



UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

NEURO-NAVEGACIÓN: ESTUDIO DE RESPUESTAS EMOCIONALES EN USUARIOS  
CHILENOS AL VISUALIZAR PÁGINAS WEB MEDIANTE SEÑALES DE  
ELECTROENCEFALOGRAMA

MEMORIA PARA OPTAR AL TÍTULO DE  
INGENIERO CIVIL INDUSTRIAL

LINO IGNACIO JELDEZ SALINAS

PROFESOR GUÍA:  
JUAN VELÁSQUEZ SILVA

MIEMBROS DE LA COMISIÓN:  
ALEJANDRA PUENTE CHANDÍA  
CAROLINA SEGOVIA RIQUELME

SANTIAGO DE CHILE  
2024

**RESUMEN DE LA MEMORIA PARA OPTAR AL  
TÍTULO DE INGENIERO CIVIL INDUSTRIAL  
POR: LINO IGNACIO JELDEZ SALINAS  
FECHA: 2024  
PROF. GUÍA: JUAN VELÁSQUEZ SILVA**

**NEURO-NAVEGACIÓN: ESTUDIO DE RESPUESTAS EMOCIONALES EN  
USUARIOS CHILENOS AL VISUALIZAR PÁGINAS WEB MEDIANTE  
SEÑALES DE ELECTROENCEFALOGRAMA**

En la actual era digital, las interacciones en línea tienen una influencia crucial en la vida cotidiana. En Chile, el uso intensivo de internet ha generado la necesidad de comprender mejor cómo los usuarios interactúan emocionalmente con las páginas web. Las técnicas tradicionales de marketing han mostrado limitaciones para captar respuestas emocionales subconscientes, lo que ha impulsado el uso de herramientas de neuromarketing como el EEG. Investigaciones previas han demostrado que variables como la coloridez y la complejidad visual de una página web influyen significativamente en su atractivo percibido, y que estas percepciones pueden variar considerablemente según el perfil demográfico.

Esta investigación tiene como objetivo identificar el estado emocional de los usuarios mediante el análisis de señales de electroencefalograma (EEG) mientras observaban páginas web, para entender cómo varían las respuestas emocionales según el sexo y el rango etario.

La investigación se desarrolló en varias fases. Primero, se diseñó y ejecutó un experimento en el cual se recolectaron señales EEG mientras los participantes observaban distintas páginas web. Luego, se entrenaron modelos de aprendizaje automático para identificar estados emocionales con alta precisión. Finalmente, se realizaron análisis detallados para explorar las diferencias y similitudes en las respuestas emocionales entre diferentes grupos demográficos.

El experimento se realizó con 85 participantes, y los modelos de redes neuronales desarrollados alcanzaron una exactitud promedio superior al 90 % en los casos seleccionados. El análisis reveló diferencias significativas en las respuestas emocionales entre hombres y mujeres, especialmente en relación con la cantidad de colores en las páginas web. También se encontraron diferencias significativas en cómo los distintos rangos etarios perciben y reaccionan emocionalmente a las páginas web, subrayando la importancia de los factores demográficos en la experiencia digital. Además, se observó una correlación no significativa entre la respuesta declarada y las captadas mediante EEG, lo que indica que aportan información complementaria y valiosa,

Esta investigación profundiza sobre cómo diferentes grupos demográficos interactúan con las páginas web y cómo el neuromarketing puede proporcionar información valiosa sobre estas interacciones. Los hallazgos sugieren que los hombres tienden a experimentar emociones más positivas al ver páginas con menos colores, mientras que las mujeres prefieren sitios más coloridos. Asimismo, las leves diferencias entre respuesta declarada y emociones detectadas mediante EEG destacan la utilidad de estas herramientas para obtener nueva información, y así crear experiencias más personalizadas y efectivas para diversas audiencias.

*Dedicado a los que me han dedicado una sonrisa...*

# Agradecimientos

En primer lugar, quiero expresar mi más sincero agradecimiento a mi profesor guía, Juan Velásquez, por brindarme la oportunidad de trabajar en su proyecto de investigación y confiar en mí para llevar a cabo esta tesis. Su apoyo y orientación han sido fundamentales en este proceso.

Quiero extender un especial agradecimiento a la profesora co-guía, Alejandra Puente, por sus valiosos comentarios y por motivarme a dar lo mejor de mí en cada etapa del trabajo. Su retroalimentación fue crucial para mejorar continuamente.

A mis compañeros de tesis, Pablo Villanueva y Cristóbal Subiare, les agradezco profundamente el trabajo realizado en conjunto, especialmente en la recolección de datos del experimento. Su colaboración y dedicación fueron clave para el desarrollo de esta investigación.

Finalmente, agradezco a todos los integrantes del WIC por su amabilidad y por acogernos como parte de la institución. Su disposición y calidez contribuyeron a que este proceso fuera una experiencia enriquecedora.

A todos, ¡muchas gracias!

# Tabla de Contenido

<b>1. Introducción</b>	<b>1</b>
1.1. Justificación de la investigación . . . . .	2
1.2. Preguntas de investigación . . . . .	3
1.3. Objetivos . . . . .	4
1.3.1. Objetivo general . . . . .	4
1.3.2. Objetivos específicos . . . . .	4
1.4. Alcances . . . . .	5
<b>2. Marco teórico</b>	<b>6</b>
2.1. Conceptos Clave . . . . .	6
2.1.1. Cerebro humano . . . . .	7
2.1.2. Neuromarketing . . . . .	8
2.1.3. Electroencefalograma . . . . .	9
2.1.4. Ritmos cerebrales . . . . .	11
2.1.5. Emociones . . . . .	11
2.2. Inteligencia Artificial . . . . .	14
2.2.1. Aprendizaje automático . . . . .	16
2.2.2. Redes neuronales . . . . .	17
2.2.3. Evaluación de modelos de aprendizaje automático . . . . .	22
2.3. EEG para detectar emociones . . . . .	25
2.3.1. Enfoques . . . . .	26

2.3.2.	Localización de emociones en el cerebro . . . . .	26
2.3.3.	Evocación de emociones . . . . .	29
2.4.	Estudios relevantes en el reconocimiento de emociones con EEG . . . . .	30
2.4.1.	Electroencefalogram-Based Preference Prediction Using Deep Transfer Learning . . . . .	32
2.4.2.	EEG-Based Emotion Recognition Using Genetic Algorithm Optimized Multi-Layer Perceptron (GA - MLP) . . . . .	34
2.4.3.	Otras investigaciones relevantes . . . . .	37
2.5.	Páginas web . . . . .	40
2.5.1.	Preferencias visuales en páginas web . . . . .	40
2.6.	Test estadísticos . . . . .	45
2.6.1.	Conceptos básicos . . . . .	45
2.6.2.	Correlación de Spearman . . . . .	47
2.6.3.	Test t de Student . . . . .	48
2.6.4.	Prueba de Chi Cuadrado ( $\chi^2$ ) . . . . .	49
<b>3.</b>	<b>Metodología</b>	<b>51</b>
<b>4.</b>	<b>Desarrollo Metodológico</b>	<b>54</b>
4.1.	Fase I: Comprensión del negocio y levantamiento de información . . . . .	54
4.1.1.	Detalles del experimento . . . . .	54
4.1.2.	Diseño experimental . . . . .	62
4.1.3.	Hipótesis . . . . .	64
4.2.	Fase II: Comprensión de los datos . . . . .	66
4.2.1.	Análisis exploratorio de datos . . . . .	66
4.3.	Fase III: Preparación de los datos . . . . .	72
4.3.1.	Preprocesamiento de señales EEG . . . . .	72
4.3.2.	Sincronización Señal-Estímulo . . . . .	74
4.3.3.	Extracción de características . . . . .	74

4.4.	Fase IV: Modelado . . . . .	75
4.4.1.	Modelo 1: 1 capa oculta y Bandas de frecuencia . . . . .	75
4.4.2.	Modelo 2: 2 capas ocultas y Bandas de frecuencia . . . . .	77
4.4.3.	Modelo 3: 2 capas ocultas y Vector de frecuencias . . . . .	78
4.4.4.	Modelo seleccionado . . . . .	79
4.4.5.	Estudio de la cantidad de colores por página web . . . . .	84
4.4.6.	Modelo de predicción del grupo etario del participante . . . . .	85
4.4.7.	Modelo de predicción del sexo del participante . . . . .	87
4.5.	Fase IV: Despliegue . . . . .	88
4.5.1.	Diferencias entre sexos . . . . .	88
4.5.2.	Diferencias entre grupos etarios . . . . .	89
4.5.3.	Diferencias por sexo y cantidad de colores . . . . .	91
4.5.4.	Respuesta emocional por categoría de la página web . . . . .	94
4.6.	Comparación entre respuesta emocional y respuesta consciente . . . . .	99
4.6.1.	Análisis de medias . . . . .	99
4.6.2.	Análisis estadístico . . . . .	101
<b>5.</b>	<b>Conclusiones</b>	<b>104</b>
5.1.	Principales hallazgos . . . . .	104
5.1.1.	Diferencias por sexo . . . . .	104
5.1.2.	Diferencias por grupo etario . . . . .	105
5.1.3.	Análisis por categorías de páginas Web . . . . .	105
5.1.4.	Relación entre Respuesta Emocional y Consciente . . . . .	105
5.2.	Discusión . . . . .	106
5.2.1.	Modelo único vs Modelo personalizado . . . . .	106
5.2.2.	Puesta a prueba de hipótesis . . . . .	107
5.2.3.	Generalización de los resultados . . . . .	107
5.2.4.	Metodología Neuromarketing vs Marketing tradicional . . . . .	108

5.3.	Implicaciones y aplicaciones prácticas . . . . .	109
5.3.1.	Aplicabilidad a empresas chilenas . . . . .	110
5.3.2.	Optimización del diseño web basada en demografía . . . . .	110
5.3.3.	Integración de tecnología EEG en el diseño de experiencias de usuario . . . . .	111
5.3.4.	Diseño centrado en la experiencia emocional . . . . .	111
5.3.5.	Personalización basada en categorías de contenido . . . . .	111
5.3.6.	Implicaciones éticas y legales . . . . .	112
5.4.	Recomendaciones para futuras investigaciones . . . . .	113
5.5.	Conclusión general . . . . .	114
	<b>Bibliografía</b>	<b>120</b>
<b>6.</b>	<b>Anexo</b>	<b>121</b>
6.1.	Anexo A: Imágenes de Emomadrid seleccionadas . . . . .	121
6.2.	Anexo B: Páginas web . . . . .	122
6.3.	Anexo C: Resultados estadísticos por categorías de páginas web . . . . .	125

# Índice de Tablas

2.1. Electrodo y lóbulos . . . . .	10
2.2. Categorización de ritmos en bandas de frecuencia. . . . .	12
2.3. Estadísticas de imágenes utilizadas para predecir el colorido . . . . .	41
4.1. Categorías de la variable demográfica: Sexo. . . . .	55
4.2. Categorías de la variable demográfica: Grupo etario. . . . .	55
4.3. Páginas web seleccionadas . . . . .	58
4.4. Imágenes seleccionadas de la base de datos EmoMadrid. . . . .	60
4.5. Señales EEG que presentan problemas graves. . . . .	70
4.6. Parámetros clave del Modelo 1. . . . .	76
4.7. Métricas clave obtenidas del Modelo 1. . . . .	77
4.8. Parámetros clave del Modelo 2. . . . .	78
4.9. Métricas clave obtenidas del Modelo 2. . . . .	78
4.10. Métricas clave obtenidas del Modelo 3 . . . . .	79
4.11. Modelos de participantes mayores a 80 % de precisión por grupo etario. . . . .	79
4.12. Modelos de participantes mayores a 80 % de precisión por sexo . . . . .	80
4.13. Resultados emocionales de páginas web por sexo. . . . .	80
4.14. Resultados emocionales de páginas web por grupo etario. . . . .	80
4.15. Páginas web seleccionadas con la cantidad de colores en cada sitio . . . . .	85
4.16. Resultados modelo de predicción de grupo etario. . . . .	86
4.17. Matriz de confusión para la clasificación de grupos etarios. . . . .	86

4.18. Resultados modelo de predicción de sexo. . . . .	87
4.19. Matriz de confusión para la clasificación de sexo. . . . .	87
4.20. Respuesta emocional promedio por categoría: Hombres y Mujeres . . . . .	94
4.21. Respuesta emocional promedio por categoría: Grupo 1, Grupo 2, Grupo 3 y Grupo 4 . . . . .	95
4.22. Diferencia entre sexos por categoría de estímulo . . . . .	97
4.23. Respuesta consciente promedio por categoría: Hombres y Mujeres . . . . .	99
4.24. Respuesta consciente promedio por categoría: Grupo 1, Grupo 2, Grupo 3 y Grupo 4 . . . . .	100
4.25. Correlación de Spearman y p-valor por categoría . . . . .	101
6.1. Categoría de estímulo: Joyas . . . . .	125
6.2. Categoría de estímulo: Saturada . . . . .	127
6.3. Categoría de estímulo: Mascotas . . . . .	128
6.4. Categoría de estímulo: Guerra . . . . .	128
6.5. Categoría de estímulo: Farmacia . . . . .	128
6.6. Categoría de estímulo: Grandes marcas . . . . .	129
6.7. Categoría de estímulo: Videojuego . . . . .	129

# Índice de Ilustraciones

2.1. Ubicación lóbulos del cerebro. . . . .	7
2.2. El sistema internacional 10-20. . . . .	11
2.3. Rueda de Plutchick. . . . .	13
2.4. Mapa 2D, Valencia-Activación. . . . .	14
2.5. Representación del cuestionario de SAM. . . . .	15
2.6. Relación entre Inteligencia artificial, aprendizaje automático, redes neuronales y redes neuronales profundas. . . . .	16
2.7. Comparación entre neuronas biológicas y artificiales. . . . .	19
2.8. Red neuronal simple. . . . .	20
2.9. Matriz de confusión para dos clases. . . . .	23
2.10. Exactitud, Precisión, Sensibilidad y Especificidad a partir de la matriz de confusión de dos clases. . . . .	25
2.11. Metodología clásica del reconocimiento de emociones a partir de EEG. . . . .	31
2.12. Electrodo utilizados en GA - MLP. . . . .	34
2.13. Representación del operador Single Point Crossover. . . . .	37
2.14. Representación gráfica de GA - MLP. . . . .	38
2.15. Coloridad y Atractivo visual . . . . .	43
2.16. Complejidad visual y Atractivo visual . . . . .	43
2.17. Coloridad y Atractivo visual por sexo . . . . .	44
2.18. Coloridad y Atractivo visual por grupo etario . . . . .	45
4.1. Electrodo utilizados del sistema internacional 10-20. . . . .	56

4.2. Imágenes seleccionadas distribuidas en el plano de Valencia-Activación . . . . .	61
4.3. Proceso de muestra de páginas web. . . . .	64
4.4. Distribución de demográfica de los participantes del experimento. . . . .	66
4.5. Respuesta consciente agrupada por Sexo. . . . .	67
4.6. Respuesta consciente agrupada por Grupo etario. . . . .	68
4.7. Respuesta consciente agrupada por Grupo etario y Sexo. . . . .	69
4.8. Respuesta consciente agrupada por categoría de la página web . . . . .	69
4.9. Distribución de demográfica de los participantes de las señales a utilizar. . . . .	70
4.10. Señales EEG para una mujer de 51 años (grupo etario 3). . . . .	71
4.11. Señales EEG filtradas para una mujer de 51 años (grupo etario 3). . . . .	73
4.12. Páginas web que produjeron respuestas emocionales extremas por sexo. . . . .	82
4.13. Páginas web que produjeron respuestas emocionales extremas por grupo etario. . . . .	83
4.14. Atractivo visual versus cantidad de colores por sexo. . . . .	92
4.15. Estado emocional versus cantidad de colores por sexo. . . . .	93

# Capítulo 1

## Introducción

En la era digital actual, los sitios web se han establecido como puntos de contacto esenciales, no solo para los consumidores, sino para una amplia gama de usuarios con diversos intereses y necesidades. Tan diversos como la adquisición de información para intereses personales o laborales hasta el entretenimiento y la comunicación, los sitios web desempeñan un papel crucial en cómo interactuamos con el mundo digital.

Hoy en día, es común que las personas pasen varias horas al día en Internet, utilizando una amplia gama de dispositivos. Se han desarrollado y aplicado diversas técnicas con el objetivo de analizar y entender profundamente su comportamiento en línea. Una de las prácticas más comunes es monitorear estadísticas clave como el número de visitas, usuarios únicos, tasa de rebote, tiempo en el sitio, etc. . Otra técnica esencial son los mapas de calor, que representan visualmente las áreas más visitadas de una página web y muestran los puntos donde los usuarios hacen clic y cómo se desplazan por ella. Además, se utilizan habitualmente los cuestionarios y tests para recoger retroalimentación directa de los usuarios sobre su experiencia y preferencias.

Estas técnicas convencionales se centran en observar el comportamiento y las respuestas conscientes de los usuarios frente a los sitios web. Sin embargo, el objetivo de este estudio es adentrarse en la mente de los usuarios para obtener un entendimiento más profundo de sus preferencias y emociones al observar páginas web. Este enfoque forma parte del ámbito del neuromarketing.

El neuromarketing, un campo en pleno desarrollo que conecta aspectos cognitivos y emocionales del comportamiento del consumidor, combina conocimientos de psicología, neurociencia, ingeniería y aprendizaje automático. Desde su surgimiento en 2002, ha ganado rápidamente la confianza de profesionales en publicidad y marketing, muchos de los cuales han comenzado a implementar estrategias basadas en neuromarketing.

Una herramienta clave en el neuromarketing es la electroencefalografía (EEG), que registra la actividad eléctrica del cerebro mediante electrodos colocados en el cuero cabelludo. Esta técnica es muy utilizada para analizar las respuestas emocionales y los niveles de atención de los consumidores.

En este informe se propone detallar la investigación realizada sobre la medición de la actividad cerebral mediante EEG en varios usuarios mientras observan sitios web. El objetivo es identificar los estados emocionales subyacentes durante la observación web, aplicando técnicas de neuromarketing e inteligencia artificial, para detectar diferencias en las respuestas emocionales de distintos grupos demográficos. Específicamente, se busca encontrar diferencias en los estados emocionales a través de variables demográficas como sexo y rango etario.

Se profundizará en los fundamentos científicos y técnicos del reconocimiento de emociones y preferencias a través de señales EEG, revisando el estado actual de la investigación en este campo, sus aplicaciones principales y los desafíos a enfrentar. Asimismo, se explorarán las teorías existentes sobre las emociones y cómo estas se han traducido en modelos computacionales que permiten a las máquinas tener una comprensión parcial de la experiencia emocional humana.

Finalmente, se detallará exhaustivamente el modelo de aprendizaje automático utilizado para predecir las respuestas emocionales de los usuarios mientras observan páginas web. Este enfoque aporta una nueva dimensión al análisis del comportamiento del usuario en la web, abriendo caminos hacia perspectivas innovadoras con el objetivo de enriquecer la experiencia del usuario dentro del vasto universo digital. A partir de los resultados obtenidos, se buscarán las posibles diferencias demográficas en la población de Chile. Por otra parte, los resultados se presentarán en contraste con las respuestas conscientes, con el fin de encontrar diferencias y similitudes, demostrando así su efectividad.

## 1.1. Justificación de la investigación

El impacto del internet y de las páginas web en la vida cotidiana de las personas ha sido significativo y profundo en los últimos 20 años. Las personas utilizan internet para una variedad de actividades, entre las que se incluyen la búsqueda de información, la comunicación a través de redes sociales y correos electrónicos, el consumo de entretenimiento como videos y música, la realización de compras en línea, el acceso a servicios bancarios y financieros, y la educación mediante cursos en línea y tutoriales. Este amplio uso del internet refleja su integración profunda en múltiples aspectos de la vida diaria. Según el informe Digital 2024 publicado por We Are Social [1], se ha observado que, en promedio, un individuo que utiliza internet dedica aproximadamente 6 horas y 40 minutos al día navegando en internet.

En particular, Chile presenta unas estadísticas impresionantes en este ámbito. Los ciudadanos chilenos invierten en promedio 8 horas y 31 minutos diarios en línea, lo que sitúa a Chile en una posición destacada a nivel global, siendo el sexto país del mundo con mayor promedio de uso diario de internet. Esta cantidad de tiempo refleja no solo la penetración y adopción del internet en la vida cotidiana de los chilenos, sino también la relevancia de la tecnología digital en su rutina diaria.

El uso intensivo del internet en Chile subraya la importancia de comprender mejor cómo los usuarios interactúan con las páginas web. En este contexto, el empleo de herramientas de neuromarketing para analizar las preferencias de los usuarios representa una oportunidad significativa. Las herramientas de marketing tradicionales, como entrevistas y cuestionarios,

pueden llevar a la generación de conclusiones sesgadas o incorrectas [2], e incluso se ha demostrado que las personas no siempre reconocen lo que sucede en su inconsciente ni explicitan sus preferencias oralmente [3]. Por tanto, estas técnicas de neuromarketing ofrecen un enfoque innovador, el cual podría permitir obtener una visión más precisa y profunda de las respuestas emocionales de los usuarios.

Dentro del espectro de técnicas de neuroimagen utilizadas por el neuromarketing, la electroencefalografía (EEG) destaca como la opción menos invasiva y más económica. A diferencia de tecnologías como la resonancia magnética funcional (fMRI) o la espectroscopía infrarroja cercana funcional (fNIRS), que pueden requerir de entornos controlados, posiciones fijas prolongadas o el uso de grandes y costosos equipos. Por otra parte, el EEG posee la capacidad de capturar la actividad cerebral con una alta resolución temporal, a un bajo costo y sin ser invasivo. Esto hace del EEG una herramienta especialmente apta para el estudio de la actividad cerebral de los consumidores en condiciones naturales de observación de páginas web.

La investigación sobre el estudio de respuestas emocionales al observar páginas web mediante el uso de la electroencefalografía (EEG) representa un avance significativo e innovador en Chile. El objetivo principal de esta investigación es identificar diferencias demográficas en las respuestas emocionales, específicamente en las variables de sexo y rango etario. Al centrarse en la población chilena y utilizar técnicas de neuromarketing, esta investigación abre un nuevo horizonte en la comprensión del comportamiento del consumidor en el país. El empleo del EEG permite una exploración profunda y detallada de las respuestas emocionales que subyacen a la navegación en las páginas web, donde los métodos más tradicionales podrían no capturar con tanta precisión.

Esta metodología podría ser crucial para el diseño de estrategias de marketing digital más efectivas y personalizadas. Al considerar las particularidades culturales y sociales de los consumidores chilenos, las empresas y marcas pueden mejorar significativamente la experiencia del usuario en sus plataformas web, fomentando una mayor satisfacción y lealtad. Comprender cómo distintos grupos demográficos reaccionan emocionalmente a diversos elementos en las páginas web permite diseñar experiencias digitales más inclusivas y atractivas para todos los segmentos de la población.

Cabe destacar que la investigación fue guiada por el profesor Juan Velásquez, mientras que los procesos de adquisición y procesamiento de datos se realizaron en el Web Intelligence Centre (WIC).

## **1.2. Preguntas de investigación**

En la actual investigación, se plantea abordar una pregunta de investigación fundamental que guiará tanto el diseño experimental como el posterior análisis de los datos. Esta pregunta busca no solo profundizar en la interacción entre el usuario y la web, sino también comprender los patrones subyacentes en los diferentes segmentos poblacionales. Específicamente, se pretende investigar cómo diversos grupos demográficos, diferenciados por variables como sexo y rango etario, responden emocionalmente al navegar por distintas páginas web.

De esta manera, se espera obtener una visión más completa y detallada de las similitudes y diferencias que influyen en la experiencia del usuario en función de su perfil demográfico.

### **¿Cómo varían los estados emocionales de los distintos grupos demográficos al observar distintas páginas web?**

Esta pregunta de investigación central se desglosa en varios aspectos específicos que buscan:

1. Identificar patrones de respuesta emocional asociados a variables demográficas específicas como la edad y sexo.
2. Determinar si existen diferencias significativas en la reacción emocional de los distintos grupos frente a características de páginas web, como la cantidad de colores.
3. Determinar el grado de correlación entre el estado emocional detectado por el EEG y la respuesta consciente.

Al responder a esta pregunta, se pretende no solo contribuir al campo del neuromarketing y a la comprensión del comportamiento del consumidor en entornos digitales, sino también ofrecer insights valiosos para el diseño de páginas web. Al enfocarse en las reacciones emocionales de distintos grupos de usuarios ante características específicas, como la cantidad de colores, se pueden obtener datos precisos y relevantes que guíen el diseño web.

Se espera que los resultados permitan a los diseñadores y desarrolladores crear páginas web que no solo atraigan visualmente, sino que también generen una experiencia de usuario más inclusiva y efectiva. Comprender cómo diferentes grupos reaccionan emocionalmente a diversas características puede ayudar a personalizar el diseño para satisfacer mejor las necesidades y preferencias de cada grupo. Esto, a su vez, puede aumentar la satisfacción del usuario, mejorar la retención y fomentar una interacción más positiva con el contenido digital, logrando así un impacto significativo tanto en la experiencia del usuario como en los resultados comerciales.

## **1.3. Objetivos**

### **1.3.1. Objetivo general**

Identificar el estado emocional de los usuarios a partir de las señales EEG obtenidas durante el proceso de observación de páginas web, con el fin de entender de manera más profunda el proceso de navegación web.

### **1.3.2. Objetivos específicos**

Los objetivos específicos se detallan a continuación:

1. Elaborar el diseño experimental
2. Adquirir las señales EEG con las características descritas en el diseño experimental
3. Entrenar modelos de machine learning con los datos obtenidos, para identificar estados emocionales de los usuarios con una precisión mayor al 80 %
4. Encontrar diferencias y similitudes demográficas entre los distintos grupos demográficos
5. Evaluar los resultados y refutar ó validar las hipótesis
6. Proponer trabajos futuros

## 1.4. Alcances

El propósito de la investigación es aplicar métodos de aprendizaje automático para el análisis de señales electroencefalográficas con el fin de identificar y entender las diferencias demográficas presentes en el grupo estudiado, específicamente en lo que respecta a su estado emocional al observar sitios web.

Es importante señalar que el estudio no tiene como objetivo proporcionar recomendaciones para el diseño de páginas web, ni pretende representar de manera exhaustiva a la sociedad chilena. Además, se aclara que no se busca analizar todos los tipos de páginas web ni abarcar todas las categorías de negocio existentes en el ámbito digital. En cambio, se asegura un equilibrio demográfico en términos de edad y sexo dentro de la muestra seleccionada. Este enfoque busca generar conocimientos que puedan contribuir a futuras investigaciones o aplicaciones en el análisis de datos biométricos en entornos digitales.

# Capítulo 2

## Marco teórico

El reconocimiento de estados emocionales a partir de ondas electroencefalográficas (EEG) se ha convertido en un campo de investigación clave que fusiona la neurociencia, la psicología y la informática. Este ámbito se centra en interpretar las señales eléctricas del cerebro para descifrar cómo las emociones afectan la actividad neuronal y desarrollar algoritmos de inteligencia artificial capaces de identificarlas. La capacidad de detectar y clasificar emociones mediante EEG ofrece una perspectiva valiosa sobre los procesos mentales, con aplicaciones que van desde la interacción humano-computadora hasta estudios en neuromarketing.

En el contexto de la interacción con contenido web, el análisis de señales EEG permite investigar cómo distintos estímulos digitales, como imágenes, texto o videos, provocan respuestas emocionales en los usuarios. Dado que las páginas web son estímulos visuales complejos, su diseño y contenido pueden desencadenar una amplia gama de reacciones emocionales, lo cual es fundamental para mejorar la experiencia del usuario. Este capítulo del marco teórico examinará las bases científicas y avances tecnológicos en el reconocimiento de emociones mediante EEG, con un enfoque en la interacción con entornos digitales.

Se abordarán las teorías y modelos que vinculan las emociones con la actividad cerebral, las técnicas para capturar y analizar señales EEG, y los avances recientes en algoritmos de inteligencia artificial para su interpretación. También se revisarán estudios previos sobre la respuesta emocional a estímulos web y cómo estas respuestas varían según diferentes grupos demográficos, proporcionando un marco esencial para diseñar sistemas adaptativos que ajusten el contenido web en función de las emociones y preferencias de los usuarios.

### 2.1. Conceptos Clave

En esta sección introduce y describe los fundamentos teóricos y terminología esencial para entender el análisis emocional a través de señales EEG y su aplicación en el estudio de la interacción con páginas web. Aquí se desglosan los principales aspectos del funcionamiento del cerebro humano, los principios del neuromarketing y la metodología subyacente en la captura y análisis de señales cerebrales, como el electroencefalograma (EEG). También se

exploran las bases del procesamiento emocional, discutiendo modelos discretos y continuos que permiten clasificar y entender las emociones humanas. Esta comprensión teórica proporciona un marco sólido para interpretar los datos y desarrollar enfoques precisos en estudios de comportamiento digital.

### 2.1.1. Cerebro humano

El cerebro humano es un órgano complejo y sofisticado, responsable de las funciones más avanzadas del humano como el pensamiento, la memoria, la emoción y el control del movimiento. Compuesto por aproximadamente 86 mil millones de neuronas, permite la interpretación de sensaciones, el procesamiento de pensamientos complejos y la generación de respuestas. Este órgano no solo coordina acciones y reacciones simples sino que también es el centro de la conciencia humana, domina la capacidad de interactuar y comprender el mundo.

El cerebro se divide principalmente en tres partes: el núcleo del cerebro, el margen del cerebro y la corteza cerebral, siendo esta última la más funcional y avanzada. La corteza cerebral está compuesta por una asociación compleja de neuronas densamente empaquetadas que cubren la parte más externa del cerebro, constituyendo la materia gris. Situada justo debajo de las meninges, se divide en cuatro lóbulos: frontal, temporal, parietal y occipital, cada uno con múltiples funciones. [4]

La Figura 2.1 muestra la posición de cada lóbulo dentro del cerebro. Cada lóbulo del cerebro está asociado principalmente a tareas específicas, desempeñando roles cruciales en las funciones cognitivas y motoras del ser humano.

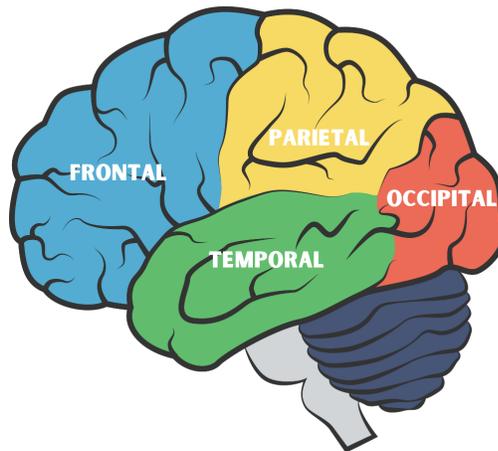


Figura 2.1: Ubicación lóbulos del cerebro.

Fuente: Elaboración propia.

- **Lóbulo frontal:** es el lóbulo más grande del cerebro, está situado delante del surco central. Es responsable de funciones cognitivas avanzadas como el pensamiento, la

planificación, la toma de decisiones y el control de impulsos. También juega un papel crucial en la expresión de la personalidad y en el procesamiento de emociones. Es fundamental para las habilidades de comunicación, incluyendo el habla y la escritura.

- **Lóbulo parietal:** ubicado al centro del cerebro, se encarga de procesar información sensorial, incluyendo el tacto, la temperatura y el dolor. También juega un papel crucial en la percepción espacial y la coordinación mano-ojo, facilitando la capacidad de orientarse en el espacio y manipular objetos.
- **Lóbulo temporal:** ubicado debajo de la fisura de Silvio del cerebro, se encarga principalmente del procesamiento auditivo y juega un papel importante en la comprensión del lenguaje, la memoria y las emociones. Facilita la habilidad de reconocer y procesar sonidos, así como de almacenar recuerdos a largo plazo.
- **Lóbulo occipital:** ubicado en la parte trasera del cráneo, es el centro de procesamiento visual del cuerpo y puede procesar información visual como el color, la luz y la sombra, y la velocidad del movimiento. Es esencial en el proceso de integración de la información recibida.

Si bien cada lóbulo del cerebro está asociado a funciones específicas, en realidad, cualquier tarea que realizamos involucra la actividad coordinada de todo el cerebro. Esto se debe a la naturaleza altamente interconectada del cerebro humano, donde diferentes áreas trabajan juntas para realizar funciones complejas.

### 2.1.2. Neuromarketing

El neuromarketing es una disciplina emergente que fusiona principios de la neurociencia con el marketing para comprender mejor cómo los consumidores reaccionan a diversos estímulos comerciales. Esta disciplina se desarrolló con el objetivo de desentrañar cómo muchas decisiones del consumidor son influenciadas por el subconsciente y el inconsciente.

Sigmund Freud propuso un modelo de la mente compuesto por tres niveles: consciente, subconsciente e inconsciente. El consciente abarca todos los pensamientos y acciones de los que estamos plenamente conscientes. El subconsciente se refiere a las reacciones y comportamientos automáticos que pueden ser traídos a la conciencia con un poco de esfuerzo. El inconsciente, por otro lado, almacena todos los eventos y recuerdos pasados que, aunque no siempre accesibles, impactan significativamente en nuestro comportamiento [5].

Mientras que la investigación sobre el nivel consciente puede realizarse a través de encuestas y cuestionarios, explorar el subconsciente y el inconsciente requiere un enfoque distinto. Además, los métodos de investigación tradicionales se enfocan principalmente en la actitud a posteriori de los consumidores hacia los productos. Por lo tanto, estas respuestas están retrasadas y simplificadas, y no representan el estado mental real en el momento de la compra [6].

Es aquí donde la neurociencia juega un papel crucial, proporcionando métodos objetivos que evitan el sesgo inherente a las respuestas conscientes. Al emplear herramientas neurocientíficas, el neuromarketing puede capturar reacciones y comportamientos en su totalidad,

ofreciendo una visión más completa y precisa de las decisiones del consumidor, más allá de lo que estos están dispuestos o pueden articular conscientemente.

El neuromarketing utiliza una variedad de técnicas de neurociencia para medir la actividad cerebral y otras respuestas fisiológicas de los consumidores mientras interactúan con diversos estímulos de marketing, tales como el electroencefalograma (EEG), la resonancia magnética funcional (fMRI), la magnetoencefalografía (MEG), la espectroscopía funcional de infrarrojo cercano (fNIRS), el seguimiento ocular (eye tracking), la electromiografía facial (EMG facial), la pupillometría, la frecuencia cardíaca (heart rate monitoring), la respuesta galvánica de la piel (GSR), el análisis de expresiones faciales y la variabilidad de la frecuencia cardíaca (HRV), entre otras.

En este caso, se estudiarán aquellas técnicas de neurociencia que se enfocan en estudiar la mente. Estas técnicas se dividen en invasivas, parcialmente invasivas y no invasivas, cada una con sus propios beneficios y limitaciones.

Las técnicas invasivas requieren cirugía para implantar electrodos directamente en el tejido cerebral, lo que permite una alta precisión en la captación de señales. Las parcialmente invasivas, por otro lado, implican la implantación de electrodos dentro del cráneo pero no en el tejido cerebral, ofreciendo un equilibrio entre precisión y riesgo quirúrgico. Finalmente, las BCI no invasivas recogen señales desde el exterior del cráneo, eliminando la necesidad de intervención quirúrgica y, por lo tanto, reduciendo significativamente los riesgos asociados.

Entre las técnicas no invasivas más populares se encuentran el electroencefalograma (EEG), la espectroscopía funcional de infrarrojo cercano (fNIRS), la resonancia magnética funcional (fMRI) y la magnetoencefalografía (MEG). El EEG es particularmente destacado debido a su portabilidad, bajo costo y facilidad de uso. Además, su excepcional resolución temporal permite capturar dinámicas cerebrales en milisegundos, lo que lo hace ideal para estudios interactivos y repetitivos del cerebro en entornos menos controlados.

Aunque el EEG tiene limitaciones en términos de resolución espacial y relación señal-ruido en comparación con fNIRS, fMRI y MEG, su practicidad lo hace óptimo para investigaciones que requieren movilidad y repetición. La fNIRS, por ejemplo, ofrece mejor resolución espacial que el EEG, pero es menos práctica debido a su mayor complejidad y costo. La fMRI y la MEG, por su parte, proporcionan imágenes de alta resolución y una excelente relación señal-ruido, pero su uso está limitado a entornos controlados debido a sus altos costos y requisitos de infraestructura.

### **2.1.3. Electroencefalograma**

El EEG (Electroencefalograma) es una herramienta utilizada para la actividad cerebral. La actividad eléctrica se registra en el cuero cabelludo mediante la evaluación de las variaciones de voltaje producidas por la actividad de las neuronas en el cerebro. Estas actividades eléctricas se registran durante un período de tiempo utilizando varios electrodos posicionados en el cuero cabelludo directamente sobre la corteza cerebral.

El EEG se utiliza rutinariamente para diagnosticar o monitorear condiciones médicas y

enfermedades como: diferenciar convulsiones epilépticas, evaluación preoperatoria, tumores, pacientes sedados en riesgo de convulsiones, pronóstico de paro cardiaco, diagnóstico de muerte cerebral, desarrollo acústico o del lenguaje, trastornos del sueño, entre otras. Para fines de investigación, el EEG se emplea en neuromarketing y psicología, enfocándose en procesos subyacentes de atención, aprendizaje, memoria y emociones.

Para colocar los electrodos en el cuero cabelludo, se utiliza principalmente el sistema internacional 10-20.

### 2.1.3.1 Sistema internacional 10-20

El sistema 10/20 o sistema internacional 10/20 es un método reconocido internacionalmente para describir la ubicación de los electrodos del cuero cabelludo. El sistema fue creado para estandarizar la colocación de electrodos. Este sistema es crucial para garantizar la consistencia y comparabilidad de los datos de EEG entre diferentes estudios y laboratorios.

El sistema se basa en la relación entre la ubicación de un electrodo y el área subyacente de la corteza cerebral. Los números '10' y '20' se refieren al hecho de que las distancias entre electrodos adyacentes son el 10% o el 20% de la distancia total adelante-atrás o derecha-izquierda del cráneo.

Cada sitio tiene una letra para identificar el lóbulo y un número para identificar la ubicación del hemisferio [7], tal como se muestra en la Tabla 2.1.

