

**MARÍA CONSUELO SÁIZ MANZANARES
RAÚL MARTICORENA SÁNCHEZ
DAVID GARCÍA-GARCÍA**

**ANÁLISIS
DE REGISTROS MULTICANAL
EN EL COMPORTAMIENTO HUMANO**



**UNIVERSIDAD
DE BURGOS**

**ANÁLISIS DE REGISTROS
MULTICANAL EN EL
COMPORTAMIENTO HUMANO**

MARÍA CONSUELO SÁIZ MANZANARES
RAÚL MARTICORENA SÁNCHEZ
DAVID GARCÍA-GARCÍA

**ANÁLISIS DE REGISTROS
MULTICANAL EN EL
COMPORTAMIENTO HUMANO**



**UNIVERSIDAD
DE BURGOS**

2026

(Manuales y Prácticas, 52)

Nota: Con el fin de facilitar la lectura del documento, se utilizará el género masculino como referente general para aludir a todos los géneros posibles. Asimismo, se hace referencia específica al trabajo con dispositivos de dos empresas (Tobii y Bitbrain), no con fines de difusión de marca, sino por tratarse de los dispositivos de los que dispone el GIR DATAHES y la UIC n.º 348, los cuales se ponen a disposición para su uso en las clases prácticas con el alumnado.

Cualquier forma de reproducción, distribución, comunicación pública o transformación de esta obra solo puede ser realizada con la autorización de sus titulares, salvo excepción prevista por la ley. Dirijase a CEDRO (Centro Español de Derechos Reprográficos, www.cedro.org) si necesita fotocopiar o escanear algún fragmento de esta obra.

Imagen de cubierta: IA (Gemini), montaje con imagenes propias.

© LOS AUTORES

© UNIVERSIDAD DE BURGOS

Edita: Servicio de Publicaciones e Imagen Institucional

UNIVERSIDAD DE BURGOS

Edificio de Administración y Servicios

C/ Don Juan de Austria, 1

09001 BURGOS - ESPAÑA

ISBN: 979-13-87585-39-6 (edición impresa)

ISBN: 979-13-87585-40-2 (ebook)

Depósito legal: BU 161-2026

DOI: <https://doi.org/10.36443/9791387585402>

La edición en formato *ebook* de esta obra está bajo una licencia de Creative Commons
[Atribución-NoComercial-SinDerivadas 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)



ÍNDICE

PRÓLOGO.....	9
INTRODUCCIÓN	15
TEMA 1	
TECNOLOGÍA <i>EYE TRACKING</i> : DEFINICIÓN	19
1.1. Introducción.....	21
1.2. Práctica Tema 1.....	31
1.3. Referencias	32
TEMA 2	
MÉTRICAS DE REGISTRO EN <i>EYE TRACKING</i> INTERPRETACIÓN	33
2.1. Introducción.....	35
2.2. Incorporación integrada de otros dispositivos	62
2.3. Práctica Tema 2.....	84
2.4. Referencias	85
TEMA 3	
INTERPRETACIÓN DE MÉTRICAS (ESTÁTICAS Y DINÁMICAS) DE REGISTRO EN <i>EYE TRACKING</i> E INTRODUCCIÓN AL REGISTRO DE SEÑAL MÚLTIPLE (<i>EYE TRACKING, GSR, EEG</i>).....	87
3.1. Introducción.....	89
3.2. Análisis de datos crudos en dispositivos integrados de señal	101
3.3. Práctica Tema 3.....	128
3.4. Referencias	129
ANEXO 1	
OBJETIVOS Y PROCEDIMIENTO DEL TRABAJO CON IAGEN.....	133
Referencias	141

ANEXO 2

DISPOSITIVOS DE SEÑAL INTEGRADA. ORIENTACIONES PARA EL ANÁLISIS DE DATOS CRUDOS. PRÁCTICA 3.	143
EEG Diadem Bitbrain.....	145
GSR Ring Bitbrain.....	148
Tobii Pro Nano (60 Hz)	154
Comparación señales	158
Referencias	178
RELACIÓN DE TABLAS.....	181
RELACIÓN DE FIGURAS	185
GLOSARIO	193
AUTORES	
María Consuelo Sáiz Manzanares	203
Raúl Marticorena Sánchez.....	204
David García García	205



PRÓLOGO

Vivimos en una época en la que la tecnología y la medicina convergen para lograr avances sin precedentes en la salud humana. En este contexto, la ingeniería biomédica se ha consolidado como un puente indispensable entre ambas disciplinas. No es casualidad que la ingeniería biomédica sea un campo interdisciplinar en plena expansión, que aplica principios de la física, las matemáticas y la ingeniería al análisis y resolución de problemas en biología y medicina. De hecho, se trata de un sector en rápido crecimiento a nivel global. Datos recientes muestran que el empleo de profesionales en ingeniería biomédica podría aumentar un 7% entre 2023 y 2033 a nivel internacional, superando la media de otras ocupaciones, mientras que en Europa el mercado de la tecnología médica lleva una década creciendo alrededor de un 5,4% anual. En España, organismos del sector, como la Federación Española de Empresas de Tecnología Sanitaria (FENIN), enfatizan el papel clave de los ingenieros biomédicos en el desarrollo de innovaciones sanitarias, anticipando que la demanda de tecnologías de salud seguirá al alza, impulsada por el envejecimiento poblacional, las enfermedades crónicas y el auge de la medicina preventiva y personalizada. Estas tendencias confirman la necesidad de profesionales altamente especializados, justo la necesidad a la que responde el Máster Universitario en Ingeniería Biomédica de la Universidad de Burgos.

Este programa de máster ofrece una formación verdaderamente interdisciplinar, integrando la ingeniería con diversas áreas de la medicina para formar expertos capaces de desenvolverse tanto en entornos clínicos y hospitalarios como en la industria tecnológica y la investigación. El plan de estudios abarca áreas de vanguardia, desde el análisis de imágenes y señales médicas hasta la inteligencia artificial aplicada a la salud, la bioingeniería, la instrumentación avanzada, la robótica médica y el procesamiento de datos biomédicos. Gracias a esta base amplia y actualizada, el alumnado adquiere las competencias necesarias para diseñar soluciones innovadoras ante problemas reales, ya sea desarrollando nuevos dispositivos biomédicos, optimizando equipamiento médico existente o aplicando técnicas de *machine learning* en el diagnóstico y la monitorización de pacientes. En suma, el máster capacita a futuros profesionales para afrontar los grandes desafíos presentes y futuros de la tecnología sanitaria con creatividad, rigor científico y conciencia ética.

Dentro de este completo marco formativo, la asignatura “Análisis de registros multicanal en el comportamiento humano”, eje de este manual, ocupa un lugar destacado. En la era de la medicina digital y de los *wearables*, la capacidad de registrar y analizar múltiples señales fisiológicas y de comportamiento de manera integrada se ha vuelto fundamental. Cada tipo de señal (actividad cerebral, movimientos oculares, respuestas de la piel, etc.) aporta una pieza del rompecabezas sobre cómo pensamos, sentimos y reaccionamos. La verdadera riqueza surge cuando estas piezas se combinan. Con el registro multimodal, cada sensor proporciona información por sí mismo, pero también añade valor al conjunto al generar una sinergia. Por ejemplo, el *eye tracking* por sí solo permite saber hacia dónde mira un participante; pero si a esos datos se añaden las señales eléctricas cerebrales (electroencefalograma – EEG) y la conductancia de la piel (*Galvanic Skin Response* – GSR), es posible identificar cuáles de los estímulos visuales resultan más impactantes o emocionalmente significativos para esa persona. Este enfoque holístico proporciona una comprensión mucho más completa de los procesos cognitivos y emocionales involucrados, algo invaluable tanto para la investigación en neurociencia como para aplicaciones prácticas en salud (desde evaluar la usabilidad de una interfaz hasta mejorar diagnósticos en trastornos del comportamiento). Precisamente, el objetivo de esta asignatura es que quien la cursa aprenda a integrar diversas fuentes de datos biomédicos para desentrañar esos procesos complejos del comportamiento humano en distintos contextos, dominando las técnicas de registro, sincronización, análisis e interpretación de señales multicanal.

Cabe destacar que la innovación no es solo objeto de estudio en este máster, sino también parte de su metodología de enseñanza. Un ejemplo actual lo encontramos en la incorporación responsable de herramientas de inteligencia artificial generativa (IAGen) en el proceso formativo. La aparición de sistemas de IAGen capaces de producir texto, imágenes o incluso análisis de datos ha abierto un abanico de oportunidades en la educación superior y este programa explora esas posibilidades con sentido crítico. Ahora bien, su uso por parte del estudiantado debe hacerse con rigor académico. La IAGen se concibe como un complemento bajo supervisión académica, nunca un sustituto, y siempre empleada con transparencia (es decir, declarando cuándo se ha utilizado y distinguiendo claramente el contenido generado) y con verificación externa de los hechos y referencias aportados. Este planteamiento coincide con las directrices internacionales sobre el uso de inteligencia artificial (IA) en educación, que abogan por enfoques centrados en el ser humano y por exigir total transparencia en las herramientas basadas en IA (véase el Manifiesto para una IA Segura en la Educación – <https://manifiesto.safeaieducation.org>). De hecho, la literatura educativa reciente ya propone escenarios graduados para integrar la IAGen en la docencia de manera pragmática y segura, de modo que se convierta en una aliada pedagógica y no en una amenaza. La clave está en aprovechar sus ventajas (como apoyo en la creación de contenidos, tutoría inteligente, etc.) sin ceder en el rigor, la equidad ni la responsabilidad que caracterizan al quehacer académico. En conso-

nancia con esta visión, este manual incluye orientaciones específicas (ver Anexo 1) para guiar al estudiante en un uso ético y eficaz de la IAGen durante las actividades prácticas de la asignatura. Este hecho refleja el compromiso del máster con una enseñanza verdaderamente innovadora, donde la tecnología punta se incorpora de forma crítica y responsable.

Finalmente, quisiera subrayar la trascendencia del camino que el lector tiene por delante. La formación que brinda el Máster en Ingeniería Biomédica de la Universidad de Burgos no solo transmite conocimientos, sino que busca cultivar una visión integradora y humana de la tecnología. Los desafíos que afrontaremos en el campo de la salud en las próximas décadas, desde el envejecimiento de la población hasta la medicina personalizada, requerirán ingenieros biomédicos con sólida preparación técnica, pero también con creatividad, sensibilidad y ética profesional. Estoy convencido de que los contenidos de este manual serán de gran utilidad para alcanzar ese perfil. Cada tema, cada práctica y cada concepto aquí presentados son peldaños hacia la formación de expertos capaces de mejorar la calidad de vida de las personas a través de la innovación tecnológica en salud.

Enhorabuena por emprender esta apasionante aventura académica. Confío en que sabrán aprovechar al máximo las páginas que siguen, aprendiendo con curiosidad científica, pero sin perder de vista el lado humano de cada desarrollo técnico. La ingeniería biomédica, al fin y al cabo, trata de personas, de aliviar, curar, ayudar y entender mejor a la gente mediante la ingeniería. Con ese propósito en mente, les animo a avanzar con entusiasmo, espíritu crítico y responsabilidad. Estoy seguro de que la dedicación que inviertan en su formación hoy se traducirá en aportes valiosos a la sociedad mañana. ¡Mucho éxito en este viaje de aprendizaje e innovación!

Francisco José García Peñalvo

*Catedrático de Ciencia de la Computación e Inteligencia Artificial
Universidad de Salamanca*



INTRODUCCIÓN

El Máster Universitario en Ingeniería Biomédica de la Universidad de Burgos responde a la creciente demanda de profesionales especializados en este ámbito, tanto a nivel nacional como en la comunidad de Castilla y León. El programa ofrece una formación interdisciplinar que integra la ingeniería con distintas áreas de la medicina, preparando al alumnado para su incorporación a entornos industriales, empresariales, hospitalarios y de investigación.

El máster proporciona una base sólida en áreas clave y de elevado interés actual, como el análisis de imágenes y señales médicas, la inteligencia artificial y el aprendizaje automático, las distintas ramas de la bioingeniería, la instrumentación y los sistemas robotizados, así como el equipamiento médico. Esta formación capacita para el diseño de procesos y soluciones innovadoras en campos como los materiales, los dispositivos biomédicos y el procesamiento avanzado de datos.

El acceso al programa está dirigido a titulados en Ingeniería de la Salud, Ingeniería Informática, Ingeniería de Telecomunicaciones, Ingeniería Mecánica, Ingeniería Electrónica y dobles grados afines.

En cuanto a las salidas profesionales, el máster prepara para tres perfiles principales: el ámbito industrial, orientado al desarrollo de tecnología sanitaria y la consultoría; el ámbito sanitario, centrado en la gestión y uso de equipamiento médico y el apoyo al diagnóstico; y el ámbito de I+D+i, enfocado a la investigación básica y aplicada en nuevas tecnologías biomédicas.

De forma específica, la asignatura «Análisis de registros multicanal en el comportamiento humano», a la que hace referencia este manual, tiene como objetivo proporcionar al estudiantado los conocimientos teóricos y prácticos necesarios para comprender, registrar, analizar e interpretar señales biomédicas y conductuales obtenidas mediante sistemas multicanal, aplicadas al estudio del comportamiento humano en distintos contextos.

La asignatura se centra especialmente en la tecnología de *eye tracking*, abordando sus fundamentos, principales métricas de registro y la diferencia entre registros estáticos y dinámicos, así como su correcta interpretación. Asimismo, se introduce el análisis integrado de señales múltiples, combinando datos de *eye tracking* con otras

señales biomédicas, como la conductancia de la piel (GSR) y la electroencefalografía (EEG), con el fin de obtener una visión más completa de los procesos cognitivos y emocionales.

Finalmente, la asignatura desarrolla competencias relacionadas con el uso de sensores, sistemas de adquisición y acondicionamiento de señales biomédicas aplicados a la evaluación, monitorización, diagnóstico y apoyo a la terapia. La metodología docente se basa en el aprendizaje basado en proyectos, fomentando el trabajo aplicado y el pensamiento crítico. En las prácticas, el estudiantado aprende a conocer y utilizar dispositivos de registro integrado de *eye tracking*, EEG y GSR, así como a extraer datos en bruto y realizar su preprocesamiento y procesamiento mediante técnicas de *Machine Learning* supervisado y no supervisado. También, se introduce el uso de herramientas de Inteligencia Artificial e Inteligencia Artificial Generativa, promoviendo un enfoque ético y responsable, en el que el alumnado debe documentar de forma transparente la ayuda recibida de estas tecnologías y el diseño adecuado de los *prompts* utilizados. Además, el desarrollo de proyectos en pequeños grupos orienta al alumnado hacia la iniciación en la investigación dentro de un entorno colaborativo, facilitando la adquisición de competencias de trabajo en equipo y favoreciendo el inicio de trayectorias investigadoras que pueden culminar en la realización de un doctorado en este ámbito de conocimiento.

María Consuelo Sáiz Manzanares

Catedrática de Universidad

Área de Psicología Evolutiva y de la Educación

Facultad de Ciencias de la Salud

Universidad de Burgos



TEMA 1

**TECNOLOGÍA *EYE TRACKING*:
DEFINICIÓN**

Dra. María Consuelo Sáiz Manzanares

Dr. Raúl Marticorena Sánchez

1.1. Introducción

La tecnología de *eye tracking* permite registrar y analizar los movimientos oculares mientras una persona realiza una tarea, ofreciendo información sobre hacia dónde dirige su atención visual. El funcionamiento básico consiste en proyectar un haz de **luz infrarroja** hacia los ojos; esta luz se refleja en la superficie ocular y es captada por las cámaras del dispositivo. A través de algoritmos especializados, el sistema identifica con precisión el **punto de fijación de la mirada** y los patrones de seguimiento ocular. En la **Figura 1** se muestran los componentes de un dispositivo de *eye tracking*, utilizando como ejemplo el **Tobii Pro Lab**.




Figura 1. Componentes del *eye tracking* en un dispositivo Tobii Pro Lab.

En la **Figura 2** se ilustra el proceso de *eye tracking*: un estímulo se presenta en la pantalla del ordenador y el sistema registra la **posición de la mirada** en coordenadas, que pueden ser bidimensionales (x, y) o tridimensionales (x, y, z), tanto para el ojo derecho como para el izquierdo. Es importante destacar que la tecnología de *eye tracking* no se limita al uso de pantallas, sino que también permite registrar los

movimientos oculares mientras el sujeto observa una **pizarra, un objeto físico** o cualquier otra superficie, como se muestra en la **Figura 3**.




Figura 2. Tomado del Manual Tobii Pro Lab v. 1.194 p. 155.




Figura 3. Tomado del Manual Tobii Pro Lab v. 1.194 p. 158.

El **eye tracking** se puede utilizar en muchos ámbitos, como marketing, educación o medicina. En esta asignatura nos centraremos en su uso en **educación y salud**. Esta tecnología es especialmente útil para personas con dificultades de movimiento, como **parálisis cerebral, Esclerosis Lateral Amiotrófica (ELA), Síndrome de Rett o lesiones medulares**, ya que permite controlar dispositivos únicamente con la mirada.

Un ejemplo de dispositivo de **eye tracking** es el **Tobii Dynavox TD I-Series**. Este es un dispositivo ligero y rápido que funciona completamente con los ojos. Incluye varios programas, como **TD Snap**, que usa pictogramas para facilitar la comunicación; **Communicator 5**; **TD Control**; **TD Browse**; **TD Talk**; y **TD Phone**. También tiene una **ventana de interlocutor** para conversaciones cara a cara y un sistema de seguimiento ocular que funciona incluso con luz solar. Específicamente, se abordará la descripción de **TD Snap**.

Concretamente, el software *TD Snap Core First* proporciona un sistema de comunicación con pictogramas y palabras frecuentes en cada idioma, ayudando a las personas a expresarse y entender a otros. Un ejemplo de su funcionamiento se muestra en la **Figura 4**.



enlace-001

Figura 4. Imagen tomada de Tobii TD Snap [enlace-001](#).

Asimismo, *TD Snap Motor Plan* permite que los comunicadores accedan a palabras en **tres selecciones o menos**, facilitando la comunicación rápida y eficiente. Este sistema está disponible en tres tamaños de cuadrícula (30, 66 y 40), con un **vocabulario cuidadosamente seleccionado** para apoyar tanto a aprendices de lenguaje inicial como a comunicadores avanzados.

Cada palabra aparece **una sola vez** y sigue una **ruta distintiva**, o plan motor, para encontrarla. Con la práctica, el comunicador puede **localizar las palabras de forma automática**, lo que reduce el esfuerzo y le permite concentrarse en el mensaje que desea transmitir. Un ejemplo de esta configuración se muestra en la **Figura 5**.



enlace-002

Figura 5. Tomado de TD Snap Motor Plan [enlace-002](#).

También *TD Snap Express* es un conjunto de páginas **intuitivo y fácil de usar**, diseñado para facilitar la comunicación. Este sistema apoya el desarrollo de **habilidades de lenguaje y comunicación** mediante el uso de palabras y frases para construir mensajes completos.

Gracias a su **navegación simplificada** y un vocabulario fácil de localizar, cualquier usuario puede aprender a utilizarlo rápidamente. Además, incluye **páginas temáticas** que permiten comunicarse de forma organizada y eficiente. Un ejemplo de su funcionamiento se muestra en la **Figura 6**.



enlace-003

Figura 6. Imagen tomada de Tobii TD Snap Express [enlace-003](#).

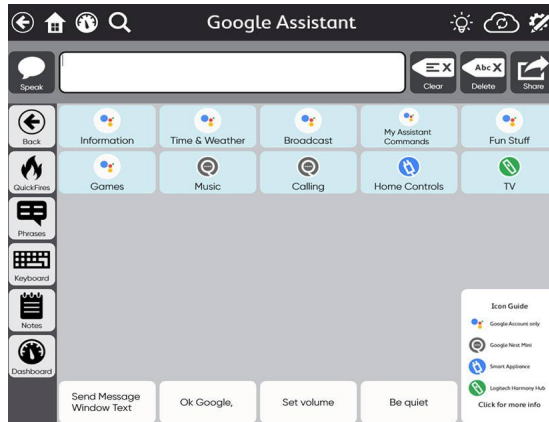
El *TD Snap Texto* es una opción de **Comunicación Aumentativa y Alternativa (CAA)** dentro de TD Snap, diseñada para personas que pueden leer y deletrear sin necesidad de **pictogramas**, o que se encuentran en **transición de los pictogramas a la lectoescritura**.

Las frases están organizadas por **temas**, y los teclados incluyen **predicción de palabras**, lo que facilita la escritura rápida y eficiente (ver **Figura 7**). Además, esta opción incorpora **sistemas inteligentes** que optimizan la comunicación según el contexto y las necesidades del usuario (ver **Figura 8**).



enlace-004

Figura 7. Imagen tomada de Tobii TD Snap Texto [enlace-004](#).



enlace-005

Figura 8. Imagen tomada de Tobii TD Snap Texto [enlace-005](#).

Además, existen **equipos de eye tracking que minimizan la restricción de movimiento**, como el *Tobii Pro Spectrum*. Este dispositivo es especialmente útil para **niños pequeños** o personas con **afectaciones motoras**, ya que permite registrar datos a **múltiples frecuencias de muestreo de hasta 1200 Hz** mientras se mantiene el **movimiento natural de la cabeza**, un ejemplo se puede consultar en el siguiente [enlace-006](#).




enlace-006

Además, en la **Figura 9** y **Figura 10** se muestran aplicaciones prácticas de este sistema con niños pequeños, ilustrando cómo se registran los movimientos oculares en tareas de seguimiento visual.



enlace-007

Figura 9. Imagen tomada de Tobii información en web [enlace-007](#).



enlace-008

Figura 10. Imagen tomada de Tobii información en web [enlace-008](#).

Otra alternativa es el uso de **gafas con software de eye tracking integrado** (ver **Figura 11**). Estas gafas permiten registrar información en un **sistema de coordenadas en tres dimensiones (3D)**. La posición del ojo y los vectores de la mirada se calculan a partir de las imágenes captadas sobre un **modelo 3D**, y el **punto de fijación de la mirada** se determina como el **punto de vergencia entre ambos vectores oculares**, proporcionando una medición precisa de hacia dónde dirige la atención el usuario.




Figura 11. Tomado del Manual Tobii Pro Lab v. 1.194 p. 159.

A continuación, se describen los pasos fundamentales para trabajar con *eye tracking*:

Paso 1. Definición de objetivos

Se deben establecer los objetivos del estudio o intervención, que pueden ser de **investigación, diagnóstico o intervención**.

Paso 2. Elección del dispositivo

Se selecciona el dispositivo de *eye tracking* más adecuado según los objetivos y la población participante. En la **Figura 12** se muestran algunas opciones con **Tobii Pro Lab**.

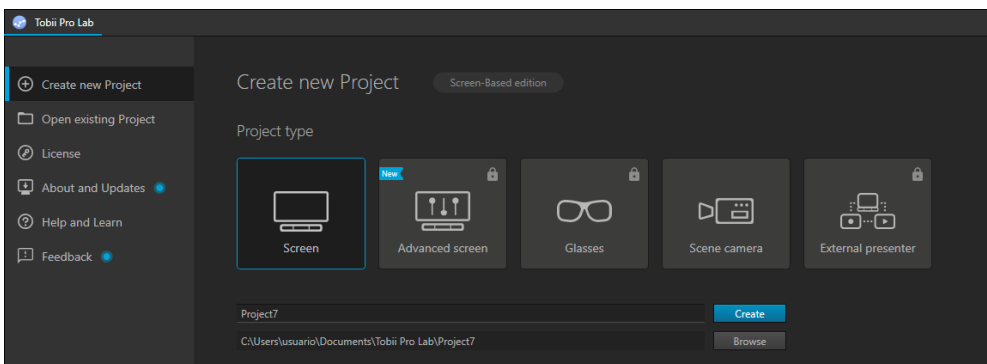


Figura 12. Posibilidades de dispositivos con Tobii Pro Lab (fuente propia).

Paso 3. Diseño del material

Se diseñan los estímulos que se mostrarán durante la tarea. Estos pueden ser **visuales** (texto, imágenes, vídeos), **auditivos** o combinados. Dependiendo de los objetivos, los estímulos se pueden **insertar directamente en el dispositivo** o **conectar mediante una página web**. Un ejemplo de diseño de estímulo se presenta en la **Figura 13**.




Figura 13. Ejemplo de diseño y aplicación de estímulos (fuente propia).

Paso 4. Calibración de cada participante

Es esencial garantizar que el registro de la mirada sea preciso y estable. Se evalúan los siguientes índices:

- **Accuracy (precisión de localización):** mide la cercanía entre la posición real del estímulo y la posición registrada por el eye tracker. Se expresa en grados visuales ($^{\circ}$). Por ejemplo, un **Accuracy = 0.5°** indica que el registro promedio está a medio grado del punto real.
- **Precision (SD – desviación estándar):** indica la consistencia de la fijación en un punto estático; valores bajos reflejan señal estable y poco ruido.
- **Precision (RMS – Root Mean Square):** cuantifica la variabilidad de la mirada respecto a su media, capturando pequeños movimientos oculares y ruido del dispositivo. Es un indicador robusto de estabilidad instantánea de la señal.

En la **Tabla 1** se presentan valores típicos de calibración en condiciones de laboratorio. En la **Figura 14** se muestra un ejemplo de buena calibración, mientras que la **Figura 15** ilustra un ajuste incorrecto. Las **Figuras 16 y 17** presentan ejemplos de calibración en distintos sujetos, mostrando cómo varía la señal según la persona.

Tabla 1. Relación de los valores típicos en condiciones de laboratorio controladas con el dispositivo de *eye tracking* de Tobii Pro Lab.

Índice	Definición	Rango esperado
<i>Accuracy</i>	Cercanía entre punto real y estimado	0.1°–0.6°
<i>Precision (SD)</i>	Estabilidad en torno al punto de fijación	0.11°–0.18°
<i>Precision (RMS)</i>	Variabilidad entre muestras consecutivas	0.11°–0.17°




Figura 14. Calibración con el dispositivo Tobii Pro Lab (fuente propia).

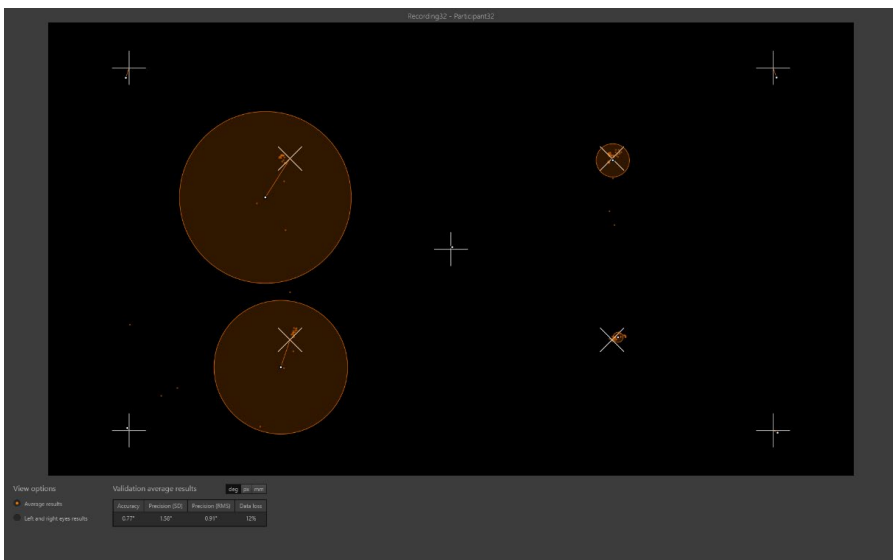


Figura 15. Calibración con el dispositivo Tobii Pro Lab (fuente propia).




Recording	Participant	Timeline	Duration	Date	Resolution	Gaze samples
Recording29	Participant29	Timeline1	00:04:51.220	29/03/2022 9:15	1920 x 1080	97%
 Validation accuracy: 0.27° Validation precision: 0.14°						
Recording12	Participant12	Timeline1	00:06:21.119	24/03/2022 9:05	1920 x 1080	87%
 Validation accuracy: 0.55° Validation precision: 0.12°						
Recording20	Participant20	Timeline1	00:05:10.040	25/03/2022 9:53	1920 x 1080	91%
 Validation accuracy: 0.44° Validation precision: 0.17°						

Figura 16. Ejemplos de calibración en distintos sujetos en un dispositivo Tobii Pro Lab (fuente propia).




Figura 17. Ejemplo de calibración con un dispositivo iView XTM v.2.7. SMI (fuente propia).

Paso 5. Definición de las características de los participantes

En esta etapa se determinan las **características relevantes de los participantes**, como el tipo de grupo, el género o la titulación académica. Un ejemplo se muestra en la **Figura 18**, donde se presentan estas variables agrupadas por tipo de estudio.

Es fundamental garantizar la **anonimización** de todos los datos y que los participantes **reciban información completa sobre los objetivos del trabajo**, proporcionando su **consentimiento informado por escrito**.

Además, el proyecto debe contar con la **aprobación de la institución correspondiente** (educativa, sanitaria u otra) mediante un informe que certifique el cumplimiento de las normas éticas internacionales y nacionales, siguiendo la **Declaración de Helsinki (2013, revisión 2024)** y las regulaciones de **protección de datos**.

