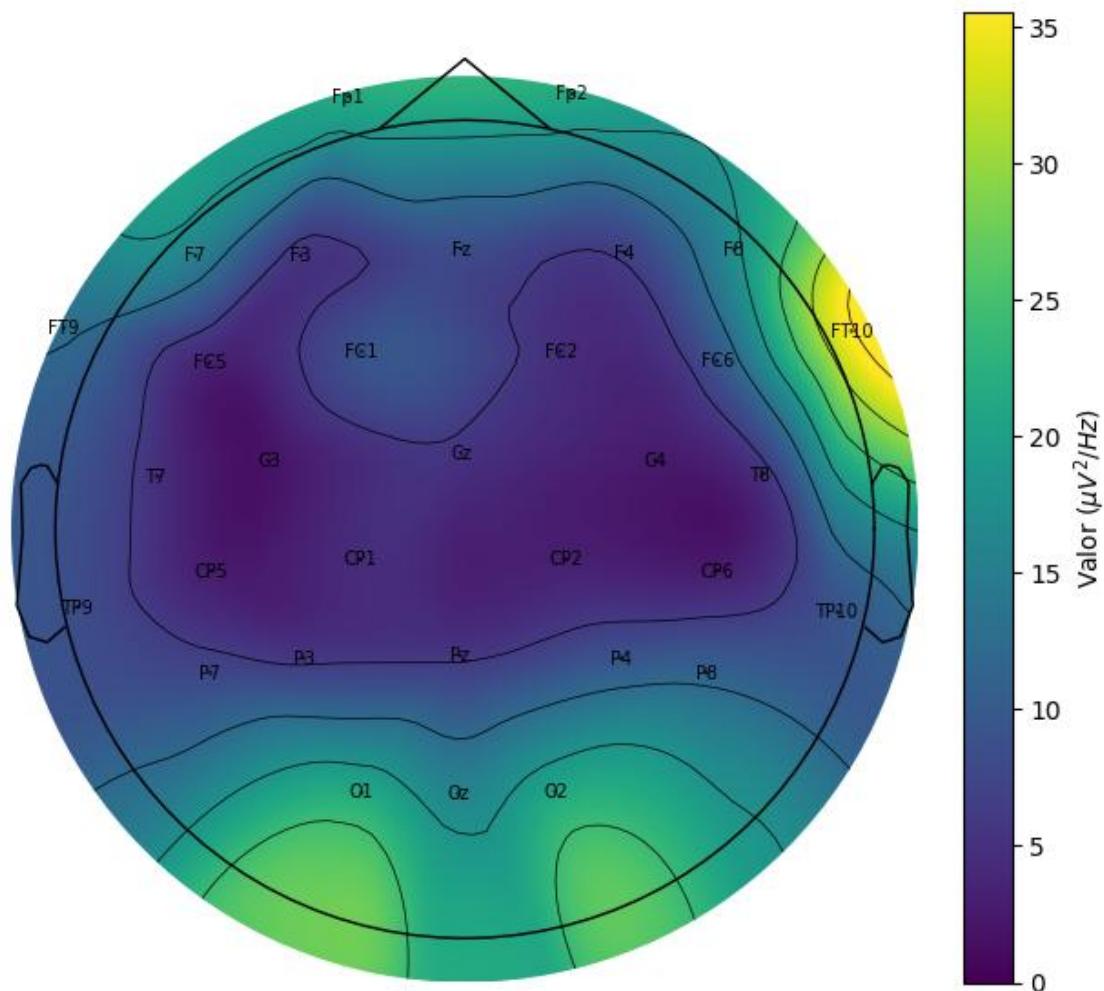


MATES ABSTRACTO

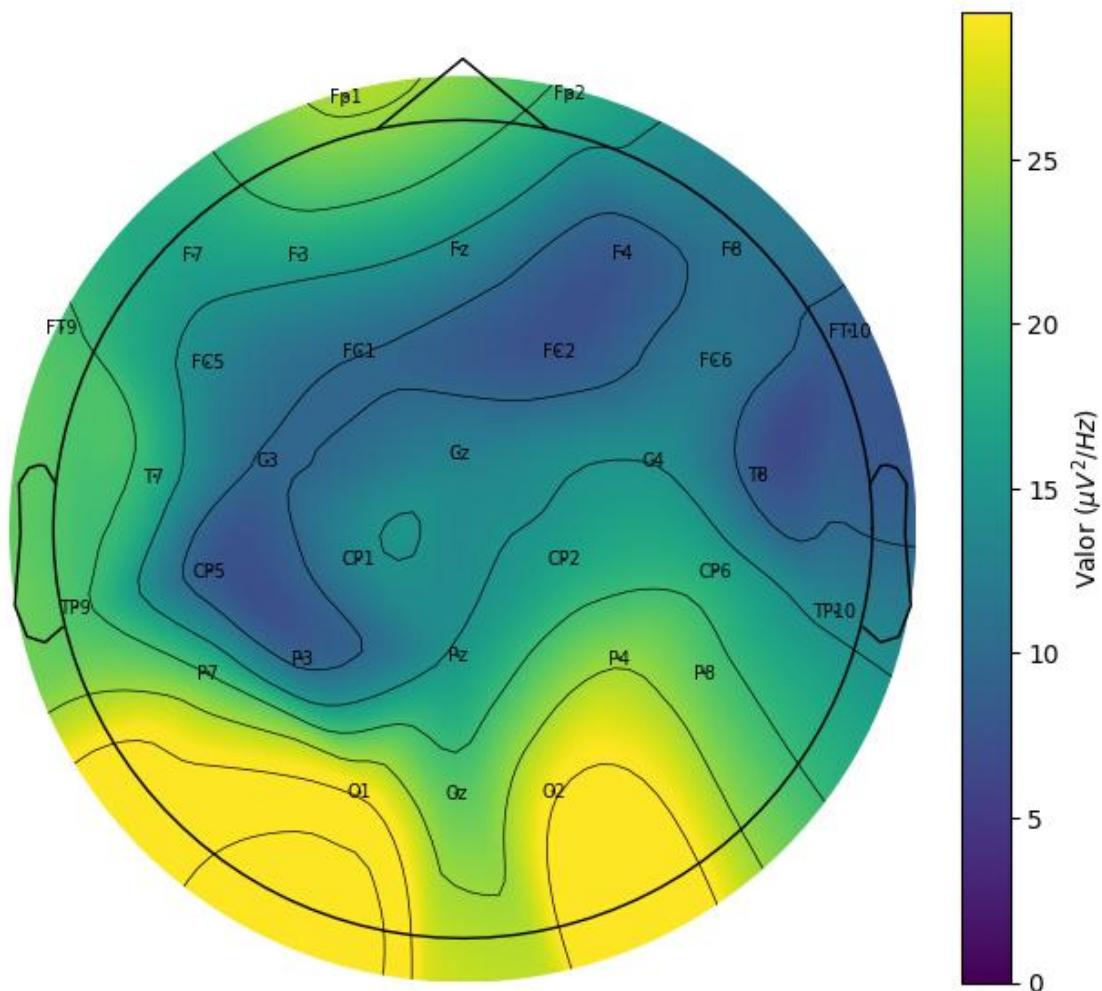
## Mapa Topográfico - Delta (1-4Hz) Potencia Absoluta



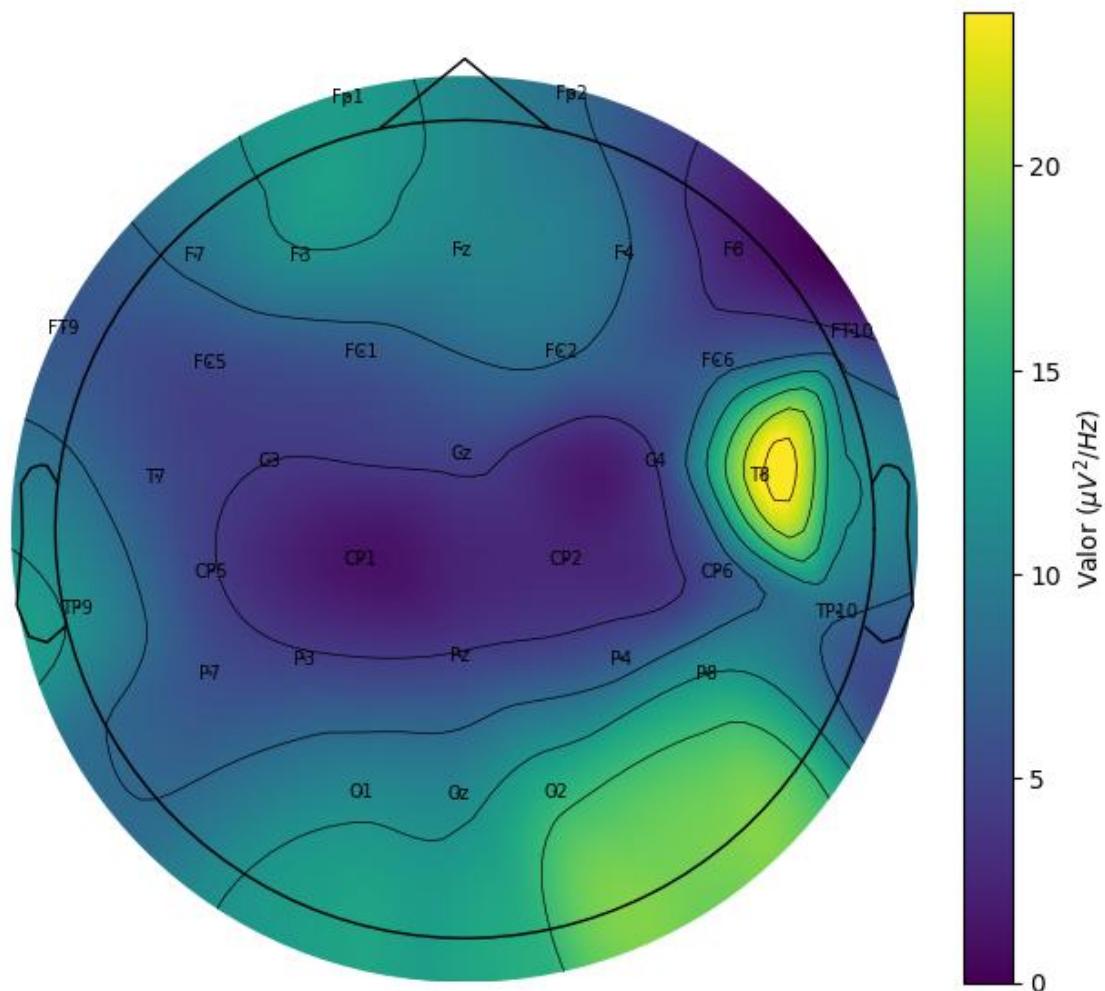
## Mapa Topográfico - Theta (4-8Hz) Potencia Absoluta