Electrodo	Lóbulo
F	Frontal
T	Temporal
C	Central*
P	Parietal
O	Occipital

Tabla 2.1: Electrodos y lóbulos

\* No existe el lóbulo central, la letra 'C' es usada para identificar el centro. Además, para nombrar a los electrodos se utilizan las siguientes reglas:

- La 'z' (zero) se refiere a un electrodo posicionado en la línea central.
- Los números pares se refieren a electrodos posicionados en el hemisferio derecho.
- Los números impares se refieren a electrodos posicionados en el hemisferio izquierdo
- Se utilizan cuatro puntos anatómicos para la colocación de los electrodos: primero, el nasión que es el punto entre la frente y la nariz; segundo, el inicio, que es el punto más bajo del cráneo desde la parte posterior de la cabeza y normalmente está indicado por un bulto prominente; los puntos preauriculares anteriores a la oreja.

En la Figura 2.2, se muestra los posicionamientos y los nombres con las características descritas anteriormente.

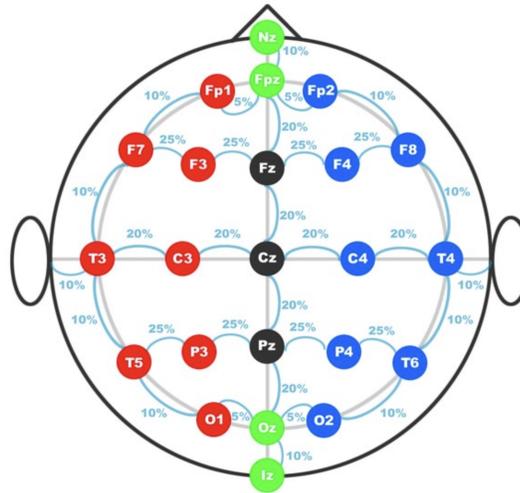


Figura 2.2: El sistema internacional 10-20.

Fuente: Extraído desde: [7]

#### 2.1.4. Ritmos cerebrales

Los ritmos cerebrales son oscilaciones eléctricas en el cerebro que resultan de la actividad sincronizada de las neuronas. Se clasifican generalmente en bandas según su frecuencia: delta, theta, alfa, beta, y gamma. Cada banda está asociada con diferentes estados de conciencia y actividades mentales, como el sueño profundo, la relajación, el estado de alerta y la resolución de problemas.

Los ritmos cerebrales también se intensifican en distintos lóbulos del cerebro, reflejando diversas funciones cognitivas y estados de conciencia asociados con cada región. Por ejemplo, los ritmos alfa son prominentes en el lóbulo occipital durante estados de relajación con los ojos cerrados, mientras que los ritmos beta se observan ampliamente en regiones frontales durante la concentración y actividad mental intensa. En la tabla 2.2 se muestran las características de los distintos ritmos.

#### 2.1.5. Emociones

Las emociones son estados complejos de sentimientos que resultan de la combinación de experiencias, creencias, y comportamientos. Se caracterizan por cambios psicológicos y fisiológicos que influyen nuestro estado de ánimo y motivación. Las emociones pueden ser positivas o negativas y varían en intensidad. Juegan un papel esencial en la toma de decisiones, en las interacciones sociales, y en la percepción del mundo. Están íntimamente ligadas a la memoria y la atención, afectando como se procesa y recuerda la información. La emoción, que engloba los estados mentales, el comportamiento y el pensamiento actuales de una persona, es tan abstracta que no puede cuantificarse [9].

En 1997 Picard [10] definió la informática afectiva, también conocida como computación

Ritmos	Frecuencia (Hz)	Amplitud ( $\mu V$ )	Ubicación	Actividad mental
Delta ( $\delta$ )	0.1 - 4	50 - 100	Frontal en adultos Posterior en niños	Dormir Soñar Bebes
Theta ( $\Theta$ )	4 - 8	<100	Lóbulo temporal Región central (Fz a Cz)	Somnolencia Imaginación Reflexivo Primer paso a dormir
Alpha ( $\alpha$ )	8 - 13	<10	Frontal Occipital	Relajación Concentración Ojos cerrados
Beta ( $\beta$ )	13 - 30	<20	Frontal Corteza Somatosensorial entre (C3 a C4)	Alerta Pensando Concentración activa
Gamma ( $\gamma$ )	>30	<2	Frontal Central Corteza Somatosensorial	Actividad mental alta Reconocimiento de objetos, sonidos ó sensaciones táctiles Concentración Agitación

Tabla 2.2: Categorización de ritmos en bandas de frecuencia.

Fuente: Modificado a partir de [8]

afectiva, es un campo interdisciplinario que se centra en desarrollar sistemas capaces de reconocer, interpretar, procesar y emular las emociones humanas. Su objetivo es permitir a las máquinas comprender y responder a las emociones de las personas de una manera más natural y efectiva. Sin embargo, a pesar de que las computadoras tienen una sólida capacidad de cálculo lógico, las computadoras no logran entender de manera profunda a los seres humanos debido a la falta de mecanismos psicológicos similares a los humanos.

Para entender las emociones hay que clasificarlas o dividir las, pero clasificar o dividir emociones es complejo debido a su naturaleza subjetiva y multidimensional. Las emociones no solo varían entre individuos, sino que una misma persona puede experimentar emociones mixtas o cambiantes. Además, factores culturales y contextuales influyen significativamente en cómo se expresan y perciben las emociones.

En la actualidad, los investigadores de la informática afectiva suelen dividir los modelos de clasificación de emociones en modelos discretos y modelos de espacio continuo dimensional.

### 2.1.5.1 Modelo de emociones discreto

Según la teoría de la evolución de Darwin, las emociones son discretas y se preservan en la selección natural. Inspirado en la teoría de Darwin, Paul Ekman en 1972 propuso seis emociones básicas: felicidad, enojo, miedo, sorpresa, tristeza y disgusto [11]. En 2003, el psicólogo Plutchik [12]. dividió las emociones en ocho categorías básicas: ira, miedo, tristeza, disgusto, expectativa, sorpresa, aprobación y felicidad. Además, Plutchik sugirió cuatro divisiones: felicidad vs tristeza, ira vs miedo, aprobación vs disgusto y sorpresa vs expectativa. Con lo anterior creó la rueda de emociones, donde las emociones contrarias están en extremos

contrarios y todas las emociones se derivan de las 8 emociones básicas. En la Figura 2.3 se muestra la rueda de emociones de Plutchik.

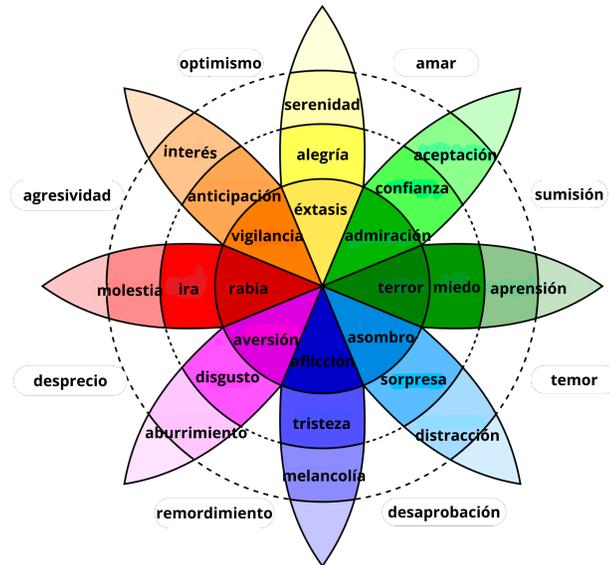


Figura 2.3: Rueda de Plutchik.

Fuente: Modificado a partir de [13]

Los métodos de clasificación de emociones discretas son relativamente simples y fáciles de entender, y se han utilizado ampliamente en muchos estudios de reconocimiento de emociones.

El modelo discreto de emociones tiene sus desventajas debido a que dividir los estados emocionales en una docena de tipos discretos limita la complejidad y la riqueza de las experiencias emocionales humanas. Esto puede resultar en una simplificación excesiva de las emociones y en la falta de reconocimiento de emociones matizadas o mixtas. Además, puede no considerar adecuadamente el contexto cultural y social en el que se experimentan y expresan las emociones, lo que es crucial para una comprensión completa de las emociones humanas. Por ejemplo, no se puede encontrar una traducción correspondiente en polaco para la emoción etiquetada como 'asco'.

### 2.5.1.2 Modelo continuo de emociones

El método de cuantificación de emociones de tipo dimensional continuo, utiliza ejes mutuamente ortogonales para mostrar diferentes dimensiones de la emoción.

Russel en 1979 propone el sistema de dos dimensiones de Valencia-Activación [14], donde 'Valencia' y 'Activación' se refieren a la intensidad del placer y a la intensidad de la emoción respectivamente. Los valores del eje de 'Valencia' de positivo a negativo se refieren a la medición de los grados de felicidad y tristeza de las personas. Del mismo modo, un valor positivo en 'Activación' indica un estado activado (excitación), mientras que un valor negativo

indica un estado no activado (calma). En la Figura 2.4, se puede observar el mapa de valencia - activación para emociones.

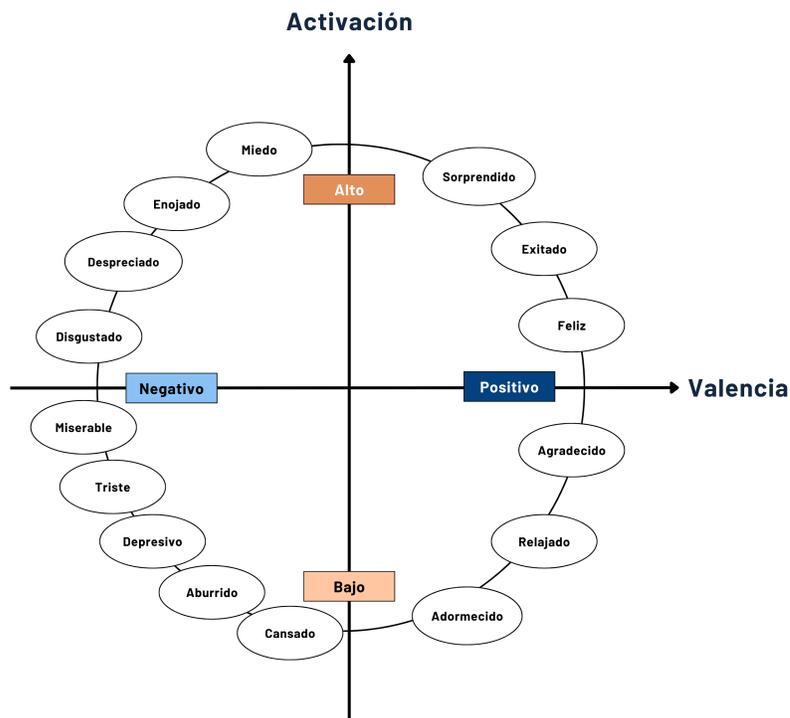


Figura 2.4: Mapa 2D, Valencia-Activación.

Fuente: Modificado a partir de [15]

### 2.1.5.3 Cuestionario SAM

El Cuestionario SAM [16] (Self-Assessment Manikins) es un método utilizado para entender y evaluar estados emocionales continuos, esta herramienta se utiliza para evaluar estados emocionales o actitudes de una manera visual y sencilla. Consiste en una escala gráfica en la que los encuestados pueden indicar su nivel de emoción o actitud mediante la selección de un maniquí que mejor represente su estado, tal como se muestra en la Figura 2.5. La escala SAM suele incluir maniqués que representan la valencia (de emociones positivas a negativas), la excitación (de baja a alta). Los usuarios eligen el maniquí que mejor refleja su estado emocional o actitud en un momento dado, y esta elección se utiliza para cuantificar sus respuestas.

## 2.2. Inteligencia Artificial

La Inteligencia Artificial (IA) es un campo de la informática dedicado al desarrollo de sistemas computacionales inteligentes, capaces de percibir, analizar y responder adecuada-

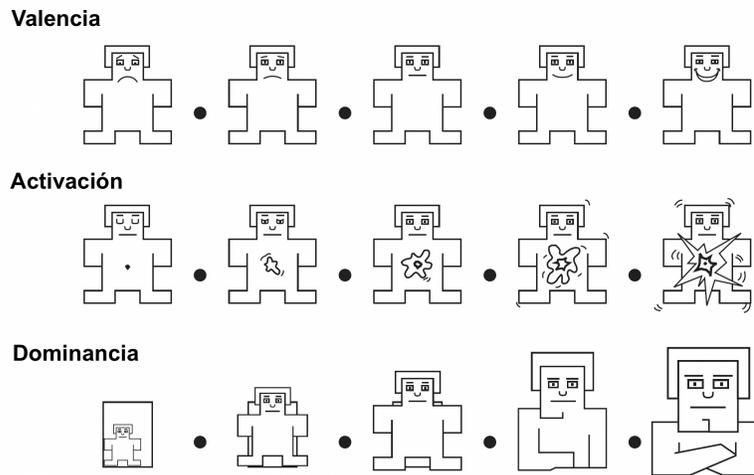


Figura 2.5: Representación del cuestionario de SAM.

Fuente: Modificado a partir de [17].

mente a los datos recibidos. Desde sus inicios en la década de 1950, la IA ha evolucionado significativamente. Comenzó con la visión de crear máquinas que pudieran replicar la inteligencia humana, liderada por pioneros como Alan Turing y John McCarthy. Hoy en día, la IA ha impulsado el avance de técnicas innovadoras para abordar problemas complejos de la vida real.

Dentro de la IA, se destaca: el aprendizaje automático (Machine Learning), las redes neuronales (Neural Networks) y el redes neuronales profundas (Deep neural networks). El aprendizaje automático, que se desarrolló a partir de las investigaciones de Arthur Samuel en los años 50, se considera un subconjunto de la IA. Luego como subconjunto del aprendizaje automático están las redes neuronales (Neural Networks), que imitan el funcionamiento del cerebro humano para procesar información y aprender de los datos. Estas redes están compuestas por capas de neuronas artificiales que se conectan entre sí.

En las últimas décadas, las redes neuronales profundas han ganado protagonismo, con raíces en los trabajos de los años 80 y 90, pero con un auge significativo en la última década gracias al aumento de poder computacional y grandes conjuntos de datos. Las redes neuronales profundas (Deep Neural Networks) son una extensión de las redes neuronales tradicionales, caracterizadas por tener muchas capas ocultas entre la entrada y la salida. Esta profundidad permite que las redes neuronales profundas capturen patrones y características mucho más complejas de los datos, lo que las hace especialmente efectivas en tareas como el reconocimiento de imágenes, procesamiento del lenguaje natural y juegos.

En la Figura 2.6 se muestra una representación gráfica de la relación entre la IA, el aprendizaje automático, las redes neuronales y las redes neuronales profundas, ilustrando cómo estas disciplinas se relacionan.

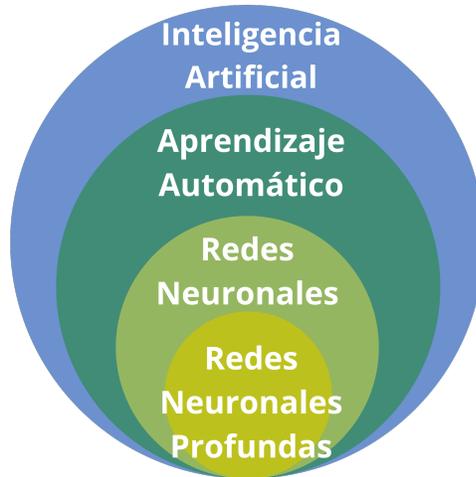


Figura 2.6: Relación entre Inteligencia artificial, aprendizaje automático, redes neuronales y redes neuronales profundas.

Fuente: Modificado a partir de [18]

### 2.2.1. Aprendizaje automático

El aprendizaje automático, o machine learning, es un campo de la inteligencia artificial que se dedica a la creación de algoritmos capaces de aprender y mejorar a partir de datos sin intervención humana constante. Este proceso imita la capacidad de los humanos para mejorar con la experiencia y se utiliza ampliamente en la resolución de problemas complejos que requieren el manejo de grandes cantidades de información, como la clasificación de correos electrónicos, la detección de fraudes y la predicción de comportamientos. A lo largo de esta sección, se explorarán los principios fundamentales del aprendizaje automático, sus principales técnicas y categorías, así como las aplicaciones que lo han posicionado como una herramienta clave en la era de los datos.

Así como los humanos pueden pensar, mejorar mediante un ciclo de auto-mejora y aprender de las experiencias pasadas, las máquinas de IA también pueden aprender de las experiencias pasadas con la ayuda del concepto conocido como aprendizaje automático. En este método, la máquina analiza el conjunto de datos disponible, conocido también como datos de entrenamiento, y con la ayuda de los algoritmos predice la salida posible sobre la entrada dada. Cuanta más información se proporcione, más perfecta será la actuación o predicción. En otras palabras, la relación entre los datos y la eficiencia es que la máquina puede mejorar su eficiencia al obtener más y más datos. Puede aprender de los datos y mejorar automáticamente.

El aprendizaje automático es especialmente útil para manejar grandes cantidades de datos de problemas complejos, que son difíciles de manejar para los humanos y además consumen más tiempo en resolver. En este proceso de computación, la máquina recibe datos como entrada y proporciona resultados utilizando un algoritmo apropiado.

Los métodos de aprendizaje automático se han aplicado para resolver muchos problemas reales, como el reconocimiento del lenguaje hablado, la detección de fraude, la gestión de relaciones con clientes, entre muchos otros. Un ejemplo de la efectividad del aprendizaje automático es su aplicación en servicios web, como la tarea de categorizar mensajes de correo electrónico como spam o no spam. En este caso, el rendimiento del método de aprendizaje automático se evalúa por el porcentaje de mensajes de correo electrónico clasificados correctamente. El entrenamiento en este problema proviene principalmente de una base de datos de correos electrónicos que han sido etiquetados como spam o no spam por humanos [19].

### 2.2.1.1 Clases de aprendizaje automático

Basado en la naturaleza de la señal que la máquina recibe, el aprendizaje automático puede clasificarse en las siguientes categorías: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo.

**Aprendizaje supervisado:** implica aprender una función a partir de ejemplos de entrenamiento basados en sus atributos (entradas) y etiquetas (salidas). Cada ejemplo de entrenamiento consiste en un par  $(x, f(x))$ , donde  $x$  representa la entrada y  $f(x)$  la salida de la función desconocida subyacente. El objetivo del aprendizaje supervisado es, dado un conjunto de ejemplos de  $f$ , retornar una función  $h$  que sea la mejor aproximación posible de  $f$ . Los algoritmos bajo este método se clasifican en dos categorías: regresión y clasificación. Un ejemplo de este método es el filtrado de spam de correos.

**Aprendizaje no supervisado:** se centra en identificar patrones y estructuras en un conjunto de datos sin la necesidad de etiquetas o respuestas predefinidas. A diferencia del aprendizaje supervisado, en el cual los algoritmos se entrenan con pares de entrada y salida, el aprendizaje no supervisado trabaja solo con datos de entrada. El objetivo es descubrir relaciones ocultas, agrupaciones y patrones inherentes dentro de los datos. Los algoritmos se clasifican en tipos de clustering y asociación. Un ejemplo de este método es la detección de anomalías, es decir, la identificación de datos atípicos o inusuales que no se ajustan a los patrones comunes.

**Aprendizaje por refuerzo:** en este método no se disponen de pares de entrada/salida para el sistema de aprendizaje. En lugar de eso, el sistema recibe algún tipo de recompensa después de cada acción, con el objetivo de maximizar la recompensa acumulativa a lo largo de todo el proceso. Por ejemplo, en la planificación de tratamientos, el sistema de aprendizaje podría recibir refuerzos del paciente (como sentirse mejor o peor, o estar curado) como resultado de las acciones realizadas durante el tratamiento.

### 2.2.2. Redes neuronales

Una red neuronal es un modelo de aprendizaje automático diseñado para tomar decisiones de manera similar al cerebro humano, utilizando procesos que simulan el funcionamiento conjunto de las neuronas biológicas para identificar fenómenos, evaluar opciones y llegar a conclusiones.

Estas redes están formadas por varias capas de nodos o neuronas artificiales, que incluyen una capa de entrada, una o más capas ocultas y una capa de salida. Cada nodo está interconectado y posee un peso y un umbral específicos. Si la salida de un nodo supera el umbral establecido, el nodo se activa y transmite datos a la siguiente capa; de lo contrario, no se envía información.

Las redes neuronales se entrenan con conjuntos de datos específicos para aprender y perfeccionar su precisión a lo largo del tiempo. Una vez optimizadas, se convierten en herramientas esenciales dentro de los campos de la computación y la inteligencia artificial, facilitando tareas como la clasificación y agrupación de datos de manera rápida y eficiente. Actividades como el reconocimiento de voz o de imágenes, que podrían llevar horas si las realiza un experto humano, se pueden ejecutar en minutos gracias a estas tecnologías.

A continuación, se explican algunos conceptos clave para comprender plenamente el funcionamiento de una red neuronal.

### 2.2.2.1 Neuronas biológicas y artificiales

Para entender cómo funcionan las redes neuronales artificiales, primero es importante comprender cómo operan las neuronas biológicas.

El cerebro humano consta de aproximadamente 100 mil millones de células nerviosas o neuronas, un ejemplo muy estilizado de las cuales se muestra en la Figura 2.7-a. Las neuronas se comunican a través de señales eléctricas que son impulsos de corta duración o "picos" en el voltaje de la pared celular o membrana. Las conexiones entre neuronas están mediadas por uniones electroquímicas llamadas sinapsis, ubicadas en las ramas de la célula denominadas dendritas.

Cada neurona típicamente recibe miles de conexiones de otras neuronas, recibiendo constantemente una multitud de señales entrantes que eventualmente llegan al cuerpo celular. Aquí, estas señales se integran o suman de alguna manera y, en términos generales, si la señal resultante excede un cierto umbral, la neurona "dispara" o genera un impulso de voltaje en respuesta. Este impulso se transmite a otras neuronas a través de una fibra ramificada conocida como axón.

Por otro lado, las neuronas artificiales reciben como entrada un vector de números  $x_i$ . Las sinapsis se modelan mediante un único número o peso, de manera que cada entrada  $x_i$  se multiplica por su correspondiente peso  $w_i$  antes de ser enviada al equivalente del cuerpo celular. En esta etapa, las señales ponderadas se suman mediante una simple adición aritmética  $\sum w_i x_i + b$ , donde  $b$  es un sesgo. El propósito del sesgo es ajustar la salida de manera positiva o negativa, lo que nos ayuda a mapear mejor tipos de datos dinámicos del mundo real.

Si el resultado de esta suma ponderada excede un cierto umbral, definido por la función de activación  $f$ , la neurona se activa y transmite la señal a la siguiente capa. Este mecanismo permite que las redes neuronales aprendan y se adapten a los datos de entrada, mejorando su capacidad para realizar tareas complejas y mapear datos dinámicos del mundo real. En la Figura 2.7-b (extraído y modificado a partir de [18]) se ilustra este proceso.

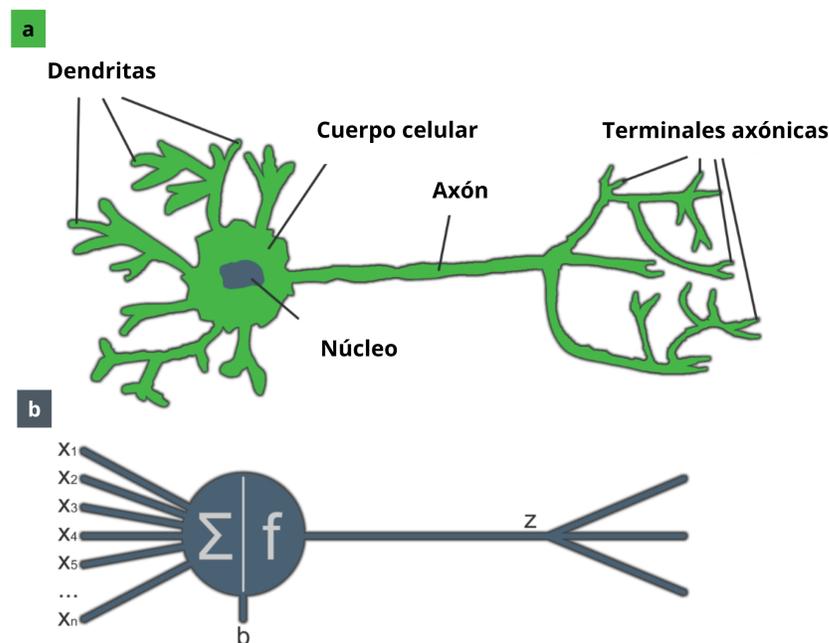


Figura 2.7: Comparación entre neuronas biológicas y artificiales.

Fuente: Modificado a partir de [18].

Las funciones de activación más comunes incluyen:

- **Función Sigmoide** ( $\sigma(x) = \frac{1}{1+e^{-x}}$ ): Mapea cualquier valor real a un rango entre 0 y 1.
- **Función Tanh** ( $\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ ): Mapea cualquier valor real a un rango entre -1 y 1.
- **Función ReLU (Rectified Linear Unit)** ( $\text{ReLU}(x) = \max(0, x)$ ): Permite que los valores positivos pasen directamente y ajusta los valores negativos a cero.
- **Función Softmax**: Utilizada principalmente en la capa de salida para problemas de clasificación, convierte los valores de salida en probabilidades que suman 1.

### 2.2.2.2 Redes neuronales profundas

Las redes neuronales profundas son un tipo de redes neuronales que tienen al menos dos capas ocultas. Un ejemplo simple de red neuronal profunda esta en la Figura 2.8, donde se puede observar una estructura simple con cuatro capas: una capa de entrada, dos capas

ocultas y una capa de salida. La capa de entrada representa los datos de entrada reales, como los valores de píxeles de una imagen o los datos de un sensor de temperatura. Estos datos, aunque pueden estar en su forma "bruta" tal como fueron recolectados, generalmente se preprocesan a través de funciones como normalización y escalado para que estén en forma numérica adecuada para el procesamiento.

Las dos capas ocultas en la red neuronal de la Figura 2.8 consisten en 4 neuronas cada una. Estas capas ocultas son responsables de extraer y aprender características más complejas de los datos de entrada. Finalmente, la capa de salida produce el resultado final de la red, que puede ser una clasificación, una predicción o cualquier otra salida deseada dependiendo del problema específico que se está abordando.

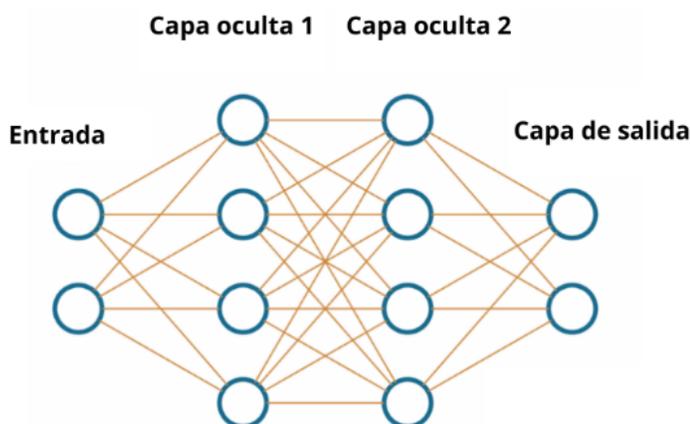


Figura 2.8: Red neuronal simple.

Fuente: Modificado a partir de [18].

Las redes neuronales pueden clasificarse principalmente en tres categorías, que se presentan a continuación:

- **Redes Neuronales Convolucionales (CNN):** son las redes neuronales más ampliamente utilizadas, las cuales tienen una red neuronal de múltiples capas. Las CNN se consideran la forma más eficiente de red neuronal, son ideales para tareas visuales, como el reconocimiento y procesamiento de imágenes, debido a su capacidad para utilizar capas convolucionales que filtran y capturan características visuales de manera eficiente.
- **Redes Neuronales Recurrentes (RNN):** Son adecuadas para datos secuenciales, como texto o música, ya que pueden 'recordar' información pasada a través de bucles en su estructura, lo que les permite manejar dependencias temporales. Algunas de las principales aplicaciones de las RNN son los chatbots, los algoritmos de detección de fraude en transacciones monetarias, la generación de subtítulos para imágenes, y muchas más.
- **Redes Neuronales de Memoria a Largo Corto Plazo (LSTM):** Una especialización de las RNN, diseñadas para superar el problema de la desaparición del gradiente y retener información durante periodos más largos, lo que las hace ideales para tareas que requieren el manejo de dependencias a largo plazo. Las principales aplicaciones de las

LSTM incluyen el procesamiento del lenguaje natural (NLP), la traducción automática, la predicción de series temporales, y el reconocimiento de voz.

### 2.2.2.3 Extracción de características

La extracción de características es fundamental en el preprocesamiento de datos antes de entrenar un modelo de redes neuronales. Este proceso implica transformar los datos brutos en una representación más adecuada para el aprendizaje automático, preservando la información relevante mientras se reduce la dimensionalidad de los datos y se eliminan características redundantes o irrelevantes.

En el caso de redes neuronales, la extracción de características puede involucrar técnicas como la selección de atributos más informativos, la aplicación de métodos de reducción de dimensionalidad como el Análisis de Componentes Principales (PCA), o la transformación de los datos para mejorar su representatividad en el modelo. Este paso es esencial para garantizar que el modelo sea capaz de aprender de manera efectiva a partir de los datos, mejorando tanto la precisión como la eficiencia del proceso de entrenamiento.

Para tareas específicas, como la clasificación de imágenes, la extracción de características se puede realizar utilizando técnicas como la convolución, que detecta patrones visuales en diferentes niveles de la imagen. En el procesamiento de texto, se pueden utilizar representaciones como los modelos de palabras (word embeddings) o técnicas de codificación de texto como TF-IDF para capturar el significado semántico de las palabras.

### 2.2.2.4 Balanceo de datos

Además de la extracción de características, es fundamental abordar el problema del desbalance de clases en el conjunto de datos, especialmente en problemas de clasificación. El desbalance de clases ocurre cuando ciertas clases están sobrerrepresentadas en comparación con otras, lo que puede sesgar el modelo hacia las clases más frecuentes y reducir su capacidad para generalizar correctamente a las clases menos comunes.

Existen varias técnicas para balancear los datos:

- **Sobremuestreo (Oversampling):** Esta técnica implica aumentar la representación de la clase minoritaria replicando ejemplos de dicha clase en el conjunto de datos. Una técnica popular de sobremuestreo es SMOTE (Synthetic Minority Over-sampling Technique), que genera ejemplos sintéticos de la clase minoritaria en lugar de simplemente duplicar ejemplos existentes, lo que ayuda a evitar el sobreajuste.
- **Submuestreo (Undersampling):** En lugar de aumentar la cantidad de ejemplos de la clase minoritaria, el submuestreo reduce la cantidad de ejemplos de la clase mayoritaria. Esto puede equilibrar el conjunto de datos, pero a costa de perder información potencialmente valiosa de la clase mayoritaria.

- **Combinación de sobremuestreo y submuestreo:** En muchos casos, una combinación de ambas técnicas puede ser la mejor opción. Esta estrategia implica reducir la cantidad de ejemplos de la clase mayoritaria al tiempo que se aumenta la representación de la clase minoritaria, lo que puede ayudar a evitar tanto la pérdida de información como el sobreajuste.
- **Técnicas de ponderación:** En lugar de modificar el conjunto de datos, se pueden aplicar técnicas de ponderación de clases durante el entrenamiento del modelo. Esto implica asignar mayores pesos a las clases minoritarias, de manera que los errores en estas clases tengan un impacto proporcionalmente mayor en la función de pérdida, incentivando al modelo a aprender mejor estas clases.
- **Generación de datos sintéticos:** Además de SMOTE, existen otras técnicas para generar datos sintéticos de manera más sofisticada, como el uso de Redes Generativas Antagónicas (GANs) o Autoencoders. Estas técnicas permiten crear nuevos ejemplos que representan de manera más compleja las características de la clase minoritaria.

Estas técnicas se aplican a los modelos de redes neuronales para no esté sesgado hacia las clases más comunes y sea capaz de generalizar bien en todas las clases, con el fin de mejorar así su rendimiento global.

### 2.2.3. Evaluación de modelos de aprendizaje automático

El objetivo primordial de un modelo de aprendizaje automático es realizar predicciones acertadas sobre datos del mundo real. Si un modelo no logra predecir los resultados de manera precisa, su utilidad se ve considerablemente reducida. Por ello, la evaluación y optimización del rendimiento del modelo resultan esenciales. Comprender las fortalezas y debilidades de los modelos permiten tomar decisiones informadas respecto a su implementación y evitar posibles dificultades.

Además, la evaluación del modelo es crucial para identificar y resolver problemas como el sobreajuste y el subajuste. El sobreajuste se produce cuando un modelo tiene un desempeño excepcional con los datos de entrenamiento, pero falla al generalizar a nuevos datos. El subajuste, por otro lado, ocurre cuando un modelo es demasiado simple y no capta los patrones subyacentes en los datos.

La tarea de evaluar modelos de clasificación consiste en medir el grado en que la clasificación sugerida mediante el modelo corresponde a la clasificación real del caso. En el caso que se quiera medir la precisión de un modelo la evaluación más simple es:

$$\text{Precisión} = \frac{\text{Número de casos clasificados correctamente}}{\text{Número total de casos}} \quad (2.1)$$

Las principales desventajas de esta métrica de evaluación de un modelo son que omite las diferencias entre los distintos tipos de errores y no considera la distribución de las clases en el conjunto de datos. Debido a estas limitaciones, se utiliza la matriz de confusión, una tabla

que permite visualizar el desempeño de un algoritmo de clasificación al mostrar la cantidad de predicciones correctas e incorrectas divididas por categoría. [20]

La matriz de confusión es cuadrada con un tamaño que depende del número de clases que el modelo está clasificando. Por ejemplo, para un problema de clasificación binario (dos clases), la matriz será de 2x2, tal como se visualiza en la Figura 2.9 (Elaboración propia).

- **Verdaderos Positivos (VP)**: Casos en los que la clase fue positiva y el modelo predijo correctamente positivo.
- **Falsos Negativos (FN)**: Casos en los que la clase fue positiva pero el modelo predijo incorrectamente negativo.
- **Falsos Positivos (FP)**: Casos en los que la clase fue negativa pero el modelo predijo incorrectamente positivo.
- **Verdaderos Negativos (VN)**: Casos en los que la clase fue negativa y el modelo predijo correctamente negativo.

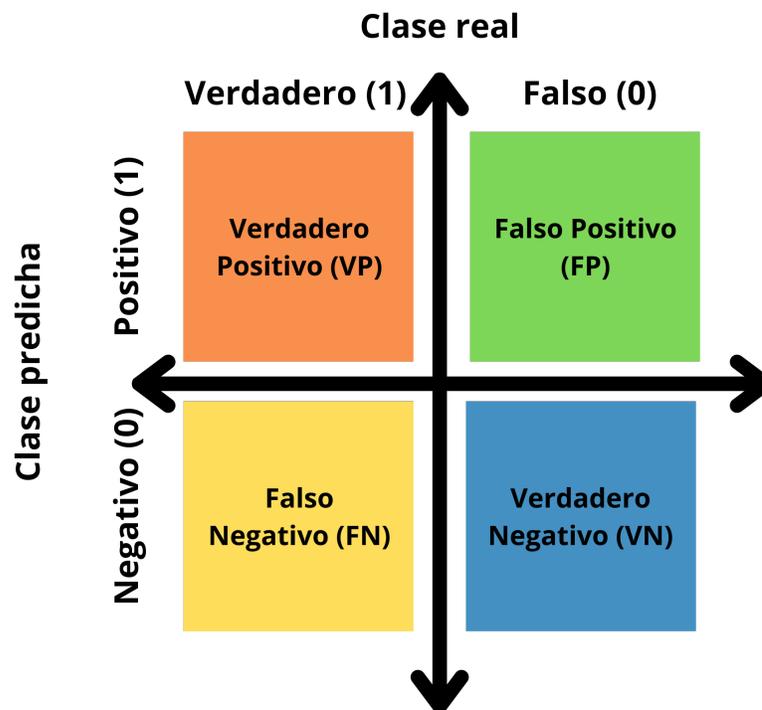


Figura 2.9: Matriz de confusión para dos clases.

Fuente: Elaboración propia.

A partir de la matriz de confusión pueden calcularse distintas métricas:

- **Exactitud (Accuracy)**: Se calcula como la suma de predicciones correctas (verdaderos positivos (VP) + verdaderos negativos (VN)) dividida por el número total de datos (VP

+ falsos negativos (FN) + falsos positivos (FP) + VN). Tal como lo muestra la Figura 2.10 - a. (Elaboración propia)

- **Precisión (Precision):** Se calcula como el número de predicciones verdaderas positivas (VP) dividido por el total de predicciones positivas (VP + FP). Tal como lo muestra la Figura 2.10 - b
- **Recall (Sensibilidad/Tasa de verdaderos positivos):** Se calcula como el número de predicciones positivas correctas (VP) dividido por el total de casos positivos (VP + FN). Tal como lo muestra la Figura 2.10 - c
- **Especificidad (Specificity):** Se calcula como el número de predicciones negativas correctas (verdaderos negativos (VN)) dividido por el total de casos negativos (VN + FP). Tal como lo muestra la Figura 2.10 - d
- **F1-Score:** Es una métrica que combina precisión y recall en una sola medida, utilizada para evaluar modelos de clasificación, especialmente en contextos de clases desequilibradas. Es útil para asegurar un equilibrio entre la precisión (la exactitud de las predicciones positivas) y el recall (la capacidad del modelo para identificar todos los positivos reales). Esta métrica es clave para comparar modelos, optimizarlos durante el desarrollo y para aplicaciones críticas como diagnósticos médicos, donde tanto la precisión como la cobertura son importantes. Se calcula como:

$$F1 - Score = \frac{2 * Precisión * Recall}{Precisión + Recall}$$

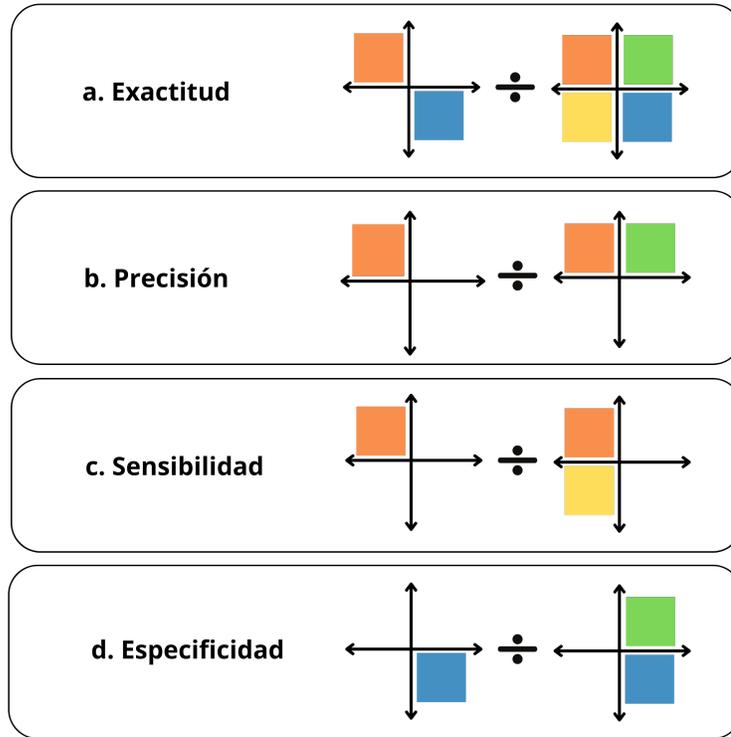


Figura 2.10: Exactitud, Precisión, Sensibilidad y Especificidad a partir de la matriz de confusión de dos clases.