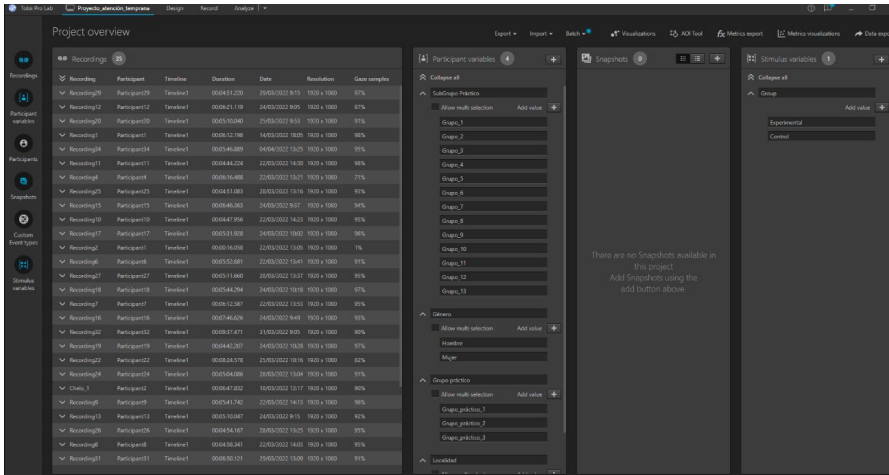


Figura 18. Ejemplos de características aplicadas.

Paso 6. Integración de dispositivos adicionales

En esta etapa es posible **incorporar otros dispositivos** para enriquecer la recolección de datos y obtener un análisis más completo del comportamiento y las respuestas fisiológicas de los participantes. Entre estos dispositivos se incluyen:

- **Eye tracking** adicional para distintos ángulos o modalidades.
- **Cámaras** para registrar expresiones faciales y movimientos corporales.
- **Micrófonos** para capturar respuestas verbales o audibles.
- **GSR (Galvanic Skin Response)** para medir respuestas fisiológicas relacionadas con la activación emocional o cognitiva.

Un ejemplo de configuración multimodal se puede consultar en la **Figura 19**, mostrando cómo se combinan los distintos dispositivos durante la tarea.




Figura 19. Integración de señales en eye tracking.

Ejemplos de proyectos

Proyectos basados en pantalla (Screen-based)

Con niños pequeños [enlace-009](#)

Técnicas de visualización [enlace-010](#)

Usabilidad de interfaces de computadoras [enlace-011](#)

Investigación en *Blink* [enlace-012](#)

Investigación en lectura [enlace-013](#)



Marketing [enlace-14](#)

Marketing toma de decisiones [enlace-15](#)

Proyectos de pantalla avanzados
(Advanced screen project)

Proyecto 1 AB Testing [enlace-16](#)

Proyecto 2 Paradigma de búsqueda preferencial [enlace-17](#)

Tobii Pro Glasses 3

Proyecto Investigación sobre compradores [enlace-18](#)



enlace-014



enlace-015



enlace-016



enlace-017



enlace-018

1.2. Práctica Tema 1

Objetivo de la práctica:

Aprender a planificar un estudio utilizando tecnología de *eye tracking*, incluyendo el diseño de estímulos, definición de objetivos y características de los participantes.

Actividades:

1. Diseño de materiales de análisis:

- Elaborar los estímulos que se aplicarán durante la tarea.
- Los materiales pueden ser:
 - **Visuales:** texto, imágenes, vídeos.
 - **Auditivos:** sonidos, instrucciones habladas.
 - **Combinados:** audio y vídeo simultáneo.
- Definir cómo se presentarán los estímulos (directamente en el dispositivo o mediante conexión a una web).

2. Elaboración de preguntas u objetivos del trabajo:

- Formular los objetivos específicos del estudio o práctica.
- Ejemplos: medir el **tiempo de fijación**, identificar **patrones de atención visual**, comparar respuestas entre distintos grupos de participantes, evaluar carga cognitiva.

3. Descripción de las características de los participantes:

- Definir las variables relevantes de los sujetos: edad, género, titulación, grupo al que pertenecen, etc.
- Recordar la importancia de **anonimizar los datos** y asegurar que todos los participantes **firmen el consentimiento informado**.

- Asegurar que el proyecto cumpla con normas éticas, siguiendo la **Declaración de Helsinki (2013, revisión 2024)** y las regulaciones de protección de datos aplicables.

***Para la realización de la práctica se pueden utilizar herramientas de Inteligencia Artificial Generativa (IAGen). Si bien, se deben seguir las instrucciones que se pueden consultar en el Anexo 1.**

1.3. Referencias

- Sáiz-Manzanares, M.C., & Santamaría Vázquez, M. (2024). *Formación y Especialización en Atención Temprana: uso de Recursos Tecnológicos y de Inteligencia Artificial*. Burgos: Servicio de Publicaciones de la Universidad de Burgos. ISBN: 978-84-18465-80-2 <https://doi.org/10.36443/9788418465802>
- Sáiz-Manzanares, M.C., & Santamaría Vázquez, M. (2024). *Training and Specialisation in Early Intervention: use of Technological Resources and Artificial Intelligence*. Burgos: Servicio de Publicaciones de la Universidad de Burgos. ISBN: 978-84-18465-81-9. <https://doi.org/10.36443/9788418465819>
- Sáiz-Manzanares, M. C. (2024). Módulo VII.3. Intervención temprana y aplicación de recursos inteligentes: utilización de la tecnología *eye tracking* y de la aplicación web *earlycare*. En M.C. Sáiz-Manzanares y M. Santamaría Vázquez (Eds.), *Formación y especialización en atención temprana: uso de recursos tecnológicos y de inteligencia artificial* (257-280). Burgos: Servicio de Publicaciones de la Universidad de Burgos. <https://doi.org/10.36443/9788418465802> (versión en español). <https://doi.org/10.36443/9788418465819> (versión en inglés)
- Sáiz-Manzanares, M. C. (2024). Module VII.3 early care and application of smart resources: use of eye tracking technology and the *earlycare* web application. En M.C. Sáiz-Manzanares y M. Santamaría Vázquez (Eds.), *Training and Specialisation in Early Intervention: use of Technological Resources and Artificial Intelligence* (pp. 247-270). Burgos: Servicio de Publicaciones de la Universidad de Burgos. ISBN: 978-84-18465-81-9. <https://doi.org/10.36443/9788418465819>
- World Medical Association. (2013). World Medical Association Declaration of Helsinki: Ethical principles for medical research involving human subjects. *JAMA*, 310(20), 2191–2194. <https://doi.org/10.1001/jama.2013.281053>

Webs

Proyecto eEarlyCare-T https://www2.ubu.es/earlycare_t/

Webs Tobii Pro Lab sample projects [enlace-19](#)



enlace-019



TEMA 2

**MÉTRICAS DE REGISTRO EN *EYE*
TRACKING INTERPRETACIÓN**

Dra. María Consuelo Sáiz Manzanares

Dr. Raúl Marticorena Sánchez

2.1. Introducción

Las métricas que se pueden extraer dependen del **dispositivo de eye tracking** utilizado. En términos generales, se pueden clasificar en **métricas estáticas** y **métricas dinámicas** (Sáiz-Manzanares et al., 2020).

A. Métricas estáticas

Estas métricas se relacionan con **fijaciones, sacadas, glances o parpadeos**, y suelen medirse a través de parámetros como **frecuencia, duración promedio y velocidad**. Se calculan sobre **puntos fijos de interés (AOIs – Áreas de Interés)** o durante períodos determinados de observación.

Se denominan «estáticas» porque **no dependen de la secuencia temporal de los movimientos oculares**, sino de la cantidad y distribución de las fijaciones en relación con un estímulo.

Ejemplos de métricas estáticas:

- Número de fijaciones en un AOI.
- Duración promedio de fijación.
- Porcentaje de tiempo observado en cada AOI.

B. Métricas dinámicas

Estas métricas, consideran la **secuencia temporal de los movimientos oculares** y cómo la mirada se desplaza entre distintas AOIs. Como ejemplo típico, dichas métricas registran el **patrón posicional de la mirada a lo largo del tiempo**, también como en el caso del conocido como *scan path*. Estas métricas son dependientes del orden, tiempo entre eventos, evolución temporal o transiciones.

Ejemplos de métricas dinámicas:

- Secuencia de fijaciones.
- Transiciones entre AOIs.
- Trayectoria del *scan path*.
- Entropía visual (grado de aleatoriedad en la exploración).

C. Estudio de métricas en distintos dispositivos

Cada dispositivo puede registrar los datos en distintos formatos, y cada formato permite calcular unas métricas específicas.

- En la **Tabla 2** se muestra una **clasificación y significado de las métricas**.
- En la **Tabla 3** se presentan las **métricas de *eye tracking*, su significado y unidad de medida**.

Tabla 2. Métricas en *eye tracking*, significado y relación cognitiva.

Métrica	Acrónimo	Significado	Relación cognitiva
<i>Duration of interval</i>	DI	Duración temporal de cada intervalo definido dentro de un estímulo o Área de Interés (AOI) durante el registro de <i>eye tracking</i> . Esta métrica indica el tiempo total que abarca cada intervalo analizado y puede resumirse mediante estadísticas descriptivas como media, mediana, suma, frecuencia, varianza y desviación estándar.	
<i>Start of interval</i>	SI	Momento temporal en el que comienza cada intervalo dentro del estímulo o Área de Interés (AOI) durante el registro de <i>eye tracking</i> . Esta métrica permite identificar cuándo se inicia el intervalo analizado y puede resumirse mediante estadísticas descriptivas como media, mediana, suma, frecuencia, varianza y desviación estándar.	
<i>Number of Events</i>	NE	Número total de eventos registrados durante la presentación de un estímulo o dentro de un intervalo de análisis. Los eventos pueden incluir marcadores experimentales, eventos personalizados o eventos registrados en tiempo real durante la sesión. Esta métrica representa la frecuencia de ocurrencia de los eventos y puede resumirse mediante estadísticas descriptivas como media, mediana, suma, frecuencia, varianza y desviación estándar.	

Métrica	Acrónimo	Significado	Relación cognitiva
<i>Validity of eye data</i>	VED	Indica el grado en que los datos de seguimiento ocular son válidos o detectables por el sistema de <i>eye tracking</i> . Esta métrica refleja si la mirada del participante ha sido correctamente registrada en un momento determinado. La validez puede verse afectada por factores como parpadeos, pérdida temporal del seguimiento ocular, movimientos de cabeza o problemas de detección del ojo, y no depende exclusivamente de la calidad de la calibración.	
<i>Calibration</i>	C	Información sobre el ajuste de calibración.	
<i>Fixation Count</i>	FC	Número de fijaciones de todos los estímulos seleccionados.	Una FC alta hace referencia a un mayor número de fijaciones en un estímulo, lo que indica que los participantes pueden poseer un menor conocimiento de la tarea o tener dificultades para discriminar entre información relevante y no relevante.
<i>Fixation Duration</i>	FD	Duración de la fijación	Da una indicación del grado de interés y de los tiempos de reacción del usuario. Una mayor duración suele estar asociada con un procesamiento cognitivo más profundo y un mayor esfuerzo. Asimismo, la duración de la fijación proporciona información sobre el proceso de búsqueda.
<i>Fixation Duration Average</i>	FDA	Duración media de la fijación	Una FDA más larga significa que el participante pasa más tiempo analizando e interpretando el contenido de la información dentro de los distintos AOI.
<i>Fixation Duration Maximum</i>	FDMA	Duración máxima de la fijación	Hace referencia a los tiempos de reacción.
<i>Fixation Duration Minimum</i>	FDMi	Duración mínima de la fijación	Hace referencia a los tiempos de reacción.

Métrica	Acrónimo	Significado	Relación cognitiva
<i>Fixation Dispersion Total</i>	FDT	Suma todas las dispersiones en los ejes de fijación (x,y o x,y,z) dependiendo de si el aparato mide en 2D o en 3D	Se refiere a la percepción de la información en diferentes componentes de la tarea.
<i>Fixation Dispersion Average</i>	FDisA	Suma de todas las dispersiones de fijación en los ejes dividida por el número de fijaciones en la prueba.	analiza las dispersiones en cada una de las fijaciones en los diferentes estímulos
<i>Saccades Count</i>	SC	Número total de sacadas en cada uno de los estímulos.	Un mayor número de sacadas implica mayores estrategias de búsqueda. Cuanto mayor sea la amplitud de la sacada, menor será el esfuerzo cognitivo. También puede referirse a problemas de comprensión de información.
<i>Saccade Frequency Count</i>	SFC	Suma de la frecuencia de todas las sacadas	Se refiere a la frecuencia de uso de las sacadas que están relacionadas con las estrategias de búsqueda.
<i>Saccade Duration Total</i>	SDT	Suma de la duración de todas las sacadas	Se refiere a la frecuencia de uso de las sacadas que están relacionadas con las estrategias de búsqueda.
<i>Saccades Duration Average</i>	SDA	Duración media de las sacadas en cada AOI	Este dato permite la discriminación de los usuarios dependientes o independientes de campo.
<i>Saccade Duration Maximum</i>	SDMa	Duración máxima de la sacada	Los usuarios noveles en la ejecución de una tarea tienen sacadas más cortas
<i>Saccade Duration Minimum</i>	SDMi	Duración mínima de la sacada	Los usuarios noveles en la ejecución de una tarea tienen sacadas más cortas
<i>Saccade Amplitude Total</i>	SAT	Suma de la amplitud de todas las sacadas	Los usuarios noveles en la ejecución de una tarea tienen sacadas más cortas
<i>Saccade Amplitude Maximum</i>	SAMa	Amplitud máxima de la sacada	Los usuarios noveles en la ejecución de una tarea tienen sacadas más cortas
<i>Saccade Amplitude Minimum</i>	SAMi	Amplitud mínima de la sacada	Los usuarios noveles en la ejecución de una tarea tienen sacadas más cortas

Métrica	Acrónimo	Significado	Relación cognitiva
<i>Saccade Velocity Total</i>	SVT	Suma de la velocidad de cada sacada	Está directamente relacionado con la velocidad de procesamiento de la información al pasar de un elemento a otro dentro de un estímulo.
<i>Saccade Velocity Maximum</i>	SVMa	Máximo valor de la velocidad registrada de la sacada	Está directamente relacionado con la velocidad de procesamiento de la información al pasar de un elemento a otro dentro de un estímulo.
<i>Saccade Velocity Minimum</i>	SVMi	Mínimo valor de la velocidad registrada de la sacada	Está directamente relacionado con la velocidad de procesamiento de la información al pasar de un elemento a otro dentro de un estímulo.
<i>Saccade Latency Average</i>	SLA	Es igual al tiempo entre el fin de una sacada y el inicio de la siguiente sacada	Está directamente relacionado con los tiempos de reacción en el procesamiento de la información. La latencia inicial de la sacada proporciona información temporal sobre el proceso de búsqueda.
<i>Blink Count</i>	BC	Número de parpadeos durante la actividad	Los parpadeos están relacionados con el procesamiento de la información durante la exposición a un estímulo para generar la siguiente acción. Los usuarios con un procesamiento de la información más rápido pueden tener parpadeos más breves y de menor duración. Sin embargo, esta acción también puede producirse cuando hay problemas atencionales. Estos resultados tendrán que compararse con los obtenidos en las otras métricas para ajustar la explicación de estos resultados dentro del análisis de un patrón de aprendizaje.
<i>Blink Frequency Count</i>	BFC	Número de parpadeos de todos los ensayos seleccionados ensayos por segundo dividido por número de ensayos seleccionados	
<i>Blink Duration Total</i>	BDT	Suma de la duración de todos los parpadeos de los ensayos seleccionados dividida por el número de ensayos seleccionados	
<i>Blink Duration Average</i>	BDA	La suma de la duración de todos los parpadeos de todos los ensayos seleccionados dividida por el número de pruebas seleccionadas	
<i>Blink Duration Maximum</i>	BDMa	Duración máxima del parpadeo	
<i>Blink Duration Minimum</i>	BDMi	Duración mínima del parpadeo	

Métrica	Acrónimo	Significado	Relación cognitiva
<i>Pupil diameter</i>	PD	Diámetro de la pupila	Hace referencia al interés que un estímulo o parte de él puede llamar la atención del usuario
<i>Total duration of Visit</i>	TDV	Tiempo total en el que cada participante ha visitado cada AOI	Da datos sobre la atención respecto de un estímulo o parte del mismo.
<i>Average duration of Visit</i>	ADV	Duración media de cada participante respecto de cada AOI sobre la media total.	
<i>Number of Visits</i>	NV	Número de visitas dentro de cada AOI.	
<i>Scan Path Length</i>	SPL	Proporciona el patrón de aprendizaje conductual del usuario durante la resolución de la tarea	El estudio de los patrones de comportamiento del aprendizaje facilitará las orientaciones sobre la forma de aprender. La longitud del recorrido de exploración proporciona información sobre los tiempos de reacción en tareas sin duración predeterminada.
<i>Dwell Time</i>	DWT	Duración en el tiempo de todas las fijaciones y sacadas dentro de un AOI, incluyendo las revisitas (salidas y reentradas) de todos los participantes en el estudio dividido por el número de participantes.	El DWT se refiere al interés de un participante en un estímulo dentro de una AOI determinada.
<i>Glance Duration</i>	GD	Duración de la sacada al entrar en el AOI más la suma de todas las duraciones de fijación y sacada antes de salir del AOI.	GD indica los tiempos de reacción al procesar una información dentro de un estímulo y un AOI. Ayudará a distinguir entre los participantes dependientes vs. los independientes del campo.
<i>Diversion Duration</i>	DD	La suma de todas las duraciones de las sacadas que entran y salen del AOI más la suma de todas las duraciones de las fijaciones y de las sacadas dentro del AOI antes de salir.	DD puede utilizarse para analizar la entrada, el tiempo de permanencia y el tiempo de salida de cada estímulo insertado en cada AOI.

Métrica	Acrónimo	Significado	Relación cognitiva
<i>Glance Count</i>	GC	Número de miradas a un objetivo (tomadas desde el exterior) en un periodo determinado con ambos ojos.	El GC ayuda a analizar los tiempos de reacción y su duración en diferentes estímulos. Esto proporciona información sobre cómo procesar la información en diferentes participantes.

Tabla 3. Variables y métricas en *eye tracking*, significado y unidad de medida.

Métrica	Significado	Unidad de medida
General		
<i>Participant variables</i>	Valores de los participantes	
<i>Timeline name</i>		
<i>Interval</i>	Número de intervalos dentro de la AOI	
AOI	Número de AOI	
Interval metrics		
<i>Duration of interval</i>	Duración de un intervalo	Milisegundos
Start of interval	Hora de inicio del intervalo	Milisegundos
Event metrics		
<i>Time to first Event</i>	Inicio del primer evento	Milisegundos
<i>Last key press</i>	Registro del último <i>keypress</i>	
AOI fixation metrics		
<i>Total duration of fixations</i>	Duración total de las fijaciones dentro de una AOI en un intervalo	Milisegundos
<i>Average duration of fixations</i>	Duración media de las fijaciones dentro de una AOI durante un intervalo	Milisegundos
<i>Minimum duration of fixations</i>	La duración más corta de una fijación dentro de una AOI durante un intervalo	Milisegundos
<i>Maximun duration of fixations</i>	La duración más larga de una fijación dentro de una AOI durante un intervalo	Milisegundos
<i>Number of fixations</i>	Número de fijaciones dentro de una AOI durante un intervalo	Frecuencia
<i>Time to first fixation</i>	Hora de la primera fijación dentro de una AOI de un intervalo	Milisegundos
<i>Duration of first fixation</i>	La duración de la primera fijación dentro de una AOI durante un intervalo	Milisegundos

Métrica	Significado	Unidad de medida
<i>Last AOI viewed</i>	Hace referencia a la última Área de Interés (AOI, <i>Area of Interest</i>) en la que se registró una fijación ocular del participante antes de finalizar la presentación del estímulo o antes de que se produzca un cambio de estímulo o intervalo de análisis.	
<i>AOI at Interval end</i>	Hace referencia al Área de Interés (AOI, <i>Area of Interest</i>) en la que se encuentra la mirada del participante en el momento exacto en que finaliza un intervalo de análisis o la presentación de un estímulo.	
<i>Average pupil diameter</i>	La media del diámetro de la pupila de todas las muestras de fijación en una AOI en un intervalo. Calculado utilizando el resultados del diámetro de la pupila aplicando un filtro.	Milímetros
AOI fixation metrics (exclude partial fixations)		
<i>Total duration of whole fixations</i>	Duración total de las fijaciones dentro de una AOI durante un intervalo.	Milisegundos
<i>Average duration of whole fixations</i>	Duración media de las fijaciones dentro de una AOI durante un intervalo.	Milisegundos
<i>Minimum duration of whole fixations</i>	Duración de la fijación más corta dentro de una AOI durante un intervalo.	Milisegundos
<i>Maximum duration of whole fixations</i>	Duración de la fijación más larga dentro de una AOI durante un intervalo.	Milisegundos
<i>Number of whole fixations</i>	Número de fijaciones que ocurren en una AOI durante un intervalo	Frecuencia
<i>Time of first whole fixation</i>	Hora de la primera fijación dentro de una AOI durante un intervalo	Milisegundos
<i>Duration of first whole fixation</i>	Duración de la primera fijación dentro de una AOI en un intervalo	Milisegundos
<i>Average whole-fixation pupil diameter</i>	Media del diámetro de la pupila de todas las muestras de fijaciones completas en una AOI en un intervalo.	Milímetros
AOI visit metrics		
<i>Total duration of Visit</i>	Duración total de visitas dentro de una AOI en un intervalo	Milisegundos
<i>Average duration of Visit</i>	Duración total de las visitas dentro de una AOI en un intervalo.	Milisegundos
<i>Minimum duration of Visit</i>	Duración de la visita más corta dentro de una AOI en un intervalo.	Milisegundos
<i>Maximum duration of Visit</i>	Duración de la visita más larga dentro de una AOI en un intervalo.	Milisegundos

Métrica	Significado	Unidad de medida
<i>Number of Visits</i>	Número de visitas dentro de una AOI en un intervalo	Frecuencia
<i>Time to first Visit</i>	Hora de la primera visita dentro de una AOI en un intervalo.	Milisegundos
<i>Duration of first Visit</i>	Duración de la primera visita dentro de una AOI en un intervalo.	Milisegundos
AOI Glance metrics		
<i>Total duration Glances</i>	Duración total de las miradas dentro de una AOI en un intervalo.	Milisegundos
<i>Average duration of Glances</i>	La duración media de las miradas dentro de una AOI en un intervalo.	Milisegundos
<i>Minimum duration Glances</i>	Duración de la mirada más corta dentro de una AOI en un intervalo.	Milisegundos
<i>Maximum duration Glances</i>	Duración de la mirada más larga dentro de una AOI en un intervalo.	Milisegundos
<i>Number of Glances</i>	Número de miradas dentro de una AOI en un intervalo.	Frecuencia
<i>Time to first Glance</i>	Hora de inicio de la primera mirada dentro de una AOI en un intervalo.	Milisegundos
<i>Duration of first Glance</i>	Duración de la primera mirada dentro de una AOI en un intervalo.	Milisegundos
AOI Click metrics		
<i>Number of mouse clicks</i>	Número de veces que se pulsa el botón izquierdo del ratón en una AOI durante un intervalo.	Frecuencia
<i>Time of first mouse click</i>	Tiempo transcurrido hasta la primera pulsación del botón izquierdo del ratón dentro de un AOI durante un intervalo.	Milisegundos
<i>Time from first fixation to mouse click</i>	Tiempo transcurrido desde la primera fijación en un AOI hasta la primera pulsación del botón izquierdo del ratón dentro de ese AOI durante un intervalo.	Milisegundos
<i>Number of mouse clicks & releases</i>	Número de acciones completas de clic (pulsación y liberación del botón izquierdo del ratón) realizadas dentro de un AOI durante un intervalo de tiempo.	Frecuencia
<i>Time to first mouse clicks & releases</i>	Tiempo transcurrido desde la primera fijación en un AOI hasta la primera acción completa de clic (pulsación y liberación del botón izquierdo del ratón) dentro de ese AOI durante un intervalo.	Milisegundos
AOI saccade metrics		
<i>Number of saccades in AOI</i>	Número de sacadas dentro de una AOI en un intervalo.	Frecuencia

Métrica	Significado	Unidad de medida
<i>Time to entry saccade</i>	Hora de la primera sacada dentro de una AOI en un intervalo.	Milisegundos
<i>Time to exit saccade</i>	Hora de la última sacada dentro de una AOI en un intervalo.	Milisegundos
<i>Peak velocity for entry saccade</i>	Pico de velocidad dentro de la primera sacada dentro de una AOI en un intervalo.	Grados/segundos
<i>Peak velocity for exit saccade</i>	Pico de velocidad dentro de la última sacada dentro de una AOI en un intervalo.	Grados/segundos
AOI reading metrics		
<i>Character index</i>	Índice del AOI a nivel de carácter dentro de su AOI a nivel de palabra	Posición
<i>Word index</i>	Índice del AOI a nivel de palabra dentro de su AOI a nivel de palabra	Posición
<i>Sentence index</i>	Índice del AOI a nivel de sentencia dentro de su AOI a nivel de palabra	Posición
<i>AOI string</i>	Cadena de texto que contiene una AOI	
<i>Text unit type</i>	Tipo de texto de la unidad: gráfico, palabra, sentencia.	
<i>Number of units</i>	Número de unidades	Frecuencia
<i>First-pass first fixation duration</i>	Duración de la primera fijación durante la primera visualización dentro de una AOI en un intervalo.	Milisegundos
<i>First-pass duration</i>	Duración total de las fijaciones durante la primera pasada dentro de un AOI durante un intervalo	Milisegundos
<i>Selective regression-path duration</i>	Duración total de las fijaciones desde la primera fijación en esta AOI hasta que se produce una fijación en una AOI progresiva a ésta, durante un intervalo. Anteriormente conocida como duración <i>Go-past</i> .	Milisegundos
<i>First-pass regression</i>	Indica si el lector sale de la AOI con una regresión (1) o sigue leyendo progresivamente (0).	Binaria
<i>Total duration of fixations</i>	La duración total de las fijaciones dentro de la AOI durante un intervalo.	Milisegundos
<i>Regression-path duration</i>	La duración total de las fijaciones desde la primera fijación en esta área de interés hasta que se produce una fijación en una AOI progresiva a ésta, incluidas las fijaciones en áreas de interés regresivas, durante un intervalo.	Milisegundos

Métrica	Significado	Unidad de medida
<i>Re-reading duration</i>	Duración de la trayectoria de regresión excluidas las fijaciones de la primera pasada durante un intervalo	Milisegundos

A continuación, se presentan ejemplos de aplicación e interpretación cognitiva de las métricas de *eye tracking*, en algunos ejemplos combinadas con métricas de otros dispositivos que serán más desarrolladas posteriormente. Es importante analizar estos significados en relación con la propuesta o interpretación de datos en distintos estudios. La numeración de estas tablas se mantiene respecto al artículo referenciado:

Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Escolar-Llamazares, M.C., Martín-Antón, L.J., & Velasco-Saiz, R. (2025). Monitoring university students' learning processes: application of Advanced Learning Technologies and integrated multichannel techniques. *Thinking Skills and Creativity*, 58, 101938. <https://doi.org/10.1016/j.tsc.2025.101938>

Table 2. Métricas integradas de seguimiento ocular multicanal y su importancia en relación con el uso de estrategias cognitivas y metacognitivas, p. 6.

Métricas	Significado	Relación con las estrategias cognitivas y metacognitivas
Fijaciones	Indica la atención del alumno a un estímulo en áreas relevantes frente a no relevantes. Proporciona información sobre el tipo de procesamiento de la información que el estímulo hace explícita.	Estrategias de orientación. Estrategias de Planificación.
Sacadas	Indica el paso de una fijación a otra dentro de un estímulo. La velocidad de los movimientos sacádicos implica el acceso a la información durante el procesamiento de la misma y depende del conocimiento previo y la comprensión de la información. La amplitud de la sacada está relacionada con el esfuerzo cognitivo que la tarea supone para el alumno.	Estrategias de orientación. Estrategias de Planificación.
Diámetro de la pupila	Se refiere al interés del alumno por la información. Un diámetro mayor se refiere al interés por la información que es relevante para el alumno o la alumna.	Estrategias de orientación.
Amplitud GSR	Se refiere al GSR. Está relacionado con el interés en el estímulo y se refiere a una alta carga cognitiva y un alto nivel de excitación emocional.	Estrategias de orientación.

Métricas	Significado	Relación con las estrategias cognitivas y metacognitivas
SCR (<i>skin conductance response</i>) count	Se refiere al número de respuestas de conductancia de la piel (SCR) en cada intervalo de tiempo de interés. Las puntuaciones altas indican un alto nivel de carga cognitiva y un alto nivel de activación.	Estrategias de orientación.

Table 3. Modelos explicativos del proceso de aprendizaje en el b-Learning utilizando ALT, p. 6.

Modelo	Espacios para el análisis	Método de captura de datos	Procesamiento de datos	Análisis cognitivo y metacognitivo
Chango et al. (2022) basado en el Modelo de Mu et al. (2020)	Espacio digital	Tipo de <i>Learning Management Systems</i> (LMS)	Datos sobre tecnología educativa	
	Espacio físico	Sensores	Datos de comportamiento externo	
	Espacio psicológico	EEG y ECG (electrocardiograma)	Intrinsic physiological data Datos fisiológicos intrínsecos	
	Espacio psicométrico	Autoinformes y cuestionarios	Datos psicométricos	
Molenaar et al. (2023)	Espacio medioambiental	Análisis del espacio físico (temperatura, iluminación, etc.)	Datos sobre el entorno de aprendizaje	
	Contextual	Autoinformes (encuesta, entrevista, datos de vídeo, datos de voz, diálogo, pensamiento en voz alta)		Estrategias cognitivas y metacognitivas, estados afectivos y motivación.
	Conductual	Datos de registro, seguimiento ocular, ratón y teclado.		Estrategias cognitivas y metacognitivas
	Fisiológico	EDA y EEG		estados afectivos y motivación
Sáiz-Manzanares et al. (2024)	Espacio digital	Tipo de recursos de aprendizaje aplicados en el LMS	Datos sobre tecnología educativa	Estrategias metacognitivas para la orientación, la planificación, la evaluación y la elaboración

Modelo	Espacios para el análisis	Método de captura de datos	Procesamiento de datos	Análisis cognitivo y metacognitivo
	Características personales del alumno	Datos sobre edad, género, conocimientos previos sobre la tarea, tipo de titulación, autoinformes sobre el uso percibido de estrategias metacognitivas.	Selección de características	Estrategias metacognitivas medidas fuera de línea (Schellings et al., 2023)
	Indicadores de la carga cognitiva de la tarea a realizar	Comportamental (seguimiento ocular: fijaciones, sacadas, diámetro de la pupila, etc.)	Características Técnicas de aprendizaje automático supervisado (predicción y clasificación)	Estrategias cognitivas y metacognitivas medidas en línea (Schellings et al., 2023).
		Fisiológico (GSR y SCR)	Características Técnicas de aprendizaje automático supervisado (predicción y clasificación)	Estrategias cognitivas y metacognitivas medidas en línea (Schellings et al., 2023), estados motivacionales.