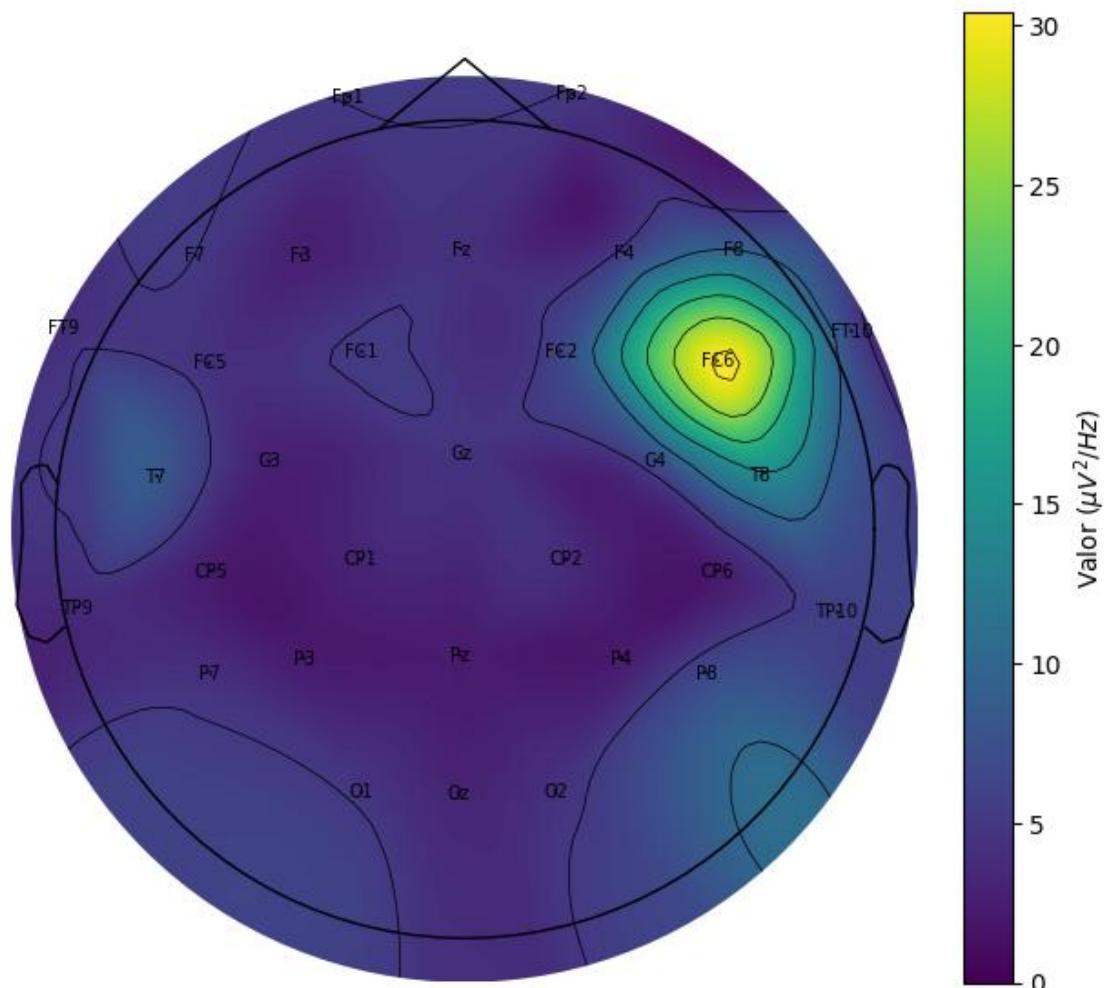
## Mapa Topográfico - Alpha (8-13Hz) Potencia Absoluta



## Mapa Topográfico - Beta Bajo (13-20Hz) Potencia Absoluta



## Mapa Topográfico - Beta Alto (20-30Hz) Potencia Absoluta



## Mapa Topográfico - Gamma (30-40Hz) Potencia Absoluta