Fuente: Elaboración propia.

## 2.3. EEG para detectar emociones

El electroencefalograma (EEG) es una herramienta fundamental en la neurociencia cognitiva para el estudio de las emociones y su origen neuronal. Esta técnica no invasiva permite registrar la actividad eléctrica del cerebro a través de electrodos colocados en el cuero cabelludo. A pesar de las limitaciones inherentes al EEG, como su baja resolución espacial en comparación con técnicas invasivas como la electrofisiología intracraneal, su uso extendido en entornos clínicos y de investigación se debe a su capacidad para detectar cambios rápidos en la actividad neuronal asociados con diferentes estados emocionales.

Los estudios que utilizan EEG para la detección de emociones han avanzado significativamente, proporcionando una comprensión más profunda de cómo y dónde se generan las emociones en el cerebro. Estos estudios se basan en la identificación de patrones específicos de ondas cerebrales que se asocian con distintas emociones, permitiendo a los investigadores mapear la actividad emocional en diferentes regiones cerebrales. En particular, áreas como la amígdala y el lóbulo frontal han sido identificadas como cruciales en la mediación de las respuestas emocionales.

En esta sección, se revisarán estudios relevantes que han utilizado EEG para investigar la detección de emociones y sus principales hallazgos.

### 2.3.1. Enfoques

En la neurociencia cognitiva, el estudio de la relación entre emociones y su origen neuronal es esencial. Se distinguen principalmente dos enfoques:

**Locacionista:** Este enfoque postula que las emociones específicas están asociadas con áreas cerebrales determinadas y bien definidas. Uno de los ejemplos más estudiados y conocidos es la amígdala, una estructura ubicada en el lóbulo temporal del cerebro, que se ha identificado como crucial para la generación y procesamiento de emociones como el miedo y la agresión. [21].

La teoría locacionista sostiene que cada emoción básica tiene un "centro" neuronal donde se origina. Por ejemplo, además de la amígdala para el miedo, se ha sugerido que la corteza orbitofrontal está implicada en la experiencia de la recompensa y el placer, mientras que la ínsula se asocia con emociones como el disgusto. Esta perspectiva ha sido apoyada por estudios de neuroimagen que muestran una activación específica en estas áreas durante la experimentación de emociones particulares.

Los defensores de la teoría locacionista argumentan que la especificidad funcional de estas regiones cerebrales permite una respuesta rápida y eficiente a estímulos emocionales, lo cual ha sido ventajoso desde una perspectiva evolutiva.

Sin embargo, esta visión también ha sido criticada por su simplicidad y por no considerar la complejidad y la interacción dinámica de las redes neuronales en la generación de emociones.

**No-Localizacionista:** Este enfoque se opone a la idea de que existen zonas cerebrales exclusivas para emociones individuales, sugiriendo en cambio que las emociones emergen de la interacción entre diversas áreas corticales. Según esta perspectiva, no hay una correspondencia uno a uno entre emociones específicas y regiones cerebrales particulares. En lugar de ello, las emociones se conciben como el resultado de patrones dinámicos de actividad neuronal distribuidos a través de múltiples áreas del cerebro.

La teoría no-localizacionista destaca la importancia de las redes neuronales y la conectividad funcional entre diferentes regiones corticales. Por ejemplo, se ha demostrado que la experiencia emocional implica la activación y coordinación de áreas como la corteza prefrontal, la ínsula y la amígdala.

Según esta visión, las emociones no solo dependen de la activación de ciertos nodos neuronales, sino también de la manera en que estas regiones comunican y procesan información en conjunto.

### 2.3.2. Localización de emociones en el cerebro

Localizar las fuentes neuronales a partir del EEG del cuero cabelludo presenta desafíos significativos, ya que no se puede asumir que la actividad eléctrica registrada proviene exclusivamente del córtex adyacente.

Por ello, la neurociencia cognitiva utiliza la electrofisiología intracraneal para abordar estas cuestiones. La electrofisiología intracraneal es una técnica que implica la inserción de electrodos directamente en el cerebro, permitiendo la medición precisa de la actividad eléctrica neuronal en áreas específicas. Este método proporciona una resolución espacial y temporal superior en comparación con el EEG del cuero cabelludo, facilitando una mejor comprensión de las dinámicas neuronales. Estudios basados en electrofisiología intracraneal han aportado evidencia a favor de la visión no-localizacionista, sugiriendo que las emociones emergen de la interacción de diversas áreas corticales.

A pesar de estos desafíos, es posible identificar emociones en el cerebro a partir de las señales de EEG capturadas en el cuero cabelludo. No obstante, no todas las partes del cerebro contienen la misma información ni se asocian con las mismas emociones. Las dos principales áreas del cerebro relacionadas con la actividad emocional son la amígdala y el lóbulo frontal. Según Sarno y sus colegas [22], el cuero cabelludo frontal muestra más activación emocional en comparación con otros lóbulos del cerebro, como el temporal, parietal y occipital. Adicionalmente, investigaciones han demostrado que el hemisferio izquierdo está más estrechamente relacionado con las emociones positivas, mientras que el hemisferio derecho está más relacionado con las emociones negativas.

En 2015, Boksem y colaboradores [23] encontraron que la corteza frontal medial se asocia a la preferencia individual en el espectro beta en áreas frontomedias mediante electrodos determinados. También identificaron que la preferencia a nivel de población corresponde a áreas fronto-centrales en el espectro theta con una configuración específica de electrodos. En 2019, Agarwal y colaboradores [24] encontraron que los principales atributos de la preferencia, como la atención, la emoción y el gusto, están relacionados con los electrodos F3, C3, P3, Pz, Fz, Cz y C4.

En cuanto a los ritmos de frecuencia de las señales EEG más relacionados con el proceso emocional, Aftanas y sus colaboradores [25] en 2006 encontraron que los ritmos de mayor frecuencia Beta-2 (18-22 Hz), Beta-3 (22-30 Hz) y Gamma (30-45 Hz) están relacionados con la emoción. Descubrieron que cuando se experimenta felicidad, se presenta una disminución de la potencia de Beta-2 en las regiones frontales centrales y de Beta-3 y Gamma en toda la corteza. Por otro lado, al sentir enojo, las bandas Beta-2, Beta-3 y Gamma experimentan un aumento de potencia en el lóbulo frontal de ambos hemisferios.

En 2017, Tammasan y sus colaboradores [26] estudiaron las emociones en las ondas cerebrales al estimular a los participantes con extractos de vídeos musicales y observaron que los ritmos de frecuencia más altos, como gamma, se detectaban de manera más prominente cuando los sujetos escuchaban canciones desconocidas. También en 2017, Zhuang y sus colaboradores encontraron que para clasificar emociones, los ritmos cerebrales más útiles son alpha, beta y gamma, es decir, aquellos con mayores frecuencias.

Sin embargo, otros estudios [27, 28] han encontrado que si bien los ritmos con mayor frecuencia en los lóbulos frontales del cerebro son los más precisos para clasificar las emociones, agregar información sobre otros lóbulos y ritmos a los algoritmos de clasificación aumenta la precisión.

En conclusión, aunque no existe un consenso claro sobre cuál es el área del cerebro que

más se relaciona con las emociones ni cuál es el ritmo específico, la evidencia sugiere que el lóbulo frontal y las ondas de mayor frecuencia, como Beta y Gamma, juegan un papel crucial en el procesamiento emocional. Estos hallazgos subrayan la importancia de considerar tanto la conectividad funcional entre diferentes regiones cerebrales como los ritmos específicos en el estudio de la actividad emocional cerebral.

### 2.3.3. Evocación de emociones

La evocación de emociones es una técnica fundamental para investigar los correlatos neuronales de los estados emocionales. La capacidad de inducir emociones de manera controlada y replicable es crucial para estudiar cómo estas emociones se representan y procesan en el cerebro. Las técnicas de evocación de emociones varían desde el uso de estímulos visuales y auditivos hasta la interacción social y la evocación de recuerdos personales. A continuación, se describen algunas de las técnicas más utilizadas para la evocación de emociones:

- **Imágenes y videos emocionales:**

- Imágenes: Imágenes diseñadas para evocar respuestas emocionales específicas, clasificadas según su valencia y nivel de activación emocional.
- Clips de video: Extractos de películas o videos musicales utilizados para inducir emociones como alegría, tristeza, miedo o enojo.

- **Música:**

- Piezas musicales seleccionadas para influir en el estado de ánimo y evocar emociones específicas validadas en estudios previos.

- **Tareas cognitivas:**

- Tareas de Stroop emocional: Identificación del color de palabras con connotaciones emocionales, induciendo estrés o ansiedad.
- Juegos y simulaciones: Escenarios virtuales diseñados para inducir emociones como miedo o euforia.

- **Recuerdos personales:**

- Solicitud a los participantes de recordar y describir experiencias personales que hayan evocado emociones intensas, aprovechando la conexión entre memoria autobiográfica y emociones.

- **Interacción social:**

- Situaciones de interacción social, como entrevistas o juegos de rol, utilizadas para inducir emociones relacionadas con la socialización, como vergüenza, orgullo o empatía.

- **Estímulos auditivos y olfativos:**

- Sonidos y olores específicos utilizados para evocar emociones, como la risa para inducir alegría o ciertos olores para evocar nostalgia o repulsión.

#### 2.3.3.1 EmoMadrid

En la presente investigación, se utilizará la base de datos EmoMadrid como estímulo visual para evocar emociones en los participantes. La elección de esta base de datos se fundamenta en

su validación y en la diversidad de categorías visuales que abarca, lo cual permite inducir una amplia gama de estados emocionales. Durante los experimentos, las imágenes seleccionadas de EmoMadrid serán presentadas a los participantes mientras se registran sus respuestas neuronales mediante electroencefalografía (EEG).

EmoMadrid es una base de datos de imágenes emocionales que se ha utilizado ampliamente para la investigación de procesos afectivos [29]. Iniciada por un grupo de investigadores en España, esta base de datos consta actualmente de 1202 imágenes emocionales. Las imágenes se agrupan en distintas categorías de contenido visual, tales como: animales, comida, paisajes, objetos, personas y deportes.

La valencia y la activación de cada una de las imágenes fueron evaluadas por un promedio de 140 voluntarios. Estos voluntarios utilizaron una escala de 5 niveles para evaluar dos dimensiones emocionales principales: el eje de valencia (de muy negativo a muy positivo) y el eje de activación (de muy calmado a muy energético). Esta meticulosa evaluación permite que la base de datos EmoMadrid ofrezca un conjunto estandarizado y validado de estímulos visuales, apto para diversos estudios sobre emociones.

El uso de EmoMadrid facilita la evocación controlada y reproducible de emociones, lo cual es crucial para el análisis riguroso de los correlatos neuronales de las emociones. Además, la amplia aceptación y uso de esta base de datos en la comunidad científica refuerza su idoneidad como herramienta de investigación.

## 2.4. Estudios relevantes en el reconocimiento de emociones con EEG

En esta sección se presentarán los estudios más relevantes sobre la identificación de emociones y estados emocionales utilizando señales de EEG mientras los participantes observan estímulos visuales. Comprender cómo se llevan a cabo estas investigaciones es esencial, ya que la metodología empleada es prácticamente uniforme en todos los estudios. En la Figura 2.11 se ilustra este proceso en detalle, destacando los pasos cruciales desde la evocación hasta la clasificación de emociones.

- **Evocación de emociones:** Los participantes son expuestos a estímulos diseñados para evocar emociones específicas. Estos estímulos pueden ser imágenes, videos, música, tareas cognitivas, recuerdos personales, situaciones de interacción social o estímulos auditivos y olfativos. El objetivo es inducir estados emocionales controlados y replicables en los participantes.
- **Grabación de EEG:** Durante la exposición a los estímulos, se registra la actividad eléctrica del cerebro utilizando electroencefalografía (EEG). Los electrodos colocados en el cuero cabelludo capturan las señales neuronales. El objetivo es obtener datos en tiempo real sobre la actividad cerebral asociada con las emociones inducidas.
- **Pre-procesamiento:** Las señales EEG brutas se filtran y se limpian para eliminar artefactos y ruido, lo cual incluye la eliminación de interferencias, la corrección de

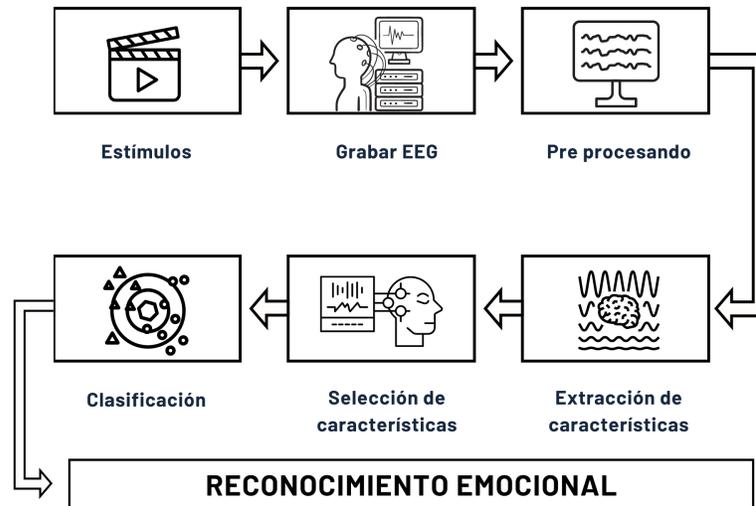


Figura 2.11: Metodología clásica del reconocimiento de emociones a partir de EEG.

Fuente: Elaboración propia.

movimientos y el ajuste de la línea base. El objetivo es asegurar que los datos utilizados para el análisis sean de alta calidad y representativos de la actividad cerebral real.

- **Extracción de Características:** Se extraen características relevantes de las señales EEG preprocesadas, incluyendo información sobre las frecuencias de las ondas cerebrales, la potencia de las bandas de frecuencia y otros parámetros temporales y espectrales. El objetivo es reducir la complejidad de los datos y resaltar las características más significativas para el análisis emocional.
- **Selección de Características:** Se seleccionan las características más relevantes y discriminativas para la tarea de clasificación, utilizando técnicas de reducción de dimensionalidad y selección de características. El objetivo es mejorar la eficiencia y precisión del modelo de clasificación al centrarse en las características más informativas.
- **Clasificación:** Utilizando las características seleccionadas, se entrenan modelos de aprendizaje automático para clasificar los estados emocionales de los participantes. Los modelos pueden incluir algoritmos de clasificación ó redes neuronales u otros métodos de clasificación. El objetivo es identificar y clasificar las emociones experimentadas por los participantes en respuesta a los estímulos presentados.

Generalmente, las bases de datos públicas se encargan de los primeros pasos del proceso, que incluyen la evocación de emociones y la grabación de las señales de EEG, y en algunos casos, también del pre-procesamiento de estas señales. Posteriormente, los informáticos se encargan de los siguientes pasos de la metodología, que consisten en la extracción de características, la selección de características y la clasificación, con el objetivo de lograr el reconocimiento de las emociones. En esta sección, se presentarán y explicarán las bases de datos públicas más utilizadas, seguidas de una descripción de las investigaciones que han ob-

tenido buenos resultados utilizando esta información. A continuación, se muestran conjuntos de datos más empleados en los últimos tiempos y con acceso público son:

- **DEAP (2011)**: Es una base de datos fisiológica y emocional multimodal extensa, desarrollada por Koelstra y sus colaboradores en una asociación de cuatro universidades. Este conjunto de datos abierto permite analizar los estados emocionales humanos y contiene información de 32 participantes (16 hombres y 16 mujeres). En el estudio, se recolectaron datos de EEG (32 electrodos) y señales fisiológicas periféricas, y se grabaron expresiones faciales de 22 participantes. Los participantes observaron 40 videoclips musicales durante 1 minuto cada uno, y al finalizar cada videoclip evaluaron sus emociones mediante la escala SAM con calificaciones del 1 al 9 para las dimensiones de activación, valencia y dominancia. El agrado fue medido mediante una escala de positivo, neutral y negativo [17].
- **SEED (2015)**: Es una base de datos de emociones EEG creada por el Centro de Investigación BCMI de la Universidad Jiaotong de Shanghai. En el experimento participaron 15 personas (7 hombres y 8 mujeres), de los cuales se recogieron datos de 62 canales de EEG. Los participantes visualizaron 15 clips de películas chinas que generaban emociones positivas, neutrales y negativas, con cinco clips por categoría emocional, cada uno de aproximadamente 4 minutos de duración, presentados en secuencia alternada. Durante el experimento, se les dio un aviso de 5 segundos antes de cada video. Luego, realizaron una autoevaluación de 45 segundos seguida de un descanso de 15 segundos. Se solicitó a los participantes completar el experimento tres veces durante una semana o más, observando los mismos 15 clips y registrando sus emociones de autoevaluación [30].
- **SEED IV (2018)**: Es una versión actualizada del conjunto de datos SEED, ampliamente utilizada en investigaciones recientes. Este conjunto está diseñado para estudiar cuatro emociones específicas. En el estudio participaron 44 sujetos, todos estudiantes universitarios, que autoevaluaron sus emociones mientras visualizaban 168 clips de películas que representaban emociones de felicidad, tristeza, miedo y neutralidad. Se seleccionaron 72 clips con distintas etiquetas emocionales para las pruebas, grabando la actividad EEG de 15 participantes en tres sesiones, con un total de 24 pruebas por sujeto [31].

#### 2.4.1. Electroencefalogram-Based Preference Prediction Using Deep Transfer Learning

En el estudio realizado por Marshael Aldayel y sus colaboradores [32], se investiga el uso del aprendizaje profundo y la transferencia de aprendizaje (DTL) en la predicción de preferencias basada en señales EEG. Se propone un modelo de DTL que transfiere conocimientos del reconocimiento de emociones al reconocimiento de preferencias, basado en la idea de que el conocimiento adquirido por un modelo durante el proceso de reconocimiento de emociones puede reutilizarse para reconocer preferencias (gustos o disgustos) a partir de señales EEG. En lugar de entrenar un modelo desde cero para reconocer preferencias, se utiliza un modelo

previamente entrenado para reconocer emociones y se adapta o refina para la nueva tarea de clasificación de preferencias.

Para el estudio se utilizó el conjunto de datos DEAP [17]. En el cuál las calificaciones en el eje de valencia se reagruparon, donde de 1 a 5 era disgusto y de 5 hacia arriba era gusto.

En el proceso de preprocesado de las señales EEG, se llevaron a cabo varias etapas clave para preparar los datos antes de la extracción de características y la clasificación. A continuación se describen los pasos realizados:

- **Selección de Electroodos:** Se seleccionaron cinco electrodos específicos para reducir la carga computacional sin perder información relevante. Los electrodos seleccionados fueron: AF3, AF4, F3, F4, FZ.
- **Filtrado Pasabanda:** Las señales EEG fueron filtradas utilizando un filtro pasabanda con un rango de frecuencia de 4.0 Hz a 45.0 Hz.
- **Eliminación de Artefactos:** Para eliminar los artefactos de movimientos oculares (EOG), se aplicó un Análisis de Componentes Independientes (ICA). Este método permite separar las fuentes de señal independientes en los datos EEG y eliminar aquellas componentes que se asociaban con artefactos de EOG.

Luego para la extracción de características, se utilizó la Densidad Espectral de Potencia (PSD) de las señales EEG, la cual permitió identificar las bandas de frecuencia relevantes para el análisis.

En la investigación se propusieron dos enfoques de DTL: el reentrenamiento y el ajuste fino. Los cuales se detallan a continuación:

- **Reentrenamiento Completo (Retraining):** En este enfoque, se reutiliza un modelo preentrenado en la tarea de reconocimiento de emociones, pero se reemplaza la última capa del modelo (la capa de salida) para adaptarla a la nueva tarea de clasificación de preferencias (gustos o disgustos). Luego, el modelo completo se reentrena utilizando los datos de preferencias.
- **Ajuste Fino (Fine-tuning):** En este enfoque, las primeras capas del modelo preentrenado (las que capturan características generales de las señales EEG) se mantienen congeladas, y solo la última capa (que se ha ajustado para la tarea de clasificación de preferencias) se entrena con los nuevos datos. Este enfoque evita el sobreajuste y permite aprovechar el conocimiento general aprendido en la tarea de reconocimiento de emociones.

Los modelos empleados en este estudio incluyeron tanto redes neuronales profundas (DNN) como clasificadores convencionales, tales como SVM, Random Forest (RF) y K-Nearest Neighbors (KNN). Las DNN se construyeron con una arquitectura de tres capas ocultas y fueron entrenadas utilizando el algoritmo de optimización Adam. En cuanto a la Transferencia de Aprendizaje Profundo (DTL), exploraron diferentes funciones de pérdida,

incluyendo entropía cruzada categórica, entropía cruzada binaria y la función hinge, con el objetivo de optimizar el rendimiento del modelo.

### Resultados:

- El modelo DNN sin Transferencia de aprendizaje logró del 87 % en la tarea de clasificación.
- El modelo basado en DTL con Ajuste Fino, logró una precisión del 93 % al utilizar la función hinge.
- Los clasificadores convencionales también presentaron resultados competitivos. El modelo Random Forest (RF) logró una precisión del 92 %, mientras que el clasificador KNN alcanzó un 88 % de precisión.

### 2.4.2. EEG-Based Emotion Recognition Using Genetic Algorithm Optimized Multi-Layer Perceptron (GA - MLP)

Este algoritmo presenta un enfoque innovador creado por Shyam Marjit, Upasana Talukdar y Shyamanta Hazarika. Aprovecharé esta oportunidad para expresar el sincero agradecimiento a los autores por su contribución al campo con su trabajo titulado 'EEG-Based Emotion Recognition Using Genetic Algorithm Optimized Multi-Layer Perceptron' [33] y su generosidad en compartir su trabajo mediante la plataforma Github [34].

El modelo opera de la siguiente manera: tras completar el preprocesamiento de los datos, se seleccionan únicamente cuatro electrodos de la base de datos: FP1, FP2, F3 y F4. Estos electrodos están situados en el lóbulo frontal del cerebro, siguiendo el estándar internacional 10-20. La disposición precisa de estos electrodos se muestra en la Figura 2.12.

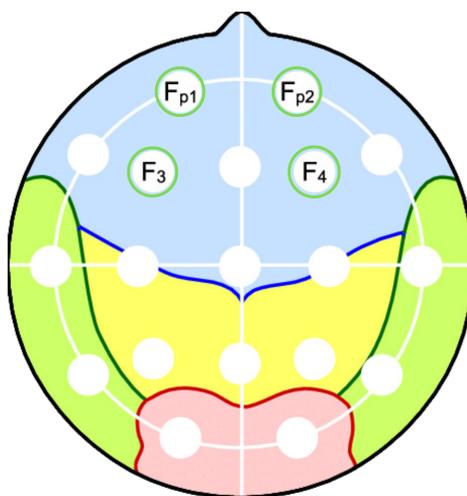


Figura 2.12: Electrodos utilizados en GA - MLP.

Fuente: Elaboración propia.

Posteriormente se calcula la densidad espectral de potencia (PSD) con el método de periodograma promedio de Welch [35]. El método de Welch mejora la estimación de la densidad espectral de potencia de una señal. Divide la señal en segmentos, posiblemente solapados, a los que se aplica una ventana para reducir fugas de datos. Cada segmento se transforma con una FFT (Fast Fourier Transform) para obtener periodogramas que luego se promedian, este método ofrece una estimación más precisa y con menos ruido.

Luego de realizar el método de Welch para los 4 canales (electrodos) la señal de frecuencias se divide en 5 bandas comúnmente utilizadas y descritas en la sección 2.1.4:

- Delta: 0.5 - 4 Hz (La señal Delta se desecha debido a que esta asociada principalmente con el sueño profundo [36])
- Theta: 4 - 7.5 Hz
- Alpha: 8 - 13 Hz
- Beta: 13 - 30 Hz
- Gamma: 30 - 45 Hz

A continuación, se calcula la potencia media de cada banda de frecuencia para cada canal de la siguiente forma:

$$Media(\mu_x) = \frac{1}{N} \sum_{i=1}^N X_i$$

donde  $X_i$  es la información espectral obtenida por el método de Welch y  $N$  es la cantidad de puntos de frecuencia de cada banda de frecuencia asociada. Con esta información se construye el vector de características que será el 'Input' del modelo:

$$\begin{aligned} Input = \langle &Media(FP1_Theta), Media(FP2_Theta), Media(F3_Theta), Media(F4_Theta), \\ &Media(FP1_Alpha), Media(FP2_Alpha), Media(F3_Alpha), Media(F4_Alpha), \\ &Media(FP1_Beta), Media(FP2_Beta), Media(F3_Beta), Media(F4_Beta), \\ &Media(FP1_Gamma), Media(FP2_Gamma), Media(F3_Gamma), Media(F4_Gamma) \rangle \end{aligned} \quad (2.2)$$

Este modelo utiliza un algoritmo genético, es una técnica de optimización inspirada en la selección natural y la genética. Simula la evolución biológica para resolver problemas complejos creando una población de candidatos y utilizando procesos como selección, cruce y mutación para mejorar soluciones a lo largo de generaciones. Son particularmente útiles en problemas con amplios espacios de búsqueda donde no se conoce una solución exacta.

Los individuos de la población se definen por el número de neuronas en las capas ocultas, que actúan como los genes de la estructura del cromosoma. Estos genes son valores enteros

discretos. Para representar estos genes, se utiliza una codificación o representación entera. La estructura de datos de un individuo puede representarse como una secuencia de números que indican la cantidad de neuronas en cada capa oculta. Por ejemplo, un individuo se representa como [17, 42] donde 17 es el número de neuronas en la primera capa y 42 es el número de neuronas en la segunda capa.

La red neuronal utilizada en el modelo consta de una capa de entrada, dos capas ocultas y una capa de salida. El algoritmo genético (GA) se desarrolla en tres fases distintas:

1. **Selección:** El algoritmo selecciona a los mejores individuos según su ajuste al modelo. Para calcular este ajuste, se entrena el clasificador MLP con los siguientes parámetros:
  - **Función de Activación:** la función de activación de la capa oculta es seleccionada aleatoriamente de: Tanh (Tangente Hiperbólica), Sigmoid (Logística), Lineal (Identidad) y ReLU (Unidad Lineal Rectificada).
  - **Optimización de Pesos:** es escogido aleatoriamente de: L-BFGS [37], Descenso del Gradiente Estocástico (SGD) [38] y ADAM [39].
  - **Número de Neuronas:** El número de neuronas de las dos capas ocultas son escogidas aleatoriamente entre 2 y 50.
  - **Criterio de Convergencia:** para la convergencia del algoritmo, se utiliza un criterio híbrido con 1000 iteraciones; si no mejora la precisión después de 80 iteraciones, se detiene el entrenamiento del clasificador MLP.

El 'accuracy' del clasificador de MLP se considera el valor de ajuste del individuo. Basado en este valor de ajuste, se seleccionan los mejores individuos para la nueva generación.

2. **Cruce:** En esta fase se aplica el operador de cruce, el cual combina la información de los dos padres para generar un nuevo individuo. La recombinación usada es Single Point Crossover [40], la cual consiste que el intercambio de genes de los padres comienza desde el gen n-ésimo. En la Figura 4.1, hay una representación del operador.
3. **Mutación:** En esta fase se aplica el segundo operador, el operador de Mutación con el fin de aumentar más la variabilidad genética y evitar los mínimos locales.

Para obtener la solución óptima usando un algoritmo genético en un problema de clasificación, se deben considerar 3 parámetros: Tamaño de la población, Probabilidad de cruce y Probabilidad de mutación.

Para seleccionar estos parámetros existen diversas formas, en este caso se utiliza la recomendación de De Jong [41]. De Jong indica que el tamaño óptimo se encuentra entre 50 y 100 individuos y que la Probabilidad de mutación debe ser muy baja para esta cantidad de individuos, debido a que una alta probabilidad en este parámetro lleva a la aleatoriedad. A partir de lo anterior los parámetros son los siguientes:

- **Tamaño de la población:** 50 individuos

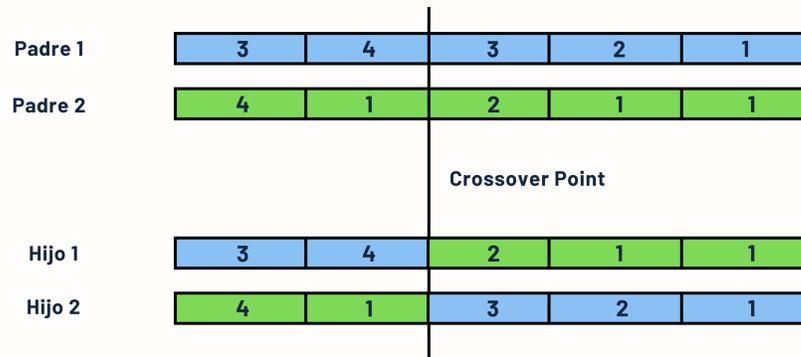


Figura 2.13: Representación del operador Single Point Crossover.

Fuente: Elaboración propia.

- Probabilidad de cruce: 95 %
- Probabilidad de mutación: 0,1 %

En la Figura 2.14, se muestra un ejemplo ilustrativo sobre el funcionamiento del algoritmo genético utilizado.

### 2.4.3. Otras investigaciones relevantes

En esta sección se examinan investigaciones destacadas en el campo del estudio de emociones y preferencias mediante el uso de señales EEG.

Phan y sus colaboradores en 2021 [42] investigaron el reconocimiento de emociones a través de señales EEG, centrándose en la correlación entre canales y bandas de frecuencia para mejorar la precisión de la predicción. Utilizaron una red neuronal convolucional bidimensional (CNN) con núcleos de escala múltiple para captar patrones locales y globales en las señales EEG. Mediante una validación cruzada de diez pliegues en el conjunto de datos DEAP, lograron una precisión promedio del 98.27 % para la clasificación binaria de arousal y 98.36 % para valencia. Estos resultados demuestran que la inclusión de interacciones entre canales y bandas de frecuencia puede potenciar significativamente el reconocimiento de emociones basadas en EEG.

Zhang y Etemad en 2023 [43] propusieron una innovadora arquitectura de red neuronal profunda para el aprendizaje de representaciones espacio-temporales de EEG. Su modelo aborda la complejidad inherente y la alta dimensionalidad de las señales EEG mediante el uso de matrices de covarianza espacial (SCMs) en un espacio de variedades Riemannianas. La información se proyecta posteriormente en un espacio Euclidiano a través del aprendizaje del espacio tangente. Adicionalmente, el modelo integra la información temporal empleando características como la entropía diferencial y el espectro de potencia, utilizando una red LSTM con un mecanismo de atención. La estrategia de fusión de la información espacial y temporal demuestra una mejora significativa en la toma de decisiones, evaluando su eficacia

## Ejemplo ilustrativo Modelo GA - MLP


a: Número de neuronas primera capa oculta  
b: Número de neuronas segunda capa oculta

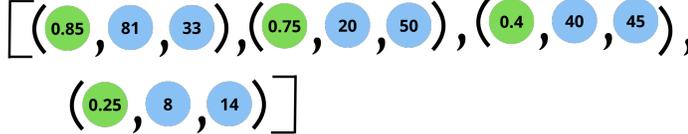
1. Sea una **población inicial** con 4 individuos:



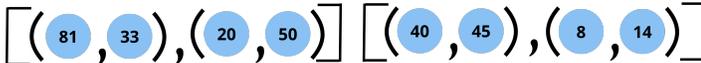
2. Luego la **Exactitud** de cada uno de los individuos es:



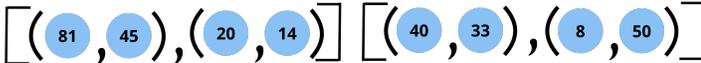
3. Luego se **ordenan los individuos** a partir de su valor de **Exactitud**:



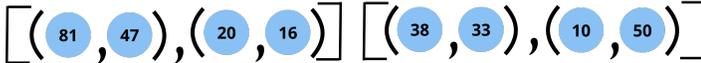
4. Se definen los **Padres**:

Padre 1:
Padre 2:  


5. Se aplica el **Crossover**:

Hijo 1:
Hijo 2:  


6. Se aplica la **Mutación**:

Hijo 1:
Hijo 2:  


7. Se repite hasta completar las 10 generaciones y se entrega el individuo con mayor Exactitud

Figura 2.14: Representación gráfica de GA - MLP.

Fuente: Elaboración propia.

en cuatro conjuntos de datos públicos en tareas de reconocimiento de emociones, estimación de vigilancia y clasificación de imágenes motoras, lo que demuestra la robustez de su enfoque en el aprendizaje de representaciones EEG.

Aldayel y sus colaboradores en 2023 [44] desarrollaron un sistema para predecir decisiones individuales mediante el uso de señales EEG del conjunto de datos SEED de la Universidad Jiao Tong de Shanghai. Aplicaron varios modelos de aprendizaje profundo, como redes neuronales convolucionales (CNN), LSTM y un modelo híbrido, para predecir decisiones influenciadas por estímulos emocionales. Además, compararon el rendimiento de estos modelos con clasificadores clásicos, como máquinas de soporte vectorial (SVM), vecinos más

cercanos (KNN) y regresión logística (LR), así como con métodos en conjunto como Random Forest, AdaBoost y XGBoost. El modelo LSTM propuesto alcanzó una precisión del 96 %, evidenciando la eficacia de los métodos de aprendizaje profundo en la predicción de decisiones basadas en estímulos emocionales.

Georgiadis y sus colaboradores en 2023 [45] presentaron un conjunto de datos de neuromarketing multimodal denominado NeuMa, que incluye información de 42 participantes expuestos a una serie de folletos publicitarios de supermercado mientras seleccionaban productos. Los datos recopilados abarcan grabaciones EEG, seguimiento ocular (ET), respuestas a cuestionarios demográficos y de perfil, así como datos de movimiento del ratón. Este estudio busca ofrecer una perspectiva más integral del comportamiento del consumidor mediante el análisis de respuestas cerebrales, oculares y conductuales a estímulos de marketing. NeuMa brinda a los investigadores la oportunidad de explorar conceptos clave del neuromarketing, como la percepción, la toma de decisiones y la evaluación de productos, superando las limitaciones de estudios anteriores centrados únicamente en señales EEG.

## 2.5. Páginas web

Desde la década de 1990, la World Wide Web, comúnmente conocida como la web, se ha convertido en una pieza esencial de la infraestructura comunicativa de las sociedades modernas. Este medio ha evolucionado desde los tradicionales como los periódicos, el cine, la radio y la televisión, y se ha integrado profundamente en la vida social, cultural y política. Es fundamental distinguir entre la web y el internet en general; la web se refiere específicamente a la parte del internet que utiliza los protocolos www, establecidos a principios de los años 90.

En la actualidad, las páginas web desempeñan un papel crucial, influyendo significativamente en individuos y organizaciones en diversos aspectos. Facilitan el acceso inmediato a información en áreas como la educación, las noticias, la ciencia y el entretenimiento. En el ámbito económico, el comercio electrónico ha revolucionado las formas de comprar y vender, abriendo nuevas oportunidades para las pequeñas empresas. Además, las redes sociales se han convertido en herramientas esenciales para la interacción social y el intercambio de ideas. Los sitios web gubernamentales mejoran la eficiencia y la transparencia, permitiendo a los ciudadanos acceder a servicios y realizar trámites en línea. En educación, las plataformas en línea amplían el acceso a recursos educativos. En el sector de la salud, las páginas web facilitan la gestión de la atención médica a distancia. Culturalmente, museos y artistas utilizan la web para alcanzar audiencias globales y hacer la cultura accesible a nivel mundial.

Las páginas web se dividen principalmente en dos tipos: estáticas y dinámicas, cada una con características y aplicaciones específicas que las hacen adecuadas para diferentes necesidades. El diseño web es un proceso multifacético que abarca tanto la creación visual de un sitio web como la planificación de su funcionalidad y usabilidad. Los diseñadores web se encargan de la apariencia estética del sitio, eligiendo paletas de colores, tipografías, imágenes y otros elementos visuales que resulten atractivos y comuniquen efectivamente la marca y los valores de la empresa.

### 2.5.1. Preferencias visuales en páginas web

Aunque aún no se ha desarrollado un método exhaustivo para cuantificar el atractivo visual de un sitio web en todas sus facetas, los investigadores se han centrado en dos características destacadas: la coloridez y la complejidad visual.

Un estudio publicado en 2010, realizado en ciudadanos de Japón, Alemania y Canadá, encontró que al aumentar el atractivo visual de los colores, se incrementa la confianza y satisfacción del cliente. Esto sugiere que los colores vivos y bien combinados pueden mejorar la percepción general del sitio, creando una experiencia más positiva para el usuario.[46]

En 2012, otro estudio reveló que la complejidad visual de una página web está negativamente relacionada con su atractivo visual. Es decir, mientras más compleja sea la disposición y los elementos visuales de una página, menos atractiva resulta para los usuarios. Esta relación negativa implica que un diseño sobrecargado puede abrumar a los visitantes, reduciendo su interés y satisfacción.[47]

Katharina Reinecke lideró un par de investigaciones en las que se analizaron las preferencias visuales hacia páginas web. A continuación, se presentan los resultados más destacados de estas investigaciones.

### 2.5.1.1 Predicting Users' First Impressions of Website Aesthetics with a Quantification of Perceived Visual Complexity and Colorfulness

En esta investigación [48] se presenta un método para predecir las primeras impresiones de los usuarios sobre la estética de los sitios web. En el estudio, se recolectaron calificaciones de lo colorido, complejidad visual y atractivo visual de 450 sitios web por parte de 548 voluntarios.