Nota. Se utilizan los términos EDA o GSR según la nomenclatura de los autores, aunque ambos se refieren a registros de actividad electrodérmica en diversos entornos o ante diversos estímulos.

Sáiz-Manzanares, M. C., Marticorena-Sánchez, R., Sáez-García, J., & González-Díez, I. (2024). Analysing Virtual Labs Through Integrated Multi-Channel Eye-Tracking Technology: A Proposal for an Explanatory Fit Model. *Applied Sciences*, 14(21), 9831. <https://doi.org/10.3390/app14219831>

Tabla 1. Lista de elementos que deben tenerse en cuenta en el espacio de realización de tareas y los indicadores de medición, p. 4.

Elementos a considerar	Medición
Características de la tarea, indicadores de la carga cognitiva extrínseca (forma de presentación de la tarea (visual—imagen, texto, etc.) y carga cognitiva extrínseca escrita, auditiva, todas), entorno de aprendizaje multimedia, simulación, calendario de ejecución de la tarea, etc.	Descripción del tipo de tarea Análisis de la presentación de la tarea
Espacio físico [características del espacio en el que se desarrolla la tarea (iluminación, espacio, etc.)].	Indicadores de brillo, temperatura, ruido, hora y hora del día.
Características del alumnado (edad, género, conocimientos previos, motivación hacia la tarea, forma de responder, forma de resolver, tipo de razonamiento aplicado, etc.).	Variables asignadas (edad, género, etc.) Análisis de conocimientos previos Estilo cognitivo y estilo de aprendizaje

Elementos a considerar	Medición
Indicadores fisiológicos de la carga cognitiva intrínseca	Diámetro de la pupila Fijaciones Sacadas Amplitud GSR Recuento SCR
Percepción de la carga germana	Indicadores de rendimiento en la ejecución de la tarea

Sáiz-Manzanares, M.C., Marticorena-Sánchez, R.; Escolar-Llamazares, M.C., González-Díez, I., Martín Antón, L.J. (2024). Using integrated multimodal technology: a way to personalised learning in Health Sciences and Biomedical engineering Students. *Applied Sciences*, 14(16), 7017. <https://doi.org/10.3390/app14167017>

Tabla 1. Indicadores de registro multimodal en el procesamiento de la información, p. 3.

Tipo de instrumento de medición	Sensor	Significado	Implicaciones neurológicas	Implicaciones cognitivas y metacognitivas
Actividad electrodérmica	Electrodos en diferentes partes del cuerpo (por ejemplo, los dedos). La respuesta psicogalvánica de la piel (GSR) No invasiva.	Variación eléctrica en la conductancia de la piel. Cambios en el nivel de sudoración de la piel causados por respuestas emocionales.	Cambios en el sistema nervioso parasimpático.	Carga cognitiva y nivel de activación.
<i>Eye tracking</i>	Los rayos infrarrojos registran el movimiento ocular. Es un método no invasivo. Sin embargo, no se recomienda para personas que padecen epilepsia.	Se pueden registrar diversas métricas.	Son indicadores de entrada de información visual, auditiva y/o escrita. La duración, la velocidad, etc., en cada parámetro son indicadores indirectos del procesamiento de esa información. Procesamiento de un estímulo. Las fijaciones indican la frecuencia, la duración, la velocidad, etc., de la posición del ojo en las coordenadas x e y del estímulo.	

Tipo de instrumento de medición	Sensor	Significado	Implicaciones neurológicas	Implicaciones cognitivas y metacognitivas
		Fijaciones (frecuencia, duración, velocidad, etc.).	Procesamiento de un estímulo. Las fijaciones indican la frecuencia, duración, velocidad, etc., de la posición ocular en las coordenadas x e y del estímulo.	Atención selectiva. Carga cognitiva. Pueden ser indicadores de interés o de esfuerzo en el procesamiento.
		Sacadas (frecuencia, duración, velocidad, etc.).	Procesamiento de un estímulo. Las sacadas indican el paso de la fijación de un estímulo a otro.	Una mayor amplitud de la sacada puede indicar un menor esfuerzo cognitivo o problemas para comprender la información.
		Diámetro de la pupila	La dilatación o contracción de la pupila del ojo.	Un diámetro pupilar mayor se asocia con una mayor carga cognitiva y puede indicar mayores problemas para procesar la información de los estímulos.
		Mediciones dinámicas de la trayectoria del escaneo o del punto de mirada (registro de las coordenadas espaciales de la fijación y la sacada y posicionamiento ordinal de estos registros).	Ruta de seguimiento en un proceso de aprendizaje.	Los patrones de procesamiento de la información son diferentes para cada estudiante, aunque se pueden encontrar similitudes o diferencias que proporcionan información sobre los estilos de aprendizaje.
	En la tecnología de seguimiento ocular, se puede activar una cámara para grabar las expresiones faciales mientras se resuelve una tarea o un problema. No es invasiva. Sin embargo, los usuarios deben ser conscientes de que se está grabando su rostro y deben dar su consentimiento.	Software de reconocimiento facial.	Asociación emocional con el procesamiento de la información.	Expresión de emociones

Tipo de instrumento de medición	Sensor	Significado	Implicaciones neurológicas	Implicaciones cognitivas y metacognitivas
Registro electroencefalográfico	Los electrodos que recogen la actividad cerebral pueden ser secos (diadema) o semisecos (electrodos que deben humedecerse). Los primeros son menos invasivos.	Se trata de un registro de la actividad eléctrica del cerebro en sus diferentes áreas.	Actividad cerebral en diferentes áreas (frontal, prefrontal, temporal, parietal). La actividad puede ser excitatoria o inhibitoria.	Procesamiento de la información a partir del análisis de la activación cerebral en diferentes áreas. Las áreas frontal y prefrontal están especialmente relacionadas con la planificación y la resolución de problemas.

Tabla 2. Indicadores en el seguimiento ocular multimodal integrado y su importancia en el procesamiento de la información, p. 5.

Métricas	Significado	Indicador de medición	Significado cognitivo y metacognitivo
<i>Average duration</i>	La duración de la visualización del laboratorio virtual	milisegundos	El tiempo medio de visualización del laboratorio virtual está relacionado con los tiempos de reacción del participante en el procesamiento de la información. Una duración más larga o más corta dependerá de los conocimientos previos del sujeto y de su forma de procesar la información.
<i>Total Time Interest duration</i>	Define intervalos de tiempo basados en eventos registrados y almacenados.	milisegundos	Define el interés en los diferentes elementos del estímulo.
<i>Fixation point X</i>	Píxeles (Sistema de coordenadas del área de visualización, DACS)	Las fijaciones indican atención a los estímulos que son relevantes para el alumno, en este caso en el eje X.	Estos están relacionados con la forma en que cada participante procesa la información. En este estudio, la actividad fue regulada por avatares; por lo tanto, se minimizó la atención a estímulos irrelevantes.

Métricas	Significado	Indicador de medición	Significado cognitivo y metacognitivo
<i>Fixation point Y</i>	Píxeles (DACS)	Las fijaciones indican atención a los estímulos que son relevantes para el alumno, en este caso en el eje Y.	
<i>Average pupil diameter</i>	Diámetro medio de la pupila durante la fijación	milisegundos	Se refiere al interés del participante. En este estudio, se refiere al contenido. Un diámetro mayor puede indicar un mayor interés en la información o que la información es muy nueva.
<i>Saccade direction</i>	El ángulo de la línea recta entre la fijación precedente y la fijación sucesiva. Esto solo se puede aplicar a sacadas completas.	grados	Se refiere a la dirección en el espacio del laboratorio hacia la cual se dirigen las sacadas oculares.
<i>Saccade average velocity</i>	La velocidad media en todas las muestras pertenecientes a la sacada, incluso fuera del intervalo.	grados/segundo	Implica la transición de un estímulo a otro. En este estudio, se realiza dentro del laboratorio. Se refiere a la velocidad de procesamiento de la información, y esta depende del conocimiento previo y la comprensión de la información.
<i>Saccade peak velocity</i>	La velocidad máxima en todas las muestras pertenecientes a la sacada, incluso fuera del intervalo.	grados/segundo	Se refiere a la velocidad máxima pico de la sacada en la visualización del estímulo.
<i>Saccade amplitude</i>	La amplitud para todas las sacadas oculares	grados	La amplitud de la sacada se refiere al esfuerzo cognitivo de los participantes.
<i>GSR amplitude</i>	La señal media de respuesta galvánica de la piel (GSR), tras el filtrado, para cada momento de interés, con medias, medianas y recuentos para cada participante.	microsiemens	La amplitud de la GSR está relacionada con el interés del alumno. Las puntuaciones más altas indican una mayor carga cognitiva y un mayor nivel de activación.

Métricas	Significado	Indicador de medición	Significado cognitivo y metacognitivo
<i>SCR count</i>	El número de respuestas de conductancia cutánea, para cada intervalo en el tiempo de interés con promedios, medianas, recuentos, varianzas y desviaciones estándar ($n - 1$).	recuento	Se refiere a las respuestas de conductancia a la presentación del estímulo. Las puntuaciones más altas indican una mayor carga cognitiva y un mayor nivel de activación.

Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Martín-Antón, L.J., González-Diez, I., & Carbonero-Martín, I. (2023). Using eye tracking technology to analyse cognitive load in multichannel activities in university students. *International Journal of Human-Computer Interaction*, 40(12), 3263–328. <https://doi.org/10.1080/10447318.2023.2188532>

Table 1. List of metrics in *eye tracking*, their meaning and relationship with analysis of learning strategies, p.3.

Métrica	Acrónimo	Unidad de medida	Significado de la métrica	Relación con las estrategias cognitivas y metacognitivas
<i>Fixation count</i>	FC	Frecuencia	Un mayor número de fijaciones en un estímulo puede indicar que el alumno tiene menos conocimientos sobre la tarea o dificultad para distinguir entre información relevante vs. no relevante. Es una medida de búsqueda global.	Un indicador de la aplicación de estrategias metacognitivas de adquisición (Roman Sánchez y Gallego Rico, 2008) o, según Veenman (2017), estrategias de orientación. Estas se refieren al «qué» en el proceso de resolución.
<i>Fixation duration</i>	FD	Milisegundos	Es un indicador del grado de interés y los tiempos de reacción del alumno. Las duraciones más largas suelen estar asociadas a un procesamiento cognitivo más profundo y a un mayor esfuerzo. La duración de las fijaciones proporciona información sobre el proceso de búsqueda.	

Métrica	Acrónimo	Unidad de medida	Significado de la métrica	Relación con las estrategias cognitivas y metacognitivas
<i>Saccade count</i>	SC	Frecuencia	Hace referencia al número de sacadas en cada estímulo. Cuanto mayor sea la amplitud de la sacada, menor será el esfuerzo cognitivo. Sin embargo, también puede referirse a problemas en la comprensión de la información.	Un mayor número de sacadas sugiere un mayor uso de estrategias de focalización (según la clasificación de Veenman, 2017).
<i>Gaze point</i>	GP	Posición en los ejes X e Y en el estímulo		El estudio de los patrones de comportamiento del alumno facilitará el desarrollo de la orientación por parte del personal docente con el fin de lograr un aprendizaje lo más personalizado posible.
<i>Pupil diameter</i>	PD	Milímetros	Se recopila el diámetro pupilar medio para todas las fijaciones dentro de un AOI durante un intervalo de tiempo.	Puede proporcionar información sobre el nivel de atención o interés en la información proporcionada por el estímulo. Un diámetro pupilar mayor puede estar relacionado con una mayor carga cognitiva, así como con dificultad en el procesamiento de una tarea.
<i>Number of visitor revisits</i>	V	Frecuencia	Se refiere al número de visitas dentro de un AOI durante un intervalo de tiempo.	Puede ser un indicador de atención e interés en una información. O puede ser un indicador de la dificultad de la información para el alumno.

Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Martín-Antón, L.J., Almeida, L., & Carbonero-Martín, I. (2023). Application and challenges of eye tracking technology in Higher Education. *Comunicar*, 76, 1-12. <https://doi.org/10.3916/C76-2023-03>

Tabla 1. Métricas en la tecnología *eye tracking* y su significado en el proceso de aprendizaje, p. 36.

Métrica	Significado	Implicación en el proceso de aprendizaje
<i>Fixation Count</i> (FC)	Un mayor número de fijaciones en un estímulo puede indicar que el estudiante tiene menos conocimientos sobre la tarea o dificultad para discriminar la información relevante vs. no relevante. Es una medida de búsqueda global.	Puede servir para discriminar a los estudiantes noveles vs. experimentados y estudiantes dependientes de campo vs. independientes.
<i>Fixation Duration</i> (FD)	Es un indicador del grado de interés y de los tiempos de respuesta del estudiante. Una mayor duración se puede deber a un procesamiento de la información más profundo. La duración de la fijación proporciona información sobre el proceso de búsqueda y concentración.	Puede ayudar a discriminar el grado de reflexión aplicado por cada estudiante durante la resolución de una tarea (e.g. diferenciando los estudiantes impulsivos vs. reflexivos).
<i>Saccade Count</i> (SC)	Hace referencia al número de sacadas utilizadas en cada estímulo. Cuanto mayor sea la amplitud de la sacada, menor será el esfuerzo cognitivo. No obstante, también puede hacer referencia a problemas de comprensión de la información.	Un mayor número de sacadas hace referencia a que el estudiante utiliza más estrategias de orientación para la realización de la tarea. También, puede indicar un nivel menor de conocimientos previos.
<i>Pupil diameter</i> (PD)	<i>Eye tracking</i> recoge la media del diámetro de la pupila en todas las fijaciones dentro de un área de Interés (AOI) en un intervalo de tiempo.	Informa sobre el nivel atencional o el interés del estudiante respecto del estímulo. Un mayor diámetro de la pupila se puede relacionar con una mayor carga cognitiva o con la dificultad de procesar una tarea.
<i>Visit count</i> (VC)	Hace referencia al número de visitas dentro de una AOI durante un intervalo de tiempo.	Puede ser un indicador de la atención e interés del estudiante en una parte de la información. O bien, un indicador de la dificultad que dicha información tiene para él.”

Sáiz-Manzanares, M.C., Payo Hernanz, R.J., Zaparaín Yáñez, M.J., Andrés López, G., Marticorena Sánchez, R., Calvo Rodríguez, A., Martín, C., y Rodríguez Arribas, S. (2021). Eye-tracking Technology and Data-mining Techniques used for a Behavioral Analysis of Adults engaged in Learning Processes. *Journal of Visualized Experiments*. <https://doi.org/10.3390/10.3791/62103>

Tabla 1. Parámetros representativos que se pueden obtener con la técnica de seguimiento ocular, adaptada de Sáiz, Zaparaín, Marticorena y Velasco (2019).

Métricas	Acrónimos	Concepto	Implicaciones en el aprendizaje
<i>Dwell Time</i>	DWT	Duración a lo largo del tiempo de todas las fijaciones y sacadas dentro de un AOI, incluidas las revisitas (salidas y reentradas) de todos los participantes en el estudio dividida por el número de participantes.	DWT se refiere al interés de un participante en un estímulo dentro de una AOI determinado. La información es relevante para el profesor, en la medida en que puede facilitar el desarrollo de programas de intervención personalizados.
<i>Glance Duration</i>	GD	Duración de la sacada al entrar en el AOI más la suma de todas las duraciones de fijación y sacada antes de salir del AOI.	GD indica los tiempos de reacción al procesar una información dentro de un estímulo y una AOI. Ayudará a distinguir entre participantes dependientes del campo y participantes independientes del campo.
<i>Diversion Duration</i>	DD	La suma de todas las duraciones de sacadas entrando y saliendo del AOI más la suma de todas las duraciones de fijación y duraciones de sacadas dentro del AOI antes de salir.	DD se puede utilizar para analizar la entrada, el tiempo de permanencia y el tiempo de salida de cada estímulo insertado en cada AOI.
<i>Glance Count</i>	GC	Número de miradas a un objetivo (tomadas desde fuera) con ambos ojos durante un periodo determinado.	El GC ayuda a analizar los tiempos de reacción y su duración ante diferentes estímulos. Esto proporciona información sobre cómo procesan la información los diferentes participantes.
<i>Fixation Count</i>	FC	Número de fijaciones de todos los estímulos seleccionados.	FC alto implica un mayor número de fijaciones en un estímulo, lo que indica que los participantes pueden tener menos conocimientos sobre la tarea o tener dificultades para discriminar entre lo relevante vs. lo irrelevante.
<i>Fixation Duration Average</i>	FDA	Duración media de la fijación	Una FDA más larga implica que el participante dedica más tiempo a analizar e interpretar el contenido de la información dentro de las distintas AOI.

Sáiz-Manzanares, M.C., Ramos Pérez, I., Arnaiz-Rodríguez, Á., Rodríguez-Arribas, S., Almeida, L., & Martin, C.F. (2021). Analysis of the learning process through eye tracking technology and feature selection techniques. *Applied Sciences*, *11*, 6157, 1-24. <https://doi.org/10.3390/app11136157>

Tabla 1. Parámetros más representativos que se pueden obtener con la técnica de seguimiento ocular y su importancia en el procesamiento de la información, p. 3.

Métrica	Acrónimo	Significado de la métrica	Implicaciones en el proceso de aprendizaje
<i>Fixation Count</i>	FC	Cuenta el número de enlaces específicos en las AOI en todos los estímulos.	Un mayor número y frecuencia de fijaciones en un estímulo puede indicar que el alumno o la alumna tiene menos conocimientos sobre la tarea o dificultades para discriminar entre información relevante y no relevante. Se trata de medidas del rendimiento global en la búsqueda.
<i>Fixation Frequency count</i>	FFC		
<i>Fixation Duration</i>	FD	Duración de la fijación	Da una indicación del grado de interés y los tiempos de reacción del alumno. Una mayor duración suele asociarse con un procesamiento cognitivo más profundo y un mayor esfuerzo. En el caso de textos más complicados, el usuario tiene una duración media de fijación más larga. La duración de la fijación proporciona información sobre el proceso de búsqueda.
<i>Fixation Duration Average</i>	AFD	Duración media de la fijación	Las fijaciones más prolongadas se refieren al tiempo que el alumno dedica a analizar e interpretar el contenido informativo dentro de las diferentes áreas de interés (AOI). Se considera que la duración media oscila entre 200 ms y 260 ms.
<i>Fixation Duration Maximum</i>	FDMa	Duración máxima de la fijación	Se refieren a los tiempos de reacción.
<i>Fixation Duration Minimum</i>	FDMi	Duración mínima de la fijación	
<i>Fixation Dispersion Total</i>	FDT	Suma de todas las dispersiones de fijaciones en X e Y.	Se refiere a la percepción de la información en los diferentes componentes de la tarea.
<i>Fixation Dispersion Average</i>	FDiSA	Suma de todas las dispersiones de fijación en X e Y dividida por el número de fijaciones en la prueba.	Analiza las dispersiones en cada una de las fijaciones en los diferentes estímulos.

Métrica	Acrónimo	Significado de la métrica	Implicaciones en el proceso de aprendizaje
<i>Saccades Count</i>	SC	Número total de sacadas en cada uno de los estímulos.	Un mayor número de sacadas implica mayores estrategias de búsqueda. Cuanto mayor sea la amplitud de la sacada, menor será el esfuerzo cognitivo. También puede referirse a problemas para comprender la información.
<i>Saccade Frequency count</i>	SFC	Suma de todas las sacadas	Se refieren a la frecuencia de uso de las sacadas oculares relacionadas con las estrategias de búsqueda.
<i>Saccade Duration Total</i>	SDT	Suma de la duración de todas las sacadas.	
<i>Saccades Duration Average</i>	SDA	Duración media de las sacadas oculares en cada una de las AOI	Permite distinguir entre alumnos dependientes del campo y alumnos independientes del campo.
<i>Saccade Duration Maximum</i>	SDMa	Duración máxima de la sacada.	Se refieren a la percepción de la información en diferentes componentes de la tarea.
<i>Saccade Duration Minimum</i>	SDMi	Duración mínima de la sacada.	
<i>Saccade Amplitude Total</i>	SAT	Suma de la amplitud de todas las sacadas oculares	Los aprendices noveles suelen tener sacadas más cortas.
<i>Saccade Amplitude Maximum</i>	SAMa	Amplitud máxima de la sacada	
<i>Saccade Amplitude Minimum</i>	SAMi	Mínimo de la amplitud sacádica	
<i>Saccade Velocity Total</i>	SVT	Suma de la velocidad de todas las sacadas oculares	Están directamente relacionados con la velocidad de procesamiento de la información al pasar de un elemento a otro dentro de un estímulo.
<i>Saccade Velocity Maximum</i>	SVMa	Valor máximo de la velocidad sacádica	
<i>Saccade Velocity Minimum</i>	SVMi	Valor mínimo de la velocidad de la sacada	

Métrica	Acrónimo	Significado de la métrica	Implicaciones en el proceso de aprendizaje
<i>Saccade Latency Average</i>	SLA	Es igual al tiempo transcurrido entre el final de una sacada y el inicio de la siguiente.	Está directamente relacionado con los tiempos de reacción en el procesamiento de la información. La latencia inicial de la sacada proporciona información temporal detallada sobre el proceso de búsqueda.
<i>Blink Count</i>	BC	Número de parpadeos en la prueba	Está relacionado con la velocidad de procesamiento de la información. Los estudiantes principiantes informan de una mayor frecuencia.
<i>Blink Frequency count</i>	BFC	Número de parpadeos de todas las pruebas seleccionadas por segundo dividido por el número de pruebas seleccionadas.	Los parpadeos están relacionados con el procesamiento de la información durante la exposición a un estímulo para generar la siguiente acción. Los alumnos con un procesamiento de la información más rápido pueden tener parpadeos más cortos y de menor duración. Sin embargo, esta acción también puede producirse cuando existen problemas de déficit de atención. Estos resultados deberán compararse con los obtenidos en las demás métricas para ajustar la explicación de estos resultados dentro del análisis de un patrón de aprendizaje.
<i>Blink Duration Total</i>	BDT	Suma de la duración de todos los parpadeos de las pruebas seleccionadas dividida por el número de pruebas seleccionadas.	
<i>Blink Duration Average</i>	BDA	La suma de la duración de todos los parpadeos de todas las pruebas seleccionadas dividida por el número de pruebas seleccionadas.	
<i>Blink Duration Maximum</i>	BDMa	La mayor duración de los parpadeos registrados.	
<i>Blink Duration Minimum</i>	BDMi	La duración más corta de los parpadeos registrados	

Métrica	Acrónimo	Significado de la métrica	Implicaciones en el proceso de aprendizaje
Scan Path Length	SPL	Proporciona un patrón de comportamientos de aprendizaje para cada usuario.	El estudio de los patrones de comportamiento del aprendizaje facilitará al profesor la realización de orientaciones personalizadas atendiendo a la forma de aprender de cada estudiante. La longitud de la trayectoria de exploración proporciona información sobre los tiempos de reacción en tareas sin duración predeterminada.

En la **Figura 20** se muestra un ejemplo de definición de AOI utilizando un dispositivo **iView XTM** junto con **SMI Experimenter Center 3.0** y **SMI BeGaze™**, en un monitor con resolución de **1680 × 1050**. Con esta configuración se registraron los **movimientos oculares**, las **coordenadas de la mirada** y el **diámetro pupilar de cada ojo**. En este estudio se utilizó una **frecuencia de muestreo de 60 Hz**.

Otro ejemplo de definición de AOI se presenta en la **Figura 21**, utilizando un dispositivo **Tobii Pro Lab**, en el que se aplicó una **frecuencia de muestreo de 64 Hz**. Estos ejemplos ilustran cómo diferentes dispositivos y frecuencias de muestreo permiten registrar datos precisos de la mirada para su análisis posterior en términos de fijaciones, trayectorias y otros parámetros.




Figura 20. Definición de AOI en un dispositivo iViwe XTM, SMI Experimenter Center 3.0 y SMI BeGaze™ (fuente propia).

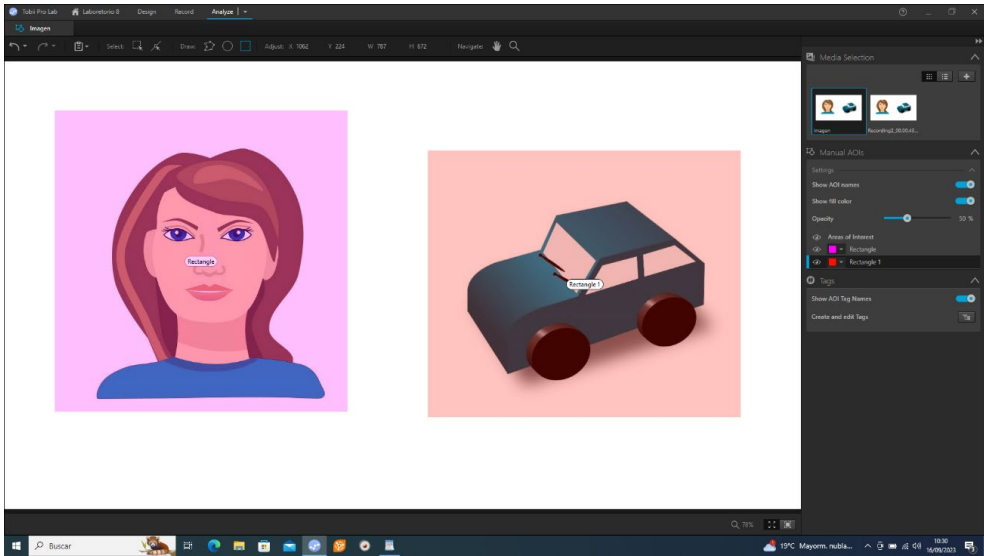


Figura 21. Definición de AOI en un dispositivo Tobii Pro Lab v. 24.21.435 (x64) (fuente propia).

Asimismo, en la **Figura 22** se puede consultar un ejemplo de un *scan path* realizado con el dispositivo iViwe XTM, SMI Experimenter Center 3.0 y SMI BeGaze™ y en la **Figura 23** un ejemplo realizado con el dispositivo Tobii Pro Lab v. 24.21.435 (x64).

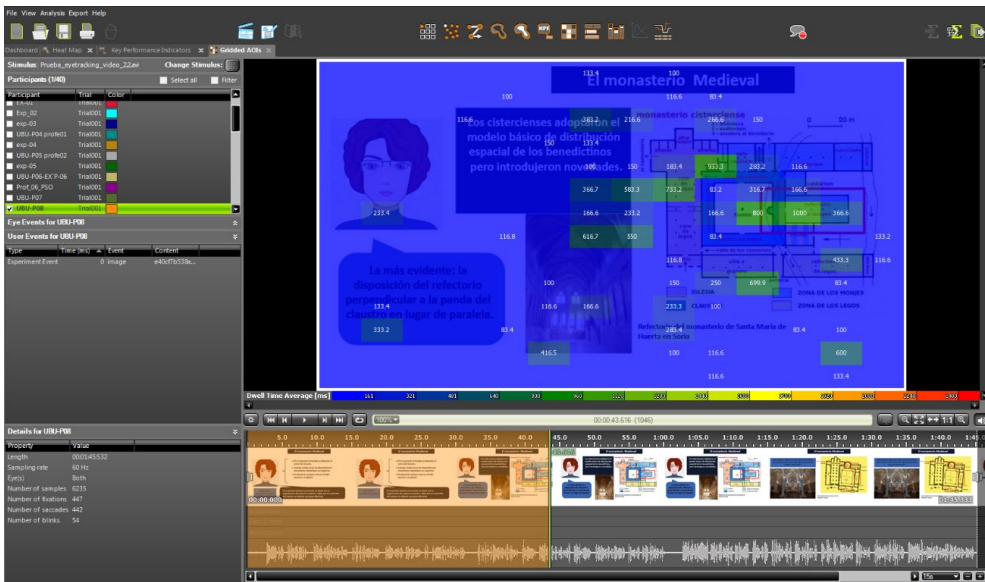


Figura 22. *Scan path* realizado con un dispositivo iViwe XTM, SMI Experimenter Center 3.0 y SMI BeGaze™ (fuente propia).

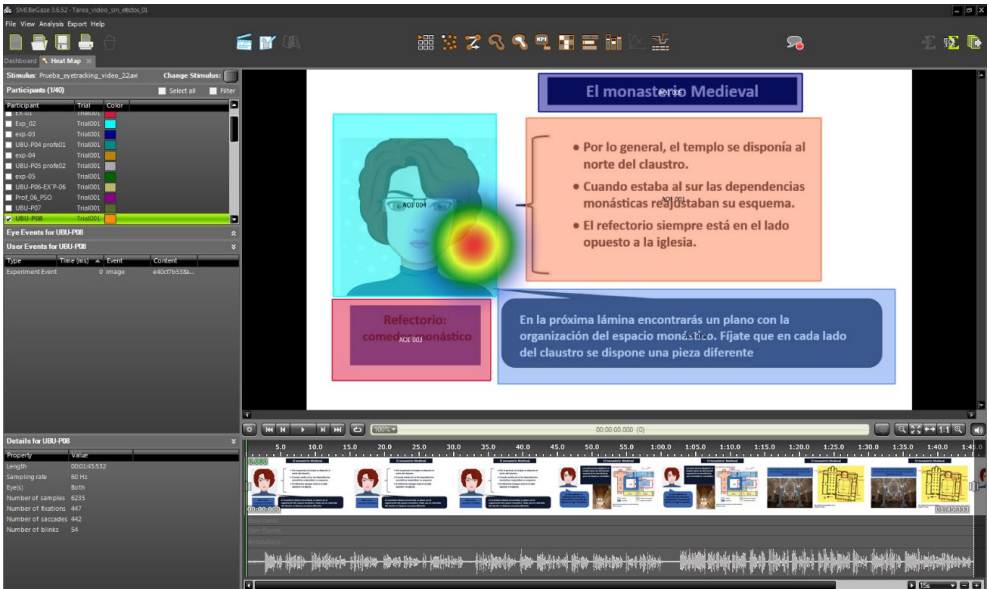


Figura 25. Gaze point realizado con un dispositivo iViwe XTM, SMI Experimenter Center 3.0 y SMI BeGazeTM.

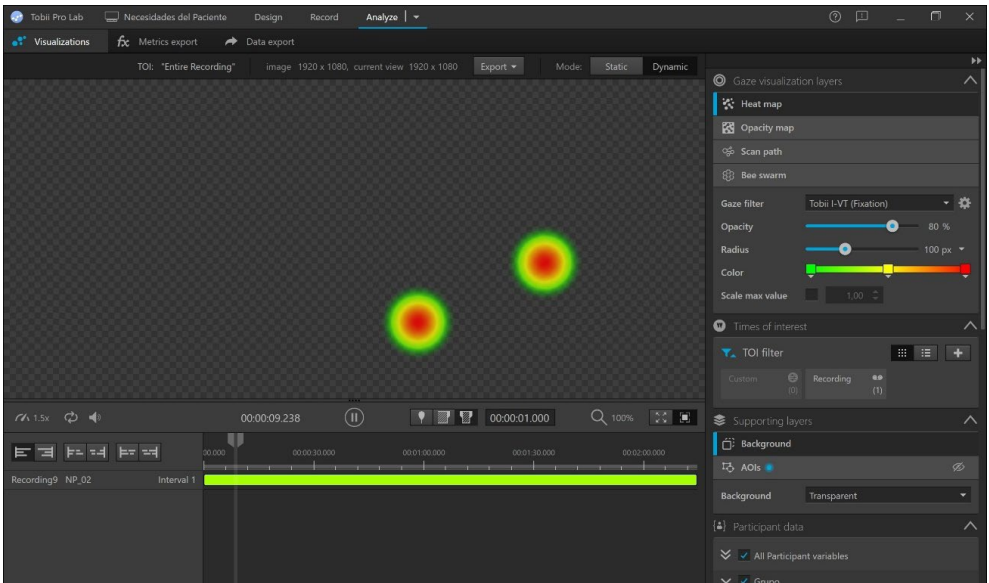


Figura 26. Gaze point realizado con un dispositivo Tobii Pro Lab v. 24.21.435 (x64).

2.2. Incorporación integrada de otros dispositivos

Actualmente se está potenciando la **integración de eye tracking** con otros dispositivos, como aquellos que registran *Galvanic Skin Response (GSR)* o actividad

electroencefalográfica (EEG). Esto permite estudiar no solo hacia dónde se dirige la mirada, sino también **respuestas fisiológicas y emocionales** de los participantes en tiempo real.

A. Caso de estudio: *Eye tracking* y principales funcionalidades de Shimmer GSR:

El dispositivo Tobii Pro Lab permite integrar señales de GSR procedentes de distintos equipos. Un ejemplo frecuente es el Shimmer GSR, un dispositivo portátil ampliamente utilizado en psicofisiología, experiencia de usuario (UX) e investigación clínica. Seguidamente, se describe sus funcionalidades.

- **Medición de conductancia/actividad electrodérmica (EDA/GSR):**
 - Registra cambios en la conductancia de la piel asociados con la actividad del **sistema nervioso simpático** (respuesta emocional, estrés, excitación).
 - Compatible con **electrodos adhesivos o de clip** en dedos o palmas.
- **Registro de frecuencia cardíaca y variabilidad (HRV/PPG/ECG opcional).**
- **Acelerómetro integrado (3 ejes):**
 - Detecta movimiento y posición, ayudando a controlar **artefactos de movimiento** durante la recolección de datos.
- **Conectividad:**
 - **Bluetooth** para transmisión en tiempo real.
 - **Almacenamiento en tarjeta microSD** para estudios de campo sin conexión continua.
- **Flexibilidad en la adquisición de datos:**
 - Frecuencia de muestreo configurable, hasta varios cientos de Hz según el sensor.
 - Integración con software como **ConsensysPRO** y exportación a entornos como **MATLAB o LabVIEW**.
- **Portabilidad:**
 - Dispositivo pequeño, ligero y adecuado para estudios en **laboratorio** o en **entornos naturales**.

En la **Figura 27** se muestra la **conexión del Shimmer GSR con Tobii Pro Lab**. Asimismo, en la **Figura 28** se ilustra el **procesamiento de la señal**. También, en la **Figura 29** se presenta un ejemplo de aplicación en un **sujeto experimental**.

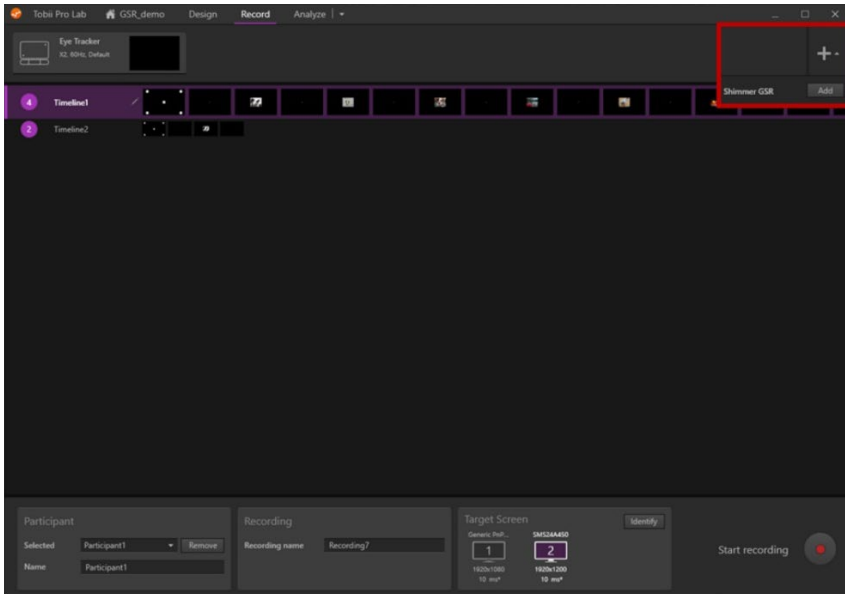


Figura 27. Conexión de un dispositivo Shimmer en un dispositivo Tobii Pro Lab (fuente propia).

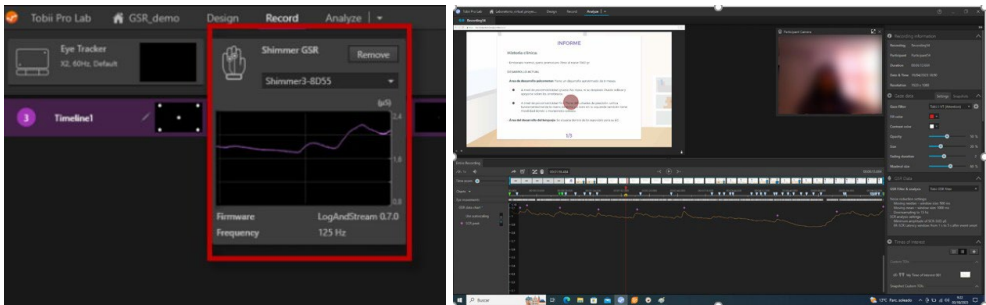


Figura 28. Procesamiento de la señal de un dispositivo Shimmer en un dispositivo Tobii Pro Lab (fuente propia).



Figura 29. Dispositivo Shimmer en un dispositivo experimental (fuente propia).

Tobii Pro Lab aplica un proceso de filtrado y detección automática de respuestas en la conductancia de la piel —*Skin Conductance Responses* (SCRs)— con estas métricas específicas:

- Filtrado del ruido: Se aplica primero un filtro de mediana (500 ms) y luego un filtro de media (1000 ms) para eliminar variaciones rápidas y artefactos.
- Reducción de la frecuencia de muestreo: El software reduce la tasa original del sensor (125 Hz) mediante decimación (sin interpolación), con un factor de reducción de 8, lo que da como resultado un muestreo final de aproximadamente 15 Hz.
- Detección de SCRs: Se utiliza un método estándar de detección de picos (*trough-to-peak*). Se identifica un SCR cuando la amplitud entre un valle (mínimo) y un pico supera 0,03 μ S.

Métricas calculadas para cada SCR detectado:

Average GSR = La media de la señal GSR después de filtrado en un intervalo.

Number of SCR = Número de skin conductance responses (SCRs) para cada intervalo.

Amplitude of event related SCR = La amplitud de cada evento respuesta de conductancia de la piel relacionada (ER-SCR), durante un intervalo. ER-SCR.

A partir de esta integración, es posible **sincronizar múltiples fuentes de información de forma multimodal**:

- Señales de *eye tracking*.
- Imagen del participante para **reconocimiento facial**.
- **Micrófono** para capturar datos de voz.
- Señal de **GSR**.

Un ejemplo de esta integración se muestra en la **Figura 30**, donde se visualizan las distintas señales sincronizadas para un análisis completo de la interacción fisiológica y conductual del participante.

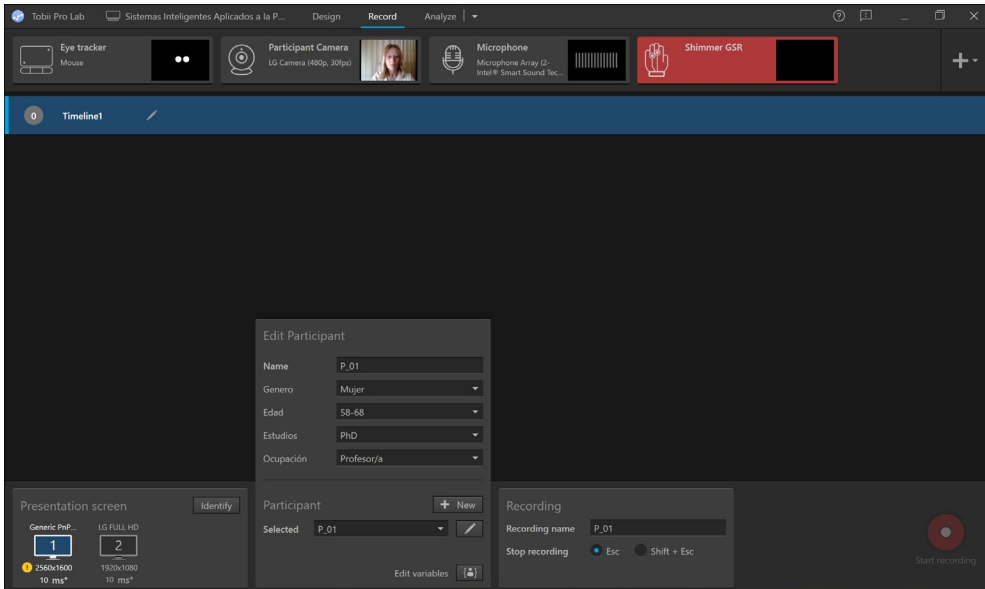


Figura 30. Registro de distintas señales de información en un dispositivo de *eye tracking* (fuente propia).

B. Caso de estudio: *Eye tracking* combinado con Registro Encefalográfico (EEG) de Bitbrain

Además de los dispositivos de GSR y otros sensores fisiológicos, es posible integrar señales de EEG junto con los registros de *eye tracking*. Esta integración permite sincronizar los datos de seguimiento ocular con la actividad cerebral, proporcionando información sobre los procesos cognitivos que ocurren durante la realización de tareas visuales, auditivas o multimodales.

Los dispositivos de EEG permiten registrar señales cerebrales mediante **electrodos secos o semisecos**, con configuraciones variables según el equipo: **8, 12, 16, 32 o 64 canales**.

- Los sensores están diseñados para ofrecer **monitorización versátil**, con alta precisión incluso en **situaciones de movimiento**, lo que permite estudios en laboratorio o en entornos naturales.
- Los **canales EEG** pueden colocarse en distintas regiones del cerebro según los objetivos del estudio áreas: **frontal, prefrontal y occipital**, entre otras.
- Un ejemplo de **áreas de registro con 16 canales** se muestra en la **Figura 31**, tomada de información pública de **Bitbrain**, indicando la disposición de los electrodos para la monitorización de actividad cognitiva y emocional.

Esta integración permite correlacionar **movimientos oculares, atención visual y actividad cerebral**, facilitando un análisis multimodal de los procesos cognitivos y fisiológicos de los participantes.

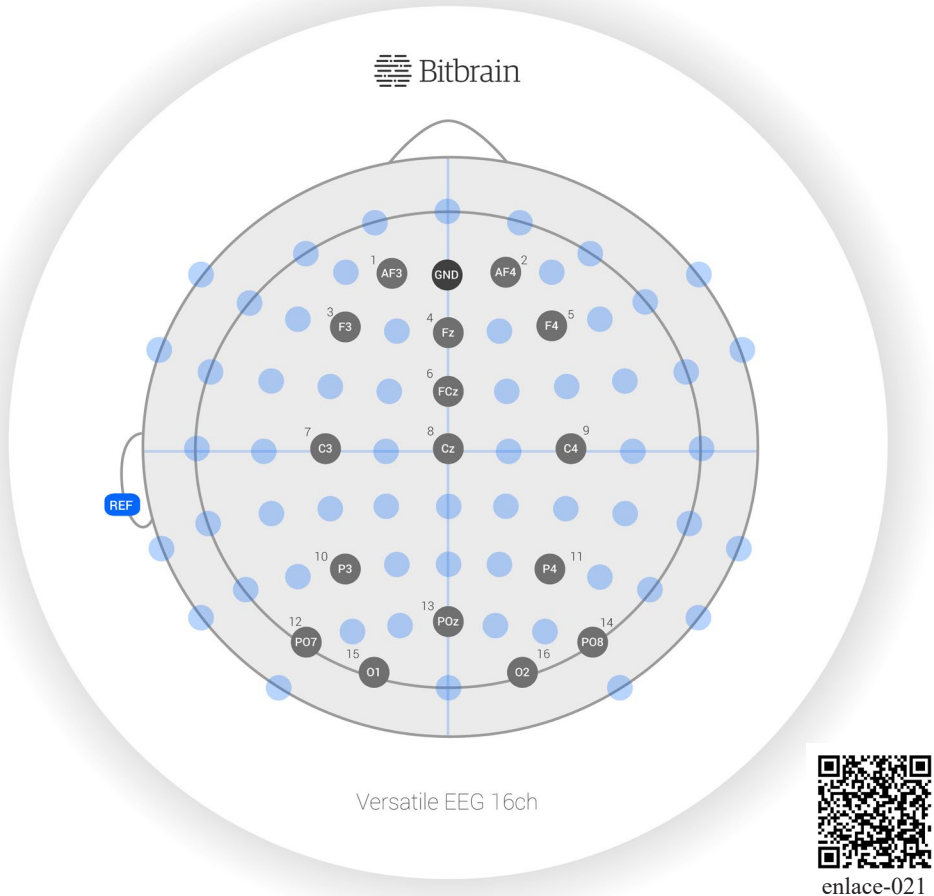


Figura 31. Imagen del registro en EEG con 16 canales tomado de Bitbrain [enlace-021](#).

Para comprender mejor los datos obtenidos mediante **EEG**, **GSR** y *eye tracking*, es importante contextualizar la relación entre los **sensores** y las **áreas cerebrales** que monitorizan.

En la **Figura 32** se muestra la **ubicación de las principales áreas cerebrales**. A continuación, se describen las **regiones cerebrales**, su **función** y la **localización típica de los sensores**:

1. Área frontal:

- **Función:** control ejecutivo, toma de decisiones, planificación y regulación de emociones.
- **Sensores:** electrodos frontales (Fz, Fp1, Fp2, etc.).

2. Área prefrontal:

- Función: atención, memoria de trabajo y procesamiento de información compleja.
- Sensores: electrodos prefrontales situados en la parte anterior de la frente.

3. Área occipital:

- Función: procesamiento visual y percepción de estímulos visuales.
- Sensores: electrodos occipitales (O1, O2, Oz, etc.).

4. Área parietal (si se incluye):

- Función: integración sensorial, percepción espacial y control de la atención.
- Sensores: electrodos parietales (Pz, P3, P4).

5. Área temporal (opcional según configuración):

- Función: procesamiento auditivo, reconocimiento de objetos y emociones.
- Sensores: electrodos temporales (T3, T4, etc.).

Esta contextualización permite **interpretar las señales de EEG, GSR y eye tracking** en función de **la actividad cerebral subyacente**, facilitando análisis multimodales y más precisos de **procesos cognitivos, emocionales y de atención** en los participantes.

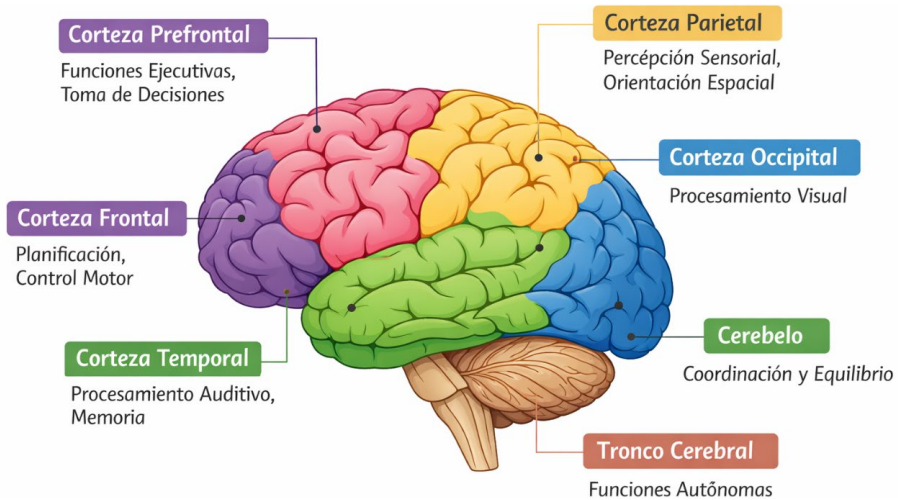
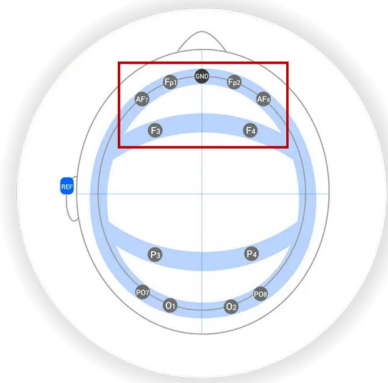
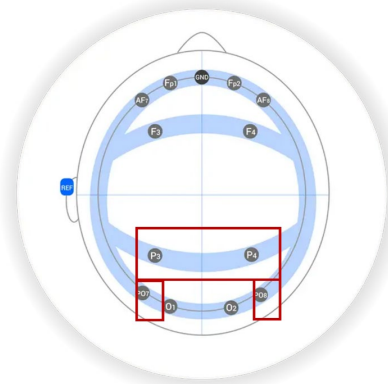
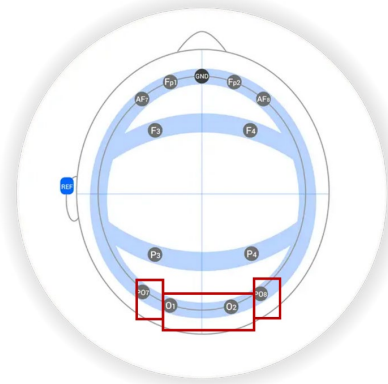


Figura 32. Representación de las áreas cerebrales (imagen elaborada por ChatGPT).

A continuación, se detallan las principales áreas cerebrales, los canales EEG típicos asociados y sus funciones cognitivas y fisiológicas.

Región frontal y prefrontal	
	<p>Referencia al razonamiento, pensamiento abstracto, el autocontrol, la toma de decisiones, la planificación y las habilidades pragmáticas.</p> <p>Fp₁ = polo frontal izquierdo Fp₂ = polo frontal derecho AF₇ = anterior frontal AF₈ = anterior frontal F₃ = Frontal F₄ = Frontal</p>
Región parietal-occipital	
	<p>Relación con la sensibilidad somática (áreas 5 y 7 de Brodmann). El análisis y la integración de la información sensitiva en el lóbulo parietal inferior hace referencia a las experiencias perceptivas complejas.</p> <p>P₃ = Parietal P₄ = Parietal PO₇ = Parietal Occipital PO₈ = Parietal Occipital</p>
Región occipital	
	<p>La actividad fundamental es visual a nivel de color, de formas y de movimientos. Esta información se incorpora para contribuir a ajustes posturales, relación retino-foveal.</p> <p>PO₇ = Parietal Occipital PO₈ = Parietal Occipital O₁ = Occipital O₂ = Occipital</p>

Seguidamente, se describen las métricas procesadas que se pueden extraer del dispositivo de EEG diadema de Bitbrain.

Engagement, definición: Es una medida del grado de **implicación** o **conexión** entre el **participante** y el **estímulo** o la **tarea**. Es un indicador más complejo que la atención, ya que un participante puede estar **atento** a una tarea, aunque la información presentada **no sea de su interés**. La implicación se expresa como un **porcentaje**. Un valor cercano al **0 %** indica que **no hay conexión** o **vínculo** con los **estímulos**. Un valor cercano al **100%** indica una **alta implicación** con los **estímulos** o la **tarea**.

$$Engagement\ Index = \frac{\beta}{\alpha + \theta}$$

donde $Beta (\beta) = 13 - 30\ Hz$, se asocia a estados de alerta y concentración

$Alfa (\alpha) = 8 - 13\ Hz$, un α alto indica relajación y bajo activación

$Theta (\theta) = 4 - 8\ Hz$, θ se incrementa con el cansancio, la fatiga o una carga cognitiva alta.

En esta asignatura se va a seguir la categorización de (Webster y Nimunkar, 2020) donde los intervalos de frecuencia por banda delta (δ): 1-4 Hz; theta (θ) 4-8 Hz; alfa (α): 8-13 Hz; beta (β): 13-30 Hz y gamma low (γ): 30-45 Hz.

Valencia, mide el grado de **atracción experimentado en respuesta a un estímulo o a una situación determinada**, desde una reacción positiva/agradable hasta una reacción negativa/desagradable. La valencia se expresa como un porcentaje. Un valor del 100% positivo o negativo equivale al valor medido en respuesta al medio de calibración. Es posible que el nivel de valencia supere el 100% (positivo o negativo) si la reacción calculada supera la medida durante la calibración. La valencia afectiva se basa en el análisis de la asimetría frontal de alfa (α), si disminuye hay una mayor activación cortical.

$$FAA_{\alpha} = \ln(\alpha\ right) - \ln(\alpha\ left)$$

Memorización, este indicador mide la **intensidad de los procesos cognitivos relacionados con la formación de recuerdos futuros durante la presentación de estímulos o durante una experiencia**. Capta el grado de **almacenamiento, codificación y retención en la memoria**. La memorización se expresa como un porcentaje. Un valor del **0%** indica que la **posibilidad de que el estímulo sea recordado es baja**. Un valor cercano al **100%** indica una **alta posibilidad de que el estímulo sea retenido** en la memoria del participante.

$$Memory = \omega_1 + \theta_{frontal} - \omega_2 * \alpha_{frontal} (\omega_3 * \gamma_{frontal})$$

donde ω son coeficientes de ponderación asignados a la banda de frecuencia.

Workload, la carga de trabajo mide el enfoque neurológico, o la **concentración** de un participante cuando se le presentan estímulos o durante experiencias. En otras

palabras, representa el uso de **recursos cognitivos para llevar a cabo una tarea o visualizar un estímulo**. La carga de trabajo se expresa en porcentajes. Los valores cercanos al **0%** indican que el participante está muy distraído, mientras que un valor cercano al **100%** indica que está muy atento al estímulo.

$$Workload \alpha = \frac{\theta_{frontal}}{\alpha_{frontal}}$$

Los algoritmos son aproximados en función de lo consensuado en la literatura científica, ya que Bitbrain no los aporta en el Manual.

C. Caso de estudio: *Eye tracking* con Registro de la Respuesta Psicogalvánica de la piel (GSR) con Bitbrain

En la actualidad, la tecnología de *eye tracking* permite la sincronización de la información del seguimiento visual con otros canales de registro, como la **respuesta galvánica de la piel (GSR)**. La teoría tradicional del análisis de la GSR se basa en la suposición de que la **resistencia de la piel varía con la actividad de las glándulas sudoríparas**. La sudoración del cuerpo humano está regulada por el **Sistema Nervioso Autónomo (SNA)**. En particular, si la rama simpática (SNS) del SNA se encuentra muy excitada, la actividad de las glándulas sudoríparas aumenta, lo que a su vez incrementa la **conductancia de la piel**, y viceversa. Por lo tanto, la conductancia de la piel puede considerarse una medida de la actividad del SNS humano.

Este sistema está directamente involucrado en la **regulación del comportamiento emocional**. Además, diversos estudios han destacado la relación entre la señal GSR y ciertos estados físicos que pueden influir en los estados mentales, como el **estrés, la fatiga y el grado de compromiso con una actividad**. La señal GSR se registra mediante dos electrodos colocados en el segundo y tercer dedo de una mano. La variación de una corriente de bajo voltaje aplicada entre ambos electrodos se utiliza como medida de la **actividad electrodérmica (EDA)**.

La tecnología de **Bitbrain** para GSR, compatible con la tecnología **Tobii**, permite la **integración de señales** y puede ofrecer las siguientes medidas:

Activación: nivel basal de **activación fisiológica** producida por un **estímulo o situación**. La **activación emocional** puede deberse a una **respuesta emocional positiva o negativa**. La activación se expresa en porcentajes basados en una línea de base definida durante los **estímulos de calibración**. Los **valores inferiores a 0** se asocian a un **estado de relajación o calma**. Los valores superiores a 0 se asocian a un **estado de excitación**. Un valor de **-100 %** se refiere a la **máxima respuesta de relajación** observada durante la calibración. Un **valor del 100 %** se refiere a la **máxima respuesta** observada en respuesta a los medios de calibración. Es posible un valor superior al 100 % si la reacción calculada supera la medida durante la calibración.

La activación se calcula utilizando señales de respuesta GSR y de actividad cardiovascular (BVP).

GSR normalizada

$$GSR_{norm} = \frac{GSR_{present} - GSR_{baseline}}{GSR_{baseline}}$$

BVP normalizada

(puede utilizarse frecuencia cardíaca, variabilidad o amplitud del pulso)

$$BVP_{norm} = \frac{BVP_{present} - BVP_{baseline}}{BVP_{baseline}}$$

La activación se obtiene como una combinación ponderada de ambas señales:

$$Activation = w_1 \cdot GSR_{norm} + w_2 \cdot BVP_{norm}$$

Donde

$$w_1 + w_2 = 1$$

Por lo que el algoritmo de activación es

$$Activation (\%) = \frac{Activation - Activation_{min}}{Activation_{max} - Activation_{min}} \times 200 - 100$$

El **impacto emocional** mide la **cantidad de cambios puntuales y la intensidad de las variaciones en el estado emocional** de un individuo producidas por la exposición a un estímulo, un acontecimiento externo o durante la realización de una tarea. En este sentido, el impacto permite identificar **momentos en los que el estímulo genera sorpresa, activación emocional o estrés**.

La medida del impacto puede expresarse de forma agregada en porcentaje. Un valor de **0 % indica ausencia de impacto**, mientras que **100 % corresponde al nivel de respuesta registrado durante la fase de calibración con estímulos de referencia**. En algunos casos, el valor puede **superar el 100 %** cuando la respuesta fisiológica registrada durante la tarea es mayor que la observada durante la calibración.

El impacto emocional se estima a partir del procesamiento de señales fisiológicas asociadas a la activación del sistema nervioso autónomo, principalmente la **respuesta galvánica de la piel (GSR)** y la **señal de volumen del pulso sanguíneo (BVP)**. Para permitir la comparación entre participantes y condiciones experimentales, ambas señales se **normalizan respecto a una línea base (baseline)** obtenida durante la fase de calibración.

Normalización de la señal de GSR

La señal de GSR se normaliza de la siguiente forma:

$$GSR_{norm} = \frac{GSR_{present} - GSR_{baseline}}{GSR_{baseline}}$$

Donde:

$GSR_{present}$ corresponde al valor de la señal durante la presentación del estímulo o tarea.

$GSR_{baseline}$ corresponde al valor de referencia obtenido durante el periodo de calibración.

Esta normalización permite expresar la variación relativa de **la activación electrodermal respecto al estado basal**.

Normalización de la señal de BVP

De forma análoga, la señal de BVP se normaliza mediante:

$$BVP_{norm} = \frac{BVP_{present} - BVP_{baseline}}{BVP_{baseline}}$$

$BVP_{present}$ corresponde al valor de la señal durante la presentación del estímulo o tarea.

$BVP_{baseline}$ corresponde al valor de referencia obtenido durante el periodo de calibración.