Los resultados muestran que la complejidad visual y la coloridad percibida pueden medirse con precisión mediante estadísticas de imágenes, las estadísticas utilizadas para predecir la coloridad se muestran en la Tabla 2.3. Los modelos desarrollados explican aproximadamente la mitad de la variabilidad en las calificaciones de atractivo estético dadas después de ver un sitio web durante solo 500 ms. Además, se encontró que la complejidad visual tiene un mayor impacto negativo en el atractivo visual que la coloridez, y que factores demográficos como la edad y el nivel educativo influyen en las primeras impresiones de los usuarios. Estos hallazgos subrayan la importancia de la simplicidad visual y la elección de colores en el diseño web, así como la influencia de los antecedentes demográficos en la percepción estética.

Métrica de imagen	Descripción
Número de áreas de imagen	Cantidad de áreas distintas de imagen identificadas
Colorfulness (Hasler y Suesstrunk)	Medición de la coloridez basada en la distancia del color al gris
Saturación	Intensidad del color
Valores de color HSV (hue, saturación, valor)	Modelo de color que incluye matiz, saturación y brillo
Porcentaje de colores W3C	Porcentaje de píxeles cercanos a uno de los dieciséis colores definidos por W3C

Tabla 2.3: Estadísticas de imágenes utilizadas para predecir el colorido

El modelo desarrollado para predecir la complejidad visual tiene un  $R^2$  de 0.65, indicando que explica el 65% de la variabilidad en las calificaciones de complejidad visual. Por otro lado, el modelo para predecir la coloridez percibida tiene un  $R^2$  de 0.78, lo que indica que explica el 78% de la variabilidad en las calificaciones de coloridez. Estos resultados refuerzan la precisión de los modelos en la evaluación de la estética web basándose en factores visuales cuantificables.

El estudio también evaluó diversas variables demográficas para analizar su influencia en la percepción estética de los sitios web. Los participantes tenían edades que oscilaban entre 15 y 70 años, con una media de 32.3 años, y la edad afectó significativamente la percepción de la

complejidad visual y la coloridez de los sitios web. Se incluyó información sobre el género de los participantes para investigar posibles diferencias en la percepción estética entre hombres y mujeres, aunque no se encontraron efectos significativos del género. Los niveles educativos reportados variaban desde educación secundaria hasta niveles superiores como maestrías y doctorados, y esta variable influye en cómo se valora el atractivo visual de los sitios web.

### 2.5.1.2 Quantifying Visual Preferences Around the World

En una segunda investigación (2014), Katharina Reinecke y Krzysztof Z. Gajos exploraron las preferencias visuales hacia páginas web. Este estudio se centró en analizar las preferencias estéticas de los usuarios de sitios web y cómo estas varían en función de diferentes factores demográficos. Para lograr una comprensión más profunda de estas preferencias visuales, los investigadores recolectaron 2.4 millones de calificaciones de la apariencia visual de sitios web, obtenidas de casi 40 mil participantes provenientes de diversas partes del mundo.

El objetivo de esta investigación fue identificar los patrones de preferencia estética y cómo estos se ven influenciados por variables demográficas como la edad, el género, el nivel educativo y el país de residencia. [49].

Para llevar a cabo este estudio, se diseñó un experimento con el objetivo de comparar las primeras impresiones de los participantes sobre la estética de los sitios web según sus diferentes antecedentes demográficos, y desarrollar modelos predictivos que tuvieran en cuenta estas diferencias en la percepción del atractivo visual. Los estímulos consistieron en 430 capturas de pantalla de sitios web, que incluían 350 en inglés, 60 en otros idiomas y 20 nominados a los premios Webby. Los sitios seleccionados representaban una variedad de géneros y niveles de colorido y complejidad visual.

El estudio se llevó a cabo como una prueba en línea en la plataforma LabintheWild.org para asegurar diversidad en términos de ubicación geográfica, edad, nivel educativo y experiencia en la web. Los participantes del estudio calificaron las capturas de pantalla en una escala de 1 a 9 basada en el atractivo visual percibido, con las imágenes mostradas durante 500 ms para capturar la primera impresión y reducir la influencia del contenido.

Todas las páginas web fueron evaluadas previamente para determinar su complejidad visual y colorido percibido utilizando un programa desarrollado en la investigación anterior, "Predicting Users' First Impressions of Website Aesthetics with a Quantification of Perceived Visual Complexity and Colorfulness" [48].

La relación entre el colorido y el atractivo visual sigue una forma de U invertida, donde los participantes, en promedio, prefirieron sitios web con un nivel de colorido moderado a alto, con el pico de atractivo en un nivel de colorido de aproximado 6 en una escala de 9. En cuanto a la complejidad visual, el atractivo visual tiene un pico en un nivel de complejidad de aproximadamente 4 de 10, siendo los sitios de complejidad moderada los más preferidos. En la Figura 2.15 y en la Figura 2.16, se muestran los resultados de la Coloridad y Complejidad versus el Atractivo Visual.

El estudio reveló cómo las preferencias varían según diferentes factores demográficos,

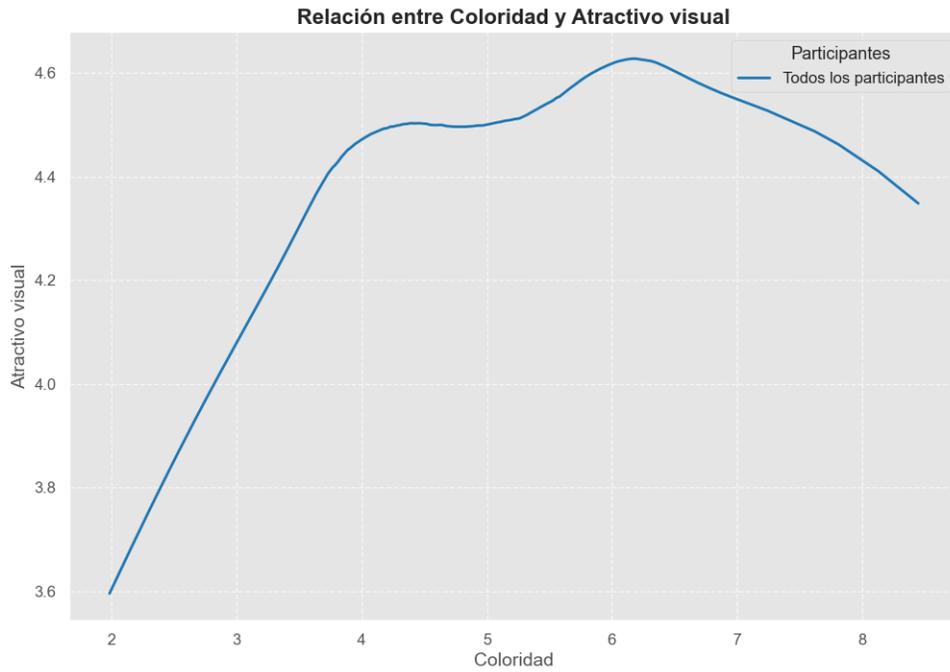


Figura 2.15: Coloridad y Atractivo visual

Fuente: Hecho a partir de los datos de [49]

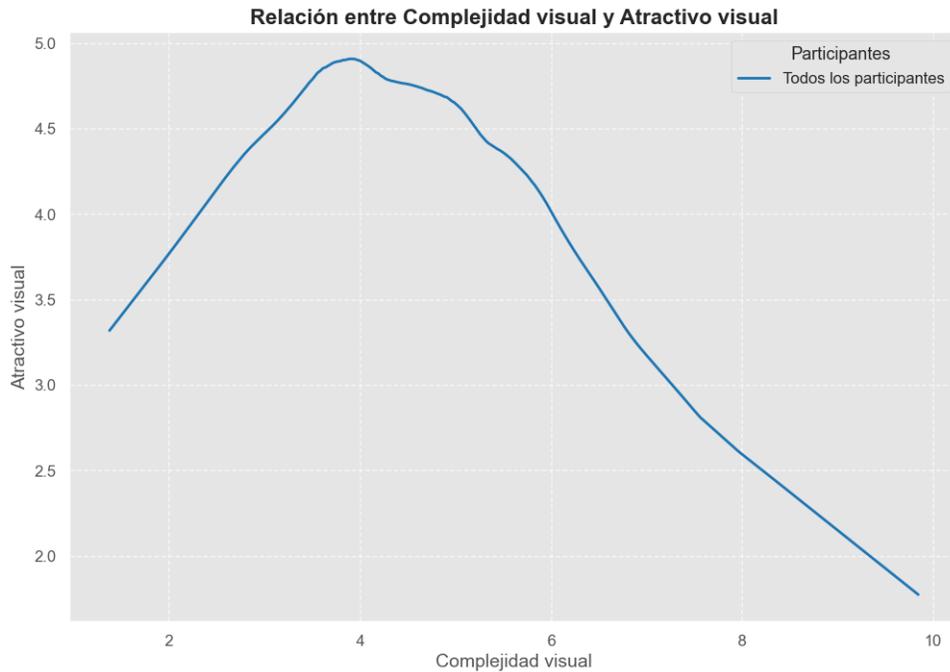


Figura 2.16: Complejidad visual y Atractivo visual

Fuente: Hecho a partir de los datos de [49]

incluyendo edad, género, nivel educativo y país de residencia. Un hallazgo notable fue que las mujeres tienden a preferir sitios web más coloridos que los hombres. Aunque ambos géneros

muestran una preferencia similar por niveles moderados de complejidad visual, la inclinación por el colorido es más pronunciada entre las mujeres. Esto indica que las mujeres pueden valorar una experiencia visual más vibrante y llamativa, apreciando un mayor uso de colores en el diseño web.

El análisis detallado mostró que las mujeres prefieren un nivel de colorido más alto en comparación con los hombres. En la Figura 2.17, se presenta un gráfico que ilustra la relación entre el colorido y el atractivo visual desglosado por sexo, proporcionando una visualización clara de cómo varían las preferencias de colorido entre hombres y mujeres.

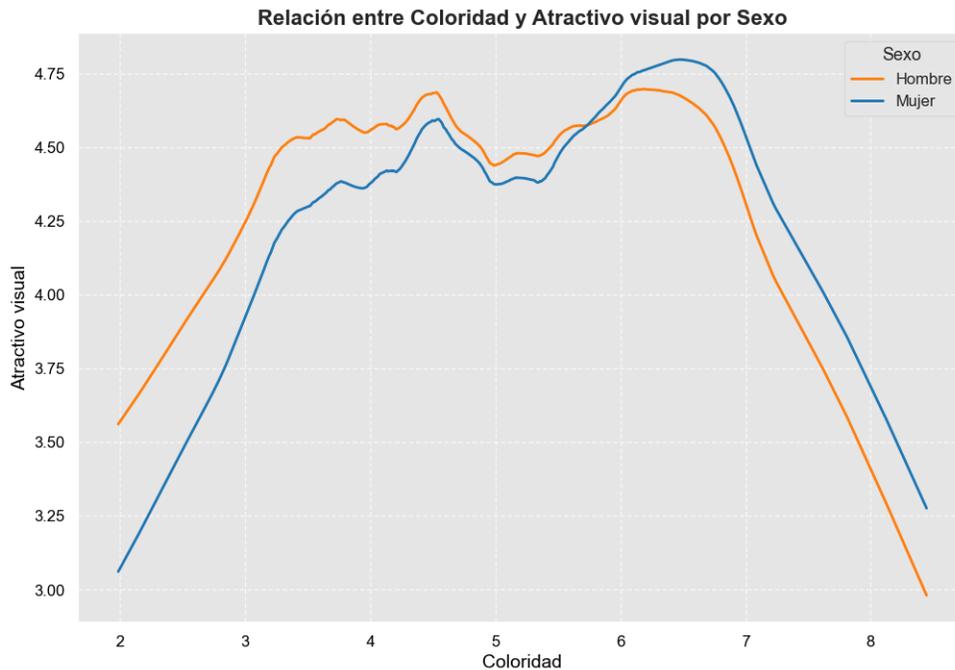


Figura 2.17: Coloridad y Atractivo visual por sexo

Fuente: Hecho a partir de los datos de [49]

Por otra parte, los usuarios del grupo etario de mayor edad (+51) mostraron una tendencia a preferir niveles más altos de colorido en los sitios web. En la Figura 2.18, se ilustra la relación entre lo colorido y el atractivo visual desglosado por grupo etario.

Finalmente, un nivel educativo más alto se correlaciona negativamente con la preferencia por sitios coloridos y complejos. Los participantes con menor nivel educativo prefieren sitios más coloridos y complejos. Además, las preferencias varían significativamente según el país de residencia. Por ejemplo, los participantes de Rusia prefirieron sitios con baja complejidad visual, mientras que los de Macedonia prefirieron sitios altamente coloridos.

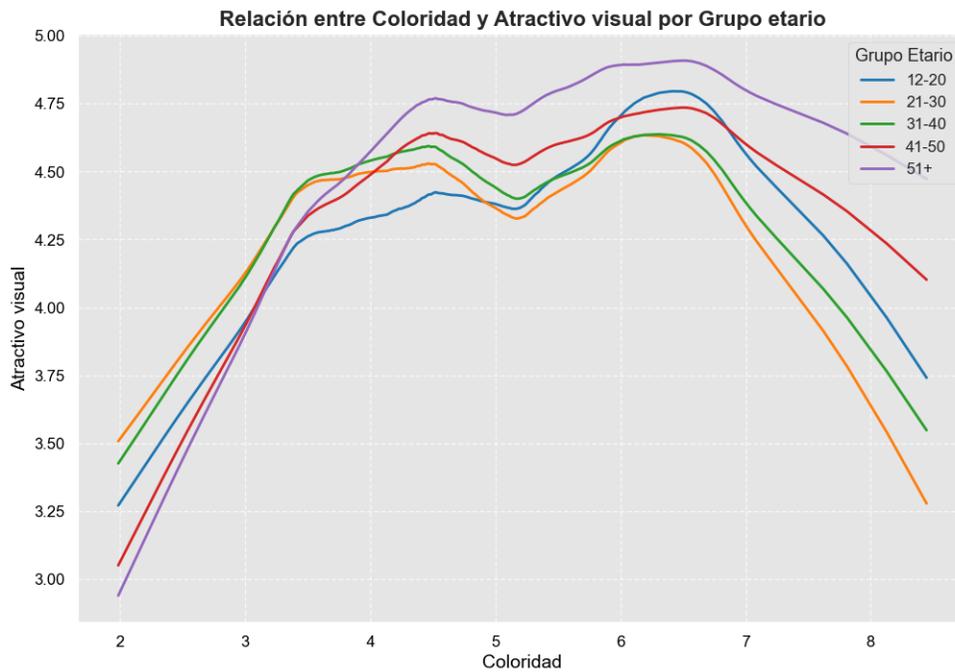


Figura 2.18: Coloridad y Atractivo visual por grupo etario

Fuente: Hecho a partir de los datos de [49]

## 2.6. Test estadísticos

En esta sección se abordarán los principales test estadísticos que se utilizarán en la investigación. Estos test permiten analizar la relación entre variables, comprobar hipótesis, y evaluar la significancia de los resultados obtenidos. A continuación, se detallan los conceptos y las pruebas que serán empleadas:

### 2.6.1. Conceptos básicos

#### 2.6.1.1 P-Valor

El p-valor (*p-value*) es un concepto fundamental en la inferencia estadística que permite evaluar la evidencia en contra de la hipótesis nula. Este valor representa la probabilidad de obtener un resultado tan extremo, o más extremo, que el observado, bajo la suposición de que la hipótesis nula es verdadera. Es un indicador cuantitativo que ayuda a los investigadores a decidir si los resultados obtenidos en un experimento o análisis son consistentes con la hipótesis nula o si se debe considerar la hipótesis alternativa.

El p-valor se calcula a partir de la estadística de prueba específica que se utiliza en un análisis. La fórmula general del p-valor depende del tipo de prueba estadística empleada. Por ejemplo, en un test t de Student para muestras independientes, el p-valor se calcula en función de la distribución t con  $n - 2$  grados de libertad:

$$p = P(T > |t_{\text{observado}}|) \quad (2.3)$$

Donde:

- $T$  es la variable aleatoria que sigue una distribución t con  $n - 2$  grados de libertad.
- $t_{\text{observado}}$  es el valor de la estadística t calculada a partir de los datos muestrales.

Un p-valor bajo, generalmente menor a un nivel de significancia predefinido (comúnmente  $\alpha = 0,05$ ), indica que los resultados observados son improbables bajo la hipótesis nula. Esto sugiere que la hipótesis nula puede ser rechazada en favor de la hipótesis alternativa. Sin embargo, es importante destacar que un p-valor bajo no confirma la hipótesis alternativa, sino que simplemente proporciona evidencia en contra de la hipótesis nula.

La interpretación del p-valor es clave en la toma de decisiones estadísticas:

- **Si  $p \leq \alpha$ :** Se rechaza la hipótesis nula ( $H_0$ ) en favor de la hipótesis alternativa ( $H_1$ ). Esto sugiere que los resultados obtenidos no son consistentes con la hipótesis nula y que existe una diferencia significativa o una asociación relevante.
- **Si  $p > \alpha$ :** No se puede rechazar la hipótesis nula. En este caso, no hay suficiente evidencia para concluir que existe una diferencia significativa o una asociación entre las variables estudiadas.

El p-valor, por lo tanto, es una herramienta esencial para determinar la significancia estadística de los resultados obtenidos en diversas pruebas, como la correlación de Spearman, el test t de Student y la prueba de Chi Cuadrado.

### 2.6.1.2 Hipótesis Nula ( $H_0$ )

La hipótesis nula ( $H_0$ ) es una proposición inicial que plantea la ausencia de un efecto o una relación significativa entre las variables bajo estudio. Es el punto de partida para la mayoría de los análisis estadísticos, y su propósito es proporcionar una base contra la cual se pueda evaluar la validez de los resultados obtenidos.

En diferentes pruebas estadísticas, la hipótesis nula toma formas específicas:

- En el **test t de Student**, la hipótesis nula establece que no existe diferencia significativa entre las medias de los grupos comparados:

$$H_0 : \mu_1 = \mu_2$$

- En la **prueba de Chi Cuadrado**, la hipótesis nula sostiene que no hay asociación entre las variables categóricas:

$$H_0 : \text{Las variables son independientes.}$$

- En la **correlación de Spearman**, la hipótesis nula indica que no existe una correlación monótonica entre las dos variables:

$$H_0 : \rho = 0$$

### 2.6.2. Correlación de Spearman

La correlación de Spearman, también conocida como  $\rho$  de Spearman, es un test estadístico no paramétrico que se emplea para medir la fuerza y la dirección de la asociación entre dos variables. A diferencia de la correlación de Pearson, que asume una relación lineal y normalidad en los datos, la correlación de Spearman se basa en los rangos de las variables. Esto la convierte en una opción más robusta frente a valores atípicos y distribuciones no normales.

La correlación de Spearman se calcula utilizando la siguiente fórmula:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (2.4)$$

Donde:

- $\rho$  es el coeficiente de correlación de Spearman.
- $d_i$  es la diferencia entre los rangos de las dos variables para el  $i$ -ésimo par de observaciones.
- $n$  es el número de observaciones.

El coeficiente de correlación de Spearman varía entre -1 y 1:

- Un valor de  $\rho = 1$  indica una correlación perfecta y positiva entre los rangos de las variables.
- Un valor de  $\rho = -1$  indica una correlación perfecta y negativa.
- Un valor de  $\rho = 0$  sugiere que no hay una correlación monótonica entre las variables.

La correlación de Spearman es particularmente útil en los siguientes contextos:

- **Variabes Ordinales:** Cuando las variables bajo estudio son ordinales, es decir, cuando los datos representan rangos o posiciones relativas pero no magnitudes absolutas. Por ejemplo, en una encuesta donde se clasifica la satisfacción del cliente en una escala de 1 a 5, la correlación de Spearman puede evaluar la asociación entre la satisfacción y otro factor ordinal.

- **Distribuciones No Normales:** En situaciones donde las variables cuantitativas no siguen una distribución normal, lo que invalidaría el uso de la correlación de Pearson. La correlación de Spearman es apropiada porque no requiere normalidad en los datos.
- **Relaciones No Lineales:** Aunque la correlación de Spearman no mide la linealidad de la relación, sí evalúa la monotonía. Esto significa que se puede utilizar para detectar relaciones en las que, a medida que una variable aumenta, la otra también lo hace (o disminuye), independientemente de que la relación sea lineal.
- **Datos con Valores Atípicos:** En presencia de valores atípicos que podrían distorsionar el coeficiente de correlación de Pearson, la correlación de Spearman es más resistente, ya que se basa en los rangos en lugar de los valores absolutos.

En esta investigación, se utilizará la correlación de Spearman para comparar la correlación entre dos conjuntos de datos con distintas escalas: una variable binaria, con valores 0 y 1, y otra variable multicategórica, con valores de 1 a 5. La elección de Spearman es adecuada en este contexto, ya que permite evaluar la asociación entre variables que no cumplen con los supuestos de linealidad o normalidad requeridos por el coeficiente de Pearson, y es robusta ante la diferencia de escalas y la naturaleza ordinal de una de las variables.

### 2.6.3. Test t de Student

El test t de Student es una prueba paramétrica utilizada para determinar si existen diferencias significativas entre las medias de dos grupos. Este test se emplea bajo la suposición de que los datos siguen una distribución normal y que las varianzas de los grupos son homogéneas. La prueba t de Student es adecuada para comparaciones donde se desea evaluar si la diferencia en las medias observadas entre dos grupos es lo suficientemente grande como para no ser atribuida al azar.

Existen diferentes versiones del test t de Student, cada una aplicable en contextos específicos:

- **Test t para muestras independientes:** Esta versión del test se utiliza cuando se comparan las medias de dos grupos diferentes e independientes entre sí. Es útil en estudios donde se quiere evaluar si dos poblaciones distintas tienen medias significativamente diferentes en una variable de interés.
- **Test t para muestras relacionadas:** También conocido como test t de muestras pareadas, se aplica cuando se comparan las medias de un mismo grupo en dos momentos diferentes o bajo dos condiciones diferentes. Es común en estudios longitudinales o en experimentos donde se mide el efecto de una intervención sobre el mismo grupo de sujetos antes y después del tratamiento.

Para muestras independientes, la fórmula del test t de Student es la siguiente:

$$t = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad (2.5)$$

Donde:

- $\overline{X}_1$  y  $\overline{X}_2$  son las medias de los dos grupos.
- $s_1^2$  y  $s_2^2$  son las varianzas muestrales de los dos grupos.
- $n_1$  y  $n_2$  son los tamaños de muestra de los dos grupos.

Para muestras relacionadas, la fórmula es ligeramente diferente, ya que se basa en la diferencia de las observaciones pareadas:

$$t = \frac{\overline{D}}{s_D/\sqrt{n}}$$

Donde:

- $\overline{D}$  es la media de las diferencias entre las observaciones pareadas.
- $s_D$  es la desviación estándar de las diferencias.
- $n$  es el número de pares de observaciones.

En la presente investigación, se aplicará el test t de Student para evaluar si las diferencias observadas entre las medias de distintos grupos son estadísticamente significativas. Se utilizará principalmente el test t para muestras independientes, dado que los grupos bajo comparación son diferentes y no están relacionados. Este análisis permitirá determinar si las diferencias observadas en la variable de interés entre los grupos pueden considerarse significativas desde un punto de vista estadístico, lo que aportará solidez a las conclusiones de la investigación.

#### 2.6.4. Prueba de Chi Cuadrado ( $\chi^2$ )

La prueba de Chi Cuadrado ( $\chi^2$ ) es un test estadístico no paramétrico utilizado para evaluar la asociación entre variables categóricas. Esta prueba se fundamenta en la comparación entre las frecuencias observadas y las frecuencias esperadas bajo la hipótesis nula de independencia, es decir, la suposición de que no existe una relación entre las variables categóricas en estudio.

El estadístico  $\chi^2$  se calcula utilizando la siguiente fórmula:

$$\chi^2 = \sum \frac{(O_i - E_i)^2}{E_i}$$

Donde:

- $O_i$  representa la frecuencia observada en la  $i$ -ésima celda de la tabla de contingencia.
- $E_i$  es la frecuencia esperada en la  $i$ -ésima celda de la tabla de contingencia.

El valor de  $\chi^2$  obtenido se compara con un valor crítico de la distribución  $\chi^2$  con  $k - 1$  grados de libertad, donde  $k$  es el número de celdas independientes. Si el valor calculado de  $\chi^2$  excede el valor crítico, se rechaza la hipótesis nula, sugiriendo que existe una asociación significativa entre las variables categóricas.

Las frecuencias esperadas ( $E_i$ ) son un concepto clave en la prueba de Chi Cuadrado. Representan las frecuencias que se esperarían observar en cada celda de una tabla de contingencia si las variables fueran independientes. El cálculo de las frecuencias esperadas se realiza de la siguiente manera:

$$E_i = \frac{(F_i \cdot F_j)}{N}$$

Donde:

- $F_i$  es la frecuencia total en la fila correspondiente a la celda  $i$ .
- $F_j$  es la frecuencia total en la columna correspondiente a la celda  $j$ .
- $N$  es el número total de observaciones.

La comparación entre  $O_i$  (frecuencia observada) y  $E_i$  (frecuencia esperada) en cada celda permite evaluar si las diferencias son debidas al azar o si indican una relación real entre las variables.

La prueba de Chi Cuadrado es particularmente útil en los siguientes contextos:

- **Tablas de Contingencia:** Se aplica comúnmente en tablas de contingencia, donde se analizan las distribuciones conjuntas de dos o más variables categóricas. Por ejemplo, en estudios que examinan la asociación entre el género y la preferencia por un producto.
- **Evaluación de Independencia:** Se utiliza para evaluar si las variables categóricas son independientes o si existe una asociación significativa entre ellas. La hipótesis nula establece que las variables son independientes, mientras que la hipótesis alternativa sugiere una dependencia entre las variables.
- **Datos Categóricos:** Es ideal para datos que son nominales o categóricos, donde las categorías no tienen un orden inherente, como colores, géneros, o tipos de tratamiento.

En esta investigación, la prueba de Chi Cuadrado se empleará para analizar la relación entre variables categóricas y determinar si las asociaciones observadas son estadísticamente significativas. El uso de esta prueba permitirá evaluar si las diferencias en las frecuencias observadas de las categorías pueden ser atribuibles a una relación real entre las variables, o si son simplemente resultado del azar. Este análisis será crucial para validar las hipótesis planteadas y para entender mejor las posibles interdependencias entre las variables categóricas bajo estudio.

# Capítulo 3

## Metodología

La metodología adoptada en la investigación es CRISP-DM (Cross-Industry Standard Process for Data Mining) pero con pequeños ajustes que se han adaptado a esta investigación científica. CRISP-DM un estándar ampliamente reconocido en proyectos de análisis de datos. A lo largo de sus diferentes fases, desde la comprensión del problema hasta la evaluación de resultados, se aborda cuestiones fundamentales desde la realización de hipótesis hasta la interpretación de resultados con el fin de dilucidar cómo la actividad cerebral puede ayudar a identificar los estados emocionales del usuario mientras observa páginas web.

### **Fase I: Comprensión del negocio y levantamiento de información**

En esta fase se definió el problema de investigación. Se identificaron preguntas específicas de investigación que se buscaban responder a través del análisis de datos y los objetivos que se esperaban cumplir. Además, se realizó un estudio de investigaciones similares y literatura asociada para asegurar un marco teórico sólido y relevante.

Con la información sobre el estado del arte, se procedió a realizar el diseño experimental donde se definieron todas las características del experimento, tales como los equipos a utilizar, estímulos a mostrar, muestra, protocolo experimental, etc. Además, en esta misma fase se llevó a cabo el experimento donde se obtuvieron los datos necesarios para la investigación.

### **Fase II: Comprensión de los datos**

En esta fase, se estudiaron los datos recopilados conforme a los procedimientos especificados en el diseño experimental para la recolección de datos EEG de los participantes. Este paso crucial aseguró la adherencia a las metodologías establecidas y la integridad de los datos recogidos. Luego, se emprendió un análisis exploratorio detallado de los datos recabados, con el objetivo de evaluar su estructura y calidad general. Este análisis permitió identificar y abordar cualquier problema potencial, como valores atípicos o datos faltantes, lo que es fundamental para la validez de los análisis subsecuentes y la fiabilidad de los resultados obtenidos.

Posteriormente, se recopilaron las respuestas conscientes de los participante, y se procedió a un análisis meticuloso de estos datos, aplicando técnicas estadísticas para extraer información valiosa y pertinente al objetivo de la investigación.

### **Fase III: Preparación de los datos**

En esta fase, se realizaron meticulosas tareas de limpieza de datos para abordar las problemáticas identificadas previamente, como la eliminación del ruido en las señales de EEG. Esta limpieza es esencial para garantizar la precisión en el análisis de los datos. Además, se llevó a cabo una sincronización precisa de los datos de EEG con el contenido mostrado en pantalla, asegurando una correlación exacta entre los estímulos visuales y la respuesta neuronal registrada.

Durante la preparación de los datos, también se incluyeron procedimientos como la normalización de las señales para reducir variaciones entre los registros de diferentes sujetos y sesiones, y la segmentación de las series temporales de EEG en ventanas de tiempo adecuadas para el análisis. Estos pasos son fundamentales para la estandarización de los datos antes de su ingreso en los modelos analíticos, facilitando así una comparación más efectiva y la aplicación de técnicas de aprendizaje automático.

### **Fase IV: Modelado**

En la fase de modelado, se desarrollaron y compararon diversos modelos de redes neuronales con el propósito de predecir las señales EEG registradas mientras los participantes observan estímulos emocionales, previamente etiquetados según la investigación de EmoMadrid, descrita en la sección 2.3.3. El objetivo central de esta fase es crear un modelo predictivo que logre, al menos, un 80 % de precisión en la identificación de la etiqueta correspondiente al estímulo emocional presentado, basándose en las señales EEG.

Una vez entrenados, estos modelos se aplican para determinar el estado emocional de los participantes durante la visualización de las páginas web presentadas en la etapa 2 del experimento. Con ello, se busca responder a las preguntas de investigación señaladas en 1.2 y validar o refutar las hipótesis planteadas en 4.1.3. Los modelos se entrenan utilizando los datos obtenidos de la Fase III. La meta de alcanzar un 80 % de precisión en las predicciones guía la selección del modelo más adecuado en términos de rendimiento, garantizando que el modelo final sea no solo preciso, sino también interpretable y valioso para el análisis posterior.

### **Fase V: Despliegue**

Finalmente, en esta fase se llevó a cabo una interpretación exhaustiva de los resultados obtenidos a partir de los modelos de redes neuronales, con el objetivo de responder de manera precisa a las preguntas de investigación planteadas y evaluar las hipótesis formuladas. Se realizó un análisis profundo que permitió extraer conclusiones significativas sobre los estados emocionales de los usuarios durante su interacción con las páginas web.

Además, esta fase incluyó la formulación de recomendaciones detalladas orientadas a optimizar las futuras interacciones de los usuarios con las páginas web, basadas en los hallazgos obtenidos. Se identificaron áreas clave que requieren mayor investigación, subrayando la naturaleza iterativa y en constante evolución del proceso de investigación, y destacando las oportunidades para seguir perfeccionando el entendimiento de la relación entre la experiencia web y las respuestas emocionales de los usuarios.

En este capítulo se ha detallado el proceso metodológico utilizado en la investigación, que sigue la estructura del CRISP-DM con ciertas modificaciones para adaptarse al estudio sobre cómo la actividad cerebral puede relacionarse con los estados emocionales de los usuarios al observar por páginas web. Se describieron cinco fases, desde la comprensión del problema hasta el despliegue y evaluación de los modelos, proporcionando un enfoque sistemático que facilita tanto la respuesta a las preguntas de investigación como la identificación de áreas para futuros estudios.

# Capítulo 4

## Desarrollo Metodológico

### 4.1. Fase I: Comprensión del negocio y levantamiento de información

Esta fase inicial del estudio se centró en definir con precisión el problema de investigación, tal como se describe en el Capítulo 1. Las preguntas específicas de investigación se identificaron en la Sección 1.2, mientras que los objetivos que se esperaba alcanzar se detallaron en la Sección 1.3. Además, se estableció un marco teórico robusto, el cual se puede consultar en el Capítulo 2.

En esta sección, se expondrá en detalle el diseño experimental, el cual incluye todas las características esenciales del experimento, como los equipos a emplear, los estímulos que se presentarán, la muestra seleccionada y el protocolo experimental a seguir. Además, se discutirán las hipótesis planteadas y su correspondiente justificación, subrayando la relevancia de cada una dentro del contexto del estudio.

Se describirá también el proceso de recolección de datos, asegurando que se comprenda cómo se llevó a cabo la toma de datos, incluyendo la metodología de registro y las técnicas utilizadas para garantizar la integridad y la calidad de los datos recopilados. Esta descripción incluirá cualquier medida tomada para minimizar errores y sesgos durante la recolección de datos, así como los criterios utilizados para la selección de los sujetos de estudio y la configuración del entorno experimental.

#### 4.1.1. Detalles del experimento

Para responder a la pregunta de investigación planteada en la sección 1.2, la cual busca identificar diferencias demográficas en las respuestas emocionales al visualizar páginas web, se propuso un experimento para capturar señales de EEG en usuarios mientras observa con diversas páginas web. Tal como se detalla en la sección de Alcances (1.4), este estudio se centra en usuarios chilenos y se enfoca en analizar las diferencias demográficas basadas en el grupo etario y el sexo. Por ello, se asegurará un equilibrio en ambas variables demográficas

Categorías	Sexo
1	Masculino
2	Femenino

Tabla 4.1: Categorías de la variable demográfica: Sexo.

Fuente: Elaboración propia.

Categorías	Grupo etario
1	Edad: [18 - 24] años
2	Edad: [25 - 33] años
3	Edad: [34 - 45] años
4	Edad: [46 - 65] años

Tabla 4.2: Categorías de la variable demográfica: Grupo etario.

Fuente: Elaboración propia.

para obtener resultados representativos y significativos.

#### 4.1.1.1 Variables demográficas

Las variables demográficas grupo etario y sexo se definen de forma categórica y se detallan en las tablas 4.2 y 4.1 respectivamente. Siguiendo las categorías establecidas, se fijó como objetivo medir las respuestas emocionales en 80 usuarios, divididos equitativamente con 40 usuarios de sexo masculino y 40 de sexo femenino. Para la variable de grupo etario, se seleccionarán 20 usuarios por categoría de edad, manteniendo un balance tanto en términos de sexo como de grupo etario. Esta distribución asegura que cualquier diferencia detectada en las respuestas emocionales pueda atribuirse con mayor precisión a las variables demográficas estudiadas.

#### 4.1.1.2 Dispositivo

Para la captura de las señales de EEG, se empleó el dispositivo UltraCortex 'Mark IV' de OpenBCI, descrito en detalle en [50]. Este dispositivo es capaz de soportar hasta 35 electrodos y ofrece una frecuencia de muestreo de 125 Hz. Para este estudio, se seleccionaron específicamente los electrodos en las posiciones FP1, FP2, F3, F4, F7, F8, C3, C4, T7 y T8, ubicados en los lóbulos frontal y temporal del cráneo. Esta elección se fundamenta en las correlaciones entre estas áreas cerebrales y la actividad emocional, tal como se expone en la sección 4.1.1. La configuración exacta de los electrodos seleccionados y su disposición en el cráneo se ilustran en la Figura 4.1.

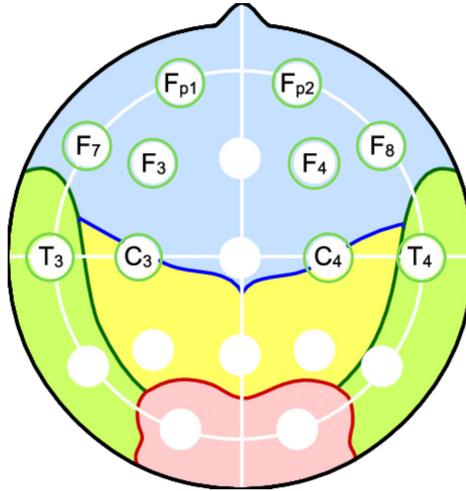


Figura 4.1: Electrodo utilizado del sistema internacional 10-20.

Fuente: Elaboración propia.

Para la captura de las señales EEG, se adoptaron dos métodos de grabación: el primero a través de Bluetooth, permitiendo la transmisión de datos en tiempo real al programa OpenBCI GUI v5, y el segundo mediante una tarjeta SD integrada en el dispositivo UltraCortex 'Mark IV'. Esta estrategia dual garantiza la continuidad de la recopilación de datos en caso de fallo de uno de los métodos, asegurando así que no se pierdan datos cruciales durante el experimento.

#### 4.1.1.3 Páginas web

Las páginas web utilizadas en el estudio se clasificaron en siete categorías distintas: joyería, farmacia, mascotas, sitios con alta densidad de información, videojuegos, grandes marcas y noticias de guerra. Estas categorías fueron seleccionadas para abarcar una amplia diversidad de contenidos y asegurar que el estudio capte una variedad de respuestas emocionales. El objetivo es explorar cómo diferentes tipos de contenido web influyen en las reacciones emocionales de los usuarios, particularmente en términos de valencia emocional, mientras visualizan estas páginas estáticas.

- **Joyería:** Las páginas de joyería suelen ser visualmente atractivas y elegantes, presentando productos de alta calidad que pueden evocar sentimientos de deseo, satisfacción y admiración. Se seleccionó esta categoría para inducir emociones positivas y estéticas, proporcionando un contraste claro con otras categorías que pueden ser más funcionales o provocar emociones más complejas.
- **Farmacia:** Las páginas web de farmacias son prácticas y orientadas a la salud, lo que puede generar una sensación de seguridad, confianza y tranquilidad en los usuarios. También, la información sobre medicamentos y productos de salud puede inducir preocupaciones menores, lo que permite capturar una gama de respuestas emocionales moderadas.

- **Mascotas:** Los sitios web dedicados a mascotas suelen ser cálidos y amigables, mostrando imágenes y productos relacionados con animales que pueden evocar sentimientos de ternura, alegría y conexión emocional. Esta categoría es ideal para observar emociones positivas y afectuosas.
- **Saturadas de información:** Los sitios web con exceso de información, plantean desafíos en términos de organización y usabilidad. Estos sitios pueden inducir sentimientos de estrés, abrumación o curiosidad, dependiendo de cómo se presenta la información y de la capacidad del usuario para procesarla.
- **Videojuegos:** Las páginas web de videojuegos suelen ser dinámicas y visualmente estimulantes, presentando gráficos llamativos y contenido interactivo. Estas características pueden evocar excitación, entusiasmo y, en algunos casos, frustración o estrés debido a la naturaleza competitiva del contenido.
- **Grandes marcas:** Las páginas web de grandes marcas están diseñadas para ser altamente funcionales y atractivas, con un enfoque en la experiencia del usuario y la conversión de ventas. Estas páginas pueden inducir una mezcla de emociones, desde la satisfacción y la comodidad hasta el deseo de compra y la comparación de productos.
- **Noticias de guerra:** Las páginas web que cubren noticias de guerra pueden evocar fuertes emociones negativas, como tristeza, miedo y preocupación. Esta categoría se incluyó para capturar respuestas emocionales intensas y negativas, proporcionando un contraste necesario con las emociones positivas inducidas por otras categorías.