La señal BVP puede derivar en distintos indicadores fisiológicos, tales como:

- frecuencia cardíaca (HR),
- variabilidad de la frecuencia cardíaca (HRV),
- amplitud del pulso.

Cálculo de la activación fisiológica

La activación fisiológica se obtiene mediante una combinación ponderada de las señales normalizadas:

$$Activation = w_1 \cdot GSR_{norm} + w_2 \cdot BVP_{norm}$$

Donde

w_1 y w_2 representan los pesos asignados a cada señal fisiológica.

Se cumple que:

$$w_1 + w_2 = 1$$

Esta combinación permite integrar la información proveniente de la actividad electrodermal (GSR) y la respuesta cardiovascular (BVP) en un único índice de activación emocional.

Escalado del índice de activación

Para facilitar la interpretación de los resultados, el valor de activación se transforma a una escala porcentual normalizada:

$$Activation (\%) = \frac{Activation - Activation_{min}}{Activation_{max} - Activation_{min}} \times 200 - 100$$

Este procedimiento permite obtener una escala de -100 a 100 , donde:

- valores negativos indican **niveles de activación inferiores al estado basal**,
- valores cercanos a 0 reflejan **niveles de activación neutros**,
- valores positivos indican **mayor activación emocional respecto a la línea base**.

El **impacto emocional** mide la **cantidad e intensidad de cambios abruptos en el estado emocional** provocados por un estímulo, evento o tarea. Refleja reacciones **sorpresivas, emocionales o asociadas al estrés**. Se expresa en **porcentaje**, donde 0% indica ausencia de impacto, 100% corresponde a la respuesta registrada durante la calibración y puede superar el 100% si la reacción excede la calibración. Este indicador se calcula **analizando los picos o cambios bruscos** en las señales de **GSR** y **BVP**.

Identificar los picos de cada señal

$$Peaks_{GSR} = \sum_i |GSR_i - GSR_{i-1}|$$

$$Peaks_{BVP} = \sum_i |BVP_i - BVP_{i-1}|$$

Combinación ponderada

$$Impact = w_1 \cdot Peaks_{GSR} + w_2 \cdot Peaks_{BVP}, w_1 + w_2 = 1$$

donde w_1 y w_2 son pesos representando la importancia relativa de cada señal.

Escalado a porcentaje

$$Impact(\%) = \frac{Impact - Impact_{min}}{Impact_{max} - Impact_{min}} \times 100$$

En la **Figura 33** se muestra un ejemplo del dispositivo de GSR, el posicionamiento de los dedos para el registro de la señal de respuesta psicogalvánica y el análisis de la señal recogida con la tecnología de Bitbrain.



Figura 33. Dispositivo GSR, posición de los dedos para el registro, ejemplo de registro tomado de Bitbrain.

En la **Figura 34** se presenta un ejemplo de un registro individual y en la **Figura 35** un ejemplo de análisis colectivo de señal integrada.




Figura 34. Ejemplo de un registro individual de señal integrada (fuente propia).

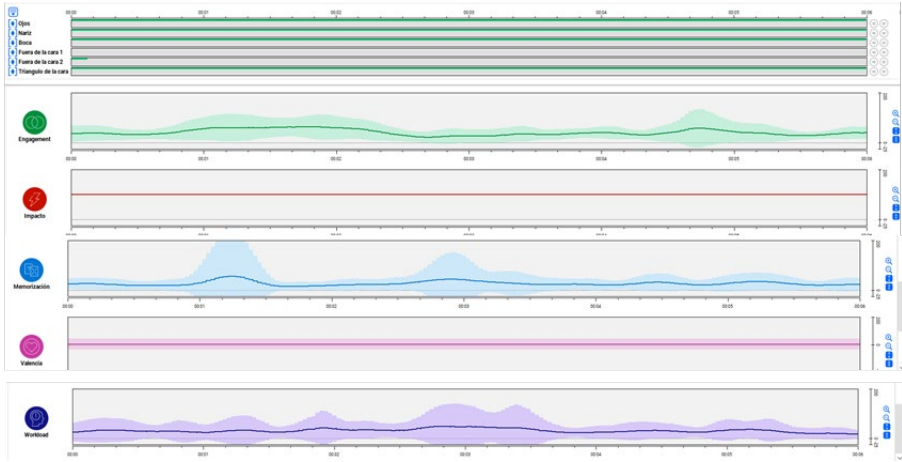


Figura 35. Ejemplo de un registro colectivo de señal integrada (fuente propia).

Además, se pueden extraer métricas a partir de las señales de *eye tracking*, tales como: mapa de calor (ver Figura 36), mapa de biométricas (ver Figura 37), mapa de focalización (ver Figura 38), mapa de tiempo (ver Figura 39) y mapa de trayectoria (ver Figura 40).

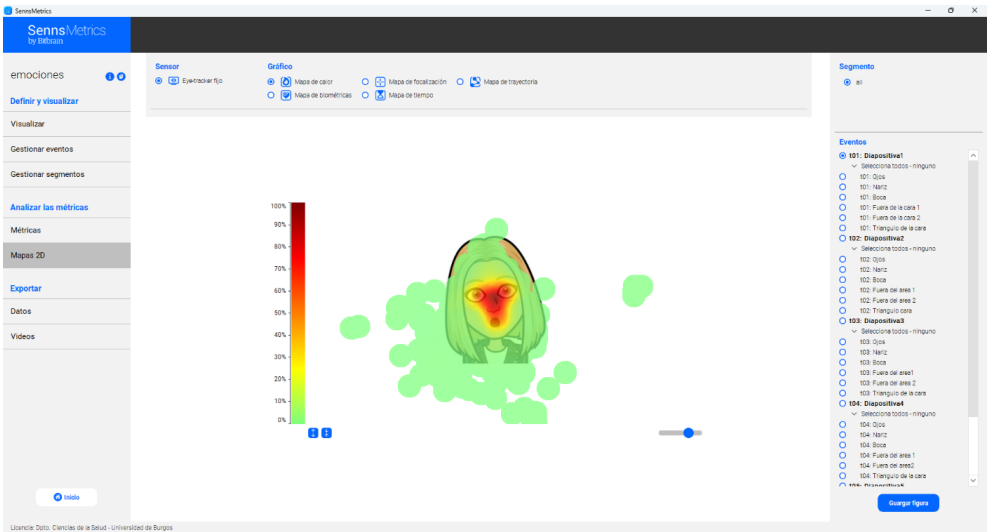


Figura 36. Mapa de calor en señal de *eye tracking* (imagen propia).

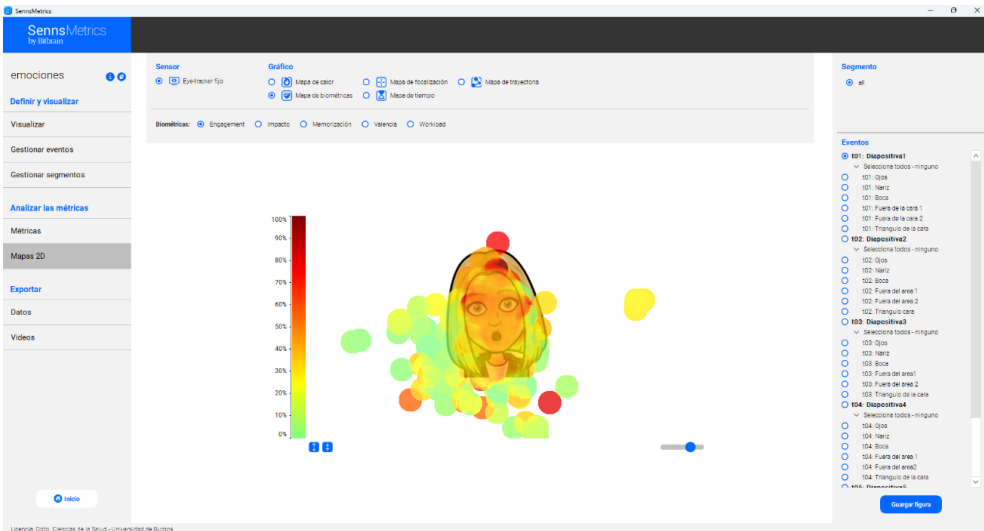


Figura 37. Mapa de biométricas en señal de eye tracking (imagen propia).

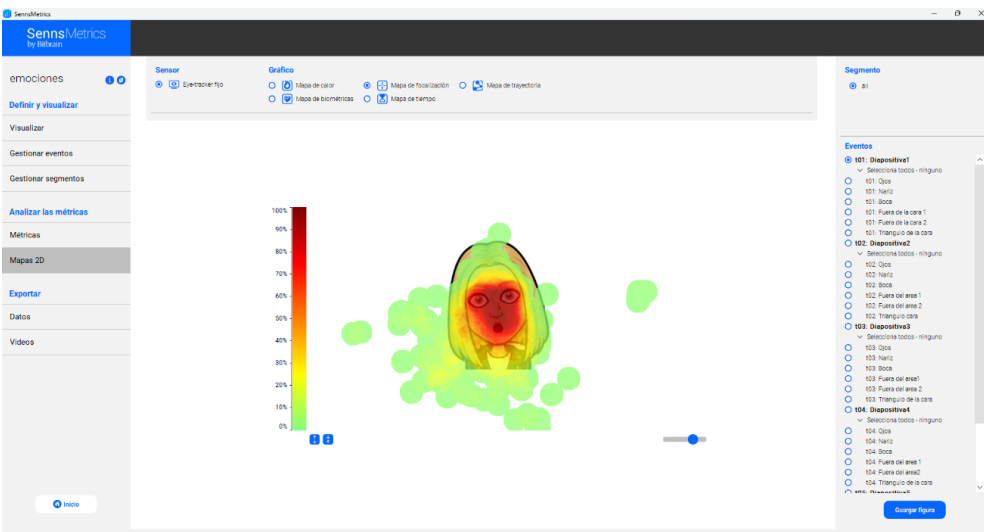


Figura 38. Mapa de focalización de eye tracking (imagen propia).

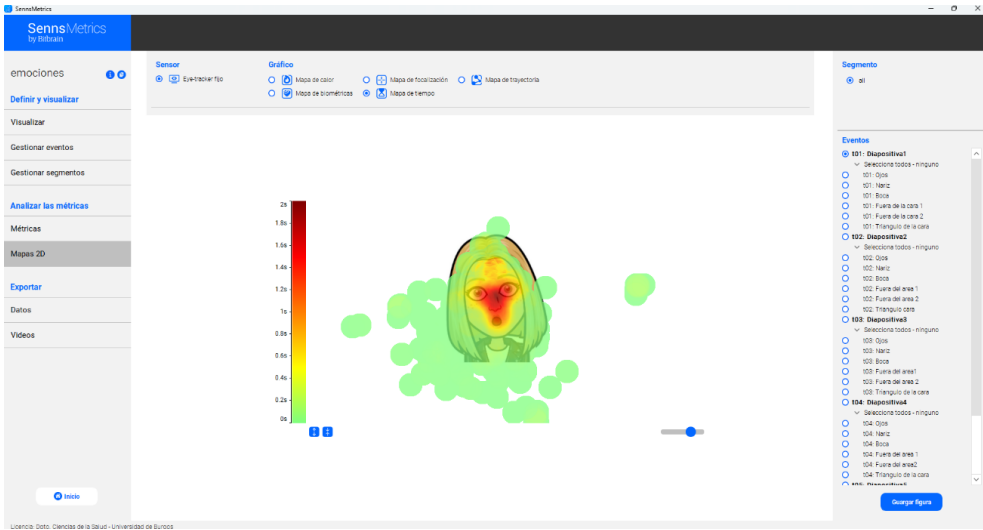


Figura 39. Mapa de tiempo en señal de *eye tracking* (imagen propia).

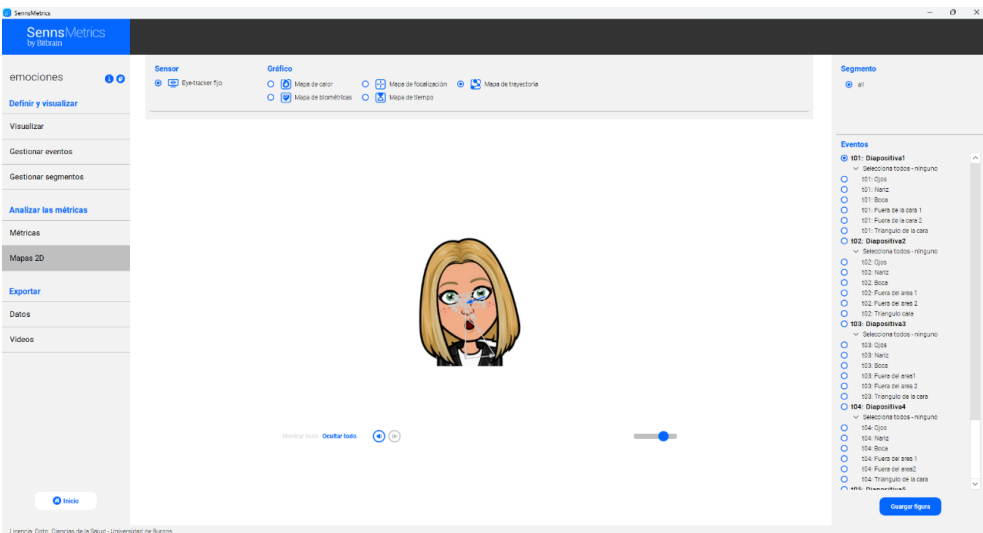


Figura 40. Mapa de trayectoria de *eye tracking* (imagen propia).

De igual manera, es posible **visualizar los resultados de los biosensores** para las distintas medidas. En las Figuras 41, 42, 43 y 44 se presentan las **medias y desviaciones típicas** de las métricas de *engagement*, *valencia*, *memorization* y *workload* correspondientes a cinco imágenes que representan distintas emociones.

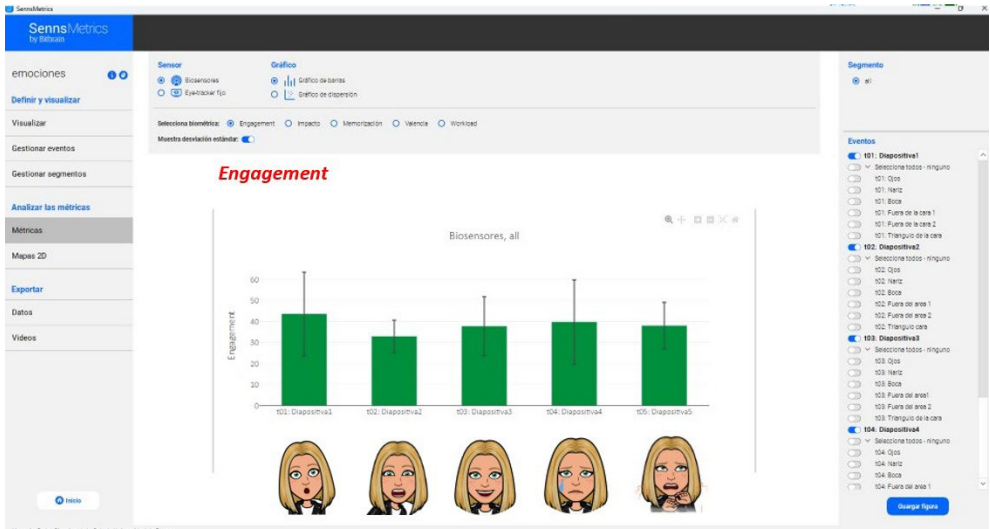


Figura 41. Medias y Desviaciones Típicas en *engagement* en distintas emociones (imagen propia).

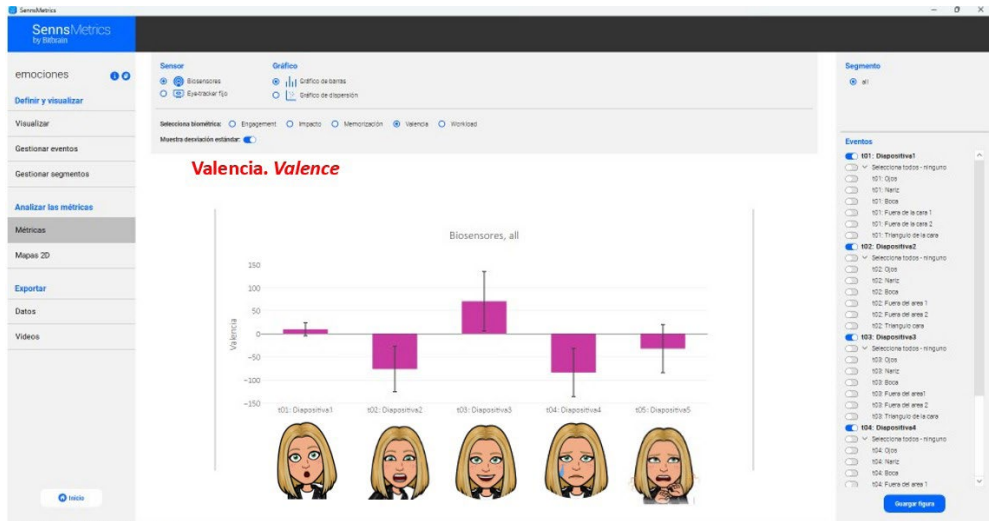


Figura 42. Medias y Desviaciones Típicas en *valencia* en distintas emociones (imagen propia).

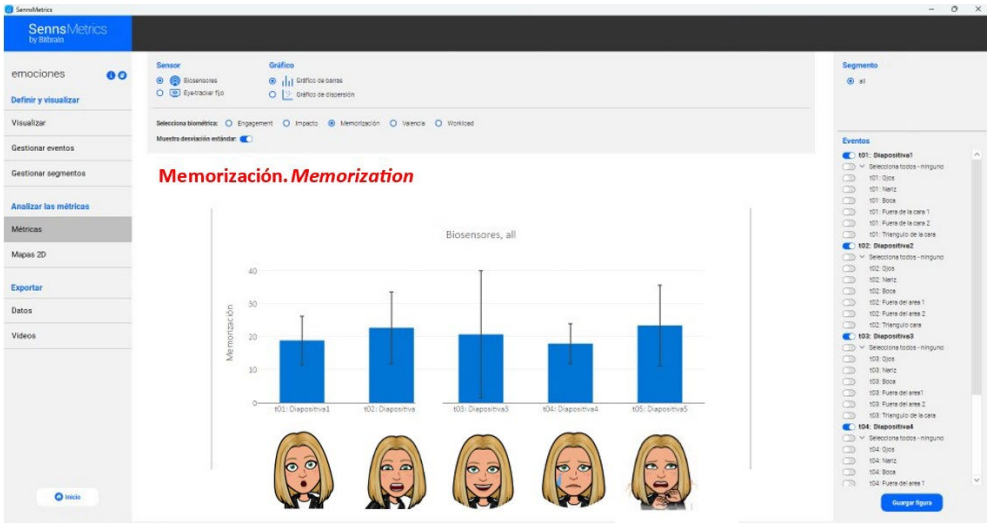


Figura 43. Medias y Desviaciones Típicas en *memorization* en distintas emociones (imagen propia).

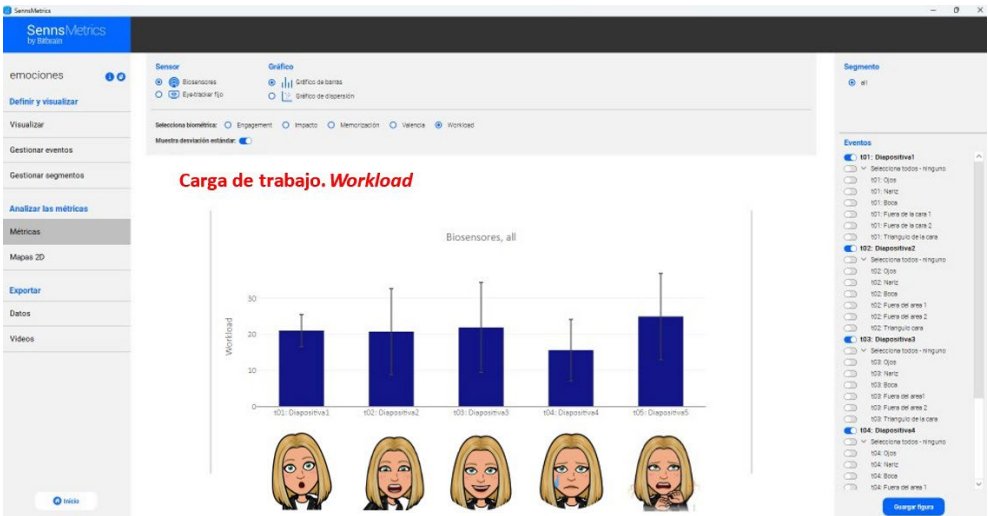


Figura 44. Medias y Desviaciones Típicas en *workload* en distintas emociones (imagen propia).

Asimismo, es posible realizar un **análisis dentro de cada estímulo** respecto de las **AOIs** previamente definidas. En las Figuras 45, 46, 47, 48 y 49 se presenta un ejemplo de **análisis por AOI** para cada una de las imágenes, considerando la métrica de *engagement*.

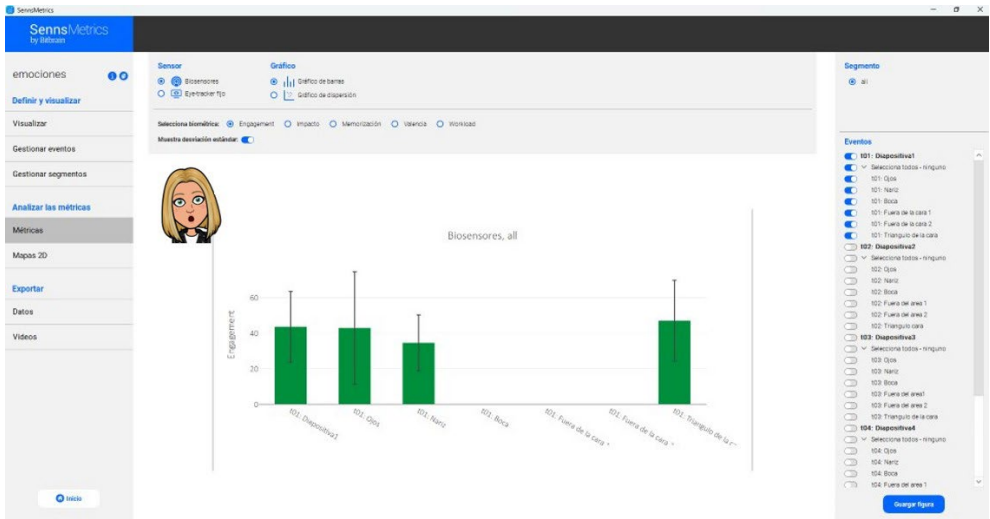


Figura 45. Análisis de AOI en la métrica *engagement* respecto de la emoción de sorpresa (imagen propia).

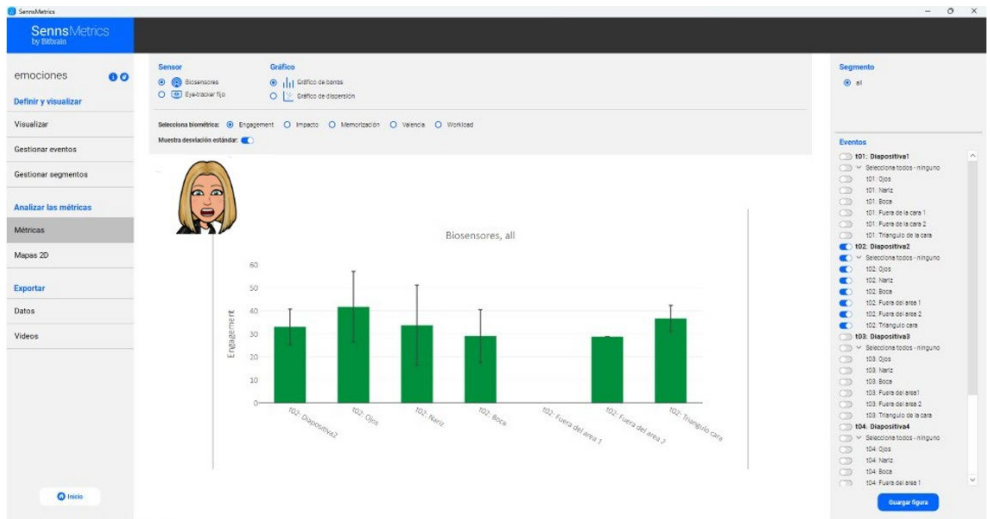


Figura 46. Análisis de AOI en la métrica *engagement* respecto de la emoción de enfado (imagen propia).

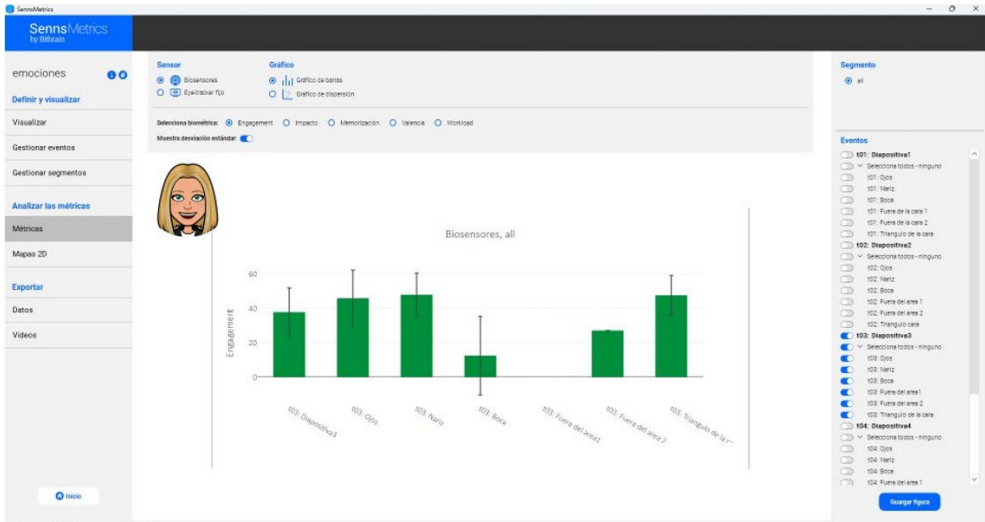


Figura 47. Análisis de AOI en la métrica *engagement* respecto de la emoción de alegría (imagen propia).

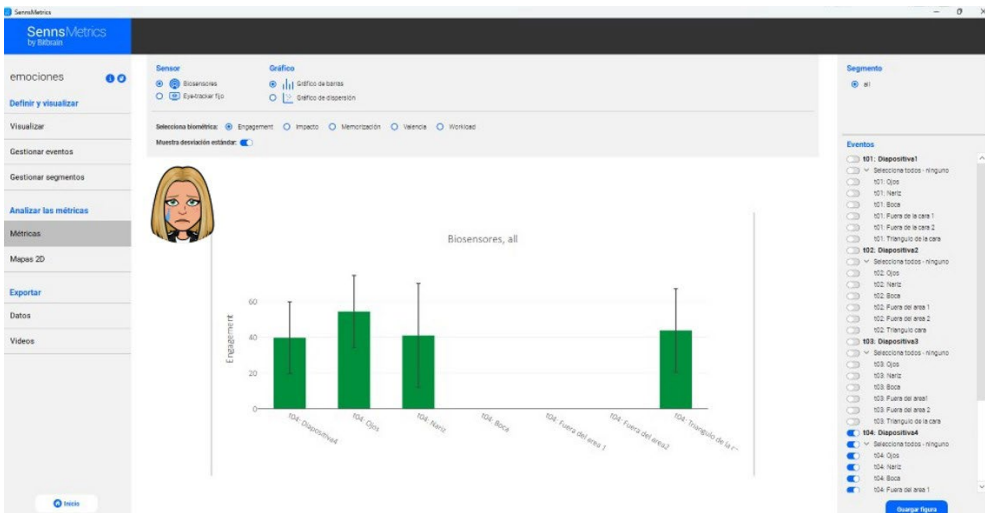


Figura 48. Análisis de AOI en la métrica *engagement* respecto de la emoción de tristeza (imagen propia).

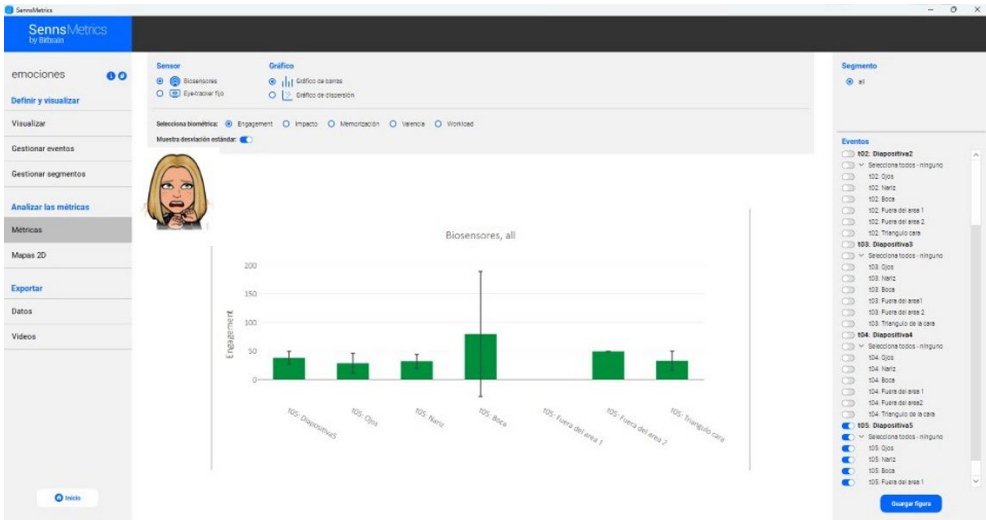


Figura 49. Análisis de AOI en la métrica *engagement* respecto de la emoción de miedo (imagen propia).

Procedimiento

1. Sincronización temporal de las señales

Cada dispositivo posee su propia frecuencia de muestreo (por ejemplo, *eye tracking*: 60–120 Hz; EEG: 256 Hz; GSR: 32 Hz). Es fundamental **alinear todas las señales mediante los timestamps** para que cada instante corresponda a la misma referencia temporal. Si las frecuencias difieren, se puede **interpolar o resampear** para igualarlas, o mantenerlas en su resolución original y trabajar con **ventanas de tiempo comunes**.

2. Preprocesamiento de señales

- **EEG**: Filtrado de ruido (artefactos musculares, parpadeos), segmentación por eventos o estímulos.
- **GSR**: Filtrado de picos espurios y extracción de componentes **tónicas y fásicas** (respuesta rápida vs. nivel basal).
- **Eye tracking**: Detección de fijaciones, sacadas y dilatación pupilar, así como limpieza de datos faltantes o erróneos.

3. Extracción de métricas relevantes

- **EEG**: Bandas de frecuencia (alfa, beta, theta), activación cortical e índices de *engagement* o **carga cognitiva**.
- **GSR**: Picos de conductancia, nivel basal y variaciones abruptas → indicadores de **activación emocional y estrés**.

- **Eye tracking:** Fijaciones, tiempo de atención y patrones visuales → reflejan **interés o atención visual**.

4. Integración de señales

- Combinar métricas temporales correspondientes a los **mismos eventos o ventanas de tiempo**.
- Aplicar **ponderación o normalización** para que señales con rangos diferentes (por ejemplo, microvoltios vs. microsiemens) sean comparables.
- Posible cálculo de **indicadores compuestos**, como activación total (EEG + GSR) o engagement visual-cognitivo (EEG + *eye tracking*).

5. Análisis e interpretación conjunta

- Identificar correlaciones entre señales; por ejemplo, picos de GSR junto con aumento de beta en EEG y fijaciones prolongadas pueden indicar **alta activación emocional y atención**.
- Comparar respuestas entre **diferentes estímulos o condiciones experimentales**.
- Detectar patrones de interés, estrés o fatiga combinando indicadores de las tres señales.

6. Visualización

- Generar **gráficos sincronizados** de EEG, GSR y *eye tracking* para cada evento.
- Crear **mapas temporales o dashboards** que muestren cambios simultáneos en activación, atención y respuesta emocional.

2.3. Práctica Tema 2

En función del diseño desarrollado en la práctica correspondiente al Tema 1, se deberán seleccionar las medidas de *eye tracking* consideradas más adecuadas, justificando tanto los motivos de su elección como su relación con los aspectos cognitivos o de aprendizaje que se pretende estudiar.

Las prácticas se realizarán utilizando el software Tobii Pro Lab v.25.7.1400 (x64). No obstante, se podrán mencionar otras métricas potencialmente aplicables, siempre que se justifique su pertinencia en relación con los objetivos del proyecto que se va a desarrollar.

***Para la realización de la práctica se pueden utilizar herramientas de IAGen. Si bien, se deben seguir las instrucciones que se pueden consultar en el Anexo 1.**

2.4. Referencias

- Escolano, C., López-Larraz, E., Minguez, J., y Montesano, L. (2022). Brain-Computer Interface-Based Neurorehabilitation: From the Lab to the Users' Home. En D. Torricelli, M. Akay, y J.L. Pons. (Eds.), *Converging Clinical and Engineering Research on Neurorehabilitation IV. ICNR 2020*. Biosystems & Biorobotics, vol 28. Springer, Cham. https://doi.org/10.1007/978-3-030-70316-5_91
- Manual iView XTM v.2.7. SMI.
- Manual Sennsmetrics. Bitbrain.
- Manual Sennslab. Bitbrain.
- Manual Tobi Pro Lab versión v 25.7 April 2025.
- Perez-Valero, E., Morillas, C., Lopez-Gordo, M.A., y Minguillon, J. (2023). Supporting the Detection of Early Alzheimer's Disease with a Four-Channel EEG Analysis. *International Journal of Neural Systems*, 33(4), 2350021. <https://doi.org/10.1142/S0129065723500211>
- Sáiz-Manzanares, M.C. (2019). *Metacognición e inteligencia artificial: más allá del paralelismo de funcionamiento*. Tesis Doctoral. Burgos: Servicio de Publicaciones de la Universidad de Burgos. <http://hdl.handle.net/10259/5357> acceso 25/09/2024
- Sáiz-Manzanares, M.C., Ortega-Renuncio, R., y Marticorena-Sánchez, R. (2026). Processing and Analysis of Portable EEG Data for Cognitive Load Assessment in Neurotypical University Students. *Frontiers in Human Neuroscience*.
- Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Escolar-Llamazares, M.C., Martín-Antón, L.J., & Velasco-Saiz, R. (2025). Monitoring university students' learning processes: application of Advanced Learning Technologies and integrated multichannel techniques. *Thinking Skills and Creativity*, 58, 101938. <https://doi.org/10.1016/j.tsc.2025.101938>
- Sáez-García, J., Sáiz-Manzanares, M. C., Marticorena-Sánchez, R. (2024). Challenges in data processing analysis by monitoring the learning process with Eye Tracking and Galvanic Skin Response. *Computers*, 13, 289. <https://doi.org/10.3390/computers13110289>
- Sáiz-Manzanares, M. C., Marticorena-Sánchez, R., Sáez-García, J., & González-Díez, I. (2024). Analysing Virtual Labs Through Integrated Multi-Channel Eye-Tracking Technology: A Proposal for an Explanatory Fit Model. *Applied Sciences*, 14(21), 9831. <https://doi.org/10.3390/app14219831>
- Sáiz-Manzanares, M.C., Marticorena-Sánchez, R.; Escolar-Llamazares, M.C., González-Díez, I., Martín Antón, L.J. (2024). Using integrated multimodal technology: a way to personalised learning in Health Sciences and Biomedical

engineering Students. *Applied Sciences*, 14(16), 7017. <https://doi.org/10.3390/app14167017>

- Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Martín-Antón, L.J., González-Díez, I., & Carbonero-Martín, I. (2023). Using eye tracking technology to analyse cognitive load in multichannel activities in university students. *International Journal of Human-Computer Interaction*, 40(12), 3263–328. <https://doi.org/10.1080/10447318.2023.2188532>
- Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Martín-Antón, L.J., Almeida, L., & Carbonero-Martín, I. (2023). Application and challenges of eye tracking technology in Higher Education. *Comunicar*, 76, 1-12. <https://doi.org/10.3916/C76-2023-03>
- Sáiz-Manzanares, M.C., Payo Hernanz, R.J., Zaparaín Yáñez, M.J., Andrés López, G., Marticorena Sánchez, R., Calvo Rodríguez, A., Martín, C., y Rodríguez Arribas, S. (2021). Eye-tracking Technology and Data-mining Techniques used for a Behavioral Analysis of Adults engaged in Learning Processes. *Journal of Visualized Experiments*. <https://doi.org/10.3390/10.3791/62103>
- Sáiz-Manzanares, M.C., Ramos Pérez, I., Arnaiz-Rodríguez, Á., Rodríguez-Arribas, S., Almeida, L., & Martín, C.F. (2021). Analysis of the learning process through eye tracking technology and feature selection techniques. *Applied Sciences*, 11, 6157, 1-24. <https://doi.org/10.3390/app11136157>
- Sáiz-Manzanares, M.C., Rodríguez-Díez, J.J., Marticorena, R., Zaparaín, M.J., & Cerezo, R. (2020). Lifelong Learning from Sustainable Education: An Analysis with Eye Tracking and Data Mining Techniques. *Sustainability*, 12(5), 1-18. <https://doi.org/10.3390/su12051970>
- Schwarz, A., Escolano, C., Montesano, L., y Müller-Putz, G.R. (2020) Analyzing and Decoding Natural Reach-and-Grasp Actions Using Gel, Water and Dry EEG Systems. *Front. Neurosci.*, 14, 849. <https://doi.org/10.3389/fnins.2020.00849>
- Webster, J.G & Nimunkar, A. . (2020). *Medical Instrumentation: Application and Design*. Hoboken, USA: Wiley.



TEMA 3

**INTERPRETACIÓN DE MÉTRICAS
(ESTÁTICAS Y DINÁMICAS) DE
REGISTRO EN *EYE TRACKING* E
INTRODUCCIÓN AL REGISTRO DE
SEÑAL MÚLTIPLE (*EYE TRACKING*,
GSR, EEG)**

Dra. María Consuelo Sáiz Manzanares

Dr. David García-García

3.1. Introducción

Seguidamente, se analiza la visualización de algunas de las métricas que pueden obtenerse mediante distintos dispositivos. Por ejemplo, el sistema iView X™ junto con SMI Experimenter Center 3.0 y SMI BeGaze™ permite procesar datos relacionados con el comportamiento visual, asociados a diversos parámetros tales como el diámetro pupilar, la velocidad y la aceleración ocular, tanto en el ojo derecho como en el izquierdo. Con este dispositivo, los datos generados por la cadena de adquisición pueden extraerse en formatos .csv o .xlsx y posteriormente procesarse mediante técnicas de *machine learning* no supervisado.

Para entender los pasos a realizar en procesamiento y análisis de este tipo de datos, vamos a emplear un ejemplo que puede encontrarse en el trabajo siguiente.

Sáiz-Manzanares, M.C., Rodríguez-Díez, J.J., Marticorena, R., Zaparaín, M.J., & Cerezo, R. (2020). Lifelong Learning from Sustainable Education: An Analysis with Eye Tracking and Data Mining Techniques. *Sustainability*, 12(5), 1-18. <https://doi.org/10.3390/su12051970>

Este estudio utilizó un dispositivo de *eye tracking* y técnicas de minería de datos para analizar cómo distintos perfiles de participantes procesan información sobre arte medieval mediante el seguimiento de sus rutas visuales y la resolución de un acertijo en forma de crucigrama. Los investigadores identificaron patrones eficaces para una educación personalizada y sostenible.

La herramienta de *eye tracking* utilizada fue iView X™, con ella se registraron los movimientos oculares y sus coordenadas exactas sobre una pantalla con una resolución de 1680 × 1050 píxeles. Para procesar estos datos, cada página de la presentación visual fue dividida en cuadrantes con una rejilla de 14 × 14, generando 196 regiones de fijación distintas. A cada región, se le asignó un código alfanumérico.

Asimismo, se realizó una clasificación de las Áreas de Interés (AOIs) agrupando los cuadrantes de la pantalla de acuerdo con la función de la información que contenían, distinguiendo específicamente entre zonas relevantes (datos clave), no relevantes (vacíos) y poco relevantes (interfaz y títulos) (ver **Figura 50**).




Figura 50. Patrón de comportamiento visual en ejes cartesianos en el dispositivo iView XTM, SMI Experimenter Center 3.0 y SMI BeGazeTM.

Para que un movimiento se considere una fijación ocular, debe cumplir criterios específicos:

- La mirada debe permanecer estática en un punto durante un intervalo de tiempo comprendido entre 83.1 y 1033.2 milisegundos.
- El movimiento ocular debe mantenerse dentro de un radio máximo de 100 píxeles.

A partir de estos criterios, se calcularon las frecuencias de fijaciones en cada uno de los cuadrantes y se visualizó su relación con las áreas de interés (AOIs) (ver la Figura 51). Posteriormente, sobre las frecuencias por cuadrante se realizó un análisis de clustering mediante el algoritmo *k*-means (ver la Figura 52), el cual permite agrupar de forma independiente las AOIs.




Figura 51. Frecuencias en los cuadrantes y relación con las AOIs, (Saiz-Manzanares et al. 2020, p.10).




Figura 52. Análisis de *clustering* con *k-means* sobre las frecuencias en las AOIs, (Saiz-Manzanares et al. 2020, p.11).

Para analizar los patrones de los diferentes sujetos, se emplearon las secuencias de fijación visual o *scan-paths*, que son métricas dinámicas que describen tanto el orden espacial como la secuencia temporal de las fijaciones que un participante realiza durante la ejecución de una tarea. Pueden entenderse como un **camino de la mirada**, que representa el recorrido que realiza la mirada del usuario a lo largo de la pantalla.

Por ejemplo, si un sujeto observa primero el cuadro **A1**, luego el **G5** y finalmente el **J3**, su *scan-path* se representa simplemente como la secuencia: «**A1–G5–J3**». La longitud de los *scan-paths* de los distintos sujetos no tiene por qué ser igual.

Entonces, ¿cómo se comparan los *scan-paths*? Para ello se emplean técnicas de distancia de edición (*string edit distance*), entre las que se incluyen:

- Distancia de Levenshtein (la utilizada en el artículo).
- Distancia de Hamming.
- Distancia de Damerau–Levenshtein.

Dependiendo del método, se permiten una o varias de las siguientes operaciones:

- **Inserción:** añadir un carácter.
- **Eliminación:** borrar un carácter.
- **Sustitución:** reemplazar un carácter por otro.

A continuación, se describe específicamente cómo se calcula la distancia de Levenshtein:

Sean $s = s_1 \dots s_{|s|}$ y $t = t_1 \dots t_{|t|}$ dos cadenas.

Se define $D(i,j)$ como la **distancia mínima** entre los primeros i caracteres de s y los primeros j caracteres de t .

$$D(i, j) = \begin{cases} 0 & \text{si } i = 0 \text{ y } j = 0 \\ j & \text{si } i = 0 \\ i & \text{si } j = 0 \\ \min \begin{cases} D(i-1, j) + c_{\text{del}} & (\text{eliminación}) \\ D(i-1) + c_{\text{ins}} & (\text{inserción}) \\ D(i-1, j-1) + c_{\text{sub}}(s_i, t_j) & (\text{sustitución}) \end{cases} & \text{en otro caso} \end{cases}$$

donde $c_{\text{del}} = 1$ y $c_{\text{ins}} = 1$

Finalmente, la distancia entre cadenas es:

$$d(s, t) = D(|s|, |t|)$$

¿Y qué ocurre con C_{sub} ? Puede definirse de distintas formas según la métrica utilizada.

A. Distancia uniforme (discreta)

En este caso, se considera que todas las operaciones tienen el mismo costo, por tanto:

$$c_{\text{sub}}(s_i, t_j) = \begin{cases} 0 & \text{si } s_i = t_j \\ 1 & \text{si } s_i \neq t_j \end{cases}$$

Con esta métrica podemos obtener la distancia entre los diferentes sujetos, que representamos mediante un mapa de calor (ver **Figura 53**).




Figura 53. Heatmaps de las cadenas de scan-path: Uniform Distance model, (Saiz-Manzanares et al. 2020, p.12).

B. Distancia *City Block* o Manhattan

La distancia entre dos puntos en un espacio n -dimensional se mide como la suma de las diferencias absolutas de sus coordenadas. Se llama *City Block* (bloques de ciudad) porque imagina que te mueves en una cuadrícula de calles rectas y perpendiculares, como en un plano urbano: la distancia entre dos puntos es la suma de los tramos en horizontal y vertical, no la línea recta (que sería la distancia Euclidiana).

$$x = (x_1, x_2, \dots, x_n), y = (y_1, y_2, \dots, y_n)$$

La *City Block* se define como:

$$d_{\text{man}}(x, y) = \sum_{i=1}^n |x_i - y_i|$$

de forma que:

$$c_{\text{sub}}(s_i, t_j) = \begin{cases} 0 & \text{si } s_i = t_j \\ d_{\text{man}}(s_i, t_j) & \text{si } s_i \neq t_j \end{cases}$$

En la **Figura 54** se muestra el mapa de calor si se emplea distancia Manhattan para la sustitución.




Figura 54. Heatmaps de las cadenas de scan-path: *City Block Distance model*, (Saiz-Manzanares et al. 2020, p.13).

C. Distancia euclídea

Es la métrica más clásica para medir la distancia entre dos puntos en un espacio n -dimensional. Se define como la longitud de la línea recta que une los dos puntos.

Si se tienen dos vectores

$$x = (x_1, x_2, \dots, x_n), y = (y_1, y_2, \dots, y_n)$$

la distancia euclidiana se calcula como

$$d_{\text{euc}}(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

de forma que

$$c_{\text{sub}}(s_i, t_j) = \begin{cases} 0 & \text{si } s_i = t_j \\ d_{\text{euc}}(s_i, t_j) & \text{si } s_i \neq t_j \end{cases}$$

En la **Figura 55** se muestra el mapa de calor si se emplea distancia euclídea para la sustitución.




Figura 55. Heatmaps de las cadenas de scan-path: *Euclidian Distance model*, (Saiz-Manzanares et al. 2020, p.13).

Con los datos de distancias obtenidos, se puede aplicar el **Escalamiento Multidimensional** (*Multi-Dimensional Scaling*, MDS). Esta es una técnica de *machine learning no supervisado* que permite representar relaciones de distancia o similitud entre objetos en un espacio geométrico de baja dimensión (generalmente 2D o 3D). Se trata de un método estadístico que, a partir de una matriz de distancias o similitudes, busca proyectar los objetos en un espacio de menor dimensionalidad, preservando en la medida de lo posible las relaciones de distancia originales.

En términos sencillos, las gráficas resultantes del Escalamiento Multidimensional pueden interpretarse como un **mapa de similitud** entre los sujetos. En lugar de representar coordenadas espaciales de la pantalla, muestran qué tan cercano o distante es el comportamiento visual de un participante con respecto al de los demás.

Para el ejemplo analizado, este procedimiento se presenta en la **Figura 56** (distancia uniforme), **Figura 57** (distancia Manhattan) y **Figura 58** (distancia euclídea). Como puede observarse, en este estudio el modelo basado en **distancia uniforme** fue el que mostró una agrupación más marcada entre las cadenas generadas por los participantes, permitiendo una discriminación más clara de los casos extremos.



Figura 56. Multi-dimensional scaling a partir de las distancias en *Uniform Distance model*, (Saiz-Manzanares et al. 2020, p.14).



Figura 57. Multi-dimensional scaling a partir de las distancias en *City Block Distance model*, (Saiz-Manzanares et al. 2020, p.14)..



Figura 58. Multi-dimensional scaling a partir de las distancias en *Euclidian Distance model*, (Saiz-Manzanares et al. 2020, p.15).

A partir de lo expuesto, se ha mostrado cómo se puede realizar un análisis completo a partir de los datos proporcionados por el dispositivo. Por otro lado, el dispositivo **iView X™**, junto con **SMI Experimenter Center 3.0** y **SMI BeGaze™**, también permite el procesamiento automático del análisis de patrones visuales.

A continuación, se presentan distintos ejemplos de patrones correspondientes a diferentes participantes. En la **Figura 59** se muestra un ejemplo de patrones visuales en un estudiante; en la **Figura 60**, un ejemplo de la distribución de las fijaciones en las áreas de interés (AOIs); y en la **Figura 61**, la distribución de las fijaciones entre el ojo derecho y el ojo izquierdo.

De forma análoga, se presentan ejemplos de la interacción de un profesor frente a los mismos estímulos en la **Figura 62**, **Figura 63** y **Figura 64**, respectivamente.




Figura 59. Patrón de interacciones visuales en distintos estímulos en un estudiante.
(fuente propia)




Figura 60. Distribución de las fijaciones en AOIs en un estudiante.
(fuente propia)




Figura 61. Representación de las fijaciones en ojo derecho y en ojo izquierdo en un estudiante.
(fuente propia)




Figura 62. Patrón de interacciones visuales en distintos estímulos en un profesor. (fuente propia)




Figura 63. Distribución de las Fijaciones en AOIs en un profesor. (fuente propia)




Figura 64. Representación de las fijaciones en ojo derecho y en ojo izquierdo en un profesor. (fuente propia)

Otro dispositivo de *eye tracking* es **Tobii Pro Lab**, versión 24.21.435 (x64), este permite el procesamiento automático de los datos y la generación de diversas visualizaciones. Entre ellas se incluyen los **mapas de calor**, que analizan el *gaze point* a partir de métricas estáticas, donde las zonas representadas con mayor intensidad en color rojo indican los puntos de mayor fijación y, por ende, de mayor atención visual (véase la **Figura 65**).

Asimismo, el sistema permite exportar una visualización de la secuencia espacial de la mirada, correspondiente a una medida dinámica (*scan-path*) (véase la **Figura 66**). De igual modo, cuando se trabaja con distintos grupos de usuarios, es posible visualizar la interacción mediante una imagen comparativa (véase la **Figura 67**).




Figura 65. Mapa de calor con dispositivo Tobii Pro Lab. (fuente propia)

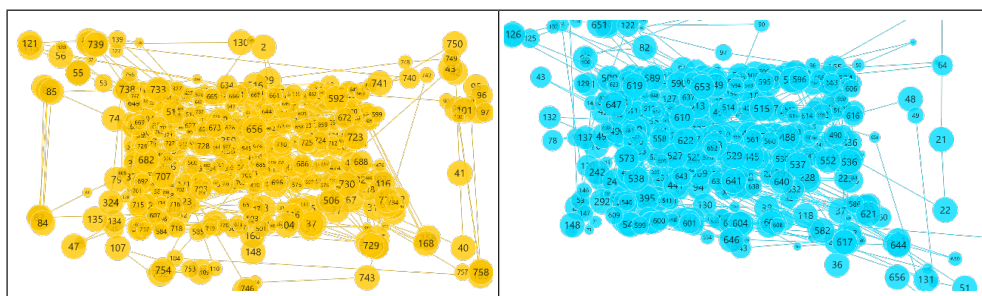


Figura 66. Cadena *scan path* con dispositivo Tobii Pro Lab. (fuente propia)

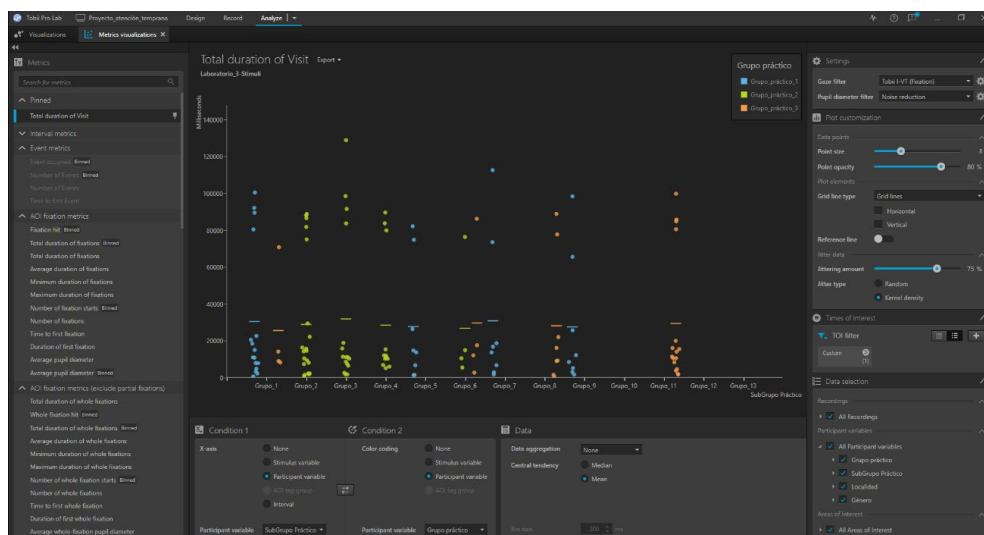


Figura 67. Visualización del comportamiento de los usuarios por grupo durante la presentación de los estímulos. (fuente propia)

3.2. Análisis de datos crudos en dispositivos integrados de señal

No obstante, no todos los datos se proporcionan preprocesados o procesados. En el caso de algunos dispositivos, es posible obtener **datos crudos**, es decir, datos sin ningún tipo de procesamiento previo. Un ejemplo de ello son los datos que pueden extraerse de dispositivos como los de la plataforma **Bitbrain**, los cuales integran señales recogidas de forma simultánea por distintos sensores.

Este enfoque de trabajo con los datos permite obtener información relativa a las **bandas cerebrales** activadas ante cada estímulo, así como realizar una **cartografía cerebral**. Estos aspectos resultan de especial interés en el ámbito de la biomedicina.

En primer lugar, se presenta una breve reseña sobre las bandas cerebrales y su significado desde el punto de vista neuropsicológico. Cabe señalar que no existe una definición unificada respecto a los intervalos de frecuencia, medidos en hercios (Hz), asociados a cada banda cerebral. Por este motivo, en esta asignatura se adopta la cla-

sificación propuesta por **Webster y Nimunkar (2020)**, según la cual los intervalos de frecuencia son los siguientes: delta (δ): 1–4 Hz; theta (θ): 4–8 Hz; alfa (α): 8–13 Hz; beta (β): 13–30 Hz; y gamma baja (γ): 30–45 Hz.

3.2.1. Introducción histórica a la electroencefalografía

La **electroencefalografía** es una disciplina relativamente joven (Serman y Chartier, 2023). Según estos autores (p. 104), en 1875 **Richard Caton** fue el primero en informar sobre la observación de actividad eléctrica en los cerebros de monos y conejos, si bien las técnicas disponibles en aquella época no le permitieron registrar de manera adecuada las diferentes bandas de actividad. Caton llevó a cabo sus observaciones mediante un dispositivo denominado **galvanómetro de espejo de Thomson** (Caton, 1877).

Posteriormente, **Hans Berger**, considerado el padre de la electroencefalografía moderna, fue el primero en registrar el **electroencefalograma (EEG) en humanos** (véase Figura 3.20), durante su etapa como profesor de Psiquiatría en la Universidad de Jena (Alemania). En trabajos previos, Berger ya había realizado mediciones precisas de las pulsaciones cerebrales tanto en animales como en humanos y, más adelante, llevó a cabo estudios sobre la temperatura cerebral (Libenson, 2024).

Hans Berger fue un neurólogo alemán, discípulo de **Otto Ludwig Binswanger** (1852–1929) en la clínica psiquiátrica universitaria, junto con **Oskar Vogt** (1870–1959) y **Korbinian Brodmann** (1868–1918). Posteriormente, Berger llegó a ser jefe de la Unidad de Psiquiatría de la Universidad de Jena.

En sus investigaciones iniciales, su principal objetivo fue **identificar una correlación entre la actividad cerebral objetiva y los fenómenos psíquicos subjetivos**. Para ello, estudió la influencia de variables fisiológicas como los latidos cardíacos, la respiración, las funciones vasomotoras y la posición de la cabeza y del cuerpo sobre las pulsaciones cerebrales. Más adelante, el Dr. Berger trató de establecer una relación entre la temperatura cerebral y los procesos psíquicos.

Finalmente, centró sus esfuerzos en la demostración de la actividad eléctrica del cerebro humano. A partir de 1925, modificó su metodología y se especializó en el registro de las fluctuaciones espontáneas del potencial eléctrico cerebral. Su primera publicación sobre electroencefalografía data del **22 de abril de 1929**, mientras que el descubrimiento del electroencefalograma humano se sitúa el **6 de julio de 1924**. En la **Figura 68** se pueden consultar **imágenes del laboratorio de Hans Berger**.

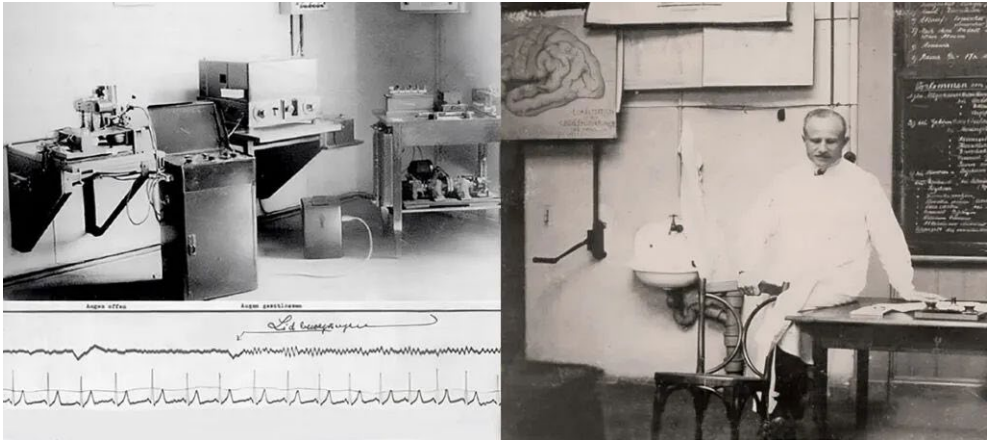


Figura 68. Laboratorio de neuropsiquiatría de Hans Berger (imágenes tomadas de acceso libre).

3.2.2. Descripción de las bandas cerebrales

En la **Figura 69** se pueden visualizar las diferentes bandas de frecuencia que se detectan habitualmente mediante **electroencefalografía (EEG)** o **magnetoencefalografía (MEG)**:

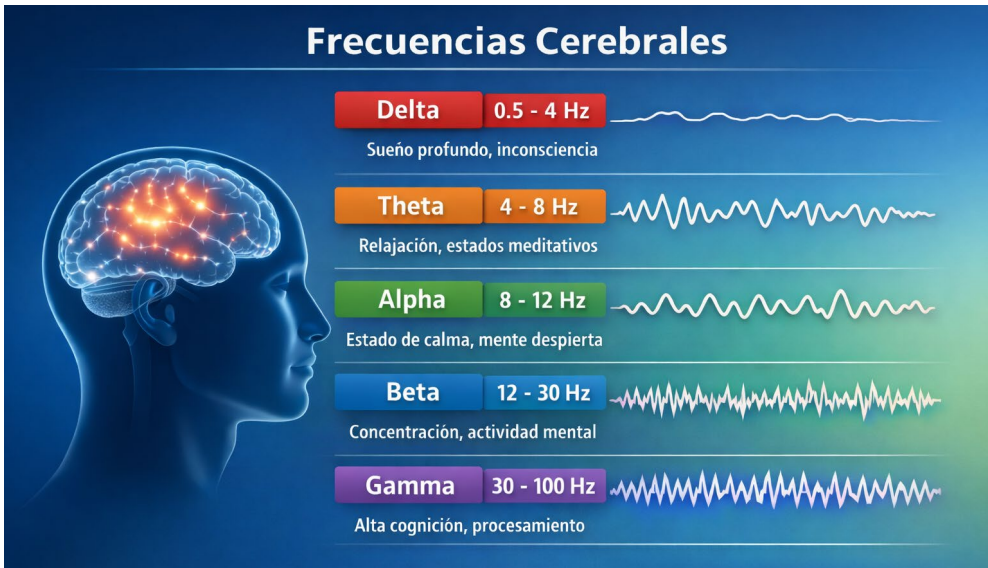


Figura 69. Representación de las bandas de frecuencia, realizada mediante ChatGPT.