Las páginas web seleccionadas se detallan en la Tabla 4.3. En el 6.2 se puede observar las páginas web estáticas mostradas.

Categoría	ID	Sitio web
Joyería	1	www.nihaojewelry.com
Joyería	2	www.gratia.com.ar
Joyería	3	www.frankronay.com
Mascotas	4	www.tiendanimal.es
Mascotas	5	www.britcare.co
Farmacia	6	www.pharmacys.com.ec
Videojuegos	7	www.habbo.es
Videojuegos	8	www.smashbros.com
Saturadas de información	9	www.lingscars.com
Saturadas de información	10	www.arngren.com
Mascotas	11	www.elmundodedali.cl
Noticias de guerra	12	www.amnesty.org
Farmacia	13	www.farma.uy
Joyería	14	www.joyeriasbizarro.com
Farmacia	15	www.farmaciauniversal.com
Farmacia	16	www.farmacity.com
Noticias de guerra	17	www.oxfam.org
Grandes marcas	18	www.apple.com
Grandes marcas	19	www.tiendalego.cl

Tabla 4.3: Páginas web seleccionadas

Fuente: Elaboración propia

#### 4.1.1.4 Estímulos emocionales

Los estímulos emocionales empleados en este estudio provienen de la base de datos Emo-Madrid [29], como se detalla en la sección 2.3.3. Esta base contiene más de 1200 imágenes emocionales que han sido evaluadas en términos de Activación y Valencia por más de 100 individuos de diversas edades y sexos, utilizando el cuestionario SAM (Self-Assessment Manikin). En este cuestionario, las respuestas oscilan entre -2 a 2 para las dimensiones de Valencia (desde Muy negativo hasta Muy positivo) y Activación (desde Muy baja activación hasta Muy alta activación). Cada imagen en la base de datos tiene asignada una media de Activación y Valencia, calculadas a partir de las evaluaciones de los participantes, que se utilizan como etiquetas en los estudios.

Con el objetivo de asegurar una cobertura completa de los estados emocionales, se seleccionaron 27 imágenes representativas del conjunto de datos. La Tabla 4.4 muestra las 27 imágenes seleccionadas, junto con sus evaluaciones en las dimensiones de Activación y Valencia. Estas imágenes abarcan un amplio espectro emocional, que va desde las emociones más negativas hasta las más positivas, proporcionando así una base sólida para el análisis de las respuestas emocionales inducidas.

Categoría	ID EmoMadrid	Valoraciones Medias	
		Valencia	Activación
1	EM0710	-1,95	1,83
1	EM0698	-1,95	1,53
1	EM0730	-1,94	1,51
1	EM0819	-1,84	1,67
2	EM0893	-1,04	0,48
2	EM0898	-0,95	0,93
2	EM0899	-0,95	0,81
2	EM0896	-0,89	0,77
3	EM0220	0,00	-0,11
3	EM0244	0,06	-0,32
3	EM0026	0,07	-0,22
3	EM0508	0,09	-0,27
4	EM1161	1,00	-0,42
4	EM1160	1,05	-1,00
4	EM1129	1,08	0,32
4	EM1119	1,13	-0,78
4	EM0352	1,16	1,00
4	EM0366	1,26	0,98
4	EM0372	1,09	0,75
4	EM0462	1,24	0,99
4	EM0924	1,24	1,33
5	EM0461	1,40	1,22
5	EM0694	1,66	1,32
5	EM0699	1,71	-1,72
5	EM0688	1,77	-1,52
5	EM0060	1,79	-1,71
5	EM0714	1,82	-1,57

Tabla 4.4: Imágenes seleccionadas de la base de datos EmoMadrid.

En la Figura 4.2 se presentan algunas de las imágenes utilizadas, distribuidas en el plano de Valencia-Activación.

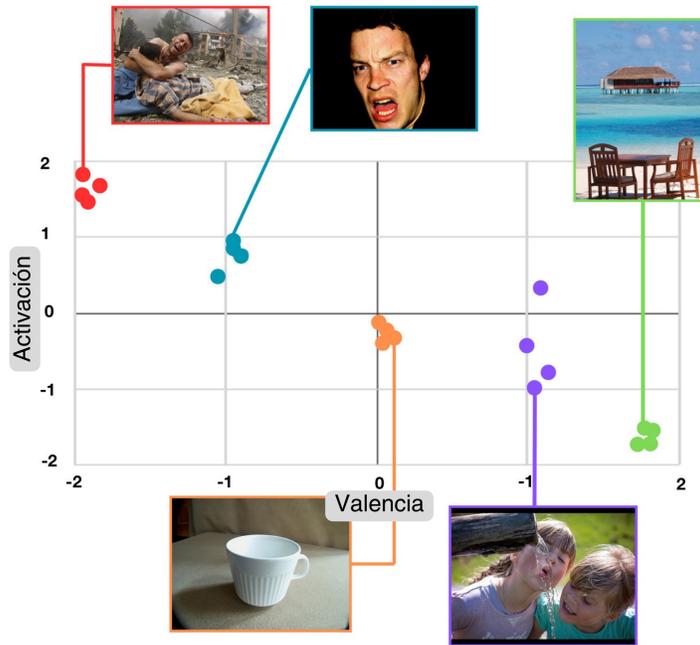


Figura 4.2: Imágenes seleccionadas distribuidas en el plano de Valencia-Activación

Fuente: Elaboración propia.

#### 4.1.1.5 Orden de los estímulos

Es fundamental destacar que, para mitigar posibles sesgos emocionales derivados de la secuencia específica en que se muestran las imágenes emocionales y las páginas web, se implementó un enfoque sistemático para diversificar el orden de presentación. Para lograr esto, se generaron cuatro secuencias distintas de presentación utilizando simulaciones de Monte Carlo. Este método no solo permitió aleatorizar el orden, sino que también aseguró que cada secuencia fuera única y estadísticamente independiente de las otras.

La selección de las cuatro secuencias se basó en la búsqueda de vectores que presentaran la menor correlación posible entre sí. La correlación entre dos vectores  $\mathbf{u}$  y  $\mathbf{v}$  se calcula utilizando la fórmula:

$$\text{Correlación}(\mathbf{u}, \mathbf{v}) = \frac{\sum_{i=1}^n (u_i - \bar{u})(v_i - \bar{v})}{\sqrt{\sum_{i=1}^n (u_i - \bar{u})^2 \sum_{i=1}^n (v_i - \bar{v})^2}} \quad (4.1)$$

donde  $u_i$  y  $v_i$  son los componentes de los vectores  $\mathbf{u}$  y  $\mathbf{v}$ , y  $\bar{u}$  y  $\bar{v}$  son los promedios de los componentes de  $\mathbf{u}$  y  $\mathbf{v}$ , respectivamente. Esta medida permite evaluar la independencia

lineal entre las secuencias de imágenes, asegurando que las variaciones en las respuestas de los participantes sean atribuibles a los estímulos y no al orden de presentación.

## 4.1.2. Diseño experimental

Este estudio fue diseñado para explorar las reacciones emocionales de los usuarios al interactuar con páginas web estáticas. Se estructuró en tres fases diferenciadas, cada una dirigida a una componente esencial del proceso de recopilación de datos. La primera fase se centró en la preparación de los participantes y en la correcta instalación del equipo necesario para registrar las señales de EEG. En la segunda fase, se observó cómo los usuarios interactuaban con una variedad de páginas web, analizando el impacto del contenido en sus estados emocionales. La tercera fase del estudio presentó imágenes emocionales cuidadosamente seleccionadas para inducir respuestas emocionales concretas. Estas reacciones fueron capturadas mediante EEG y se utilizaron para entrenar un modelo de aprendizaje automático, permitiendo así una evaluación más precisa de las respuestas emocionales a diferentes estímulos visuales.

### 4.1.2.1 Etapa 1: 'Instrucciones e instalación de equipos'

En la primera fase del experimento, se ofrece al participante una orientación completa sobre la naturaleza del estudio, incluyendo los dispositivos utilizados para registrar respuestas fisiológicas (ET, GSR, **EEG**, cámara web), y la duración esperada del experimento. Antes de comenzar, se asegura que cada participante firme un consentimiento informado, detallando los procedimientos y garantizando su comprensión y acuerdo con los términos de participación. Las instrucciones específicas incluyen:

- Mantener los movimientos del cuerpo y la cabeza al mínimo para reducir interferencias en las señales capturadas, sin comprometer la naturalidad del comportamiento.
- Concentrarse en el contenido mostrado en la pantalla.
- Levantar la mano derecha si surge algún problema o incomodidad.
- Atender y seguir todas las instrucciones presentadas en pantalla.

Posteriormente, se procede a la instalación de los equipos de medición de la siguiente manera:

- *Shimmer3 GSR+ Unit*: Este dispositivo mide la respuesta galvánica de la piel (GSR)[51]. Se coloca una muñequera en la mano no dominante del usuario, con sensores adheridos al dedo anular y medio. El dispositivo se conecta por Bluetooth al sistema de registro para asegurar una transmisión fluida de la data. Se verifica que la conexión sea estable antes de proceder.

- *Electroencefalograma*: Antes de colocar el casco Ultracortex 'Mark IV', se solicita al usuario que recoja su cabello si es largo. El casco se ajusta cuidadosamente para asegurar el contacto óptimo de todos los electrodos con el cuero cabelludo. Se pregunta al usuario si se siente cómodo con el ajuste del casco y, de ser necesario, se hacen ajustes a los electrodos para mantener el confort sin perder conectividad. Una vez ajustado, se verifica la estabilidad de la conexión de cada electrodo.
- *TOBII Eye-Tracker y Cámara web*: Estos dispositivos se instalan en el monitor del computador. Se ajusta la altura y posición de la silla del usuario para garantizar que ambos dispositivos capturen adecuadamente la cara y los ojos del participante.

#### 4.1.2.2 Etapa 2: 'Páginas web'

En la segunda etapa del experimento, los participantes son expuestos a diversas páginas web según un protocolo cuidadosamente diseñado para capturar datos precisos del Eye-Tracker y evaluar las reacciones emocionales. El procedimiento se inicia mostrando una imagen de calibración que consiste en una cruz centrada sobre un fondo completamente difuminado; los píxeles de la imagen están desordenados y homogeneizados en color, pero mantienen la cruz en el centro. Este paso es crucial para ajustar el tamaño de la pupila del participante a la iluminación y colores de la pantalla, y para centrar su atención en el punto medio, optimizando así la precisión del seguimiento ocular.

Tras la imagen de calibración, se presenta la página web de interés durante exactamente 7 segundos. Este tiempo ha sido seleccionado para permitir una respuesta emocional suficiente sin causar fatiga o desinterés. Inmediatamente después de la visualización de la página web, se despliega un cuestionario breve. La pregunta clave es: "¿Cómo clasificas el efecto que te produjo el sitio web anterior?" Las opciones de respuesta van desde "Muy negativo" hasta "Muy positivo", asignadas a los números del 1 al 5 respectivamente, facilitando al participante la selección de una respuesta rápida y precisa mediante la elección de un número correspondiente a su reacción emocional.

La pregunta final no tiene un límite de tiempo definido para responderse, una vez que el participante selecciona una opción, el procedimiento se reinicia automáticamente con una nueva imagen de calibración seguida de otra página web. En la Figura 4.3, se muestra un ejemplo de lo anterior.

#### 4.1.2.3 Etapa 3: 'Evocación de emociones'

En la segunda fase del experimento, los participantes serán expuestos a un conjunto de 27 imágenes emocionales, descritas detalladamente en la sección 4.1.1. Para asegurar una evaluación consistente de las respuestas emocionales, se seguirá un protocolo similar al utilizado con las páginas web.

Cada sesión comienza con la presentación de una imagen inicialmente difuminada, sirviendo esta para calibrar la visión y preparar al usuario sin revelar el contenido emocional inmediato de la imagen siguiente. A continuación, se muestra la imagen emocional durante



Figura 4.3: Proceso de muestra de páginas web.

Fuente: Elaboración propia.

un período de 5 segundos. Este tiempo es suficiente para provocar una respuesta emocional detectable sin sobrecargar cognitivamente al usuario. La imagen emocional no será evaluada explícitamente por los participantes.

Al finalizar la presentación de cada imagen emocional, la secuencia se reinicia con otra imagen difuminada, preparando al participante para la siguiente imagen emocional. Este ciclo se repite para cada una de las 27 imágenes.

### 4.1.3. Hipótesis

En esta investigación sobre las respuestas emocionales que subyacen a la interacción de los usuarios chilenos con páginas web, se han planteado preguntas centradas en cómo los estados emocionales se reflejan en la actividad cerebral, medida a través del electroencefalograma (EEG). Este enfoque permite explorar las conexiones entre la neurociencia y el comporta-

miento en entornos digitales, especialmente en cómo los estímulos visuales de las páginas web evocan respuestas emocionales específicas.

La hipótesis principal sostiene que:

**Es posible identificar diferencias demográficas significativas en las respuestas emocionales, clasificadas por un algoritmo de aprendizaje automático a partir de señales de EEG, mientras los usuarios observan las páginas web.**

La hipótesis secundaria sostiene que:

- **Las mujeres presentarán un estado emocional más positivo al visualizar páginas web que contienen más colores en comparación con los hombres**

#### 4.1.3.1 Justificación de hipótesis

La hipótesis principal se fundamenta en investigaciones previas, como los estudios de Reinecke (referenciados en la sección 2.5.1), que indican que diferentes grupos demográficos perciben y responden de manera distinta al diseño visual de las páginas web. Por ejemplo, las preferencias estéticas pueden variar entre géneros y grupos etarios, lo que debería influir directamente en las respuestas emocionales.

En cuanto la hipótesis secundaria se fundamenta en los mismos estudios de Reinecke, pero en este caso en los hallazgos relacionados con el sexo de los observadores de páginas web. En donde se descubre que existe una diferencia en el atractivo visual entre hombres y mujeres dependiendo de la coloridad de la página web.

Además, gracias a los avances en el análisis de señales de EEG, como se discutió en la sección 2.4, han demostrado la capacidad de identificar y clasificar estados emocionales con alta precisión a partir de patrones cerebrales. Esta tecnología permite explorar cómo los estímulos visuales impactan las respuestas emocionales, lo que proporciona una herramienta sólida para investigar diferencias significativas entre grupos demográficos durante la interacción con páginas web.

En conjunto, estas justificaciones apoyan la investigación sobre las diferencias demográficas en las respuestas emocionales ante las distintas páginas web, utilizando herramientas avanzadas de neuromarketing para explorar y validar estas hipótesis.

## 4.2. Fase II: Comprensión de los datos

En este capítulo se describen los datos obtenidos, a partir del experimento realizado en el Web Intelligence Center con la participación de 85 individuos de nacionalidad chilena. La selección y distribución de los participantes fue planificada para mantener un equilibrio en términos de género y grupos etarios, como se describe en la sección 4.1 y se visualiza la distribución obtenida en la Figura 4.4. Este equilibrio es esencial para minimizar posibles sesgos y asegurar que los resultados del estudio sean representativos de la población general.

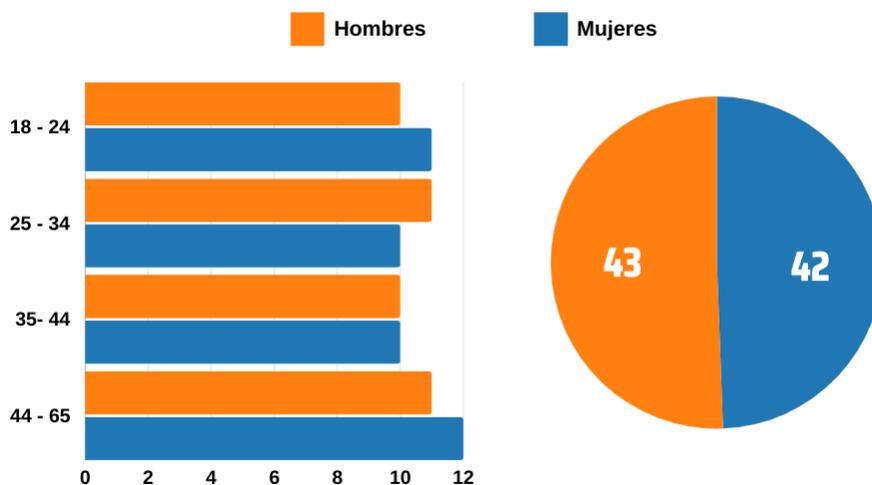


Figura 4.4: Distribución de demográfica de los participantes del experimento.

Fuente: Elaboración propia.

La composición demográfica balanceada de los participantes es vital para validar la hipótesis del estudio, que propone que las diferencias individuales influyen significativamente en las respuestas emocionales y neuronales ante variados estímulos visuales en entornos digitales. Este enfoque permite examinar cómo factores demográficos específicos pueden afectar la interacción de los usuarios con contenido digital, proporcionando una base sólida para interpretaciones más precisas y generalizables de los datos recogidos.

### 4.2.1. Análisis exploratorio de datos

Debido al experimento realizado a 85 participantes, se recolectaron dos tipos principales de datos: las respuestas conscientes de los participantes a la pregunta "¿Cómo clasificas el efecto que te produjo el sitio web anterior?" y las señales de EEG registradas durante el transcurso del experimento. Cada sesión de EEG duró aproximadamente 15 minutos, y dado que el dispositivo de EEG empleado tiene una frecuencia de muestreo de 125 Hz, la longitud total de la señal capturada asciende a aproximadamente 110.000 puntos de datos por canal.

Los datos recogidos están almacenados en un archivo CSV. Este archivo está estructurado

con la primera columna representando el timestamp y luego las 16 columnas que tienen información de los 16 canales con los que graba este dispositivo, en este caso se utilizaron 10 canales por lo que existen 6 columnas vacías.

#### 4.2.1.1 Respuesta consciente

La respuesta consciente de los participantes a la pregunta: '¿Cómo clasificarías el efecto que te produjo el sitio web anterior?' realizada después de haberles mostrado la página web, proporciona información valiosa sobre las preferencias individuales de los usuarios y el impacto consciente que el sitio web les genera. En esta sección, se llevará a cabo un análisis exploratorio de datos sobre estas respuestas, con el objetivo de identificar patrones y tendencias en la percepción de los usuarios. Posteriormente, se procederá a segmentar los datos según grupos demográficos, definidos por variables clave como el sexo y el grupo etario.

Al segmentar los datos según la variable demográfica de sexo, se observó que las mujeres tienden a tener una respuesta más positiva hacia las páginas web observadas en el experimento en comparación con los hombres, tal como lo muestra la Figura 4.5. En promedio, las mujeres otorgaron una calificación de 3.25, mientras que los hombres asignaron una calificación ligeramente inferior de 3.18.

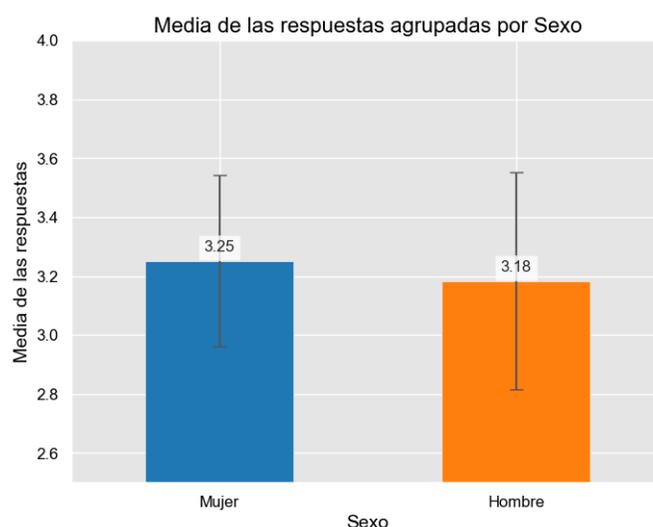


Figura 4.5: Respuesta consciente agrupada por Sexo.

Fuente: Elaboración propia.

Por otro lado, al segmentar los datos por grupo etario, se observó que el Grupo 3, compuesto por personas entre 34 y 45 años, presentó la respuesta promedio más positiva, con una media de 3,3. En contraste, el Grupo 2, que incluye a personas de entre 25 y 33 años, mostró respuestas menos favorables, con una media de 3,15. Es importante destacar que ninguno de los grupos etarios tuvo una respuesta consciente promedio inferior a 3, lo que indica que, en general, las páginas web fueron bien recibidas y no generaron en promedio impresiones negativas en ninguno de los segmentos.

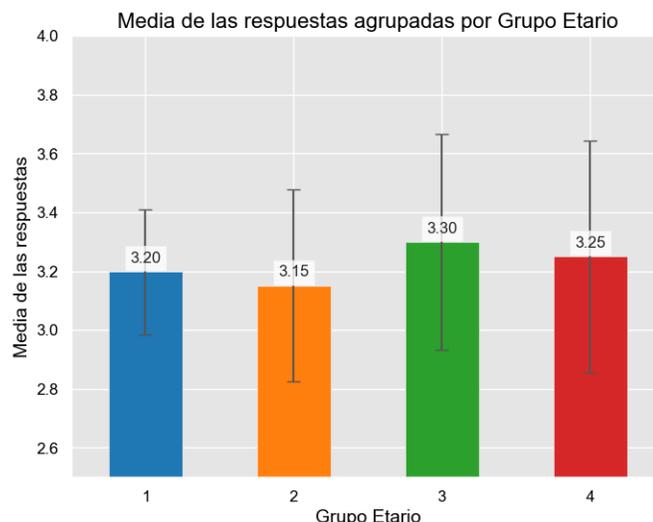


Figura 4.6: Respuesta consciente agrupada por Grupo etario.

Fuente: Elaboración propia.

La Figura 4.7 ilustra cómo las respuestas promedio varían al considerar de manera conjunta las variables demográficas de sexo y grupo etario. En el caso de las mujeres, se destaca que el grupo etario 4, el de mayor edad, registró la respuesta más positiva hacia las páginas web evaluadas, con una media de 3,38, seguido de cerca por el grupo etario 3, que alcanzó una media de 3,28. Los grupos etarios 1 y 2 presentaron respuestas algo más moderadas, con medias de 3,20 y 3,14, respectivamente.

Por otro lado, entre los hombres, el grupo etario 3 se destacó como el más favorable hacia las páginas web, obteniendo una media de 3,32, mientras que el grupo 4 mostró una media inferior de 3,10. Los grupos etarios 1 y 2 mantuvieron medias de 3,19 y 3,16, respectivamente. Es importante subrayar la notable diferencia en la percepción del grupo etario 4 entre hombres y mujeres: mientras las mujeres de este grupo otorgaron una media de 3,38, los hombres del mismo grupo solo alcanzaron una media de 3,10, lo que resalta una diferencia llamativa en la evaluación de las páginas web.

Finalmente, al agrupar las páginas web según su categoría, las respuestas promedio obtenidas se muestran en la Figura 4.8. Esta figura revela cómo diferentes categorías de imágenes influyen en la percepción de los usuarios. Por ejemplo, las categorías "Mascotas" y "Farmacia" registraron las medias más altas, con 3,54 y 3,49 respectivamente, lo que indica una percepción más positiva. En contraste, la categoría "Saturadas de información" y "Noticias de guerra" tuvieron las medias más bajas, con 2,96 y 3,06 respectivamente, lo que sugiere una percepción menos favorable.

#### 4.2.1.2 Señales del electroencefalograma

En este análisis exploratorio de datos, se examinan las señales de electroencefalograma capturadas durante un experimento diseñado para estudiar la respuesta cerebral a diversos estímulos. El objetivo principal es identificar patrones en las señales EEG, detectar posibles

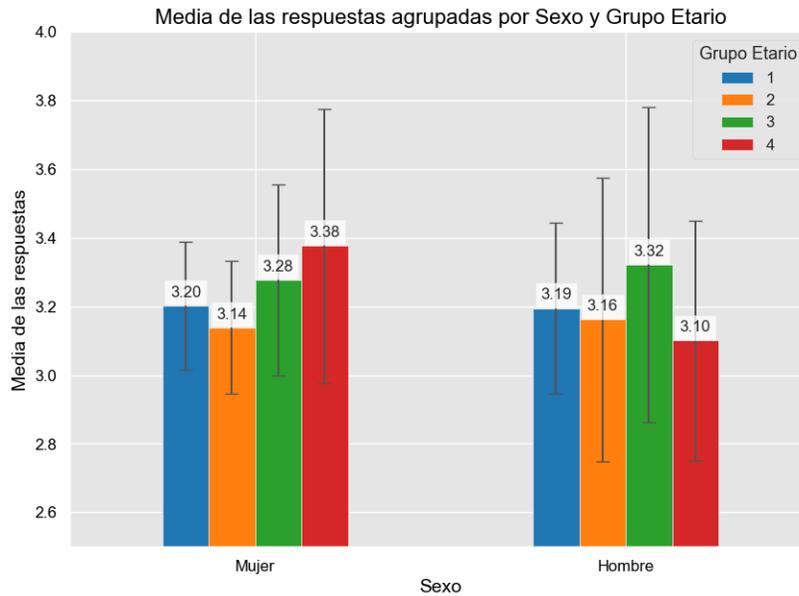


Figura 4.7: Respuesta consciente agrupada por Grupo etario y Sexo.

Fuente: Elaboración propia.

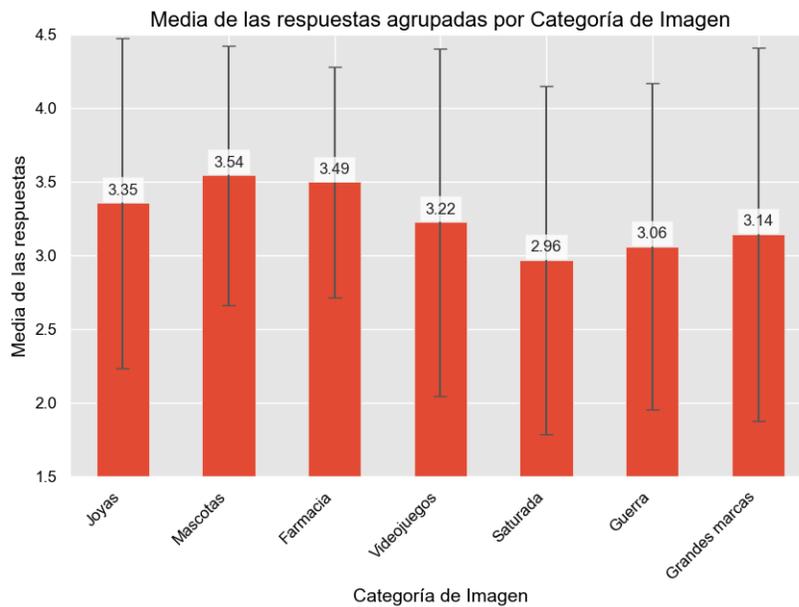


Figura 4.8: Respuesta consciente agrupada por categoría de la página web

Fuente: Elaboración propia.

anomalías en los datos y establecer una comprensión preliminar de las características clave de las señales.

Durante la captura de las señales, se registraron observaciones detalladas para identificar y recordar posibles errores ocurridos durante la toma de muestras, como pérdidas de datos, desconexiones imprevistas de equipos y otros problemas técnicos que pudieron afectar la

calidad de los registros. En la siguiente Tabla 4.5 se presentan los datos que contienen alguna imperfección, acompañados de una descripción específica de la anomalía identificada en cada caso.

Participante	Observación
6	Alta pérdida de paquetes de información de la señal de EEG
24	El electrodo de la posición F7 dejó de funcionar durante el experimento
26	Alta pérdida de paquetes de información de la señal de EEG
43	No se pudo capturar la grabación de pantalla.
45	No se pudo capturar la grabación de pantalla.

Tabla 4.5: Señales EEG que presentan problemas graves.

Fuente: Elaboración propia.

A partir de estas observaciones, se decidió excluir los datos de estos participantes del análisis. Dado que representan un pequeño porcentaje del total de muestras y que las anomalías registradas dificultan su tratamiento en igualdad de condiciones con el resto de los datos, su inclusión podría comprometer la integridad de los resultados. Por lo tanto, se consideró más adecuado omitir estos registros defectuosos en el procesamiento final. Con ello, la distribución de los participantes en los distintos grupos demográficos es la que se muestra en la Figura 4.9.

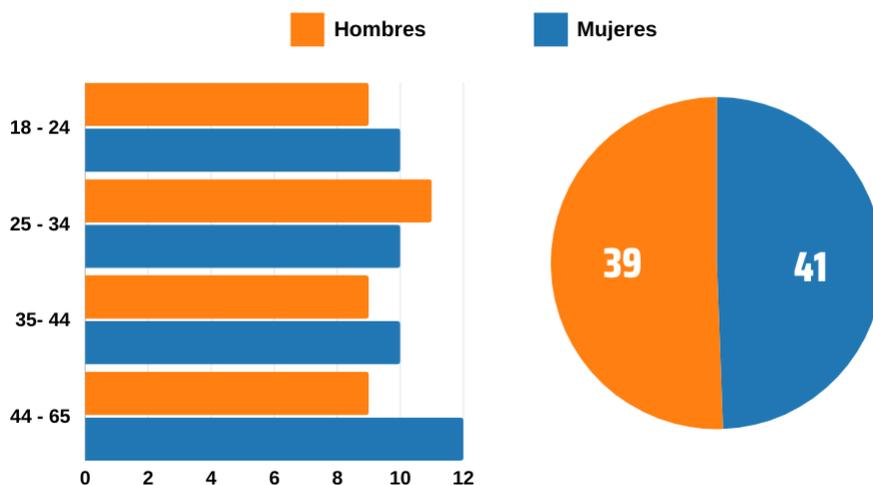


Figura 4.9: Distribución de demográfica de los participantes de las señales a utilizar.

Fuente: Elaboración propia.

Para analizar las señales de EEG, se realizaron gráficos de las señales correspondientes a todos los canales utilizados. En estos gráficos, se observan cambios abruptos en la amplitud

de las señales, lo que podría deberse a movimientos bruscos de los participantes u otros tipos de artefactos, como interferencias eléctricas o movimientos musculares. Además, se ha notado que la línea base de la señal varía entre los diferentes canales, lo cual podría estar relacionado con la falta de una correcta referencia común ó variaciones en la impedancia de los electrodos. Para ilustrar este comportamiento, en la Figura 4.10 se muestran las señales EEG de todos los canales para el participante 51, el cual corresponde a una mujer de 51 años.

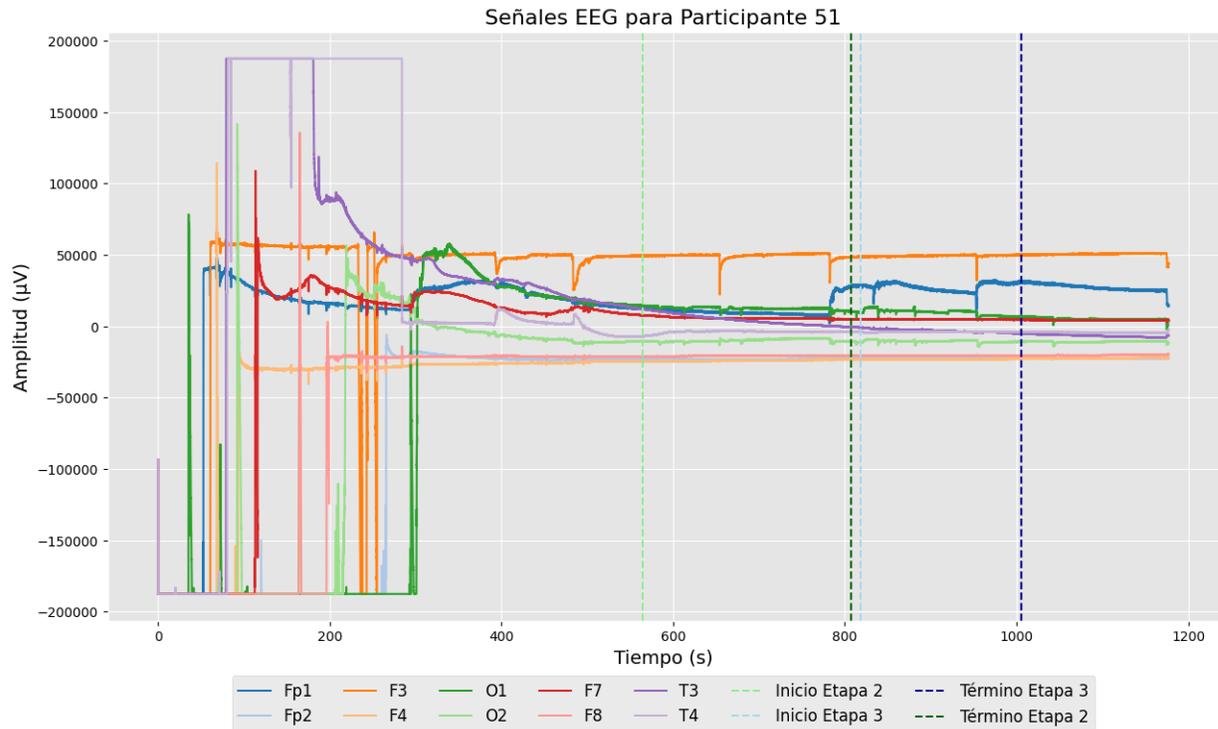


Figura 4.10: Señales EEG para una mujer de 51 años (grupo etario 3).

Fuente: Elaboración propia.

En la Figura 4.10, se puede observar que, al inicio, las señales presentan un comportamiento caótico. Este fenómeno se debe a que corresponden a la etapa inicial del registro, durante la cual se están ajustando los electrodos. A medida que avanza el tiempo, las señales comienzan a estabilizarse, indicando que los electrodos han alcanzado un contacto óptimo con el cuero cabelludo y las mediciones se vuelven más consistentes.

Estas observaciones iniciales sugieren la necesidad de aplicar técnicas de preprocesamiento para eliminar o mitigar estos artefactos y asegurar que las señales EEG sean adecuadas para un análisis más profundo y confiable.

## 4.3. Fase III: Preparación de los datos

En esta sección se describe el proceso de preparación de datos correspondiente a las señales de EEG obtenidas de los participantes durante el experimento. Dado que las señales de EEG suelen estar contaminadas por artefactos y ruidos externos, es fundamental realizar un preprocesamiento exhaustivo para garantizar la calidad de los datos antes de su análisis. Este preprocesamiento incluye la eliminación de artefactos provocados por movimientos oculares, interferencias eléctricas, y otros factores que pueden distorsionar las señales originales. Además, es crucial sincronizar las señales de EEG con los estímulos presentados a los participantes en tiempo real, lo que permite alinear las respuestas neuronales con los eventos específicos del experimento.

### 4.3.1. Preprocesamiento de señales EEG

El preprocesamiento de datos EEG es una fase esencial para mejorar la calidad de las señales antes de proceder con cualquier análisis. Dado que las señales EEG están sujetas a varios tipos de ruido y artefactos, es crucial aplicar técnicas específicas que permitan limpiar y preparar estas señales para su análisis.

#### 4.3.1.1 Filtrado de las señales

Uno de los primeros pasos en el preprocesamiento de las señales EEG es la aplicación de un filtro paso banda. Este filtro se configura con frecuencias de corte de 4 Hz en el extremo bajo y 50 Hz en el extremo alto. El propósito de este filtrado es eliminar componentes de frecuencia no deseados que podrían distorsionar la señal, como el ruido de baja frecuencia generado por movimientos oculares y el ruido de alta frecuencia proveniente de interferencias eléctricas. Filtrar las señales es importante porque permite enfocar el análisis únicamente en las frecuencias relevantes para la actividad cerebral, reduciendo el impacto de ruidos externos y mejorando la relación señal-ruido de los datos.

#### 4.3.1.2 Referencia Común Promedio (CAR)

Para mejorar aún más la calidad de las señales, se aplica una referencia común promedio (*Common Average Reference*, CAR). Esta técnica implica restar el promedio de todas las señales de cada canal individual, lo que ayuda a reducir el ruido común que podría estar presente en todos los canales EEG. La utilización de una referencia común promedio es beneficiosa porque equilibra las diferencias de amplitud entre los canales y minimiza los efectos de las señales compartidas no deseadas, proporcionando una representación más precisa de la actividad cerebral específica de cada canal.

### 4.3.1.3 Análisis de Componentes Independientes (ICA)

El siguiente paso crucial en el preprocesamiento es la aplicación del Análisis de Componentes Independientes (ICA), con un dropping component de 1. El término "dropping component" se refiere al proceso de eliminar el primer componente independiente identificado por el ICA, que suele estar asociado con un artefacto, como los movimientos oculares o los movimientos musculares. Estos componentes indeseados, si no se eliminan, pueden distorsionar la señal EEG real. El ICA es una técnica potente para identificar y separar componentes independientes de las señales EEG, algunos de los cuales pueden corresponder a estos artefactos. La aplicación de ICA, ajustada con un dropping component de 1, es esencial porque permite la eliminación selectiva de artefactos sin afectar la integridad de las señales cerebrales verdaderas, lo que mejora significativamente la calidad de los datos y la precisión de los análisis posteriores.

El preprocesamiento de las señales EEG mediante filtrado, referencia común promedio (CAR), y análisis de componentes independientes (ICA) es un paso crucial para asegurar que las señales resultantes sean de calidad y estén libres de artefactos. En la Figura 4.11 se presenta el estado de las señales después de aplicar este preprocesamiento, cabe destacar que en comparación con la Figura 4.10, en este caso solo se muestra desde el segundo 480 para mostrar con más claridad los datos. Como se puede observar, tras el término de los ajustes de electrodos, todas las señales están adecuadamente centradas en el eje X, lo que indica una correcta referencia común. Además, se ha eliminado cualquier salto repentino importante en la amplitud de las señales, lo que sugiere una limpieza efectiva de los artefactos.