Bandas delta (δ) 1-4 Hz

Esta banda, se asocia principalmente con estados de sueño profundo y con niveles de conciencia reducidos o no conscientes (véase **Figura 70**).




Figura 70. Representación de la banda delta, imagen de uso libre tomada de Bitbrain [enlace-022](#).

Bandas theta (θ) 4-8 Hz

Esta banda se asocia con el inicio de la somnolencia y con estados de relajación. Presenta un bajo voltaje y puede manifestarse en cualquier región del cerebro. Su activación se relaciona con la asimilación de información nueva, especialmente en personas de edad avanzada (véase **Figura 71**).

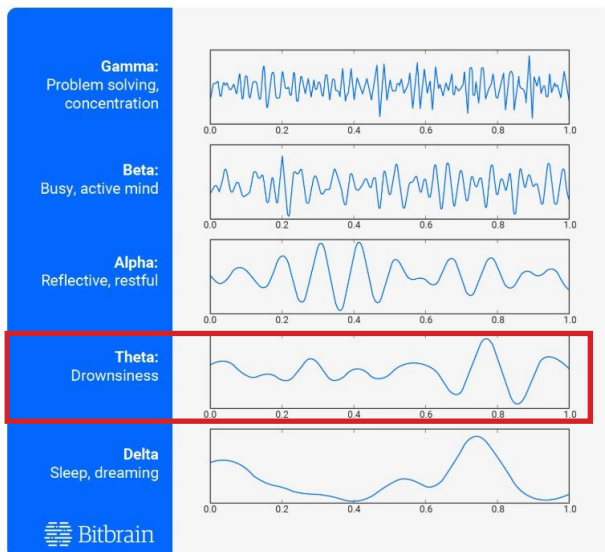



Figura 71. Representación de la banda theta, imagen de uso libre tomada de Bitbrain [enlace-023](#).

Bandas alfa (α) 8-13 Hz

También denominadas *ondas de Berger*, en honor a Hans Berger, primer investigador en aplicar la electroencefalografía a seres humanos. Las ondas alfa se detectan habitualmente mediante **EEG** o **magnetoencefalografía (MEG)** y se originan principalmente en el lóbulo occipital durante estados de relajación, con los ojos cerrados y en vigilia. Se considera que representan la actividad de la corteza visual en un estado funcional de reposo.

Estas ondas, tienden a enlentecerse durante la transición al sueño y a acelerarse al abrir los ojos, al realizar movimientos o incluso ante la anticipación de una acción o intención cognitiva (ver **Figura 72**).




enlace-024

Figura 72. Representación de la banda alfa, imagen de uso libre tomada de Bitbrain [enlace-024](#).

Bandas beta (β) 13-30 Hz

Esta banda, se asocia con estados de vigilia y conciencia plena, así como con una actividad mental activa. Está relacionada con procesos cognitivos como el pensamiento lógico, el razonamiento y la resolución de problemas, además de con estados de alerta, concentración y atención sostenida. Asimismo, la actividad beta puede incrementarse durante situaciones de estrés, ansiedad o excitación emocional (véase **Figura 73**).



enlace-025

Figura 73. Representación de la banda beta, imagen de uso libre tomada de Bitbrain [enlace-025](#).


Bandas gamma (γ) 30-100 Hz

Estas bandas, se asocian con estados de vigilia activa, atención sostenida y procesamiento cognitivo complejo (ver **Figura 74**). Se suelen subdividir en tres rangos:

Gamma baja (30–45 Hz): relacionada con atención sostenida e integración básica de información sensorial. Facilita la unión de estímulos visuales, auditivos y somatosensoriales.

Gamma media (45–70 Hz): vinculada con procesos de pensamiento cognitivo complejo, como razonamiento abstracto, toma de decisiones y memoria. Participa en funciones ejecutivas y creatividad.

Gamma alta (70–100 Hz): asociada con estados de alta conciencia y experiencias de *insight*. También puede aparecer en procesos patológicos, como episodios epilépticos.



enlace-026

Figura 74. Representación de la banda gamma, imagen de uso libre tomada de Bitbrain [enlace-026](#).

Seguidamente, se presenta una **tabla resumen de las funcionalidades de las bandas cerebrales**, considerando su **localización, función cognitiva y asociación emocional** (ver **Tabla 2**).

Tabla 2. Sensores cerebrales, localización, función cognitiva, emociones y bandas cerebrales relevantes

Sensor / Técnica	Localización	Función cognitiva	Tarea de procesamiento	Bandas cerebrales relevantes
EEG frontal	Lóbulo frontal	Control ejecutivo, inhibición	Reconocimiento de emociones faciales	Beta, Gamma
EEG temporal	Lóbulo temporal	Memoria, asociación emocional	Identificación de expresiones auditivas	Theta, Gamma media
EEG parietal	Lóbulo parietal	Atención e integración multisensorial	Detección de emociones visuales y auditivas	Beta, Theta
EEG occipital	Lóbulo occipital	Procesamiento visual	Análisis de gestos y expresiones faciales	Alfa, Gamma baja
EEG central	Corteza somatosensorial / motora	Acción y percepción táctil	Reacción a estímulos emocionales táctiles	Beta, Gamma baja

A continuación, se presenta una tabla resumen respecto de la **relación entre los sensores cerebrales, su localización y la función cognitiva**, considerando además las emociones y las bandas cerebrales más relevantes (véase **Tabla 3**).

Tabla 3. Relación entre los sensores cerebrales, su localización cerebral, su función cognitiva respecto del reconocimiento de emociones y su relación con la activación de las bandas cerebrales

Canal	Hemisferio	Lóbulo	Función cognitiva principal	Procesamiento emocional facial	Bandas relevantes
AF7	Izquierdo	Frontal anterior	Regulación emocional, control inhibitorio	Alegría, sorpresa	Alpha, Beta
FP1	Izquierdo	Prefrontal	Decisión, empatía, emociones positivas	Alegría	Alpha, Theta
FP2	Derecho	Prefrontal	Alerta, vigilancia, emociones negativas	Miedo, enfado	Beta, Theta
AF8	Derecho	Frontal anterior	Respuesta a estímulos emocionales	Miedo, sorpresa	Beta, Theta
F3	Izquierdo	Frontal medio	Lenguaje, atención, cognición verbal	Alegría	Alpha, Beta
F4	Derecho	Frontal medio	Activación emocional, evaluación de amenaza	Enfado, miedo	Beta, Theta
P3	Izquierdo	Parietal	Procesamiento espacial y sensorial	Sorpresa	Alpha, Beta
P4	Derecho	Parietal	Atención visual y reconocimiento espacial	Tristeza, miedo	Alpha, Theta
PO7	Izquierdo	Parieto-occipital	Reconocimiento de rasgos faciales sociales	Alegría, tristeza	Alpha, Theta, Delta
O1	Izquierdo	Occipital	Percepción visual inicial	Todas	Alpha, Theta, Delta
O2	Derecho	Occipital	Procesamiento emocional visual posterior	Miedo, sorpresa	Alpha, Theta, Delta
PO8	Derecho	Parieto-occipital	Integración visual-emocional, reconocimiento facial	Enfado, alegría, miedo	Beta, Alpha, Theta

Asimismo, se expone una **relación entre los sensores cerebrales, su localización y la función cognitiva**, asociada al procesamiento durante **tareas de reconocimiento de emociones** (véase **Tabla 4**).

Tabla 4. Relación entre los sensores cerebrales, su localización cerebral y su función cognitiva respecto del reconocimiento de emociones.

Canal BIC	Hemisferio	Lóbulo	Función Cognitiva Principal	Procesamiento de Emociones Visuales
AF7	Izquierdo	Frontal anterior	Regulación afectiva, empatía, control emocional	↑ en alegría y sorpresa (emociones positivas)
FP1	Izquierdo	Prefrontal	Procesamiento emocional positivo, toma de decisiones	↑ en alegría, ↓ en tristeza
FP2	Derecho	Prefrontal	Emociones negativas, vigilancia, ansiedad	↑ en miedo y enfado
AF8	Derecho	Frontal anterior	Respuesta a estímulos emocionales negativos	↑ en sorpresa, miedo
F3	Izquierdo	Frontal medio	Motivación, razonamiento verbal, atención focalizada	↑ en alegría, ↓ en tristeza
F4	Derecho	Frontal medio	Activación emocional, procesamiento de amenaza	↑ en miedo, enfado
P3	Izquierdo	Parietal	Percepción sensorial consciente, atención espacial selectiva	↑ en sorpresa, alegría
P4	Derecho	Parietal	Atención visual, vigilancia, procesamiento global	↑ en miedo, tristeza
PO7	Izquierdo	Parieto-occipital	Análisis detallado de expresiones faciales y señales sociales	↑ en alegría, tristeza
O1	Izquierdo	Occipital	Percepción visual básica	Activación general ante todas las emociones visuales
O2	Derecho	Occipital	Procesamiento visual rápido, movimiento emocional	↑ en miedo, sorpresa
PO8	Derecho	Parieto-occipital	Reconocimiento emocional facial, atención a estímulos sociales	↑ en enfado, miedo, alegría

3.2.3. Procesamiento de la señal de EEG

Como se indicó en el **Tema 2**, las señales recogidas mediante dispositivos de señal integrada pueden proporcionar resultados de datos **procesados**. No obstante, estos dispositivos también registran **datos sin procesar** que se denominan **datos en crudo**. Dichos datos, representan tanto un desafío como una oportunidad, ya que permiten al profesional **procesar y analizar directamente los datos**, obteniendo información adicional más detallada y valiosa.

En la **Figura 75** se presenta un **esquema del proceso de tratamiento de la señal de EEG**.

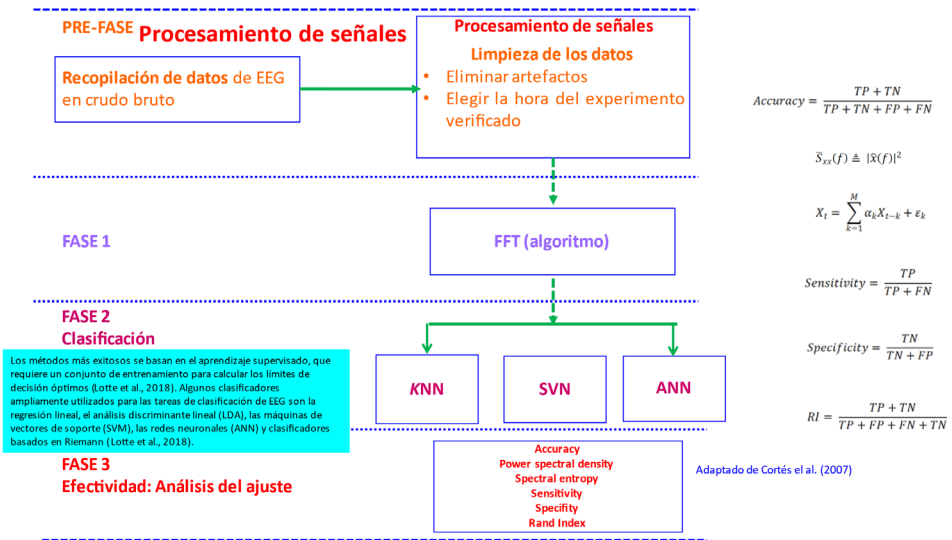


Figura 75. Fases del procedimiento de tratamiento de la señal (fuente propia).

El tratamiento de la señal de EEG se puede realizar utilizando **EEGLAB** en MATLAB o **MNE** en Python.

EEGLAB

EEGLAB es un *toolbox* de código abierto para MATLAB, ampliamente utilizado en neurociencia para **procesar, analizar y visualizar datos de EEG**. Sus principales características incluyen:

- **Importación de datos:** permite cargar datos crudos desde múltiples formatos, aunque en algunos casos es necesario convertir los archivos al estándar de EEGLAB (*.set / .fdt).
- **Preprocesamiento:** ofrece herramientas para filtrado, eliminación de artefactos (por ejemplo, parpadeo o movimientos oculares), segmentación en épocas y corrección de referencias, entre otros.

- **Análisis avanzado:** implementa técnicas como **ICA** (*Análisis de Componentes Independientes*) para separar fuentes cerebrales y artefactos, análisis de potencia espectral, coherencia, conectividad y análisis tiempo-frecuencia.

Esta herramienta es ampliamente utilizada en investigación académica debido a su capacidad para **explorar datos de EEG de manera interactiva y gráfica**, facilitando tanto el análisis exploratorio como el procesamiento avanzado de señales.

MNE-Python (MNE)

MNE-Python es una librería de código abierto en Python diseñada para el **análisis de datos de EEG y MEG** (OpenAI, 2025). Sus principales características incluyen:

- **Carga de datos:** permite importar datos crudos desde múltiples formatos, incluidos archivos exportados de sistemas como Bitbrain, generalmente en formatos estándar como *.edf*, *.bdf*, *.fif*, *.csv*, entre otros.
- **Preprocesamiento:** ofrece un ecosistema robusto que incluye filtrado, detección y corrección de artefactos, interpolación de canales, segmentación, anotación de eventos y promediado.
- **Análisis avanzado:** facilita el análisis tiempo-frecuencia, conectividad funcional, decodificación mediante *machine learning* y análisis estadísticos sobre datos crudos o promediados (ERP, oscilaciones, etc.).
- **Integración con Python:** a diferencia de EEGLAB, MNE está completamente integrado en el ecosistema Python, lo que permite pipelines reproducibles, escalables y la integración con técnicas de inteligencia artificial, siendo ideal para investigación con grandes volúmenes de datos.

Ejemplo de trabajo con MNE

Revisar los tutoriales de MNE-Python y elegir el más adecuado para el análisis deseado. Por ejemplo, el tutorial *Overview of MEG/EEG analysis with MNE-Python* cubre el flujo básico de análisis de eventos, incluyendo carga de datos, segmentación en épocas, promediado, trazado y estimación de la actividad cortical a partir de los sensores. Presenta las estructuras de datos principales de MNE-Python: **Raw**, **Epochs**, **Evoked** y **SourceEstimate**.

El flujo de trabajo típico para analizar datos EEG/MEG con MNE-Python puede resumirse en los siguientes pasos:

Paso 1. Instalación de MNE:

Se recomienda seguir las instrucciones oficiales: [MNE Installers](#).

Paso 2. Carga de datos (*Loading data*):

Se importan los datos crudos y se inspecciona su estructura, un ejemplo se puede consultar en la **Figura 76**.



MNE Installers

```

import numpy as np
import mne
sample_data_folder = mne.datasets.sample.data_path()
sample_data_raw_file = (
    sample_data_folder / "MEG" / "sample" / "sample_audvis_filt-0-40_raw.fif")
raw = mne.io.read_raw_fif(sample_data_raw_file)
raw.pick("eeg")
raw.compute_psd(fmax=45).plot(picks="data", exclude="bads", amplitude=False)
raw.plot(n_channels=12, scalings="auto")

```

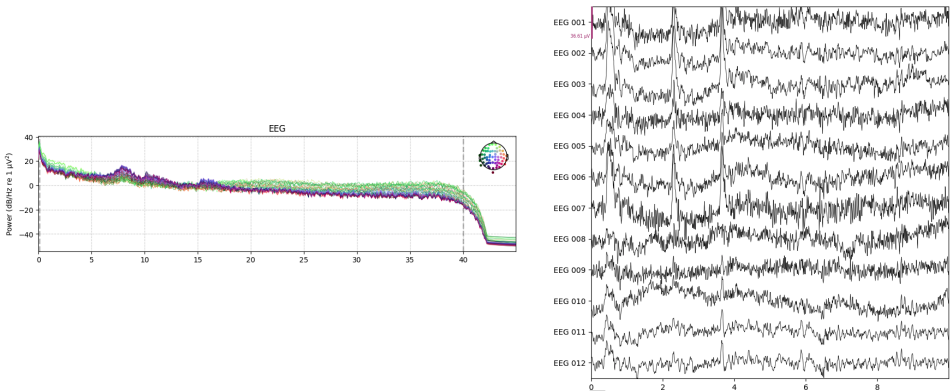


Figura 76. Representación de datos de un registro de EEG (tomado de MNE [enlace-027](#)).



enlace-027

Paso 3. Preprocesamiento (*Preprocessing*):

MNE permite realizar el filtrado y la limpieza de las señales mediante diversas técnicas, entre las que se incluye el uso de ICA (*Independent Component Analysis*), ilustrada en la **Figura 77**.

```

ica = mne.preprocessing.ICA(n_components=20, random_state=97, max_iter=800)
ica.fit(raw)
ica.exclude = [1, 2] # details on how we picked these are omitted here
ica.plot_properties(raw, picks=ica.exclude)

```

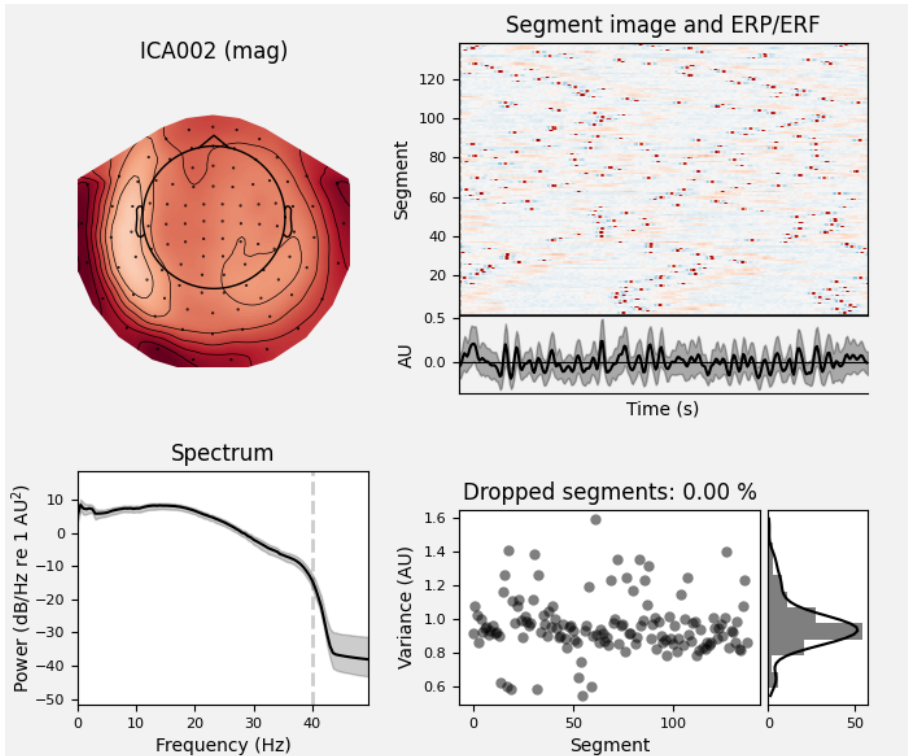


Figura 77. Limpieza de artefactos mediante ICA (tomado de MNE [enlace-028](#)).



enlace-028

Paso 4. Detección de eventos experimentales (*Detecting experimental events*):

Los conjuntos de datos de ejemplo incluyen canales STIM que registran señales eléctricas enviadas desde el ordenador de administración de estímulos (por ejemplo, pulsos de onda cuadrada). Estos pulsos se utilizan para marcar eventos experimentales: inicio del estímulo, tipo de estímulo y respuesta del participante. Los canales STIM individuales se combinan en un único canal, que se decodifica sin ambigüedad mediante `mne.find_events`. Un ejemplo se puede consultar en la **Figura 78**.

```
raw = mne.io.read_raw_fif(sample_data_raw_file)
events = mne.find_events(raw, stim_channel="STI 014")
event_dict = {"auditory/left": 1, "auditory/right": 2, "visual/left": 3,
             "visual/right": 4, "smiley": 5, "buttonpress": 32}
fig = mne.viz.plot_events(events, event_id=event_dict, sfreq=raw.info["sfreq"], first_samp=raw.first_samp)
```




Figura 78. Detección de eventos experimentales (tomado de MNE [enlace-029](#)).

Paso 5. Segmentación de datos en épocas (*Epoching*).

A partir del objeto **Raw** y la matriz de eventos se crean objetos *Epochs*, aplicando restricciones de calidad: se descartan épocas en las que la amplitud pico a pico exceda los límites definidos por tipo de canal. Para procesos automatizados, se puede emplear el paquete *autoreject*.

Una *epoch* (época) en este contexto es un fragmento temporal de datos extraído alrededor de un evento de interés (ver **Figura 79**).

```
reject_criteria = dict(
    mag=4000e-15, # 4000 fT
    grad=4000e-13, # 4000 fT/cm
    eeg=150e-6, # 150 µV
    eog=250e-6,
)
epochs = mne.Epochs(
    raw,events,
    event_id=event_dict,
    tmin=-0.2,
    tmax=0.5,
    reject=reject_criteria,
    preload=True,
)
```

```

conds_we_care_about = ["auditory/left", "auditory/right", "visual/left", "visual/right"]
epochs.equalize_event_counts(conds_we_care_about)
aud_epochs = epochs["auditory"]
vis_epochs = epochs["visual"]
aud_epochs.plot_image(picks=["EEG 021"])

```




Figura 79. *Epoch* en EEG (tomado de MNE [enlace-030](#)).



enlace-030

Paso 6. Análisis tiempo-frecuencia (*Time-frequency analysis*):

El submódulo `mne.time_frequency` permite calcular representaciones de tiempo-frecuencia, densidad espectral de potencia y densidad espectral cruzada. Un ejemplo se puede consultar en la **Figura 80**.

```

frequencies = np.arange(7, 30, 3)
power = aud_epochs.compute_tfr("morlet", n_cycles=2, return_itc=False, freqs=frequencies,
decim=3, average=True)
power.plot(["EEG 021"])

```




Figura 80. Análisis tiempo-frecuencia (tomado de MNE [enlace-031](#)).



enlace-031

Paso 7. Estimación de respuestas promediadas (*Estimating evoked responses*):

Cuando se realizan tareas de potenciales evocados auditivos y visuales, los patrones neurofisiológicos que se obtienen son los que se observan en la **Figura 81**.

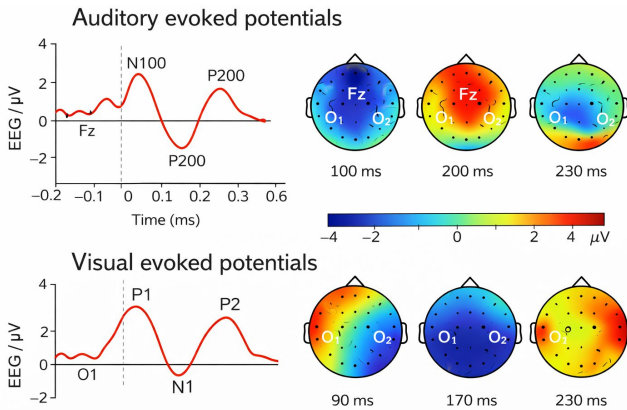


Figura 81. Topografía de registros neurofisiológicos para potenciales evocados auditivos y visuales (imagen creada por ChatGPT).

Se puede comprobar con datos propios, como, una vez obtenidas las épocas, se pueden calcular respuestas evocadas promedio por condición experimental, generando estimaciones de la actividad cerebral (ver **Figura 82**).

```
aud_evoked = aud_epochs.average()
vis_evoked = vis_epochs.average()
mne.viz.plot_compare_evoked(
    dict(auditory=aud_evoked, visual=vis_evoked),
    legend="upper left",
    show_sensors="upper right")
```




Figura 82. Estimación de respuestas promediadas (tomado de MNE [enlace-032](#)).



enlace-032

También, es posible realizar una visualización más detallada de las áreas implicadas en los eventos, tanto para tarea auditiva como visual (ver **Figura 83** y **Figura 84**).

```
aud_evoked.plot_joint(picks="eeg")
aud_evoked.plot_topomap(times=[0.0, 0.08, 0.1, 0.12, 0.2, 0.24], ch_type="eeg")
vis_evoked.plot_joint(picks="eeg")
vis_evoked.plot_topomap(times=[0.0, 0.09, 0.12, 0.18, 0.22, 0.26, 0.3], ch_type="eeg")
```

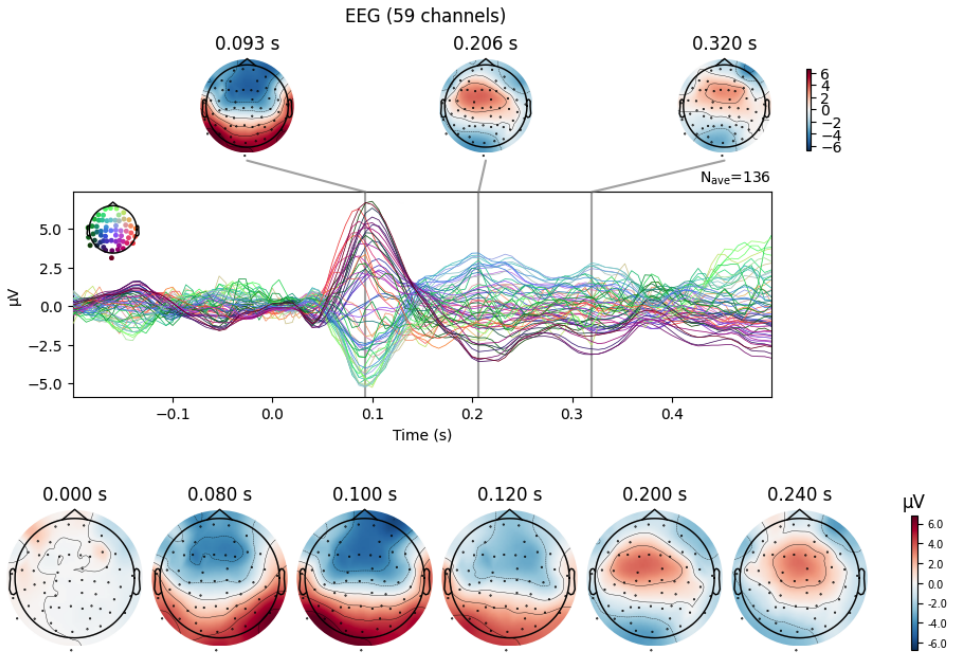


Figura 83. Visualización de la localización de la señal de EEG en tarea auditiva (tomado de tutorial MNE [enlace-033](#)).



enlace-033

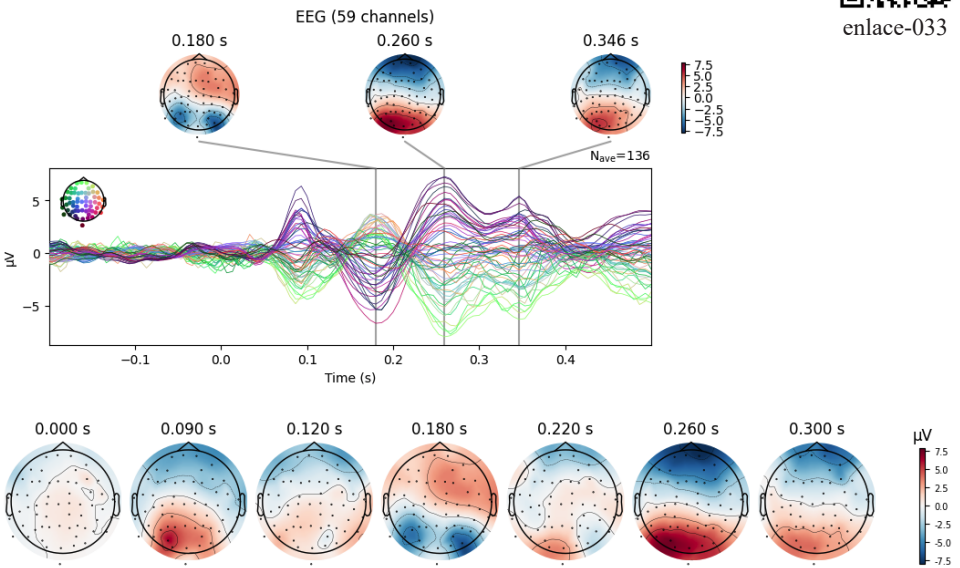


Figura 84. Visualización de la localización de la señal de EEG en tarea visual (tomado de tutorial MNE [enlace-034](#)).



enlace-034

3.2.4. Aplicaciones en ciencias biomédicas

En las décadas de 1960 y 1970 se llevaron a cabo los primeros experimentos con **interfaces cerebro-máquina (Brain Computer Interface -BCI-, por sus siglas en inglés)**. Durante los años 60, los investigadores comenzaron a explorar la posibilidad de utilizar el **EEG** para interpretar pensamientos y permitir que los usuarios controlaran dispositivos mediante la actividad cerebral. En 1973, **Jacques Vidal**, en la Universidad de California, acuñó el término *Brain-Computer Interface* y demostró que era posible usar señales cerebrales para interactuar con una computadora.