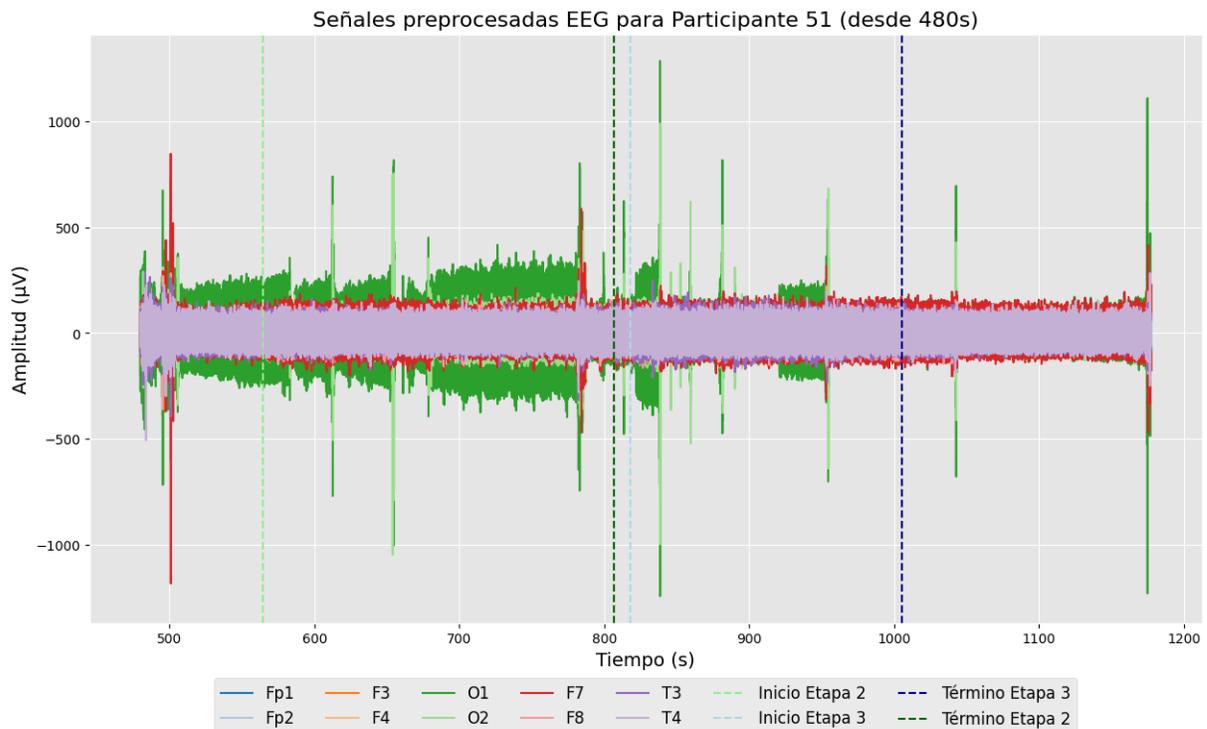


Figura 4.11: Señales EEG filtradas para una mujer de 51 años (grupo etario 3).

Fuente: Elaboración propia.

### 4.3.2. Sincronización Señal-Estímulo

Para la sincronización entre las señales de EEG y los estímulos visuales presentados, se utilizan las grabaciones de pantalla que documentan el instante exacto en que cada estímulo es mostrado a los participantes. Estas grabaciones son esenciales, ya que permiten ajustar con precisión los timestamps generados por el dispositivo de EEG, alineándolos con los momentos específicos en los que el estímulo son visualizados.

### 4.3.3. Extracción de características

En el proceso de extracción de características de las señales EEG, se empleó un enfoque basado en la transformación de las señales al dominio de la frecuencia mediante la Transformada de Fourier. Este enfoque permite descomponer las señales EEG en sus componentes frecuenciales, facilitando el análisis en diferentes bandas de frecuencia.

Antes de aplicar Transformada de Fourier, se llevó a cabo un paso crucial en el preprocesamiento: la segmentación de las señales EEG por estímulo. Después de haber filtrado y limpiado las señales de artefactos mediante técnicas como el Análisis de Componentes Independientes (ICA), se separaron las señales en ventanas de tiempo específicas correspondientes a los estímulos presentados. Para las páginas web, se extrajeron segmentos de 7 segundos, mientras que para las imágenes emocionales se utilizaron segmentos de 5 segundos. Esta segmentación es fundamental para asegurar que el análisis frecuencial se enfoque en las respuestas cerebrales directamente asociadas a cada tipo de estímulo.

Una vez segmentadas, se aplicó la Transformada de Fourier para convertir las señales en el dominio del tiempo a su representación en el dominio de la frecuencia. Esto permitió calcular características específicas en bandas de frecuencia bien definidas, como:

- **Theta (4-8 Hz):** Asociada con estados de somnolencia, meditación profunda y procesos de memoria.
- **Alpha (8-13 Hz):** Relacionada con la relajación, la disminución de la actividad mental y el estado de alerta pasivo.
- **Beta (13-30 Hz):** Conectada con la atención, la concentración activa y los procesos cognitivos complejos.
- **Gamma (30-50 Hz):** Vinculada con la percepción consciente, el procesamiento sensorial y la integración de información.

La extracción de características frecuenciales es una de las técnicas más comunes para analizar las señales EEG asociadas a las emociones, tal como se mostró en la 2.4. Además al utilizar este enfoque se facilita la comparación de señales de diferentes duraciones temporales, como en este caso los estímulos: páginas web e imágenes emocionales, que tienen duraciones variables.

## 4.4. Fase IV: Modelado

La Fase IV de esta metodología CRISP-DM adaptada para esta investigación, se centra en el modelado de las señales EEG obtenidas mientras los participantes observan estímulos emocionales etiquetados previamente por la investigación de EmoMadrid, descrito en la sección 2.3.3. El objetivo principal de esta fase es desarrollar un modelo predictivo capaz de alcanzar al menos un 80 % de precisión en la etiqueta del estímulo emocional presentado, a partir de la señal de EEG. Luego estos modelos entrenados se utilizarán para descubrir el estado emocional presentado por el participante en el momento de observar las páginas web presentadas en la etapa 2 del experimento.

Para lograr este objetivo, se emplearán redes neuronales como la metodología central del modelado, debido a su capacidad para aprender patrones complejos y no lineales, como las señales EEG.

Durante esta fase, se probarán y evaluarán diversos modelos de redes neuronales para determinar cuál puede alcanzar y superar el umbral del 80 % de precisión. Este proceso incluirá la exploración de diferentes arquitecturas de redes y la optimización de hiperparámetros.

Cabe destacar que en todos los modelos presentados, se creó un modelo para cada participante, como se hizo en la ??, y luego se agruparon los datos demográficamente.

### 4.4.1. Modelo 1: 1 capa oculta y Bandas de frecuencia

El Modelo 1 se basa en el modelo proporcionado por la investigación detallada en la Sección 2.4.2, pero con la simplificación de implementar una arquitectura de red neuronal con una sola capa oculta. Este enfoque básico permite que el modelo identifique patrones en los datos, aunque su capacidad para capturar relaciones complejas es limitada en comparación con arquitecturas más profundas. No obstante, este modelo tiene la ventaja de ser más rápido en el proceso de entrenamiento y menos propenso a sobreajuste.

Para este modelo, se adaptó el código original para trabajar con señales de 10 electrodos ubicados en las regiones frontal y temporal del cerebro. Los electrodos seleccionados fueron: FP1, FP2, F3, F4, F7, F8, C3, C4, T7 y T8, siguiendo el estándar internacional 10-20, como se ilustra en la Figura 4.1.

Después del preprocesamiento de las señales de EEG, descrito en la Sección 4.3, se calculó el vector de características que sirve como entrada al modelo de red neuronal. Para ello, se transformaron las señales temporales en el dominio de frecuencias mediante la transformada de Fourier, y se extrajo la media del espectro en cuatro bandas de frecuencia: Theta (4 - 7.5 Hz), Alpha (8 - 13 Hz), Beta (13 - 30 Hz) y Gamma (30 - 45 Hz). El vector de características se calcula según la ecuación 4.2:

$$Input = \sum_{i=1}^{10} \bar{\theta}_i + \bar{\alpha}_i + \bar{\beta}_i + \bar{\gamma}_i \quad (4.2)$$

donde  $i \in \{FP1, FP2, F3, F4, F7, F8, C3, C4, T7, T8\}$ , y  $\bar{\theta}_i, \bar{\alpha}_i, \bar{\beta}_i, \bar{\gamma}_i$  corresponden a la media de cada banda de frecuencia para cada electrodo.

Este vector se generó para cada estímulo emocional, y las etiquetas se ajustaron para simplificar el problema de clasificación. Las categorías emocionales se agruparon en dos clases: 'Negativo' (que combina 'Muy Negativo' y 'Negativo') y 'Positivo' (que combina 'Muy Positivo' y 'Positivo'). Esta simplificación permitió un enfoque más claro en la distinción entre emociones opuestas, facilitando la detección de diferencias en la actividad cerebral.

El proceso de optimización de hiperparámetros del MLPClassifier para este modelo se realizó utilizando un algoritmo genético. Se ajustaron tres hiperparámetros clave: el tamaño de la capa oculta (seleccionado entre 10 y 100 neuronas), la función de activación ('identity', 'logistic', 'tanh' o 'relu') y el algoritmo de optimización ('lbfgs', 'sgd' o 'adam'). Dado que solo hay una capa oculta, no se aplicó crossover, pero el proceso de mutación se mantuvo con una probabilidad baja.

El modelo fue entrenado independientemente para cada participante, utilizando la técnica de sobremuestreo SMOTE para abordar el desbalance de clases. Se utilizó el 80 % de los datos para el entrenamiento y el 20 % para las pruebas. Aunque este modelo es menos complejo, se esperaba que pudiera identificar patrones simples en los datos de EEG sin incurrir en un costo significativo de tiempo de entrenamiento o sobreajuste.

Los parámetros clave del Modelo 1 se resumen en la Tabla 4.6.

Capas ocultas	1
Neuronas por capa	Entre 10 y 100
Población	20
Probabilidad de cruce	0 %
Probabilidad de mutación	0,1 %
Funciones de activación	Identity, Logistic, Tanh y Relu
Solver	Lbfgs, Sgd y Adam

Tabla 4.6: Parámetros clave del Modelo 1.

Fuente: Elaboración propia.

El rendimiento del Modelo 1 se evaluó utilizando métricas estándar como exactitud, precisión, recall y puntaje F1. Los resultados acumulados para todos los participantes se muestran en la Tabla 4.7.

Exactitud	Precisión	Recall	Puntaje F1
75,8 %	77,2 %	74,7 %	76,8 %

Tabla 4.7: Métricas clave obtenidas del Modelo 1.

Fuente: Elaboración propia.

#### 4.4.2. Modelo 2: 2 capas ocultas y Bandas de frecuencia

El Modelo 2 se construye sobre la misma metodología básica del Modelo 1, pero con una diferencia crucial: este modelo emplea una arquitectura de red neuronal con dos capas ocultas. Al igual que el modelo original detallado en la Sección 2.4.2. Esta arquitectura más profunda tiene el potencial de capturar patrones más complejos en los datos de EEG, lo que podría mejorar la capacidad de generalización del modelo, aunque también aumenta el riesgo de sobreajuste y un mayor tiempo de entrenamiento.

Al igual que en el Modelo 1, se utilizaron señales de EEG de 10 electrodos ubicados en las regiones frontal y temporal del cerebro (FP1, FP2, F3, F4, F7, F8, C3, C4, T7 y T8). Estas señales se preprocesaron y luego se transformaron en el dominio de frecuencias utilizando la transformada de Fourier. Se extrajo la media del espectro en las bandas Theta, Alpha, Beta y Gamma para cada uno de los 10 electrodos. El cálculo del vector de características se realiza de acuerdo con la ecuación 4.3:

$$Input = \sum_{i=1}^{10} \bar{\theta}_i + \bar{\alpha}_i + \bar{\beta}_i + \bar{\gamma}_i \quad (4.3)$$

Al igual que en el Modelo 1, las etiquetas de las emociones se agruparon en dos clases: 'Negativo' y 'Positivo', eliminando la clase 'Neutro'. Esta simplificación permitió enfocar la clasificación en emociones opuestas.

El modelo fue entrenado independientemente para cada participante, y se utilizó la técnica SMOTE para abordar el desbalance de clases. Al igual que en el Modelo 1, el 80 % de los datos se destinó al entrenamiento y el 20 % a las pruebas.

La optimización de hiperparámetros del MLPClassifier en este modelo también se realizó mediante un algoritmo genético. En este caso, se ajustaron cuatro hiperparámetros clave: el tamaño de la primera y segunda capa oculta (seleccionadas entre 10 y 100 neuronas), la función de activación ('identity', 'logistic', 'tanh' o 'relu') y el algoritmo de optimización ('lbfgs', 'sgd' o 'adam'). A diferencia del Modelo 1, aquí sí se aplicó crossover para intercambiar partes de los cromosomas y generar descendientes, con una alta probabilidad de cruce (95 %). Además, se permitió la mutación de los cromosomas con una probabilidad baja (0,1 %).

El número máximo de generaciones para el algoritmo genético se fijó en 50 generaciones, y el tamaño de la población se estableció en 20 individuos por generación. Esto significa que en cada generación, 20 modelos con diferentes configuraciones de hiperparámetros se evaluaron y compitieron entre sí para determinar cuáles pasarían a la siguiente generación.

Los parámetros clave del Modelo 2 se resumen en la Tabla 4.8.

Capas ocultas	2
Neuronas por capa	Entre 10 y 100
Población	20
Probabilidad de cruce	95 %
Probabilidad de mutación	0,1 %
Funciones de activación	Identity, Logistic, Tanh y Relu
Solver	Lbfgs, Sgd y Adam

Tabla 4.8: Parámetros clave del Modelo 2.

Fuente: Elaboración propia.

Finalmente, el rendimiento del Modelo 2 se evaluó utilizando las mismas métricas estándar que en el Modelo 1: exactitud, precisión, recall y puntaje F1. Los resultados acumulados para todos los participantes se muestran en la Tabla 4.9.

Exactitud	Precisión	Recall	Puntaje F1
79,8 %	80,2 %	78,4 %	76,2 %

Tabla 4.9: Métricas clave obtenidas del Modelo 2.

Fuente: Elaboración propia.

#### 4.4.3. Modelo 3: 2 capas ocultas y Vector de frecuencias

En el tercer modelo se utilizó el mismo algoritmo genético que en el Modelo 2, pero con una diferencia clave en la representación del vector de características. Basado en la investigación de Aldayel y sus colaboradores [32], descrita en la Sección 2.4.1, se decidió emplear la señal espectral completa de los 10 electrodos en lugar de calcular las medias por bandas de frecuencia. Esto significa que, en lugar de extraer características específicas de las bandas Theta, Alpha, Beta y Gamma, se utilizó la transformación de Fourier de la señal de EEG para cada electrodo, obteniendo el espectro de frecuencias completo como entrada al modelo. El vector de características para este modelo puede observarse en la Ecuación 4.4.

$$Input = \sum_{i=1}^{10} S_i \quad (4.4)$$

donde  $S_i$  corresponde a la señal espectral del electrodo  $i$  en el periodo de tiempo en el cual se mostró el estímulo. Los electrodos utilizados fueron los mismos que en el Modelo 2:

FP1, FP2, F3, F4, F7, F8, C3, C4, T7 y T8, ubicados en las regiones frontal y temporal del cerebro según el estándar internacional 10-20. El objetivo de este enfoque fue capturar más información del espectro completo, lo que podría permitir al modelo detectar patrones más complejos en la actividad cerebral asociados a las emociones.

La arquitectura del modelo y los parámetros del algoritmo genético se mantuvieron iguales al Modelo 2 y se detallan en la Tabla 4.8, con una población de 20 individuos, una probabilidad de cruce del 95 %, y una probabilidad de mutación del 0,1 %. Además, se estableció un límite de 50 generaciones (Máximas generaciones) para la evolución del modelo.

Cada modelo fue entrenado de manera independiente para cada participante. El 80 % de los datos se destinó al entrenamiento y el 20 % restante para las pruebas, se utilizó SMOTE para balancear las clases en el conjunto de entrenamiento. Los modelos se evaluaron utilizando las métricas estándar de exactitud, precisión, recall y puntaje F1. Los resultados acumulados para todos los participantes utilizando la señal espectral completa se presentan en la Tabla 4.10.

Exactitud	Precisión	Recall	Puntaje F1
77,6 %	79,6 %	76,8 %	74 %

Tabla 4.10: Métricas clave obtenidas del Modelo 3

Fuente: Elaboración propia.

#### 4.4.4. Modelo seleccionado

Tras observar los 3 modelos descritos anteriormente se decidió utilizar el modelo con mejores métricas que en este caso corresponde al Modelo 2, luego a partir de la restricción impuesta anterior de buscar modelos mayores al 80 %. Tras aplicar la restricción de exactitud superior al 80 %, se seleccionaron los modelos que cumplen con esta restricción y se obtuvieron 46 modelos. Estos modelos se distribuyen de manera específica según el grupo etario y el sexo de los participantes, como se detalla en las Tablas 4.11 y 4.12, respectivamente.

Grupo etario	Cantidad	Cantidad de Hombres	Cantidad de Mujeres
1	10	5	5
2	11	6	5
3	13	5	8
4	12	7	5

Tabla 4.11: Modelos de participantes mayores a 80 % de precisión por grupo etario.

Fuente: Elaboración propia.

Sexo	Cantidad
Femenino	23
Masculino	23

Tabla 4.12: Modelos de participantes mayores a 80 % de precisión por sexo

Fuente: Elaboración propia.

Es posible observar que existe una representación equilibrada y relevante de las diferentes categorías demográficas, significativo en la fase siguiente del estudio.

Al predecir el estado emocional de los participantes mientras observan las páginas web considerando que 1 es estado emocional positivo y 0 estado emocional negativo, los resultados son los siguientes:

Hombres		Mujeres	
Media	STD	Media	STD
0,61	0,49	0,61	0,49

Tabla 4.13: Resultados emocionales de páginas web por sexo.

Fuente: Elaboración propia.

Grupo 1		Grupo 2		Grupo 3		Grupo 4	
Media	STD	Media	STD	Media	STD	Media	STD
0,65	0,48	0,53	0,5	0,67	0,49	0,59	0,5

Tabla 4.14: Resultados emocionales de páginas web por grupo etario.

Fuente: Elaboración propia.

Se observa que tanto hombres como mujeres presentan un estado emocional promedio de 0,61 al observar páginas web, lo que indica una percepción emocional similar entre ambos géneros. Al analizar los grupos etarios, se destaca que el Grupo 1 (el más joven) muestra una media emocional de 0,65, lo que sugiere una tendencia hacia un estado emocional más positivo. El Grupo 3 también presenta una media relativamente positiva de 0,67. En contraste, el Grupo 2 refleja una media más baja de 0,53, indicando una percepción emocional más neutral, mientras que el Grupo 4 (el de mayor edad) muestra una media de 0,59, lo que sugiere una ligera inclinación hacia lo positivo. La variabilidad en las respuestas emocionales es considerable en todos los grupos, como lo indica la desviación estándar cercana a 0,5 en cada caso.

Otra perspectiva para analizar los datos es identificar las páginas web que generaron las respuestas emocionales más extremas según las variables demográficas. Este enfoque permite

profundizar en cómo diferentes segmentos de la población, como sexo y grupo etario, responden emocionalmente al contenido web. En la Figura 4.12 se muestran las páginas web que produjeron emociones más positivas y más negativas, en ambos sexos.

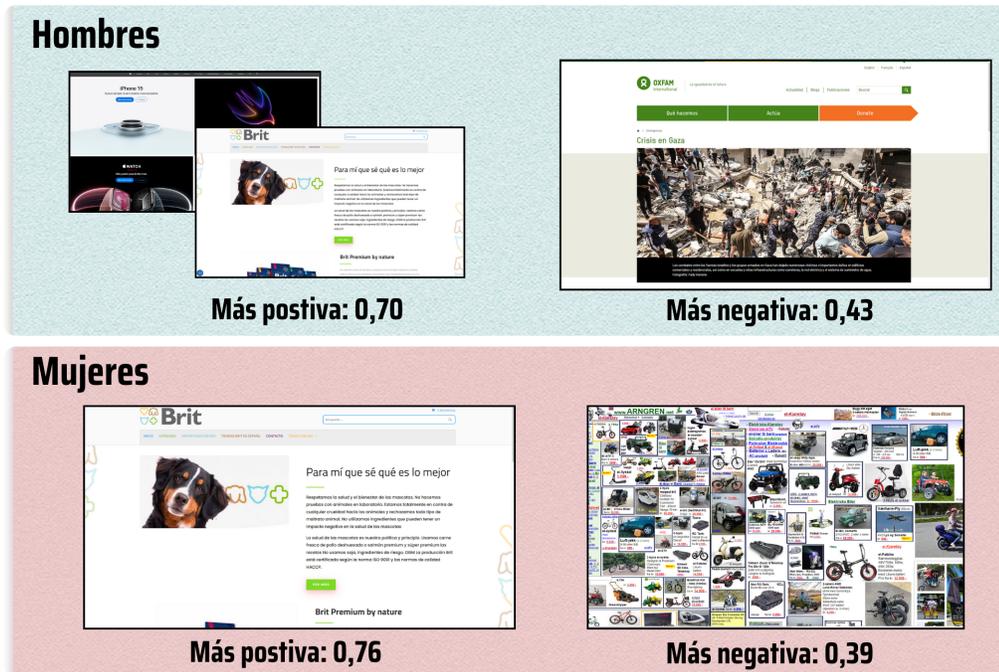


Figura 4.12: Páginas web que produjeron respuestas emocionales extremas por sexo.

Fuente: Elaboración propia.

Mientras que en la Figura 4.13 se muestran las páginas web que produjeron emociones más positivas y más negativas, para cada grupo etario.

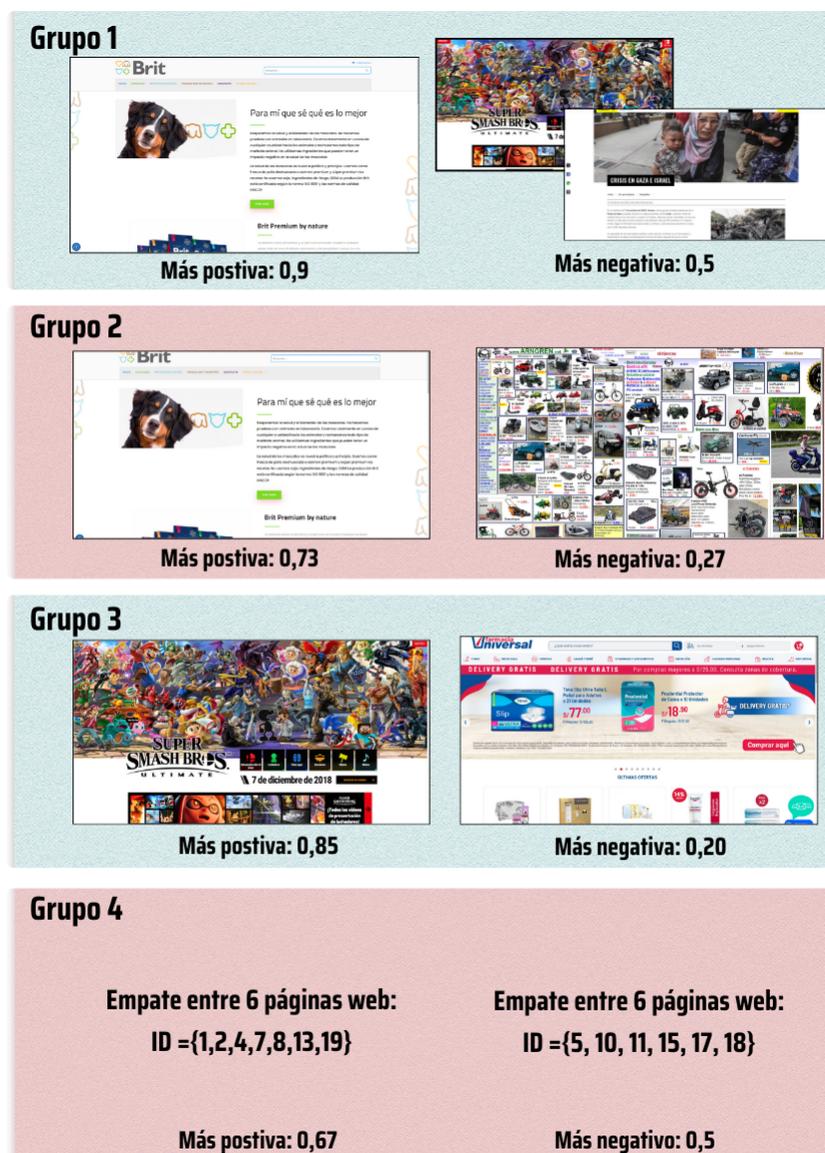


Figura 4.13: Páginas web que produjeron respuestas emocionales extremas por grupo etario.

Fuente: Elaboración propia.

A partir de los resultados, se observa que tanto hombres como mujeres experimentan su estado emocional más positivo al interactuar con el sitio web con ID = 5, que corresponde a una página sobre mascotas. En el caso de los hombres, este sitio empata con el sitio web ID = 18, que corresponde a la página de Apple. Por otro lado, los sitios web que generan un estado emocional más negativo son el ID = 17 para los hombres, relacionado con la guerra en Gaza, y el ID = 10 para las mujeres, que corresponde a una página web saturada de información.

En cuanto a los grupos etarios, siguen una tendencia similar. Los Grupos 1 y 2 experimentan su mayor estado emocional positivo con el sitio web ID = 5, relacionado con mascotas. Sin embargo, el Grupo 3 encuentra su mayor positividad en el sitio web ID = 8, que corresponde a una página de videojuegos. En términos de negatividad, el Grupo 1 considera el sitio web ID = 8 como el menos favorable, mientras que el Grupo 2 muestra una tendencia negativa

hacia el sitio web ID = 10, y el Grupo 3 encuentra el sitio web ID = 15, relacionado con una farmacia, como el menos agradable. En el caso del Grupo 4, no es posible identificar un sitio web específico como el más positivo o negativo, ya que se observan seis empates tanto para el sitio más positivo como para el más negativo.

#### **4.4.5. Estudio de la cantidad de colores por página web**

Para analizar la coloridad de las imágenes de páginas web, y verificar la hipótesis secundaria presentada en 4.1.3, se utilizó un método sencillo basado en el conteo de la cantidad de colores presentes en cada imagen. Este método cuenta la cantidad de colores únicos en cada imagen, con un límite máximo de colores establecido en  $256 \times 256 \times 256$  para cubrir la gama completa de colores posibles en una imagen RGB.

Este método proporciona una medida simple pero efectiva de la coloridad de las imágenes, basada en la cantidad de colores distintos que contienen. Los resultados permiten un análisis comparativo de la coloridad entre diferentes imágenes de páginas web, sin necesidad de aplicar algoritmos complejos para estimar la coloridad como lo hace Reinecke, y se explica en la sección 2.5.1.

La cantidad de colores de las páginas web presentadas se observan en la Tabla 4.15.

ID	Sitio web	Cantidad de Colores
1	www.nihaojewerly.com	202.743
2	www.gratia.com.ar	165.875
3	www.frankronay.com	174.839
4	www.tiendanimal.es	189.851
5	www.britcare.co	86.221
6	www.pharmacys.com.ec	240.013
7	www.habbo.es	13.207
8	www.smashbros.com	914.325
9	www.lingscars.com	289.879
10	www.arngren.com	342.094
11	www.elmundodedali.cl	100.168
12	www.amnesty.org	187.821
13	www.farma.uy	111.511
14	www.joyeriasbizarro.com	135.581
15	www.farmaciauniversal.com	174.183
16	www.farmacity.com	117.632
17	www.oxfam.org	209.127
18	www.apple.com	73.924
19	www.tiendalego.cl	162.574

Tabla 4.15: Páginas web seleccionadas con la cantidad de colores en cada sitio

Fuente: Elaboración propia

#### 4.4.6. Modelo de predicción del grupo etario del participante

Para explorar patrones específicos en las señales EEG que puedan estar relacionados con el grupo etario de los participantes, se desarrolló un modelo similar al Modelo 1. Este modelo empleó una red neuronal con una sola capa oculta. Además, se probaron dos modelos adicionales, análogos al Modelo 2 y al Modelo 3, que utilizaban 2 capas ocultas y vector de características simil a cada uno de los modelos. Sin embargo, estos modelos adicionales arrojaron resultados inferiores.

En este caso, la etiqueta asignada a cada observación corresponde al grupo etario al que pertenece participante, las cuales se muestran en la Tabla 4.2. Las señales EEG utilizadas en

este modelo corresponden específicamente a la etapa 3 del experimento, durante la cual los participantes observaban imágenes emocionales.

El procesamiento de las señales EEG siguió la misma metodología que el Modelo 1, extrayendo la media del espectro en las bandas de frecuencia Theta (4 - 7.5 Hz), Alpha (8 - 13 Hz), Beta (13 - 30 Hz) y Gamma (30 - 45 Hz), generando un vector de entrada de 40 valores por observación.

El rendimiento del modelo fue evaluado utilizando métricas estándar de clasificación: exactitud, precisión, recall y puntaje F1. Además, se aplicó el enfoque One-vs-Rest para evaluar cómo el modelo distinguía entre cada grupo etario individualmente frente a todos los demás grupos. Adicionalmente, se generaron matrices de confusión para visualizar la efectividad del modelo en la clasificación de los diferentes grupos etarios, proporcionando una visión clara de su capacidad para identificar patrones relacionados con la edad en las señales EEG.

Los resultados obtenidos a partir del modelo de predicción de grupo etario muestran un rendimiento variable en la identificación de patrones específicos en las señales EEG asociados con la edad de los participantes. En la Tabla 4.16 se presentan las métricas clave de rendimiento, incluyendo la exactitud, precisión, recall y puntaje F1 para cada clase.

Exactitud	Precisión	Recall	Puntaje F1
89,5 %	90,8 %	89,5 %	89,5 %

Tabla 4.16: Resultados modelo de predicción de grupo etario.

Fuente: Elaboración propia.

Adicionalmente, en la Tabla 4.17 se presenta la matriz de confusión correspondiente.

Clase Real	Clase Predicha			
	Grupo 1	Grupo 2	Grupo 3	Grupo 4
Grupo 1	4	0	0	0
Grupo 2	0	3	0	0
Grupo 3	0	1	7	0
Grupo 4	0	0	1	3

Tabla 4.17: Matriz de confusión para la clasificación de grupos etarios.

Fuente: Elaboración propia.

#### 4.4.7. Modelo de predicción del sexo del participante

Similar a la metodología utilizada en el modelo de predicción de grupo etario, se desarrolló un modelo similar para explorar la posibilidad de identificar patrones específicos en las señales EEG relacionados con el sexo de los participantes. Al igual que en los modelos anteriores, se utilizaron 10 electrodos y las señales EEG utilizadas corresponden específicamente a la etapa 3 del experimento, durante la cual los participantes observaban imágenes emocionales. En este caso, la etiqueta asignada a cada observación correspondía al sexo del participante.

El procesamiento de las señales EEG se realizó de manera análoga a los modelos previo, el rendimiento del modelo fue evaluado utilizando las mismas métricas estándar de clasificación: exactitud, precisión, recall y puntaje F1. Adicionalmente, se generó la matriz de confusión.

#### Resultados

Los resultados obtenidos del modelo de predicción de sexo se muestran, en la Tabla 4.18 donde se presentan las métricas clave de rendimiento, incluyendo la exactitud, precisión, recall y puntaje F1 para cada clase de sexo.

Exactitud	Precisión	Recall	Puntaje F1
84,6 %	60 %	100 %	75 %

Tabla 4.18: Resultados modelo de predicción de sexo.

Fuente: Elaboración propia.

Finalmente, se presenta en la Tabla 4.19 la matriz de confusión correspondiente, que ilustra la capacidad del modelo para clasificar correctamente las señales EEG según el sexo de los participantes.

Clase Real	Clase Predicha	
	Mujer	Hombre
Mujer	8	2
Hombre	0	3

Tabla 4.19: Matriz de confusión para la clasificación de sexo.

Fuente: Elaboración propia.

## 4.5. Fase IV: Despliegue

En esta fase de despliegue, se procederá a un análisis detallado de los resultados generados por los modelos de redes neuronales con el fin de poner a prueba las hipótesis planteadas. El objetivo principal es determinar si las diferencias observadas en los datos son estadísticamente significativas, utilizando una variedad de pruebas y técnicas de análisis. Esto incluirá la aplicación de test estadísticos adecuados para evaluar la robustez de los resultados y la consistencia de los patrones detectados.

Primero, se pondrá a prueba la hipótesis principal presentada en la sección 4.1.3: Es posible identificar diferencias demográficas significativas en las respuestas emocionales, clasificadas por un algoritmo de aprendizaje automático a partir de señales EEG, mientras los usuarios observan páginas web. Esta hipótesis se evaluará a partir de las dos variables demográficas consideradas en este estudio: el grupo etario y el sexo.

El análisis comenzará verificando si existen diferencias significativas en los estados emocionales entre los dos sexos. Posteriormente, se analizará si hay diferencias significativas en los estados emocionales entre los cuatro grupos etarios definidos. La comparación entre estas categorías demográficas permitirá determinar si las respuestas emocionales, clasificadas por el modelo de aprendizaje automático, varían de manera consistente en función del sexo o la edad de los participantes.

Además de la hipótesis principal, se pondrá a prueba una hipótesis secundaria: Las mujeres presentarán un estado emocional más positivo al visualizar páginas web que contienen más colores, en comparación con los hombres. Esta hipótesis plantea una relación específica entre la percepción emocional y el diseño visual de las páginas web, basada en diferencias de sexo.

Los resultados del modelo se entregan a través de un archivo Excel generado por el propio modelo, facilitando la revisión y el análisis de los datos obtenidos. Este archivo incluirá las clasificaciones de los estados emocionales y las correspondientes variables demográficas, proporcionando una base estructurada para realizar las comparaciones estadísticas necesarias.

### 4.5.1. Diferencias entre sexos

En esta sección, se realizó un análisis para determinar si existen diferencias significativas en las respuestas emocionales entre los sexos, pero en términos generales donde todas las páginas web están agrupadas. Utilizando los datos clasificados por un algoritmo de aprendizaje automático, se compararon las distribuciones de estados emocionales entre hombres y mujeres. Para evaluar la significancia de estas diferencias, se aplicó una prueba de chi-cuadrado ( $\chi^2$ ) de independencia.

La tabla de contingencia que se generó a partir de los datos clasificó a los participantes por sexo (hombre y mujer) y estado emocional (positivo o negativo). Los resultados de la prueba de chi-cuadrado fueron los siguientes:

- **Valor Chi-cuadrado ( $\chi^2$ ):** 0.019

- **Valor p:** 0.890
- **Grados de libertad (dof):** 1
- **Frecuencias esperadas:**
  - Hombres: [170.5 (positivo), 266.5 (negativo)]
  - Mujeres: [170.5 (positivo), 266.5 (negativo)]

La hipótesis nula ( $H_0$ ) de esta prueba establece que no existe una relación significativa entre el sexo de los participantes y sus respuestas emocionales. En otras palabras, se asume que el sexo no influye en la distribución de los estados emocionales clasificados por el modelo, y cualquier diferencia observada es atribuible al azar.

Con un valor p de 0.890, que es mucho mayor que el umbral de significancia habitual ( $\alpha = 0,05$ ), no se encontraron evidencias suficientes para rechazar la hipótesis nula. Esto sugiere que no hay diferencias estadísticamente significativas en las respuestas emocionales entre hombres y mujeres en este estudio.

En términos generales, un valor alto de chi-cuadrado indicaría una mayor discrepancia entre las frecuencias observadas y las esperadas bajo la hipótesis nula de independencia. Dado que el modelo tiene 1 grado de libertad, un valor de chi-cuadrado que indicaría una diferencia significativa sería cercano o superior a 3.841, que corresponde al valor crítico para un nivel de significancia  $\alpha = 0,05$ . Sin embargo, en este caso, el valor de  $\chi^2 = 0,019$  está muy por debajo de este umbral, lo que refuerza la conclusión de que no se encontraron diferencias significativas entre los sexos.

En resumen, aunque se observaron diferencias en las frecuencias emocionales entre los sexos, estas no resultaron ser lo suficientemente significativas como para concluir que el sexo influye de manera diferenciada en las respuestas emocionales de los participantes. Este resultado sugiere que, en este contexto, el sexo no es un factor determinante en la variabilidad de las emociones clasificadas por el modelo de aprendizaje automático.

#### 4.5.2. Diferencias entre grupos etarios

En esta sección, se realizó un análisis para determinar si existen diferencias significativas en las respuestas emocionales entre los diferentes grupos etarios. Cabe destacar que en esta sección se buscan diferencias entre los grupos etarios con todas las páginas web agrupadas, es decir, sin diferenciar por el contenido mostrado. Al observar las medias de respuestas en la Tabla 4.14, se puede notar que a medida que el grupo etario es mayor, menos positiva o más negativa es su respuesta emocional. Para comprobar ello, se realizaron distintos análisis estadísticos.

Primero, se aplicó una prueba chi-cuadrado ( $\chi^2$ ) de independencia, comparando las respuestas emocionales (positivas y negativas) entre los distintos grupos etarios. Los resultados de la prueba fueron los siguientes:

- **Valor Chi-cuadrado ( $\chi^2$ ):** 11.5724
- **Valor p:** 0.0090
- **Grados de libertad (dof):** 3
- **Frecuencias esperadas:**
  - Grupo Etario 1: [74.13 (positivo), 115.87 (negativo)]
  - Grupo Etario 2: [81.54 (positivo), 127.46 (negativo)]
  - Grupo Etario 3: [96.37 (positivo), 150.63 (negativo)]
  - Grupo Etario 4: [88.96 (positivo), 139.04 (negativo)]

El valor chi-cuadrado de 11.5724 es mayor que el valor crítico de 7.81, lo que indica una discrepancia notable entre las frecuencias observadas y esperadas, sugiriendo una asociación entre los grupos etarios y las respuestas emocionales. Además, el valor p es 0.0090, lo cual es significativamente menor que el nivel de significancia comúnmente utilizado ( $\alpha = 0,05$ ), lo que nos lleva a rechazar la hipótesis nula. Esto indica que existen diferencias estadísticamente significativas en las respuestas emocionales entre los diferentes grupos etarios.

Para explorar más a fondo las diferencias significativas entre los grupos etarios, se realizó un análisis post-hoc con comparaciones por pares entre los grupos, utilizando una corrección de Bonferroni para ajustar el nivel de significancia. A continuación se presentan los resultados:

- **Comparación Grupo Etario 1 vs. Grupo Etario 2:**
  - p-valor: 0.0840
  - Rechazar  $H_0$ : No
  - Interpretación: No hay una diferencia significativa en las respuestas emocionales entre los grupos etarios 1 y 2.
- **Comparación Grupo Etario 1 vs. Grupo Etario 3:**
  - p-valor: 1.0
  - Rechazar  $H_0$ : No
  - Interpretación: No hay una diferencia significativa en las respuestas emocionales entre los grupos etarios 1 y 3.
- **Comparación Grupo Etario 1 vs. Grupo Etario 4:**
  - p-valor: 1.0
  - Rechazar  $H_0$ : No
  - Interpretación: No hay una diferencia significativa en las respuestas emocionales entre los grupos etarios 1 y 4.
- **Comparación Grupo Etario 2 vs. Grupo Etario 3:**
  - p-valor: 0.0170

- Rechazar  $H_0$ : Sí
- Interpretación: Hay una diferencia significativa en las respuestas emocionales entre los grupos etarios 2 y 3.
- **Comparación Grupo Etario 2 vs. Grupo Etario 4:**
  - p-valor: 1.0
  - Rechazar  $H_0$ : No
  - Interpretación: No hay una diferencia significativa en las respuestas emocionales entre los grupos etarios 2 y 4.
- **Comparación Grupo Etario 3 vs. Grupo Etario 4:**
  - p-valor: 0.518
  - Rechazar  $H_0$ : No
  - Interpretación: No hay una diferencia significativa en las respuestas emocionales entre los grupos etarios 3 y 4.

El análisis post-hoc revela diferencias significativas en las respuestas emocionales entre los grupos etarios 2 y 3. No se encontraron diferencias significativas entre los otros pares de grupos etarios. Esto sugiere que la edad puede influir en la probabilidad de una respuesta emocional positiva o negativa, pero estas diferencias son más marcadas entre los grupos etarios 2 y 3.

### 4.5.3. Diferencias por sexo y cantidad de colores

Aunque no se encontraron diferencias significativas en las respuestas emocionales entre hombres y mujeres en el análisis inicial, se decidió investigar si existen diferencias al categorizar las respuestas emocionales según la cantidad de colores presentes en las páginas web. La hipótesis a probar es la siguiente: las mujeres presentarán un estado emocional más positivo al visualizar páginas web que contienen más colores en comparación con los hombres.

Esta hipótesis está fundamentada en los resultados de Reinecke [49], que evidencian diferencias en la percepción del atractivo visual y la coloridad entre los sexos, como se ilustra en la Figura 4.12. Según el estudio, las mujeres tienden a encontrar más atractivo visual en entornos con mayor coloridad en comparación con los hombres y viceversa.

Dado que la coloridad tiene como componente fundamental la cantidad de colores, se procedió a calcular la cantidad de colores en cada página web presentada en el experimento. A partir de estos datos, se graficó el atractivo visual en función de la cantidad de colores, diferenciando las respuestas entre hombres y mujeres. Los resultados se muestran en la Figura 4.14.

A partir de la Figura 4.14, se puede observar que las diferencias en el atractivo visual entre hombres y mujeres se manifiestan principalmente en los valores extremos de la cantidad de colores. Aproximadamente, en el rango de 0 a 80.000 colores, los hombres muestran un

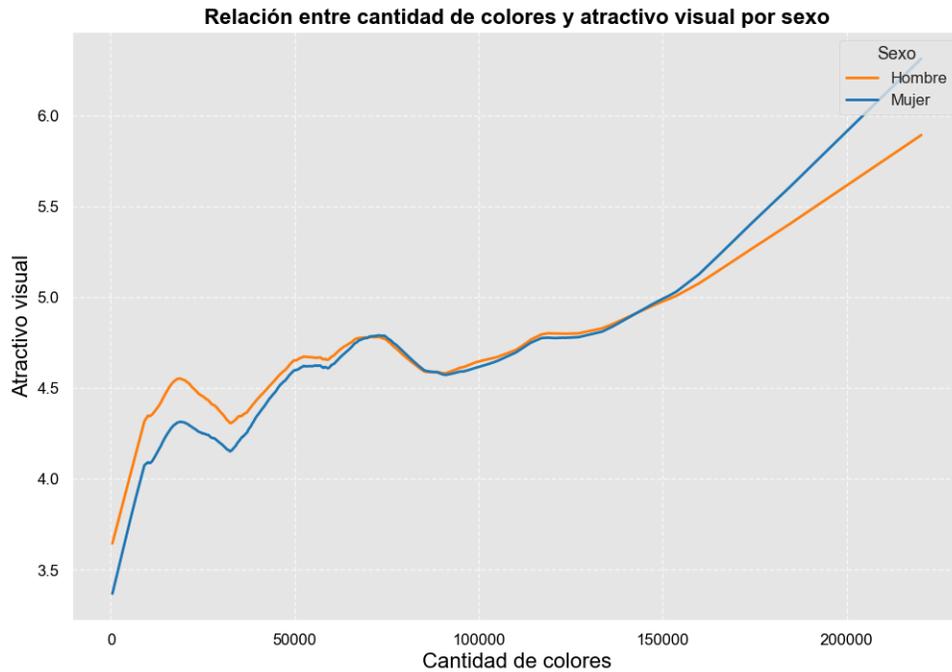


Figura 4.14: Atractivo visual versus cantidad de colores por sexo.

Fuente: Hecho a partir de los datos proporcionados en [49]

mayor atractivo visual promedio. En el intervalo de 80.000 a 160.000 colores, no se observan diferencias significativas entre ambos sexos. Sin embargo, cuando la cantidad de colores supera los 160,000, las mujeres tienden a mostrar un mayor atractivo visual promedio en comparación con los hombres.

A diferencia del análisis de atractivo visual frente a coloridad presentado en la Figura 4.12, donde las diferencias eran evidentes a lo largo de casi todo el rango de coloridad, excepto en el punto de intersección de las curvas. En ese análisis, las diferencias entre los sexos eran más consistentes, mientras que en el presente análisis, las diferencias emergen de manera más marcada solo en los valores extremos de la cantidad de colores.

Luego se grafican los resultados obtenidos sobre el estado emocional en función de la cantidad de colores, para compararlos con lo observado anteriormente. Es importante destacar que se ha eliminado los datos correspondientes a las páginas web de ID = 2, 8. Esto se debe a que la cantidad de colores en estas imágenes, alcanzó los 342.00 y 914.000 respectivamente, lo cual se aleja drásticamente de la media de las páginas web, tal como se muestra en la Figura 4.14 donde el máximo no alcanza los 300.000. El gráfico del estado emocional en función de la cantidad de colores se muestra en la Figura 4.15.

Es posible observar en esta Figura 4.15 que cuando la cantidad de colores es inferior a aproximadamente 170.000, el estado emocional de los hombres es mayor que el de las mujeres. Pero cuando la cantidad de colores supera los 170.000, las mujeres presentan un estado emocional mayor que el de los hombres. Los resultados obtenidos del estado emocional versus la cantidad de colores de una página web muestran un patrón similar al observado en la Figura 4.14, donde los hombres presentan un atractivo visual/estado emocional mayor

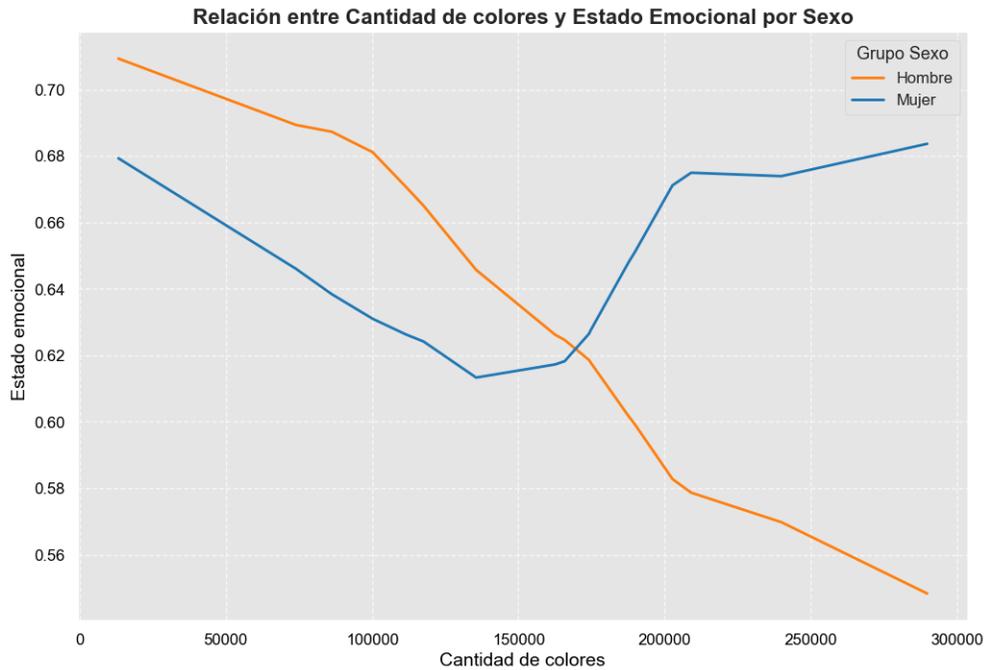


Figura 4.15: Estado emocional versus cantidad de colores por sexo.

Fuente: Elaboración propia

al observar páginas web con menos colores en comparación con las mujeres y las mujeres presentan un atractivo visual/estado emocional mayor al observar páginas web con más colores en comparación con los hombres. La diferencia se marca que en los resultados del estudio de Reinecke y sus colaboradores, existe una zona intermedia donde para hombres y para mujeres el atractivo visual es prácticamente el mismo.

#### 4.5.3.1 Análisis estadístico

A partir de la observación inicial de las curvas mostradas en la Figura 4.15, se decidió llevar a cabo un análisis estadístico con el fin de validar las diferencias apreciadas visualmente. Para este propósito, se establecieron dos rangos de interés: el primero comprendido entre 0 y 160.000 y el segundo entre 160.000 y 300.000. Estos rangos fueron seleccionados para evaluar de manera más precisa las diferencias entre las curvas correspondientes a cada grupo de sexo.

Luego se realizaron pruebas t de Student para evaluar si las diferencias observadas entre los grupos de sexo en cada rango eran estadísticamente significativas. Tras ejecutar el análisis, se obtuvieron los siguientes resultados:

- **Prueba estadística para el rango de 0 a 160.000:**

- Estadístico t: 31.7785
- Valor p: 0.0000
- **Conclusión:** Hay una diferencia estadísticamente significativa en este rango.

- **Prueba estadística para el rango de 160.000 a 300.000:**

- Estadístico t: -26.2752
- Valor p: 0.0000
- **Conclusión:** Hay una diferencia estadísticamente significativa en este rango.

Estos resultados confirman que las diferencias observadas visualmente entre los grupos de sexo en ambos rangos son significativas desde un punto de vista estadístico, lo que respalda la hipótesis inicial de que existe una variación importante en la cantidad de colores entre los grupos de sexo en relación con el estado emocional.

#### 4.5.4. Respuesta emocional por categoría de la página web

En esta sección, se realizará un análisis de las respuestas emocionales de los participantes, categorizando las páginas web en función de las distintas categorías temáticas a las que pertenecen: Saturada, Farmacia, Mascotas, Guerra y Grandes Marcas; tal como se detalla en la sección 4.1.1. El objetivo es identificar cómo las emociones de los participantes varían según el tipo de contenido al que están expuestos.

Además, este análisis se complementará con un estudio de las variables demográficas, evaluando cómo las respuestas emocionales se ven afectadas por factores como el grupo etario y el sexo de los participantes. De esta manera, se busca comprender mejor las interacciones entre el tipo de contenido, la demografía de los usuarios y sus respuestas emocionales, proporcionando una visión más completa de cómo diferentes audiencias reaccionan a diferentes tipos de páginas web.

Categoría	Todos	Hombres	Mujeres
Mascotas	0,62	0,64	0,61
Farmacia	0,60	0,61	0,60
Guerra	0,59	0,52	0,65
Grandes marcas	0,61	0,67	0,54
Saturada	0,59	0,61	0,57
Joyas	0,63	0,62	0,64
Todos	0,61	0,61	0,61

Tabla 4.20: Respuesta emocional promedio por categoría: Hombres y Mujeres

Fuente: Elaboración propia.

##### 4.5.4.1 Análisis por Sexo

- **Mascotas** y **Joyas** son las categorías que generan los estados emocionales más positivos para ambos géneros, con un promedio global de 0,62 y 0,63, respectivamente. Las

Categoría	Todos	Grupo 1	Grupo 2	Grupo 3	Grupo 4
Mascotas	0,62	0,67	0,55	0,69	0,58
Farmacia	0,60	0,70	0,57	0,60	0,56
Guerra	0,59	0,55	0,55	0,69	0,54
Grandes marcas	0,61	0,65	0,45	0,73	0,58
Saturada	0,59	0,60	0,48	0,67	0,58
Joyas	0,63	0,70	0,55	0,64	0,64
Todos	0,61	0,65	0,53	0,67	0,59

Tabla 4.21: Respuesta emocional promedio por categoría: Grupo 1, Grupo 2, Grupo 3 y Grupo 4

Fuente: Elaboración propia.

mujeres reaccionan de manera particularmente positiva a la categoría de joyas (0,64), mientras que los hombres encuentran la categoría de mascotas más positiva (0,64).

- **Farmacia** y **Saturada** son categorías que generan emociones más neutrales en general, con valores de 0,60 y 0,59 respectivamente, siendo consistentes entre hombres y mujeres.
- Una discrepancia significativa aparece en la categoría **Guerra**, donde las mujeres tienen una media emocional de 0,65, considerablemente más alta que la de los hombres (0,52). Esto sugiere una reacción emocional más fuerte y negativa en los hombres hacia este tipo de contenido.
- La categoría **Grandes marcas** produce una diferencia notable: mientras los hombres presentan un estado emocional positivo (0,67), las mujeres reaccionan de manera más neutral (0,54).

#### 4.5.4.2 Análisis por Grupo Etario

- **Mascotas** es la categoría más positiva para los Grupos 1 y 3, destacándose con valores de 0,67 y 0,69, respectivamente. Esto sugiere que los participantes más jóvenes y los de edad media responden mejor a este contenido.
- **Farmacia** tiene una fuerte aceptación en el Grupo 1 (0,70), pero disminuye en los grupos mayores, alcanzando un 0,56 en el Grupo 4.
- **Guerra** tiene respuestas emocionales variadas, con el Grupo 3 mostrando una media alta de 0,69, lo que contrasta con las respuestas más neutrales en los demás grupos.
- **Grandes marcas** es la categoría más apreciada por el Grupo 3, que presenta la media más alta de 0,73. Por otro lado, el Grupo 2 muestra la menor aceptación con una media de 0,45, lo que indica una percepción más negativa hacia este tipo de contenido en ese grupo etario.

- **Joyas** es consistentemente positiva para la mayoría de los grupos, con el Grupo 1 destacándose con un 0,70.

Al observar el promedio general de los estados emocionales por categoría, el orden de preferencia global es el siguiente:

1. **Joyas** (0,63)
2. **Mascotas** (0,62)
3. **Grandes marcas** (0,61)
4. **Farmacia** (0,60)
5. **Guerra** (0,59)
6. **Saturada** (0,59)

En resumen, las categorías de **Mascotas** y **Joyas** son generalmente bien recibidas en todos los grupos y sexos, mientras que las reacciones hacia **Guerra** y **Grandes marcas** varían significativamente entre sexos y grupos etarios. La variabilidad en las respuestas emocionales sugiere que las preferencias dependen en gran medida tanto del sexo como de la edad de los participantes.

#### 4.5.4.3 Análisis estadístico

Este análisis tiene como objetivo evaluar las diferencias emocionales observadas entre sexos y grupos etarios en función del contenido presentado en diferentes categorías de estímulo. Para ello, se ha realizado un análisis estadístico mediante la prueba de Chi-cuadrado, que permite comparar las frecuencias observadas en las respuestas emocionales entre los dos grupos de sexo y los cuatro grupos etarios. El análisis se centra en determinar si las diferencias observadas son estadísticamente significativas, lo que indicaría que las respuestas emocionales varían entre las variables demográficas en función del contenido del estímulo presentado.

Se han analizado las siete categorías de estímulo: Joyas, Saturada, Mascotas, Guerra, Farmacia, Grandes marcas y Videojuego. Los resultados del análisis Chi-cuadrado para cada una de estas categorías en función de la variable demográfica de sexo, se muestran en la Tabla 4.22.

Los resultados del análisis estadístico muestran que en ninguna de las categorías analizadas se observan diferencias estadísticamente significativas entre los grupos de sexo, dado que los valores p en todos los casos son superiores al umbral típico de significancia estadística ( $\alpha = 0,05$ ). Un valor p superior a 0,05 indica que no se puede rechazar la hipótesis nula, es decir, no hay evidencia suficiente para afirmar que las diferencias observadas en las respuestas emocionales entre los sexos son estadísticamente significativas.

En particular, los valores p para las categorías **Joyas**, **Farmacia** y **Videojuego** son 1, lo que sugiere que las frecuencias observadas en estas categorías son idénticas entre los grupos de sexo. En el caso de las categorías **Guerra** y **Grandes marcas**, aunque se observan valores

Categoría de estímulo	Valor $\chi^2$	Valor p
Joyas	0,0	1,0
Saturada	0,1196	0,7295
Mascotas	0,0309	0,8606
Guerra	1,1209	0,2897
Farmacia	0,0	1,0
Grandes marcas	1,1409	0,2855
Videojuego	0,0467	0,8290

Tabla 4.22: Diferencia entre sexos por categoría de estímulo

Fuente: Elaboración propia.

de  $\chi^2$  algo más elevados (1,1209 y 1,1409, respectivamente), los valores p asociados (0,2897 y 0,2855) siguen siendo muy superiores al umbral de 0,05, indicando que estas diferencias no son estadísticamente significativas.

El análisis de las diferencias emocionales entre los distintos grupos etarios, cuyos resultados pueden observarse en 6.3, en función de las categorías de estímulos presentados, revela lo siguiente:

- **Categoría: Joyas**

Las comparaciones entre los grupos etarios (1 vs 2, 1 vs 3, 1 vs 4, etc.) revelan valores de  $\chi^2$  bajos, con todos los valores p significativamente superiores a 0.05. El mayor valor de  $\chi^2$  (1,0) se observó en la comparación entre los grupos 1 y 2, pero el valor p correspondiente (0,32), lo que indica una ligera diferencia aunque esta diferencia no es significativa. Las respuestas emocionales entre los diferentes grupos etarios son consistentes. Los resultados se observan en la Tabla 6.1 del Anexo.

- **Categoría: Saturada**

Los resultados muestran una falta de diferencias significativas entre los grupos etarios. El valor más alto de  $\chi^2$  (1,74) se encuentra en la comparación entre los grupos 2 y 3, con un valor p de 0,19, que es superior al umbral de significancia del 0,05. Las respuestas emocionales entre los grupos etarios son consistentes en esta categoría. Los resultados se observan en la Tabla 6.2 del Anexo.

- **Categoría: Mascotas**

Los valores de  $\chi^2$  son relativamente bajos en todas las comparaciones. El valor p más bajo (0,29) sigue siendo mayor que 0,05, lo que refuerza la conclusión de que no hay diferencias significativas entre los grupos etarios. Los resultados se observan en la Tabla 6.3 del Anexo.

- **Categoría: Guerra**

Esta categoría muestra un patrón similar a las anteriores, con valores de  $\chi^2$  bajos

y valores p elevados. El valor más alto de  $\chi^2$  (0,65) se encuentra en la comparación entre los grupos 3 y 4, pero el valor p correspondiente (0,42) es demasiado alto para considerarse significativo. Los resultados se observan en la Tabla 6.4 del Anexo.

- **Categoría: Farmacia**

Aunque esta categoría muestra un valor  $\chi^2$  algo más alto (1,22) en la comparación entre los grupos 1 y 4, el valor p correspondiente (0,27) sigue siendo mayor que 0,05, indicando que las diferencias observadas no son significativas. Los resultados se observan en la Tabla 6.5 del Anexo.

- **Categoría: Grandes marcas**

Se observa un valor  $\chi^2$  de 2,73 en la comparación entre los grupos 2 y 3, el valor más alto en este análisis. Sin embargo, el valor p correspondiente (0,09) indica que, aunque cercana, la diferencia no alcanza el umbral de significancia del 5%. Los resultados se observan en la Tabla 6.6 del Anexo.

- **Categoría: Videojuego**

En esta categoría, los valores  $\chi^2$  son bajos en todas las comparaciones, con valores p que van desde , lo que sugiere una falta de diferencias significativas en las respuestas emocionales entre los grupos etarios. Los resultados se observan en la Tabla 6.7 del Anexo.

A través de este análisis, se concluye que no existen diferencias estadísticamente significativas en las respuestas emocionales entre los distintos grupos etarios ni en los distintos sexos para las categorías de estímulo presentadas.

## 4.6. Comparación entre respuesta emocional y respuesta consciente

En esta sección, se analizará la relación entre las respuestas emocionales inconscientes de los participantes, capturadas a través de señales EEG, y sus respuestas conscientes ante los mismos estímulos. Cabe recordad que durante el experimento, además de registrar las respuestas emocionales, se les preguntó a los participantes: "¿Cómo clasificarías el efecto que te produjo el sitio web anterior?", con opciones de respuesta que iban desde "muy negativo" hasta "muy positivo".

El objetivo de este análisis es comparar las respuestas emocionales inconscientes con las respuestas conscientes reportadas por los participantes, con el fin de identificar posibles concordancias o discrepancias entre ambas. Se evaluará si los resultados coinciden, y en caso contrario, se examinarán las diferencias para comprender en qué aspectos las respuestas emocionales inconscientes difieren de las conscientes.

El análisis se realizará en dos fases. Primero, se calcularán y compararán las respuestas promedio para cada categoría y variable demográfica. Luego, se aplicarán análisis estadísticos para evaluar la diferencia entre las respuestas emocionales y las conscientes.

### 4.6.1. Análisis de medias

Las respuestas promedio por categoría para la variable sexo y para la grupo etario, se observan en la Tabla 4.23 y en la Tabla 4.24 respectivamente.

Categoría	Todos	Hombres	Mujeres
Mascotas	3,30	3,19	3,41
Farmacia	3,15	3,15	3,15
Guerra	3,22	3,11	3,33
Grandes marcas	3,28	3,37	3,20
Saturada	3,16	3,10	3,22
Joyas	3,41	3,29	3,52

Tabla 4.23: Respuesta consciente promedio por categoría: Hombres y Mujeres

Fuente: Elaboración propia.

Si se comparan las preferencias conscientes e inconscientes, según las categorías de las páginas web mostradas los resultados son los siguientes:

1. **Joyas**: En ambas respuestas, **Joyas** ocupa la primera posición, lo que indica que tanto emocional (0,63) como conscientemente (3,41), es la categoría mejor valorada.

Categoría	Todos	Grupo 1	Grupo 2	Grupo 3	Grupo 4
Mascotas	3,30	3,30	3,18	3,26	3,44
Farmacia	3,15	3,13	2,84	3,35	3,25
Guerra	3,22	3,30	3,27	3,12	3,21
Grandes marcas	3,28	3,45	3,41	2,96	3,38
Saturada	3,16	3,03	3,09	3,26	3,22
Joyas	3,41	3,47	3,24	3,64	3,25

Tabla 4.24: Respuesta consciente promedio por categoría: Grupo 1, Grupo 2, Grupo 3 y Grupo 4

Fuente: Elaboración propia.

2. **Mascotas**: En la respuesta emocional, **Mascotas** ocupa el segundo lugar (0,62), y lo mismo ocurre en la respuesta consciente (3,30). Esto demuestra coherencia en ambas dimensiones.
3. **Grandes marcas**: Esta categoría se mantiene en tercera posición tanto en la respuesta emocional (0,61) como en la consciente (3,28), lo que sugiere que las percepciones emocionales y conscientes hacia las grandes marcas son consistentes.
4. **Guerra**: La diferencia más notable aparece aquí. **Guerra** ocupa el último lugar en la respuesta emocional (0,59), pero sube al cuarto lugar en la respuesta consciente (3,22). Esto sugiere que, aunque emocionalmente este contenido es percibido de manera negativa, conscientemente se le otorga una valoración más neutral.
5. **Saturada** y **Farmacia**: Ambas categorías se mantienen en posiciones similares en las dos respuestas. **Farmacia** es ligeramente mejor valorada emocionalmente (0,60), mientras que **Saturada** tiene una ligera ventaja en la respuesta consciente (3,16 vs. 3,15 para **Farmacia**).

En resumen, al comparar las respuestas emocionales inconscientes con las respuestas conscientes de los participantes ante los estímulos visuales de diferentes sitios web, se evidencia una coherencia general en la percepción hacia ciertas categorías. Las categorías de **Joyas**, **Mascotas** y **Grandes marcas** mostraron concordancia entre las respuestas emocionales y conscientes, lo que sugiere que, en estos casos, las emociones inconscientes están alineadas con las evaluaciones conscientes.

Sin embargo, la categoría de **Guerra** destaca por la discrepancia más significativa, donde la respuesta emocional negativa contrasta con una valoración más neutral en la respuesta consciente. Esto sugiere que los participantes pueden haber modulado conscientemente su percepción ante un estímulo emocionalmente negativo, posiblemente debido a factores contextuales o racionales que influyen en su autoevaluación.

Las categorías de **Saturada** y **Farmacia** muestran una ligera variabilidad entre ambas

respuestas, pero se mantienen en posiciones cercanas, lo que indica una relativa consistencia en cómo los participantes perciben estos estímulos tanto a nivel emocional como consciente.

En conjunto, estos resultados reflejan que, aunque existe una coherencia significativa entre las respuestas emocionales inconscientes y las conscientes en varias categorías, hay casos en los que las emociones y las evaluaciones conscientes no coinciden plenamente, revelando la complejidad de la experiencia perceptual y emocional de los participantes.

#### 4.6.2. Análisis estadístico

En esta sección, se abordará la comparación entre las respuestas emocionales inconscientes y las respuestas conscientes utilizando métodos estadísticos. Estos métodos nos permitirán evaluar la magnitud y significancia de las diferencias observadas en las dos dimensiones de respuesta, así como identificar patrones de concordancia o discrepancia entre las percepciones emocionales y conscientes de los participantes.

El análisis estadístico se centró en la evaluación de la relación entre las respuestas emocionales inconscientes y las respuestas conscientes por categoría utilizando correlaciones y pruebas de significancia estadística.

Para examinar la relación entre las respuestas emocionales y conscientes, se empleó la correlación de Spearman. Este método es adecuado para datos ordinales o cuando no se asume una distribución normal de los datos. La correlación de Spearman permite evaluar si existe una relación monótonica entre las dos variables, es decir, si los valores tienden a cambiar en la misma dirección, aunque no necesariamente de manera lineal.

Los resultados de la correlación de Spearman por categoría se presentan en la Tabla 4.25.

Categoría	Correlación Spearman	p-valor
Joyas	0,121035	0,157331
Saturada	-0,213956	0,011742
Mascotas	0,057473	0,503131
Guerra	-0,021397	0,839568
Farmacia	-0,132942	0,072017
Grandes marcas	0,091702	0,384638
Videojuego	-0,029577	0,779575

Tabla 4.25: Correlación de Spearman y p-valor por categoría

Fuente: Elaboración propia.

Los resultados indican lo siguiente:

- **Joyas, Mascotas y Grandes marcas** presentan correlaciones positivas débiles y no significativas ( $p > 0,05$ ), lo que sugiere una concordancia parcial pero no concluyente entre las respuestas emocionales y conscientes en estas categorías.
- **Saturada** muestra una correlación negativa moderada y significativa ( $p < 0,05$ ). Esto implica que hay una discrepancia entre las respuestas emocionales y conscientes en esta categoría, donde las respuestas conscientes tienden a ser más positivas mientras que las emocionales son más negativas.
- **Guerra y Videojuego** muestran correlaciones extremadamente bajas y no significativas, lo que sugiere una gran variabilidad en cómo los participantes responden emocional y conscientemente en estas categorías.
- **Farmacia** presenta una correlación negativa moderada cercana a la significancia estadística ( $p \approx 0,07$ ), lo que indica una posible tendencia hacia respuestas incongruentes entre las dimensiones emocional y consciente.

En conclusión, los resultados del análisis estadístico revelan una relación compleja entre las respuestas emocionales inconscientes y las respuestas conscientes de los participantes. Aunque algunas categorías, como **Joyas** y **Mascotas**, muestran una cierta alineación entre ambas dimensiones, otras categorías, como **Saturada** y **Farmacia**, destacan por una mayor discrepancia, indicando que las respuestas conscientes pueden no siempre reflejar fielmente las emociones inconscientes de los participantes.

La correlación de Spearman permitió identificar estas variaciones, resaltando que, si bien existe cierta coherencia en algunas categorías, las percepciones conscientes a menudo están influenciadas por factores adicionales que no se capturan en las respuestas emocionales inconscientes. Estas diferencias podrían deberse a influencias cognitivas, sociales o contextuales que afectan la autoevaluación consciente de los participantes.

#### 4.6.2.1 Conclusión

A partir del análisis de medias se puede observar una aparente coherencia en el orden de preferencias entre las categorías emocionales y conscientes, los resultados del análisis estadístico indican que no se puede concluir la existencia de correlaciones significativas entre ambas respuestas. Esto sugiere que, aunque las respuestas conscientes y emocionales pueden coincidir en algunas categorías, la relación entre ambas no es lo suficientemente fuerte como para ser estadísticamente significativa.

Este hallazgo resalta la importancia de considerar las respuestas emocionales inconscientes como una fuente de información valiosa y complementaria a las respuestas conscientes. Las respuestas conscientes, aunque útiles, están mediadas por factores cognitivos, racionales y sociales que pueden influir en cómo los participantes evalúan y reportan sus experiencias. Por otro lado, las respuestas emocionales inconscientes capturadas a través de EEG ofrecen una visión más directa de las reacciones automáticas y espontáneas de los individuos ante los estímulos, que no siempre son accesibles o fácilmente verbalizables.

El hecho de que no haya correlaciones significativas entre ambas dimensiones sugiere que las emociones inconscientes aportan una capa adicional de comprensión sobre las experiencias

de los participantes, que no se puede obtener únicamente preguntando por sus percepciones conscientes. Esto es particularmente relevante en situaciones donde las personas pueden no ser completamente conscientes de sus emociones o donde pueden ajustar sus respuestas conscientes para alinearlas con normas sociales o expectativas personales.

# Capítulo 5

## Conclusiones

El presente estudio tuvo como objetivo principal identificar diferencias demográficas significativas en las respuestas emocionales de usuarios chilenos ante la visualización de páginas web, utilizando señales de EEG y modelos predictivos basados en redes neuronales. Además, se planteó una hipótesis secundaria donde pone que las mujeres tienen una percepción más positiva hacia páginas web con una mayor cantidad de colores, en comparación con los hombres. A lo largo de las diferentes fases de la investigación, se recogieron datos relevantes que permitieron abordar estas preguntas de investigación de manera sistemática y rigurosa. se generaron diferentes modelos de redes neuronales y se selecciono el con mejores métricas.

### 5.1. Principales hallazgos

#### 5.1.1. Diferencias por sexo

En cuanto a las diferencias de respuesta emocional entre hombres y mujeres al interactuar con páginas web, los resultados del estudio indican que, en términos generales, no se encontraron diferencias significativas. Esto se refleja en que la media de las respuestas emocionales fue idéntica para ambos géneros, con un valor de 0,61, considerando todas las páginas web agrupadas. Este hallazgo sugiere que, a nivel global, la interacción con el contenido digital no está influenciada por el sexo del usuario en lo que respecta a las respuestas emocionales inconscientes captadas mediante EEG.

No obstante, cuando se analiza la hipótesis secundaria relacionada a las diferencias emocionales relacionadas con la cantidad de colores en las páginas web, se observa una tendencia interesante: las mujeres mostraron respuestas emocionales más positivas frente a páginas web con una mayor cantidad de colores. Por otro lado, su respuesta emocional fue más negativa en comparación con los hombres cuando las páginas web presentaban menos colores. Esta diferencia es significativa estadísticamente, en escenarios de bajo color (menos de 160,000 colores) y alto color (más de 160,000 colores), lo que resalta la importancia del diseño visual en la percepción emocional según el sexo del usuario. Este hallazgo abre la puerta a optimizar el contenido web de manera diferenciada según el sexo, especialmente en términos de diseño

visual y colorimetría, para mejorar la experiencia del usuario.

### **5.1.2. Diferencias por grupo etario**

Respecto a las diferencias por grupo etario, se identificaron patrones notables en las respuestas emocionales. Los participantes del Grupo 2 (adultos jóvenes) tienden a presentar estados emocionales más neutrales al interactuar con páginas web, en comparación con aquellos de mediana edad (Grupo 3), quienes mostraron respuestas emocionales más positivas en general. Este hallazgo es relevante para el diseño de experiencias digitales personalizadas, ya que sugiere que los usuarios de mediana edad son más receptivos emocionalmente al contenido web en comparación con los adultos jóvenes, quienes parecen mantener una actitud más neutral.

### **5.1.3. Análisis por categorías de páginas Web**

El análisis de las respuestas emocionales de los participantes, categorizando las páginas web en diferentes temáticas, reveló que las categorías de Mascotas y Joyas fueron las que generaron las emociones más positivas en todos los grupos y géneros, con promedios de 0,62 y 0,63, respectivamente. Por otro lado, las categorías de Guerra y Grandes Marcas mostraron variaciones significativas en las respuestas emocionales dependiendo del sexo y grupo etario.

Las mujeres reaccionaron de manera más positiva hacia la categoría Joyas (0,64), mientras que los hombres prefirieron Mascotas (0,64). Sin embargo, la categoría Guerra provocó una mayor reacción emocional negativa en los hombres (0,52) en comparación con las mujeres (0,65). En cuanto a las diferencias por edad, Mascotas fue particularmente positiva para los grupos más jóvenes (Grupo 1) y de mediana edad (Grupo 3), mientras que la categoría Farmacia fue bien recibida por los participantes más jóvenes, pero menos por los mayores (Grupo 4).

En general, las categorías de Mascotas y Joyas destacaron por generar las respuestas emocionales más positivas, mientras que Guerra y Grandes Marcas mostraron mayor variabilidad en las reacciones emocionales según el sexo y la edad de los participantes.

### **5.1.4. Relación entre Respuesta Emocional y Consciente**

Los principales resultados muestran una coherencia general entre las respuestas emocionales inconscientes capturadas a través de señales EEG y las respuestas conscientes reportadas por los participantes. Las categorías de Joyas, Mascotas y Grandes Marcas presentaron una fuerte concordancia entre ambas dimensiones, sugiriendo que en estos casos, las emociones inconscientes están alineadas con las evaluaciones conscientes de los participantes.

Sin embargo, se observó una discrepancia significativa en la categoría de Guerra. Aunque esta categoría generó respuestas emocionales negativas, conscientemente fue valorada

de manera más neutral. Esto sugiere que los participantes pueden haber racionalizado su experiencia, modulando conscientemente su percepción negativa inicial.

Las categorías de Saturada y Farmacia mostraron una ligera variabilidad entre las respuestas emocionales y conscientes, pero se mantuvieron en posiciones cercanas, indicando una consistencia relativa en la percepción de estos estímulos. En conjunto, los resultados reflejan la complejidad de la experiencia perceptual y emocional de los participantes, donde las emociones inconscientes no siempre coinciden plenamente con las evaluaciones conscientes.

## 5.2. Discusión

### 5.2.1. Modelo único vs Modelo personalizado

Existen dos enfoques principales para crear modelos de predicción a partir de señales EEG en investigaciones como esta: el modelo único y el modelo personalizado. El enfoque del modelo único consiste en desarrollar un solo modelo general para un grupo demográfico completo, lo que permite crear un sistema más simplificado y menos costoso en términos de tiempo y recursos. Al utilizar un conjunto de datos agrupado por características demográficas (como edad o género), se espera que el modelo capture patrones generalizados que representen a todo el grupo. La principal ventaja de este enfoque es su simplicidad, ya que requiere menos modelos individuales y facilita la implementación y el análisis de resultados a nivel poblacional. Sin embargo, su principal desventaja es que, al generalizar los patrones de señales EEG, puede no capturar las particularidades individuales de cada participante, lo que podría llevar a una menor precisión en la predicción de estímulos emocionales para casos específicos.

Por otro lado, el enfoque del modelo personalizado consiste en desarrollar un modelo único para cada individuo. Este enfoque permite adaptar el modelo a las características específicas de cada participante, lo que aumenta la posibilidad de captar patrones individuales en las señales EEG. La principal ventaja de este enfoque es que maximiza la precisión de los resultados a nivel individual, ya que el modelo está optimizado para las señales de cada persona. Sin embargo, esto implica un mayor esfuerzo computacional y una mayor complejidad al manejar múltiples modelos, uno por cada participante. Además, este enfoque puede ser más difícil de generalizar a grupos más grandes, ya que los resultados son específicos de cada individuo.

En este caso, se optó por el enfoque personalizado, creando un modelo para cada participante y luego agrupando los resultados demográficamente. Esta decisión se basó en el hecho de que el modelo personalizado obtiene mejores resultados en términos de precisión al captar las particularidades individuales de las señales EEG, lo que es crucial para alcanzar el objetivo de superar el umbral del 80% de precisión en la clasificación de los estímulos emocionales. Si bien es posible obtener resultados sobreajustados considerando las 19 muestras que el modelo tiene para entrenar por sujeto, los resultados entregan predicciones bastante ajustadas a la respuesta consciente de los participantes. Esto sugiere que el modelo no está tan desbalanceado, proporcionando resultados que se alinean con las respuestas emocionales esperadas, lo que refuerza la validez del enfoque personalizado.

### 5.2.2. Puesta a prueba de hipótesis

En relación con la hipótesis principal, que propone que es posible identificar diferencias demográficas significativas en las respuestas emocionales de los usuarios chilenos mientras observan páginas web, utilizando señales de EEG y clasificadas por un algoritmo de aprendizaje automático, los resultados obtenidos en este estudio proporcionan evidencia mixta. Si bien se lograron identificar patrones específicos de respuesta emocional en función del grupo etario de los participantes, las diferencias por sexo no fueron significativas en términos globales. Esto sugiere que las respuestas emocionales inconscientes no varían de manera considerable entre hombres y mujeres en un sentido amplio, aunque las diferencias en función del grupo etario sí resultaron relevantes. Por lo tanto, la hipótesis principal se acepta parcialmente, ya que las diferencias demográficas se identificaron de manera efectiva en ciertos subgrupos, pero no de forma consistente en todas las categorías demográficas analizadas.

Además, al analizar las respuestas emocionales segmentadas por categoría de página web, tampoco se encontraron diferencias demográficas significativas entre los distintos grupos. Aunque hubo variaciones en las respuestas emocionales generales según la temática de las páginas web, como se observó en las categorías de Guerra y Grandes Marcas, para la variable demográfica sexo, no se identificaron diferencias estadísticamente significativas. Esto indica que, independientemente del sexo o la edad, las respuestas emocionales dentro de una misma categoría de página web no mostraron variaciones significativas a nivel demográfico.

Respecto a la hipótesis secundaria, que sostiene que las mujeres presentarán un estado emocional más positivo al visualizar páginas web que contienen más colores en comparación con los hombres, los resultados confirman esta afirmación. Se encontraron diferencias significativas en las respuestas emocionales de las mujeres y los hombres cuando las páginas web presentaban variaciones en la cantidad de colores. Específicamente, las mujeres mostraron respuestas emocionales más positivas en páginas web con una mayor cantidad de colores, mientras que en aquellas con menos colores, sus respuestas fueron más negativas en comparación con los hombres. Este hallazgo respalda la hipótesis secundaria, ya que confirma que el uso de colores en el diseño de las páginas web influye de manera diferente en la percepción emocional de hombres y mujeres.

En conclusión, la hipótesis principal fue parcialmente confirmada, mientras que la hipótesis secundaria fue aceptada en su totalidad, lo que refuerza la relevancia del diseño visual en la interacción emocional de los usuarios, particularmente en función del sexo.

### 5.2.3. Generalización de los resultados

Es complicado generalizar los resultados para toda la población chilena debido a que, si bien el número de personas que participó en el experimento es relativamente alto (85), no alcanza a ser representativo de la sociedad chilena en su conjunto, y menos aún cuando los resultados analizados se obtuvieron de un subconjunto de 46 personas. Aunque este estudio ofrece un enfoque inicial valioso, su aplicabilidad y certeza respecto a los resultados obtenidos sigue siendo limitada.

## 5.2.4. Metodología Neuromarketing vs Marketing tradicional

Los resultados obtenidos en este estudio revelan tanto coherencias como discrepancias entre las respuestas emocionales inconscientes capturadas a través de EEG y las respuestas conscientes reportadas por los participantes al observar diferentes páginas web. La coherencia entre ambas dimensiones en categorías como *Joyas*, *Mascotas* y *Grandes marcas* sugiere que, en estos casos, las emociones inconscientes y las evaluaciones conscientes están alineadas, proporcionando una visión coherente de la percepción de los participantes.

Sin embargo, se encontraron discrepancias notables en categorías como *Guerra*, donde las respuestas emocionales fueron más negativas que las conscientes. Esta diferencia puede explicarse por factores sociales o racionales que influyen en las respuestas conscientes, como la tendencia de los participantes a moderar sus percepciones para alinearlas con expectativas o normas sociales, lo que no ocurre en las respuestas emocionales automáticas capturadas por el EEG. Este hallazgo resalta la importancia de utilizar herramientas como el EEG para obtener información más precisa sobre las respuestas emocionales inmediatas de los consumidores, especialmente cuando sus respuestas conscientes pueden estar influenciadas por factores externos.

### 5.4.2.1 Ventajas del uso de EEG en Neuromarketing

- **Captura de respuestas inconscientes:** El EEG ofrece una ventaja significativa al permitir la medición directa de reacciones emocionales inconscientes que los participantes no siempre pueden verbalizar o incluso reconocer conscientemente. Esto es particularmente útil en un entorno como el estudio de la percepción de sitios web, donde las respuestas emocionales inmediatas pueden influir en la experiencia de los usuarios sin que estos sean plenamente conscientes de ello.
- **Datos objetivos:** A diferencia de los métodos tradicionales, el EEG proporciona una visión más precisa y menos mediada por factores externos, como el sesgo cognitivo o las normas sociales.

### 5.4.2.2 Desventajas del uso de EEG en Neuromarketing

- **Interpretación compleja:** Si bien el EEG ofrece datos valiosos, la interpretación de los patrones de actividad cerebral puede ser compleja y no siempre ofrece una correlación clara y directa con las emociones o las percepciones conscientes. La necesidad de expertos en neurociencia y la falta de correlación exacta entre ciertos patrones de EEG y emociones específicas pueden limitar la aplicabilidad de estos resultados en un contexto de marketing más amplio.
- **Costos y logística:** El uso de EEG requiere equipo especializado y puede ser costoso y logísticamente más complicado de implementar en estudios grandes o en entornos no controlados.

### 5.4.2.3 Ventajas del Marketing Tradicional

- **Facilidad de implementación:** Métodos tradicionales como encuestas o entrevistas son más simples de ejecutar y mucho menos costosos. Permiten obtener una gran cantidad de datos sobre las percepciones conscientes de los participantes de manera rápida y eficiente, lo que los hace accesibles para la mayoría de los estudios de mercado.
- **Interpretación directa:** Las respuestas conscientes son generalmente más fáciles de interpretar, ya que los participantes expresan directamente sus opiniones y sentimientos en lugar de depender de análisis complejos de datos fisiológicos.

#### 5.4.2.4 Desventajas del Marketing Tradicional

- **Sesgos conscientes:** Las respuestas conscientes están sujetas a sesgos cognitivos y sociales, lo que puede llevar a una representación inexacta de las verdaderas percepciones y emociones de los participantes. Esto es especialmente relevante cuando los participantes ajustan sus respuestas para cumplir con las expectativas o normas sociales.
- **Limitación en la captura de emociones inconscientes:** El marketing tradicional no capta las emociones y reacciones automáticas, que a menudo son clave en la toma de decisiones de los consumidores. Esto puede resultar en una comprensión parcial de la experiencia emocional de los participantes.

Los hallazgos sugieren que el uso de herramientas como el EEG en neuromarketing complementa las metodologías tradicionales al proporcionar una capa adicional de comprensión sobre las respuestas emocionales de los participantes. Aunque las respuestas conscientes pueden ser útiles para obtener una evaluación general de las percepciones, las respuestas inconscientes capturadas mediante el EEG ofrecen una visión más directa y auténtica de las reacciones emocionales.

En conclusión, si bien el neuromarketing basado en EEG ofrece una ventaja en la captura de reacciones emocionales inconscientes, su integración con metodologías tradicionales puede proporcionar un enfoque más completo y equilibrado en la evaluación de la experiencia del consumidor. Este estudio demuestra que, para entender de manera más holística las percepciones de los usuarios, es crucial combinar ambas metodologías.

### 5.3. Implicaciones y aplicaciones prácticas

Los resultados de este estudio ofrecen valiosas implicaciones para el diseño y personalización de experiencias digitales, revelando que factores demográficos, como el sexo y el grupo etario, juegan un papel relevante en las respuestas emocionales de los usuarios. Estos hallazgos pueden guiar a desarrolladores, diseñadores y especialistas en marketing en la creación de contenido web más eficaz y emocionalmente resonante para distintos segmentos de la población.

### **5.3.1. Aplicabilidad a empresas chilenas**

Para que los hallazgos de este estudio pudieran aplicarse de forma confiable en una página web de una empresa chilena, sería necesario considerar varias mejoras metodológicas. Primero, se recomienda ampliar significativamente el tamaño de la muestra de participantes, con una distribución que contemple diversas variables demográficas tales como edad, sexo, estado civil y nivel educacional. Esta ampliación permitiría captar con mayor precisión las reacciones emocionales y cognitivas de una muestra que represente de mejor manera la diversidad de la sociedad chilena, lo cual aumentaría la generalizabilidad de los resultados.

Además, sería fundamental incrementar el número de electrodos en el equipo EEG utilizado. Una mayor cantidad de electrodos posibilitaría una captación más detallada de la actividad cerebral, brindando datos más ricos y precisos sobre las respuestas neurológicas a los estímulos. Esto permitiría detectar patrones específicos en diferentes áreas del cerebro, lo que podría proporcionar información adicional sobre la percepción y el procesamiento de los estímulos presentados en la página web.

Otro aspecto a optimizar es la duración de la exposición tanto a los estímulos como a las páginas web en el experimento. Dado que la interacción web suele ser una experiencia prolongada e interactiva, aumentar el tiempo de exposición permitiría observar cambios y reacciones en escenarios más reales y dinámicos. La naturaleza en movimiento de los contenidos web – como videos, animaciones y desplazamientos – también puede tener un impacto en la actividad cerebral, y su consideración es crucial para obtener resultados que reflejen mejor el contexto real de uso en una página web.

### **5.3.2. Optimización del diseño web basada en demografía**

Al identificar que ciertos grupos etarios, como los adultos jóvenes (Grupo 2) y los de mediana edad (Grupo 3), muestran respuestas emocionales divergentes al interactuar con contenido digital, surge la oportunidad de diseñar páginas web que se adapten mejor a las preferencias emocionales de cada grupo. Por ejemplo, para los usuarios de mediana edad, quienes demostraron una mayor respuesta emocional positiva en comparación con los adultos jóvenes, los diseñadores podrían enfatizar elementos visuales más atractivos y experiencias interactivas más ricas para captar su atención y mejorar la retención.

Del mismo modo, los hallazgos sobre las diferencias emocionales entre hombres y mujeres frente al uso de colores en el diseño web pueden ser aplicados para crear contenido visualmente más atractivo y efectivo para cada sexo. Este enfoque diferenciado podría ser especialmente útil en sectores donde la experiencia de usuario es clave, como el comercio electrónico o las plataformas de entretenimiento.

### **5.3.3. Integración de tecnología EEG en el diseño de experiencias de usuario**

El uso de señales EEG como herramienta para capturar respuestas emocionales inconscientes abre un nuevo horizonte para la investigación y desarrollo de experiencias de usuario personalizadas. La capacidad de medir directamente las reacciones emocionales de los usuarios proporciona una ventaja significativa sobre los métodos tradicionales, como las encuestas o grupos focales, que a menudo dependen de la autoevaluación consciente. Las empresas podrían implementar esta tecnología para obtener una comprensión más profunda de cómo el contenido visual y la estructura del sitio web afectan a sus usuarios a nivel emocional. Esto permitiría realizar ajustes precisos y basados en datos objetivos, mejorando así la experiencia del usuario de manera continua.

### **5.3.4. Diseño centrado en la experiencia emocional**

Además, los hallazgos sobre la discrepancia entre las respuestas emocionales inconscientes y las evaluaciones conscientes resaltan la importancia de adoptar un enfoque holístico en la investigación de la experiencia del usuario. Si bien las evaluaciones conscientes proporcionan una visión racionalizada de la percepción del usuario, las respuestas emocionales inconscientes pueden revelar patrones más profundos e intuitivos de interacción que las encuestas tradicionales podrían pasar por alto. Este doble enfoque puede ser particularmente valioso en contextos donde las decisiones emocionales son clave, como el diseño de interfaces de usuario para productos de consumo o servicios de entretenimiento.

Por ejemplo, la categoría de páginas web relacionadas con la Guerra generó respuestas emocionales inconscientes negativas en los participantes, pero fue evaluada de manera más neutral conscientemente. Esto sugiere que los usuarios pueden racionalizar su experiencia al interactuar con contenido emocionalmente intenso. Comprender esta divergencia entre lo emocional y lo consciente permite a los diseñadores crear experiencias más alineadas con las verdaderas reacciones de los usuarios, ofreciendo contenido que resuene tanto emocional como racionalmente.

### **5.3.5. Personalización basada en categorías de contenido**

Finalmente, los insights obtenidos del análisis por categorías de páginas web subrayan la importancia de adaptar el contenido a las preferencias emocionales de los usuarios según la temática. Por ejemplo, las páginas de Mascotas y Joya, que provocaron las respuestas emocionales más positivas, pueden ser optimizadas para maximizar este efecto en los usuarios que ya muestran predisposición positiva hacia estos temas. Asimismo, las categorías como Guerra y Grandes Marcas, que generaron respuestas emocionales más polarizadas, pueden ser rediseñadas para reducir el impacto emocional negativo y mejorar la percepción general del contenido.

En conjunto, estos hallazgos subrayan la importancia de considerar tanto las diferencias

demográficas como las respuestas emocionales inconscientes y conscientes en el diseño de experiencias digitales. Integrar estas dimensiones en la creación de contenido puede llevar a experiencias de usuario más satisfactorias, emocionalmente resonantes y efectivas en la consecución de los objetivos de negocio.

### 5.3.6. Implicaciones éticas y legales

El uso de señales EEG para la personalización de experiencias digitales plantea importantes consideraciones éticas y legales que deben ser cuidadosamente abordadas. En primer lugar, la privacidad de los datos de los usuarios es un aspecto crítico. Las señales EEG contienen información altamente sensible sobre el estado emocional y la actividad cerebral de las personas, lo cual requiere estrictos protocolos de recolección, almacenamiento y procesamiento de datos para evitar vulneraciones a la privacidad.

Además, el consentimiento informado es esencial en la implementación de estas tecnologías. Los usuarios deben ser plenamente conscientes de cómo se recolectarán sus datos, con qué propósito se utilizarán, y qué implicaciones tiene el uso de esta información. La transparencia en el uso de datos y el respeto a los derechos de los usuarios son pilares fundamentales para garantizar un enfoque ético.

Desde el punto de vista legal, existen normativas como el Reglamento General de Protección de Datos (GDPR) en Europa, que regulan la recolección y tratamiento de datos personales. Las empresas que deseen implementar tecnologías basadas en EEG deben asegurarse de cumplir con estas normativas y otras regulaciones locales, con el fin de evitar sanciones y, lo más importante, proteger a los usuarios.

También se debe tener en cuenta el posible impacto psicológico en los usuarios al saber que sus respuestas emocionales inconscientes están siendo monitoreadas y analizadas. Esto podría generar preocupación o incomodidad, lo cual debe ser mitigado mediante una comunicación clara y medidas que garanticen el bienestar del usuario.

La implementación comercial de la metodología basada en señales EEG puede verse considerablemente afectada por las implicaciones éticas y legales asociadas. Si bien esta herramienta tiene un gran potencial para personalizar y mejorar la experiencia del usuario, el manejo de datos personales extremadamente sensibles como los patrones de actividad cerebral exige un cumplimiento riguroso de normativas de privacidad, como el GDPR. La falta de garantías adecuadas sobre el manejo ético de los datos podría no solo conllevar sanciones legales, sino también erosionar la confianza del consumidor, limitando así la adopción de esta tecnología a nivel comercial. Para que la herramienta desarrollada sea viable en el mercado, es esencial que las empresas adopten medidas proactivas para asegurar el consentimiento informado, la protección de los datos y la transparencia en el uso de la información, de tal forma que puedan ganar la confianza de los usuarios y evitar riesgos legales que impacten su reputación y sostenibilidad.

En resumen, aunque la integración de señales EEG ofrece grandes oportunidades para mejorar la personalización y la efectividad de las experiencias digitales, es imperativo considerar las implicaciones éticas y legales de su uso. La protección de la privacidad, la obtención

del consentimiento informado, el cumplimiento normativo y la transparencia son aspectos esenciales para una implementación responsable de estas tecnologías.

## 5.4. Recomendaciones para futuras investigaciones

Este estudio abre múltiples líneas de investigación que pueden expandir la comprensión sobre las respuestas emocionales de los usuarios frente a la interacción con páginas web. En futuras investigaciones, se recomienda integrar otras herramientas de reconocimiento emocional que fueron utilizadas durante el experimento pero no fueron analizadas en profundidad en este estudio. Entre estas herramientas se incluyen el reconocimiento de emociones a través de una cámara, el *eye tracking* y la respuesta galvánica de la piel (*GSR*). La combinación de estos métodos con las señales EEG podría proporcionar una visión más completa de la experiencia emocional del usuario, al capturar tanto las respuestas emocionales inconscientes como las conscientes.

Además, para ampliar el espectro de análisis y mejorar la generalización de los modelos, se sugiere aumentar la cantidad de páginas web presentadas a los participantes, lo que permitiría incluir más categorías y una mayor variedad de colores. Esto ayudaría a explorar con mayor profundidad cómo las diferentes combinaciones de colores afectan las respuestas emocionales, y cómo estas respuestas varían según diferentes grupos demográficos.

Otra recomendación es incorporar más imágenes neutrales durante la etapa de evocación de emociones, lo que permitiría añadir una tercera categoría (etiqueta) en el reconocimiento emocional del modelo. Un conjunto equilibrado de 16 imágenes negativas, 16 positivas y 16 neutrales sería adecuado para entrenar el modelo, mejorando así su capacidad para discriminar entre diferentes estados emocionales.

Adicionalmente, se recomienda considerar dos enfoques complementarios para analizar los datos en estudios futuros. Por un lado, sería valioso construir modelos de análisis separados para cada grupo demográfico, como sexo o grupo etario, con el objetivo de identificar patrones específicos en cada subgrupo. Por otro lado, también se sugiere desarrollar un modelo general para todas las personas, que podría ofrecer una perspectiva global del comportamiento emocional frente a los estímulos presentados. La comparación entre estos enfoques y el utilizado podría ser útil para entender el comportamiento de los modelos, o si existen patrones universales que aplican a toda la población estudiada.

Por otra parte, considerando la diversidad física de los participantes, sería beneficioso utilizar un modelo de EEG que permita imprimir cascos en diferentes tallas (por ejemplo, S y L) mediante una impresora 3D. Esto optimizaría la comodidad y la rápida instalación de los cascos, adaptándolos mejor a los distintos tamaños de cráneo de los usuarios, lo que podría mejorar la calidad de los datos recogidos.

Además, se sugiere aumentar el número de canales de EEG a 16, según lo permite el modelo utilizado, para obtener más información sobre la actividad cerebral y mejorar la precisión de los modelos predictivos basados en redes neuronales.

Finalmente, sería útil incorporar otras variables demográficas en el análisis, como el nivel educacional y el estado civil, para explorar su influencia en las respuestas emocionales y obtener un panorama más completo de cómo diferentes factores demográficos afectan la interacción de los usuarios con el contenido digital.

### **Aumentar la cantidad de personas en la muestra**

La ampliación de la muestra a una mayor cantidad de individuos podría tener un impacto significativo en los resultados, ya que permitiría validar la generalización de las hipótesis planteadas y explorar posibles variaciones demográficas más detalladas. Sin embargo, se espera que las hipótesis principales no varíen de manera sustancial. En cambio, se podrían agregar nuevas hipótesis relacionadas con el nivel educacional, que podrían ofrecer información sobre cómo el contexto formativo de los participantes influye en sus respuestas emocionales ante estímulos digitales. Por ejemplo, se podría estudiar si individuos con diferentes niveles de educación muestran patrones de respuesta emocional similares o si existen diferencias notables en la forma en que interpretan el contenido de las páginas web.

En términos de la distribución de la población, es importante que la muestra refleje una diversidad demográfica adecuada, no solo en términos de edad y género, sino también de factores como nivel educativo y estado civil. Esto permitiría un análisis más profundo de cómo estas variables demográficas impactan las respuestas emocionales y mejoraría la robustez del modelo al capturar la variabilidad natural de la población.

Por otra parte, para optimizar la precisión de los datos de EEG y capturar una respuesta emocional más completa, se recomienda aumentar el tiempo de evocación de emociones y el tiempo de observación de las páginas web. Esto permitiría que el EEG capture más información sobre la actividad cerebral, proporcionando datos más detallados y representativos de las reacciones emocionales de los participantes. La extensión de estos tiempos de exposición podría revelar patrones de respuesta más profundos, fortaleciendo así la validez de los modelos predictivos y ofreciendo una visión más rica de la experiencia emocional del usuario frente a contenidos digitales.

## **5.5. Conclusión general**

El presente estudio se propuso abordar la pregunta fundamental de cómo varían los estados emocionales de distintos grupos demográficos al observar diferentes páginas web, utilizando señales EEG y modelos predictivos basados en aprendizaje automático. Partiendo de una hipótesis que planteaba la existencia de diferencias demográficas significativas en las respuestas emocionales de los usuarios, los objetivos se enfocaron en identificar patrones de respuesta emocional vinculados a variables como el sexo y el rango etario. Además, se planteó una hipótesis secundaria que sugería que las mujeres tendrían una percepción más positiva hacia páginas web con una mayor cantidad de colores en comparación con los hombres.

En términos generales, los resultados confirmaron la hipótesis principal, demostrando que es posible identificar diferencias demográficas significativas en las respuestas emocionales de

los usuarios al navegar por páginas web. El análisis de las señales EEG permitió entrenar modelos de machine learning que lograron identificar los estados emocionales de los usuarios con una precisión superior al 80 %, cumpliendo así con uno de los objetivos específicos de la investigación.

Uno de los hallazgos clave fue la confirmación de la hipótesis secundaria: se observó que las mujeres tendían a tener respuestas emocionales más positivas frente a páginas web con un mayor uso de colores, mientras que los hombres mostraron respuestas más neutrales o negativas en estos escenarios. Este resultado resalta la importancia del diseño visual y cómo elementos estéticos, como la cantidad de colores, pueden influir de manera diferenciada en la experiencia emocional de los usuarios en función de su género.

Por otro lado, el análisis por grupo etario reveló que los adultos jóvenes (Grupo 2) mostraron estados emocionales más neutrales al interactuar con páginas web, en comparación con los participantes de mediana edad (Grupo 3), quienes tuvieron respuestas emocionales más positivas. Estos resultados indican que el grupo etario también juega un papel relevante en la percepción emocional del contenido digital, lo que sugiere la necesidad de personalizar las experiencias de usuario en función de la edad para maximizar su impacto emocional.

Asimismo, se identificó una diferencia notable entre las respuestas conscientes declaradas por los participantes y las respuestas emocionales captadas a través del EEG, ya que no se encontró una correlación significativa entre ambas en ninguna de las categorías analizadas. Esto sugiere que las emociones conscientes y las respuestas emocionales inconscientes pueden divergir considerablemente, lo que resalta la importancia de utilizar herramientas como el EEG para obtener una comprensión más precisa de las reacciones emocionales genuinas ante estímulos visuales.

Además, los resultados mostraron una correlación no significativa entre las respuestas emocionales inconscientes captadas por el EEG y las respuestas conscientes reportadas por los participantes. Esto indica que las respuestas conscientes y las emocionales inconscientes aportan información complementaria y valiosa, subrayando la importancia de emplear herramientas como el EEG para lograr una comprensión más completa y precisa de las reacciones emocionales ante estímulos visuales.

En conjunto, los hallazgos de este estudio ofrecen valiosas implicaciones prácticas para el diseño y personalización de experiencias digitales, enfatizando la necesidad de considerar tanto las diferencias demográficas como las respuestas emocionales, conscientes e inconscientes, al diseñar contenido web. Los resultados proporcionan información útil para optimizar la experiencia del usuario, haciendo posible la creación de contenido más inclusivo y resonante para diferentes segmentos de la población.

Finalmente, este estudio abre nuevas líneas de investigación que pueden mejorar la comprensión de cómo los usuarios interactúan emocionalmente con el contenido digital. Se recomienda la integración de otras herramientas de medición emocional, como el reconocimiento facial de emociones, el *eye tracking* y la respuesta galvánica de la piel (*GSR*), para enriquecer el análisis. Además, incorporar más páginas web, nuevas categorías de contenido y más variables demográficas, como el nivel educacional y el estado civil, permitirá una exploración más exhaustiva y detallada de las dinámicas emocionales en entornos digitales.

En resumen, este estudio ha logrado avanzar en la comprensión de las diferencias demográficas en las respuestas emocionales frente a páginas web, utilizando técnicas de neurociencia digital y aprendizaje automático. Los resultados obtenidos no solo aportan conocimientos valiosos para la investigación en neuromarketing y comportamiento del consumidor, sino que también ofrecen herramientas prácticas para mejorar el diseño de experiencias digitales que sean emocionalmente resonantes y efectivas para diversos grupos demográficos.

# Bibliografía

- [1] We Are Social. Digital 2024 report. <https://wearesocial.com/uk/blog/2024/01/digital-2024/>.
- [2] Ariel Telpaz, Ryan Webb, and Dino J. Levy. Using eeg to predict consumers' future choices. *Journal of Marketing Research*, 52(4):511–529, 2015.
- [3] K. Ait Hammou, M. H. Galib, and J. Melloul. The contributions of neuromarketing in marketing research. *Journal of Marketing Research (JMR)*, 5(4):20, Aug 2013.
- [4] K Javed, V Reddy, and F Lui. Neuroanatomy, cerebral cortex, Jul 2023. En: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2024 Jan-. Disponible en: <https://www.ncbi.nlm.nih.gov/books/NBK537247/>.
- [5] S. Boag. Conscious, preconscious, and unconscious. In *Encyclopedia of Personality and Individual Differences*, pages 858–864. Springer Nature, Berlin, Germany, 2020.
- [6] Sharad Agarwal and Tanusree Dutta. Neuromarketing and consumer neuroscience: Current understanding and the way forward. *Decision*, 42(4):457–462, 2015.
- [7] Trans Cranial Technologies. *10-20 Electrode Positioning System Manual*, Año.
- [8] Mashael Aldayel, Mourad Ykhlef, and Abeer Al-Nafjan. Deep Learning for EEG-Based Preference Classification in Neuromarketing. *Applied Sciences*, 10(4):1525, February 2020.
- [9] Stacy Marsella and Jonathan Gratch. Computationally modeling human emotion. *Communications of the ACM*, 57(12):56–67, November 2014.
- [10] Rosalind W. Picard. *Affective Computing*. MIT Press, Cambridge, MA, 1997.
- [11] Monika Kowalska, Magdand. *Basic Emotions*, pages 1–6. Springer International Publishing, Cham, 2017.
- [12] R. Plutchik. *Emotions and Life: Perspectives from Psychology, Biology, and Evolution*. American Psychological Association, 2003.
- [13] M. M. Abbasi and A. Beltiukov. Summarizing emotions from text using plutchik's wheel of emotions. *Advances in Intelligent Systems Research*, 166, 2019.
- [14] James A Russell. Affective space is bipolar. *Journal of Personality and Social Psychology*, 37(3):345–356, 1979.

- [15] Xiaohu Wang, Yongmei Ren, Ze Luo, Wei He, Jun Hong, and Yinzhen Huang. Deep learning-based eeg emotion recognition: Current trends and future perspectives. *Frontiers in Psychology*, 14, 2023.
- [16] J. D. Morris. Sam: The self-assessment manikin an efficient cross-cultural measurement of emotional response. *Journal of Advertising Research*, 35(8):63–68, 1995.
- [17] S. Koelstra, C. Muhl, M. Soleymani, Jong-Seok Lee, A. Yazdani, T. Ebrahimi, et al. Deap: a database for emotion analysis using physiological signals. *IEEE Transactions on Affective Computing*, 3:18–31, 2012.
- [18] H. Kinsley and D. Kukić. la. *Neural Networks from Scratch in Python*. Harrison Kinsley, 2020.
- [19] Agnieszka Lawrynowicz and Volker Tresp. *Introducing Machine Learning*. AKA Heidelberg / IOS Press, 2014.
- [20] Jasmina Novakovic, Alempije Veljovic, Sinisa Ilicic, Zeljko M. Papic, and Tomovic Milica. Evaluation of classification models in machine learning. *Theory and Applications of Mathematics & Computer Science*, 7:39–46, 2017.
- [21] Heather C Lench, Sarah A Flores, and Shane W Bench. Discrete emotions predict changes in cognition, judgment, experience, behavior, and physiology: a meta-analysis of experimental emotion elicitations. *Psychological Bulletin*, 137(5):834, 2011.
- [22] R. Sarno, M. N. Munawar, and B. T. Nugraha. Real-time electroencephalography-based emotion recognition system. *International Review on Computers and Software (IRECOS)*, 11(5):456–465, 2016.
- [23] M.A.S. Boksem and A. Smidts. Brain responses to movie trailers predict individual preferences for movies and their population-wide commercial success. *J. Mark. Res.*, 52:482–492, 2015.
- [24] M. Agarwal and R.C. Sivakumar. Cerebro: A wearable solution to detect and track user preferences using brainwaves. In *Proceedings of the 5th ACM Workshop on Wearable Systems and Applications*, pages 47–52, Seoul, Korea, Jun 2019.
- [25] L. I. Aftanas, N. V. Reva, L. N. Savotina, and V. P. Makhnev. Neurophysiological correlates of induced discrete emotions in humans: an individually oriented analysis. *Neuroscience and Behavioral Physiology*, 36(2):119–130, 2006.
- [26] N. Ammasan, K. Moriyama, K. i. Fukui, and M. Numao. Familiarity effects in eeg-based emotion recognition. *Brain Informatics*, 4(1):39–50, 2017.
- [27] Weilong Zheng and Baoliang Lu. Investigating critical frequency bands and channels for eeg-based emotion recognition with deep neural networks. *IEEE Transactions on Autonomous Mental Development*, 7(3):162–175, 2015.
- [28] Xiang Li, Dawei Song, Peng Zhang, Yazhou Zhang, Yuexian Hou, and Bin Hu. Exploring eeg features in cross-subject emotion recognition. *Frontiers in Neuroscience*, 12:162, 2018.

- [29] L. Carretié, M. Tapia, S. López-Martín, et al. Emomadrid: An emotional pictures database for affect research. *Motivation and Emotion*, 43(6):929–939, 2019.
- [30] W. L. Zheng and B. L. Lu. Investigating critical frequency bands and channels for eeg-based emotion recognition with deep neural networks. *IEEE Transactions on Autonomous Mental Development*, 7:162–175, 2015.
- [31] W. L. Zheng, W. Liu, Y. Lu, B. L. Lu, and A. Cichocki. Emotionmeter: a multimodal framework for recognizing human emotions. *IEEE Transactions on Cybernetics*, 49:1110–1122, 2018.
- [32] Mashael S. Aldayel, Mourad Ykhlef, and Abeer N. Al-Nafjan. Electroencephalogram-Based Preference Prediction Using Deep Transfer Learning. *IEEE Access*, 8:176818–176829, 2020.
- [33] Shyam Marjit, Upasana Talukdar, and Shyamanta M Hazarika. Eeg-based emotion recognition using genetic algorithm optimized multi-layer perceptron. In *2021 International Symposium of Asian Control Association on Intelligent Robotics and Industrial Automation (IRIA)*, pages 304–309. IEEE, 2021.
- [34] Shyam Marjit. Eeg-based emotion recognition using genetic algorithm optimized multi-layer perceptron. <https://github.com/shyamarjit/EEG-Emotion-Recognition>, 2021.
- [35] P. Welch. The use of fast fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms. *IEEE Transactions on Audio and Electroacoustics*, 15(2):70–73, 1967.
- [36] P. A. Abhang, B. W. Gawali, and S. C. Mehrotra. *Technological basics of EEG recording and operation of apparatus*, pages 19–50. Academic Press, 2016.
- [37] Dong C. Liu and Jorge Nocedal. On the limited memory bfgs method for large scale optimization. *Mathematical Programming*, 45(1):503–528, 1989.
- [38] Herbert Robbins and Sutton Monro. A stochastic approximation method. *The Annals of Mathematical Statistics*, pages 400–407, 1951.
- [39] Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- [40] Zaineb Chelly Dagdia and Miroslav Mirchev. *When Evolutionary Computing Meets Astro- and Geoinformatics*, pages 283–306. Elsevier, 2020.
- [41] K. A. De Jong. Analysis of the behavior of a class of genetic adaptive systems. Tech. rep., Unknown, 1975.
- [42] Tran-Dac-Think Phan, Soo-Hyung Kim, Hyung-Jeong Yang, and Guee-Sang Lee. EEG-Based Emotion Recognition by Convolutional Neural Network with Multi-Scale Kernels. *Sensors*, 21(15):5092, July 2021.
- [43] Guangyi Zhang and Ali Etemad. Spatio-Temporal EEG Representation Learning on Riemannian Manifold and Euclidean Space, August 2023. arXiv:2008.08633 [cs].

- [44] Mashael Aldayel, Amira Kharrat, and Abeer Al-Nafjan. Predicting choices driven by emotional stimuli using eeg-based analysis and deep learning. *Applied Sciences*, 13(14), 2023.
- [45] Kostas Georgiadis, Fotis P. Kalaganis, Kyriakos Riskos, Eleftheria Matta, Vangelis P. Oikonomou, Ioanna Yfantidou, Dimitris Chantziaras, Kyriakos Pantouvakis, Spiros Nikolopoulos, Nikos A. Laskaris, and Ioannis Kompatsiaris. NeuMa - the absolute Neuro-marketing dataset en route to an holistic understanding of consumer behaviour. *Scientific Data*, 10(1):508, August 2023.
- [46] D. Cyr, M. Head, and H. Larios. Colour appeal in website design within and across cultures: A multi-method evaluation. *International Journal of Human-Computer Studies*, 68(1-2):1–21, 2010.
- [47] A. N. Tuch, E. Presslauer, M. Stoecklin, K. Opwis, and J. Bargas-Avila. The role of visual complexity and prototypicality regarding first impression of websites: Working towards understanding aesthetic judgments. *International Journal of Human-Computer Studies*, 70(11):Precisa agregar el rango de páginas, 2012.
- [48] Katharina Reinecke, Tom Yeh, Luke Miratrix, Rahmatri Mardiko, Yuechen Zhao, Jenny Liu, and Krzysztof Z. Gajos. Predicting users’ first impressions of website aesthetics with a quantification of perceived visual complexity and colorfulness. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, CHI ’13, page 2049–2058, New York, NY, USA, 2013. Association for Computing Machinery.
- [49] K. Reinecke and K. Z. Gajos. Quantifying visual preferences around the world. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pages 11–20, Toronto, Ontario, Canada, Apr 2014. ACM.
- [50] OpenBCI. Ultracortex mark iv. <https://shop.openbci.com/products/ultracortex-mark-iv?variant=23280741699>, 2023. Accedido: 2023-03-28.
- [51] Shimmer Sensing. Shimmer3 gsr+ unit. <https://shimmersensing.com/product/shimmer3-gsr-unit/>. Accedido: fecha de acceso.

# Capítulo 6

## Anexo

### 6.1. Anexo A: Imágenes de Emomadrid seleccionadas



## 6.2. Anexo B: Páginas web



**EM0508**



**EM0462**



**EM0688**



**EM0694**



**EM0698**



**EM0699**



**EM0710**



**EM0714**



**EM0730**



**EM0819**



**EM0893**



**EM0896**



**EM0898**



**EM0924**



**EM1161**



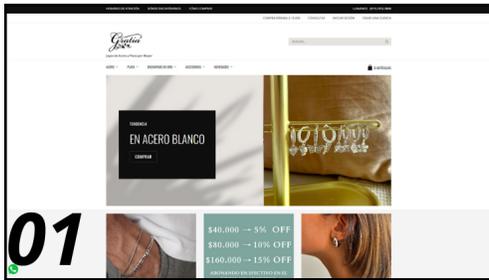
**EM1160**



### 6.3. Anexo C: Resultados estadísticos por categorías de páginas web

Comparación de grupos etarios	Valor $\chi^2$	Valor p
1 vs 2	1,0036	0,3164
1 vs 3	0,0663	0,7967
1 vs 4	0,0688	0,7932
2 vs 3	0,3396	0,5601
2 vs 4	0,2961	0,5863
3 vs 4	0,0	1,0

Tabla 6.1: Categoría de estímulo: Joyas



01



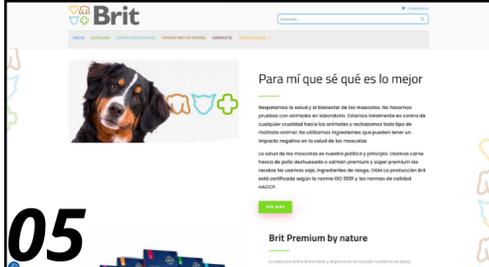
02



03



04



05



06



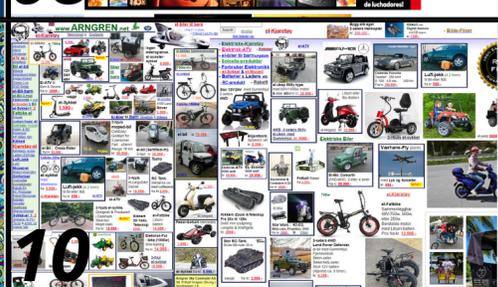
07



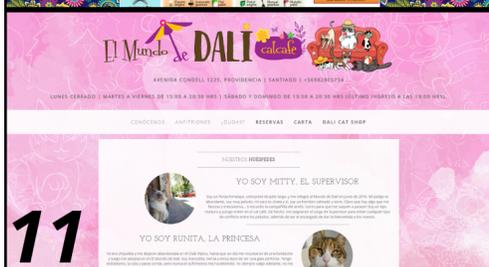
08



09



10



11



12



Comparación de grupos etarios	Valor $\chi^2$	Valor p
1 vs 2	0,4393	0,5075
1 vs 3	0,1014	0,7501
1 vs 4	0,0	1,0
2 vs 3	1,7407	0,1871
2 vs 4	0,3339	0,5634
3 vs 4	0,2566	0,6125

Tabla 6.2: Categoría de estímulo: Saturada

Comparación de grupos etarios	Valor $\chi^2$	Valor p
1 vs 2	0,5246	0,4689
1 vs 3	0,0	1,0
1 vs 4	0,1937	0,6598
2 vs 3	1,0779	0,2992
2 vs 4	0,0055	0,9410
3 vs 4	0,5499	0,4584

Tabla 6.3: Categoría de estímulo: Mascotas

Comparación de grupos etarios	Valor $\chi^2$	Valor p
1 vs 2	0,0	1,0
1 vs 3	0,4667	0,4945
1 vs 4	0,0	1,0
2 vs 3	0,5594	0,4545
2 vs 4	0,0	1,0
3 vs 4	0,6477	0,4209

Tabla 6.4: Categoría de estímulo: Guerra

Comparación de grupos etarios	Valor $\chi^2$	Valor p
1 vs 2	1,0487	0,3058
1 vs 3	0,6565	0,4178
1 vs 4	1,2222	0,2689
2 vs 3	0,0048	0,9448
2 vs 4	0,0	1,0
3 vs 4	0,0190	0,8903

Tabla 6.5: Categoría de estímulo: Farmacia

Comparación de grupos etarios	Valor $\chi^2$	Valor p
1 vs 2	0,9229	0,3367
1 vs 3	0,0713	0,7895
1 vs 4	0,0200	0,8876
2 vs 3	2,7347	0,0982
2 vs 4	0,3341	0,5632
3 vs 4	0,6412	0,4233

Tabla 6.6: Categoría de estímulo: Grandes marcas

Comparación de grupos etarios	Valor $\chi^2$	Valor p
1 vs 2	0,4474	0,5036
1 vs 3	0,0713	0,7895
1 vs 4	0,0	1,0
2 vs 3	1,8126	0,1782
2 vs 4	0,3098	0,5778
3 vs 4	0,2476	0,6188

Tabla 6.7: Categoría de estímulo: Videojuego