En las décadas de 1980 y 1990 se desarrollaron dispositivos experimentales que permitían a los usuarios controlar cursores en una pantalla mediante señales de EEG. Un hito importante ocurrió en 1999, cuando un equipo de la **Universidad de Duke**, liderado por **Miguel Nicolelis** (biólogo, médico y neurocientífico), consiguió que un mono controlara un brazo robótico mediante señales cerebrales (Lebedev y Nicolelis, 2006).

Entre 2000 y 2010 se registraron avances significativos en implantes y aplicaciones médicas. Por ejemplo, en 2004 se desarrolló el **sistema BrainGate**, que permitió a personas con parálisis controlar cursores de computadora mediante un implante neuronal (Ajiboye et al., 2017). Durante este periodo, tanto las interfaces invasivas (implantes de electrodos) como las no invasivas (EEG) mejoraron en precisión, facilitando un mayor control de prótesis y dispositivos electrónicos.

Desde 2010 hasta la actualidad, la integración de **Inteligencia Artificial** ha impulsado importantes avances en neurotecnología. Empresas como *Neuralink* (fundada en 2016), *OpenBCI* y *Kernel* están desarrollando interfaces más precisas mediante algoritmos de IA. Los esfuerzos se centran en la **restauración del habla, el movimiento y la memoria** a través de BCI, así como en aplicaciones en **entrenamiento, realidad virtual y comunicación** para personas con discapacidades severas.

Tecnologías no invasivas

A continuación, se presenta una breve descripción de las **tecnologías no invasivas** y su funcionalidad en el contexto de la **neuropsicología aplicada**:

Electroencefalografía (EEG)

La **EEG** es una técnica no invasiva de registro neurofisiológico funcional que registra la actividad eléctrica del cerebro mediante electrodos colocados sobre el cuero cabelludo. Su funcionamiento se basa en que la actividad eléctrica proviene principalmente de las **corrientes postsinápticas de las neuronas piramidales corticales**. Los electrodos detectan los **potenciales eléctricos sumados** de grandes poblaciones neuronales sincronizadas.

Estas señales se representan como **bandas cerebrales en función del tiempo**, permitiendo analizar frecuencia, amplitud y ritmo de la actividad neuronal. La EEG se utiliza ampliamente en investigación cognitiva, diagnóstico de epilepsia, trastornos del sueño, alteraciones neurológicas y monitorización intraoperatoria.

Espectroscopía Funcional de Infrarrojo Cercano (fNIRS)

La **fNIRS** es una técnica no invasiva de neuroimagen funcional que utiliza luz en el rango del **infrarrojo cercano (650–1000 nm)** para medir cambios hemodinámicos asociados con la actividad neuronal. Esta técnica registra variaciones en el **flujo sanguíneo cerebral**, que reflejan la activación de regiones específicas del cerebro.

Su principio se basa en que, cuando una región cerebral se activa, aumenta el consumo de oxígeno, lo que produce cambios locales en la concentración de **hemoglobina oxigenada (HbO₂)** y **desoxigenada (HbR)**. La fNIRS emite luz a través del cráneo y mide cómo esta luz es absorbida y dispersada en el tejido cerebral. Como la hemoglobina absorbe la luz en longitudes de onda específicas, es posible inferir la **dinámica del flujo sanguíneo cerebral** relacionada con la actividad neuronal. Funciona de manera similar al BOLD-fMRI, pero con la ventaja de ser **portátil y más accesible**. Se emplea principalmente en estudios cognitivos y en la rehabilitación de pacientes con daño cerebral.

Magnetoencefalografía (MEG)

La **MEG** es una técnica no invasiva que registra la actividad cerebral midiendo los **campos magnéticos generados por las corrientes eléctricas de las neuronas**, principalmente las células piramidales de la corteza.

El principio de funcionamiento se basa en que la **activación sincrónica de grupos de neuronas** genera corrientes eléctricas que producen **campos magnéticos extremadamente débiles** (del orden de femtoteslas, 10^{-15} T). La MEG detecta estos campos mediante **magnetómetros superconductores (SQUIDS)** o, más recientemente, **sensores de espín atómico (OPMs)**.

Estas mediciones permiten inferir la **dinámica temporal y espacial de la actividad neuronal**. La MEG ofrece una **mejor resolución espacial que la EEG**, ya que los campos magnéticos no se distorsionan significativamente por el cráneo y el cuero cabelludo. Se utiliza frecuentemente en **investigación en neurociencia cognitiva** y en la evaluación de patologías como la **epilepsia**. En la **Tabla 5** se presenta una comparativa entre estas técnicas de registro no invasivas.

Tabla 5. Comparativa de la funcionalidad de técnicas no invasivas.

Técnica	Señal medida	Principio de funcionamiento	Resolución temporal	Resolución espacial	Aplicaciones principales
EEG	Potenciales eléctricos de la corteza	Detecta corrientes postsinápticas sumadas de neuronas piramidales mediante electrodos en el cuero cabelludo	Muy alta (ms)	Baja	Investigación cognitiva, epilepsia, trastornos del sueño, monitorización intraoperatoria
fNIRS	Cambios hemodinámicos (HbO ₂ /HbR)	Mide la absorción de luz infrarroja cercana por hemoglobina oxigenada y desoxigenada	Moderada (segundos)	Baja-moderada	Estudios cognitivos, rehabilitación de daño cerebral, seguimiento de activación cortical
MEG	Campos magnéticos generados por corrientes neuronales	Detecta campos magnéticos de corrientes neuronales sin distorsión por cráneo/cuero cabelludo, mediante SQUIDs u OPMs	Muy alta (ms)	Alta	Investigación en neurociencia, epilepsia, localización funcional cortical

En la **Figura 85** se presenta una visualización de las técnicas no invasiva.



Figura 85. Comparativa de técnicas no invasivas: EEG, fNIRS y MEG (imagen elaborada por ChatGPT).

Tecnologías invasivas

Las **tecnologías invasivas** son métodos que requieren penetrar en el organismo, en este caso en el cerebro, ya sea mediante cirugía o implantación. Estas técnicas permiten **registrar la actividad neuronal de forma directa**, mejorando la **precisión y velocidad** de los dispositivos controlados por el usuario. Entre los ejemplos más representativos se incluyen: **implantes de electrodos intracorticales, estimulación cerebral profunda y BCI invasivas**. Por ejemplo, los implantes de electrodos intracorticales que registran la actividad neuronal, la estimulación cerebral profunda para tratar afectaciones neurológicas como la **enfermedad de Parkinson** e interfaces cerebro-computadora invasivas, que registran señales neuronales con alta fidelidad para controlar los dispositivos internos. Los implantes proporcionan una conexión directa con el cerebro, **mejorando precisión y velocidad**, seguidamente se va a poner algún ejemplo de estas tecnologías.

Neuralink

Neuralink, es una empresa de neurotecnología fundada en 2016 por Elon Musk y otros colaboradores, dedicada al desarrollo de interfaces cerebro-computadora (BCI) invasivas que permitan registrar y estimular actividad neuronal directamente en el cerebro. Su objetivo fundamental es crear dispositivos implantables que conecten el cerebro humano con computadoras u otros dispositivos electrónicos para: **restaurar funciones perdidas por lesiones neurológicas; tratar enfermedades neurológicas** (parálisis, Parkinson, epilepsia) y eventualmente, **aumentar capacidades cognitivas humanas mediante comunicación directa con máquinas**. Las características de esta tecnología se relacionan con la utilización de **implantes de electrodos flexibles ultrafinos capaces de registrar la actividad neuronal con alta resolución**. Dichos electrodos, se conectan a un *chip* implantado en el cráneo, que transmite información al exterior de forma inalámbrica. Este diseño pretende ser menos invasivo y más seguro que los implantes tradicionales, aunque sigue requiriendo cirugía. Además, incluye un **robot quirúrgico** especializado para implantar los electrodos de manera precisa y minimizando daños en el tejido cerebral.

BrainGate

BrainGate, es un sistema de **interfaz cerebro-computadora (BCI)** invasiva diseñado para permitir a personas con **parálisis cerebral severa o pérdida de funciones motoras controlar dispositivos externos**, como computadoras, prótesis o brazos robóticos, **utilizando únicamente sus pensamientos**. Esta tecnología, se basa en la **lectura directa de la actividad neuronal en la corteza motora del cerebro**. El sistema *BrainGate* fue desarrollado inicialmente por el laboratorio del Dr. John P. Donoghue en el Departamento de Neurociencia de la Universidad de Brown. Posteriormente, en 2002, se fundó la empresa Cyberkinetics, Inc. (más tarde Cyberkinetics Neurotechnology Systems, Inc.) como una spin-off de la universidad para llevar a cabo ensayos clínicos con humanos. En 2009, la empresa fue

adquirida por BrainGate, Inc., que actualmente posee y gestiona la tecnología y la propiedad intelectual asociada al sistema BrainGate. El sistema *BrainGate* consta de dos componentes principales: un *array* de microelectrodos (Utah Array): Un conjunto de **electrodos ultrafinos implantados en la corteza motora del cerebro**, capaces de **registrar la actividad eléctrica** de las neuronas, un **decodificador externo**: Un dispositivo que **interpreta las señales neuronales registradas y las traduce en comandos para controlar dispositivos externos, como un cursor en una pantalla, un brazo robótico o una silla de ruedas**. *BrainGate* ha sido utilizado en ensayos clínicos con personas que padecen **tetraplejía** o **esclerosis lateral amiotrófica (ELA)**. En estos estudios, los participantes han logrado controlar dispositivos externos con alta precisión, permitiéndoles realizar tareas como mover un cursor en una pantalla, escribir correos electrónicos o beber de una taza utilizando un brazo robótico controlado por sus pensamientos.

Synchron

Synchron, es una empresa de neurotecnología que ha desarrollado una **interfaz cerebro-computadora (BCI) mínimamente invasiva denominada Stentrode**. Este dispositivo permite a personas con **parálisis cerebral severa controlar dispositivos digitales utilizando únicamente sus pensamientos**, sin necesidad de cirugía cerebral abierta. La tecnología de Implante *Stentrode* hace referencia a un **arreglo de electrodos de platino incrustados en un stent de nitinol**¹, insertado a través de la vena yugular hasta un vaso sanguíneo cercano a la corteza motora. Esta ubicación permite registrar la actividad neuronal relacionada con la intención de movimiento sin penetrar directamente en el cerebro. También, incluye un **decodificador de señales**: Las señales neuronales captadas por el *Stentrode* **se transmiten a un dispositivo externo que las interpreta y las convierte en comandos digitales, permitiendo al usuario controlar dispositivos** como computadoras, tabletas o asistentes de voz. Su aplicación clínica se centra en la **restauración de funciones motoras** facilitando la interacción con dispositivos digitales para **personas con movilidad limitada**, permitiéndoles realizar tareas como enviar mensajes, navegar por internet o controlar dispositivos del hogar inteligente. También, es reseñable su colaboración con Apple en dispositivos de iPad y Vision Pro, utilizando las funciones de accesibilidad incorporadas para permitir el control por pensamiento y con Nvidia, en este caso para mejorar la decodificación de señales cerebrales, aumentando la precisión y velocidad de la interfaz. En la **Tabla 6** se presenta una comparativa entre estas técnicas invasivas.

¹ Un stent de nitinol es un dispositivo médico en forma de malla metálica, fabricado con una aleación de níquel y titanio conocida por sus propiedades de memoria de forma y alta flexibilidad. Este tipo de stent se utiliza para abrir arterias o vasos sanguíneos estrechados u obstruidos, permitiendo restablecer el flujo sanguíneo de manera eficiente fuente <https://www.mts.com/la/articles/biomedical/nitinol-devices>. El nitinol proporciona al stent excelente elasticidad, resistencia a la fatiga y adaptación a la anatomía vascular, lo que lo hace ideal para ubicaciones donde hay movimiento o torsión fuente <https://vascular.abbott.com/supera-stent-design-sla.html>.

Tabla 6. Comparativa de tecnologías invasivas de BCI.

Tecnología	Tipo de BCI / Método	Implantación / Procedimiento	Área de registro	Señal registrada	Decodificación / Salida	Aplicaciones
<i>Neuralink</i>	BCI invasiva	Implante de electrodos ultrafinos en el cráneo, con chip inalámbrico	Corteza cerebral general (electrodos flexibles)	Actividad neuronal de alta resolución	Chip externo que transmite señales inalámbricas	Restauración de funciones, tratamiento de enfermedades neurológicas, aumento cognitivo
<i>BrainGate</i>	BCI invasiva	Utah Array implantado en la corteza motora	Corteza motora	Actividad eléctrica de neuronas motoras	Decodificador externo interpreta señales y controla dispositivos	Control de prótesis, brazos robóticos, computadoras para personas con parálisis o ELA
<i>Synchron – Stentrode</i>	BCI mínimamente invasiva	Arreglo de electrodos de platino en <i>stent</i> insertado por vena yugular	Cerca de la corteza motora	Actividad neuronal relacionada con intención de movimiento	Decodificación externa que traduce señales en comandos digitales	Restauración de funciones motoras, control de dispositivos digitales, accesibilidad tecnológica

Asimismo, en la **Figura 86** se presenta una visualización de las técnicas de tecnología invasiva.

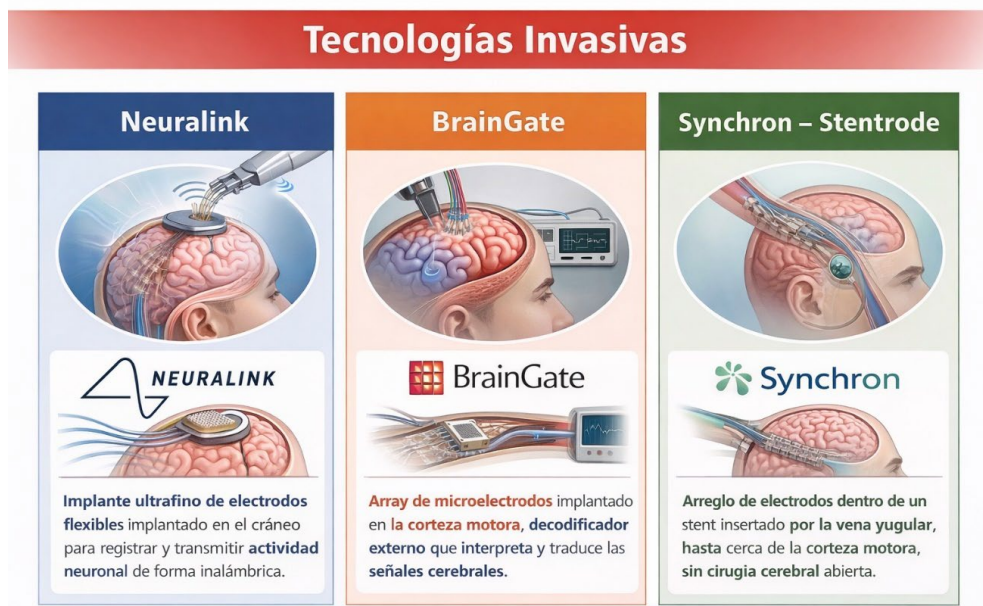


Figura 86. Comparativa de técnicas invasivas: Neuralink, BrainGate y Synchron-Stentrode (imagen elaborada por ChatGPT).

3.2.5. Avances en Inteligencia Artificial y Neurociencia Computacional

La **Inteligencia Artificial (IA)** aplicada a la **neurociencia** está transformando radicalmente la forma en que se analizan y comprenden los datos cerebrales. Las técnicas de **aprendizaje automático** y **aprendizaje profundo** se utilizan para procesar señales obtenidas mediante EEG, MEG, fNIRS y fMRI, permitiendo detectar patrones complejos de actividad neuronal asociados a **estados cognitivos, emocionales o motores**.

En el ámbito de las **interfaces cerebro-computadora (BCI)**, la IA tiene un papel crucial en la **decodificación neuronal**, traduciendo señales cerebrales en comandos capaces de controlar **prótesis robóticas, sintetizadores de voz o cursores en pantalla**. Esto permite una interacción directa entre el cerebro y dispositivos electrónicos, con aplicaciones clínicas para personas con parálisis o discapacidades motoras severas.

En cuanto a la **neuroimagen avanzada**, los modelos de IA mejoran significativamente la **reconstrucción de imágenes cerebrales**, aumentando la resolución y reduciendo el ruido, lo que facilita la identificación de **biomarcadores de enfermedades neurológicas** como la epilepsia, el Alzheimer y otros trastornos neurodegenerativos. La IA permite procesar grandes volúmenes de datos neuronales, optimizando el análisis longitudinal y multimodal, mientras que la **neurociencia computacional** inspira nuevos algoritmos de aprendizaje que imitan procesos cognitivos y de procesamiento cerebral.

Esta convergencia entre IA y neurociencia abre el camino hacia:

- **Prótesis neurales más eficaces y adaptativas**, capaces de integrarse mejor con la actividad cerebral del usuario.
- **Diagnósticos precoces y personalizados** de trastornos neurológicos.
- Una **comprensión más profunda de los mecanismos cerebrales** subyacentes a la cognición, la emoción y el comportamiento.

De manera complementaria, los avances futuros implican desafíos éticos y regulatorios, incluyendo la necesidad de **legislación internacional** sobre privacidad neuronal, manipulación de datos cerebrales y derechos cognitivos. Entre las aplicaciones prospectivas destacan:

- La **conectividad neuronal en la nube**, que permitiría almacenar y compartir información relacionada con la actividad cerebral de forma segura.
- **Incremento de la memoria y del aprendizaje** mediante estimulación cerebral controlada por algoritmos inteligentes.
- **Interfaces cognitivas avanzadas**, capaces de potenciar la creatividad, la atención y la resolución de problemas mediante integración entre IA y sistemas neuronales.

En resumen, la integración de **IA y neurociencia computacional** no solo mejora el análisis de datos y el desarrollo de BCI, sino que también **expande el horizonte de la neurotecnología**, con potencial de transformar la medicina, la educación, la rehabilitación y las interacciones humanas con dispositivos inteligentes.

3.2.6. Aplicación de la tecnología multicanal integrada en contextos biomédicos

La **tecnología multicanal integrada**, por ejemplo, *eye tracking*, *GSR* y *EEG*, presenta múltiples aplicaciones en el ámbito de las ciencias de la salud, permitiendo registrar y analizar el comportamiento visual y otras señales fisiológicas de manera simultánea y precisa (una síntesis de las potencialidades se puede consultar en la **Figura 87**).



Figura 87. Ejemplos de aplicación de las señales integradas. (imagen elaborada por ChatGPT).

Entre sus principales aplicaciones destacan:

a) Detección y diagnóstico de afectaciones médicas

La utilización de dispositivos de *eye tracking* puede contribuir al diagnóstico precoz y seguimiento de diversas patologías. Por ejemplo:

- **Enfermedades oculares:** detección de glaucoma, degeneración macular u otros trastornos visuales, ejemplo con Tobii [enlace-035](#).



enlace-035

- **Enfermedades neurodegenerativas:** seguimiento de patrones de fijación y exploración visual en pacientes con Alzheimer, Parkinson o demencias frontotemporales.
- **Lesiones cerebrales:** evaluación de déficits en la atención visual, seguimiento ocular y coordinación ojo-mano tras traumatismos o accidentes cerebrovasculares (por ejemplo, utilizando sistemas Tobii [enlace-036](#), [enlace-037](#), [enlace-038](#)).



enlace-036



enlace-037



enlace-038

b) Tratamiento y rehabilitación

La tecnología multicanal permite diseñar estrategias de rehabilitación personalizadas:

- Mejora de habilidades de **lectoescritura** y aprendizaje en niños con dislexia o dificultades de aprendizaje.
- Desarrollo de capacidades **lógico-matemáticas** mediante entrenamiento guiado de atención y seguimiento visual.
- Rehabilitación cognitiva en pacientes con daño cerebral adquirido, utilizando tareas adaptativas basadas en la atención visual y la interacción multicanal.

c) Formación de profesionales de la salud

La utilización de un dispositivo de *eye tracking* integrado en simuladores médicos o quirúrgicos permite:

- Evaluar y mejorar la **atención, la toma de decisiones y la coordinación** en entornos clínicos y quirúrgicos.
- Entrenar a médicos, enfermeros y otros profesionales de la salud en **procedimientos complejos**, optimizando su rendimiento mediante retroalimentación basada en la actividad visual (por ejemplo, con sistemas Tobii).

d) Optimización de entornos médicos y asignación de recursos

- Integración de un dispositivo de *eye tracking* en **pantallas médicas y estaciones de monitoreo**, permite priorizar información relevante según los patrones de atención del personal sanitario.
- Asimismo, mejora el **flujo de trabajo**, reduciendo errores y aumentando la eficiencia en entornos clínicos y quirúrgicos.

e) Control de dispositivos mediante la mirada

- La utilización de dispositivos de *eye tracking* permite a personas con **discapacidad motora severa** interactuar con computadoras, sillas de ruedas, prótesis o sistemas de comunicación mediante control ocular, facilitando autonomía y calidad de vida, ejemplo con Tobii [enlace-39](#).



enlace-039

f) Registro e interpretación de biomarcadores conductuales

- Los datos de *eye tracking* permiten identificar **indicadores conductuales y cognitivos**, como patrones de atención, toma de decisiones o estrés, útiles en la investigación clínica y en estudios de neuropsicología aplicada (por ejemplo, mediante plataformas Tobii [enlace-40](#)).



enlace-040

En conjunto, la **tecnología multicanal integrada**, combinando *eye tracking* con otros sistemas de medición fisiológica y cognitiva, proporciona una **herramienta poderosa para diagnóstico, tratamiento, formación y mejora de la interacción humano-máquina** en contextos biomédicos. En la **Figura 88** se puede consultar una síntesis de posibles aplicaciones de la tecnología multicanal integrada a las ciencias biomédicas.

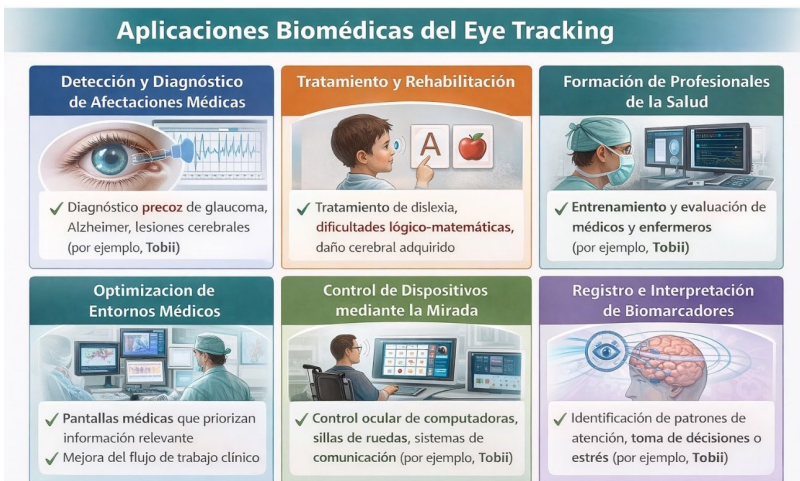


Figura 88. Aplicaciones biomédicas de *eye tracking* en tecnología multicanal: diagnóstico, rehabilitación, formación, optimización de entornos, control de dispositivos y biomarcadores (imagen elaborada por ChatGPT).

3.3. Práctica Tema 3

Objetivo:

Realizar un análisis de **datos multicanal integrados**, obtenidos durante las prácticas, aplicando técnicas de preprocesamiento, análisis y visualización que permitan extraer información relevante sobre la actividad cerebral y conductual.

Procedimiento sugerido:

1. Carga de datos crudos:

- Importar los datos en su formato original (por ejemplo, *.csv*, *.edf*, *.bdf*, *.fif*), provenientes de distintos dispositivos como EEG, *eye tracking* o fNIRS.
- Justificación: Mantener los datos crudos permite conservar toda la información original y evita pérdidas de señal que podrían afectar el análisis posterior.

2. Preprocesamiento de señales:

- **Filtrado:** aplicar filtros pasa-bajo, pasa-alto o *notch* según la frecuencia de interés para eliminar ruido, artefactos eléctricos o interferencias externas.
 - Ventaja: mejora la relación señal/ruido y facilita la identificación de patrones neuronales.
 - Inconveniente: un filtrado excesivo puede eliminar información relevante si no se seleccionan correctamente los rangos de frecuencia.
- **Eliminación de artefactos:** mediante técnicas como ICA (Análisis de Componentes Independientes) para separar movimientos oculares, parpadeos o actividad muscular.
 - Ventaja: permite limpiar la señal de contaminaciones externas.
 - Inconveniente: requiere interpretación cuidadosa para no eliminar componentes neuronales importantes.
- **Segmentación:** dividir la señal continua en épocas relacionadas con eventos experimentales (*stimuli*, respuestas, tareas).
 - Ventaja: facilita el análisis comparativo y promediado de la actividad cerebral.

3. Integración de canales y sincronización:

- Si se trabaja con datos multicanal (EEG, *eye tracking*, fNIRS), sincronizar temporalmente las señales para permitir comparaciones directas entre modalidades.

- Justificación: la integración multicanal permite correlacionar actividad cerebral con comportamiento visual o fisiológico, aumentando la comprensión del fenómeno estudiado.

4. Análisis de señales:

- **Análisis temporal y espectral:** para examinar frecuencia, amplitud y potencia de las ondas cerebrales.
- **Análisis conductual:** patrones de fijación, tiempo de mirada, *scan path* (ruta de la mirada).
- **Análisis correlacional o de conectividad:** determinar relaciones entre diferentes canales y modalidades.
- Justificación: cada análisis aporta información complementaria, permitiendo interpretar la actividad cerebral y su relación con la conducta de manera más completa.

5. Visualización de resultados:

- Mapas de calor, gráficos de potencia espectral, diagramas de conectividad, trazado de scan path.
- Ventaja: facilita la comprensión de patrones complejos y la comunicación de los hallazgos.

6. Interpretación y discusión:

- Comparar resultados obtenidos con los datos crudos y procesados.
- Evaluar la influencia de cada procedimiento de preprocesamiento en la señal y en la interpretación de los datos.
- Justificación: permite validar la metodología utilizada y comprender las limitaciones de cada técnica aplicada.

***Para la realización de la práctica se pueden utilizar herramientas de IAGen. Si bien, se deben seguir las instrucciones que se pueden consultar en el Anexo 1.**

****Las orientaciones detalladas y ampliadas para la realización de esta práctica se pueden consultar en el Anexo 2.**

3.4. Referencias

Ajiboye, A.B., Willett, F.R., Young, D.R., Memberg, W.D., Murphy, B.A., Miller, J.P., Walter, B.L., Sweet, J.A., Hoyen, H.A., Keith, M.W., Peckham, P.H., Simeral, J.D., Donoghue, J.P., Hochberg, L.R., y Kirsch, R.F. (2017). Restoration of reaching and grasping movements through brain-controlled muscle stimulation

- in a person with tetraplegia: a proof-of-concept demonstration. *Lancet.*, 6, 389(10081),1821-1830. [https://doi.org/10.1016/S0140-6736\(17\)30601-3](https://doi.org/10.1016/S0140-6736(17)30601-3)
- Lebedev, M.A, y Nicolelis, M.A. (2006). Brain-machine interfaces: past, present and future. *Trends Neurosci.* 29(9), 536-46. <https://doi.org/10.3390/10.1016/j.tins.2006.07.004>
- MNE-Python. (2025). MNE-Python: Open-source Python software for exploring, visualizing, and analyzing human neurophysiological data. Recuperado el 27 de agosto de 2025, de <https://mne.tools/stable/index.html>
- OpenAI. (2025). ChatGPT [Large language model]. Recuperado el 01/12/2025. <https://chat.openai.com/>
- Sáez-García, J., Sáiz-Manzanares, M. C., Marticorena-Sánchez, R. (2024). Challenges in data processing analysis by monitoring the learning process with Eye Tracking and Galvanic Skin Response. *Computers*, 13, 289. <https://doi.org/10.3390/computers13110289>
- Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Martín-Antón, L.J., González-Díez, I., & Carbonero-Martín, I. (2023). Using eye tracking technology to analyse cognitive load in multichannel activities in university students. *International Journal of Human-Computer Interaction*, 40(12), 3263–328. <https://doi.org/10.1080/10447318.2023.2188532>
- Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Martín-Antón, L.J., Almeida, L., & Carbonero-Martín, I. (2023). Application and challenges of eye tracking technology in Higher Education. *Comunicar*, 76, 1-12. <https://doi.org/10.3916/C76-2023-03>
- Sáiz-Manzanares, M.C., Ramos Pérez, I., Arnaiz-Rodríguez, Á., Rodríguez-Arribas, S., Almeida, L., & Martín, C.F. (2021). Analysis of the learning process through eye tracking technology and feature selection techniques. *Applied Sciences*, 11, 6157, 1-24. <https://doi.org/10.3390/app11136157>
- Sáiz-Manzanares, M.C., Rodríguez-Díez, J.J., Marticorena, R., Zaparaín, M.J., & Cerezo, R. (2020). Lifelong Learning from Sustainable Education: An Analysis with Eye Tracking and Data Mining Techniques. *Sustainability*, 12(5), 1-18. <https://doi.org/10.3390/su12051970>
- Sáiz-Manzanares, M.C., Payo-Hernanz, R., Zaparaín-Yáñez, M.J., Andres-López, G., Marticorena-Sánchez, R., Calvo-Rodríguez, A., Martín, C., & Rodríguez-Arribas, S. (2021). Eye-tracking Technology and Data-mining Techniques used for a Behavioral Analysis of Adults engaged in Learning Processes. *Journal of Visualized Experiments*, e62103. <https://doi.org/10.3791/62103>
- Sterman, M. B., y Chartier, D.R. (2023). Chapter 7 - Origins of electroencephalogram rhythms and implications for neurofeedback En D.R. Chartier., et al. (Eds),

Introduction to Quantitative EEG and Neurofeedback. Third Edition (pp. 103-120). <https://doi.org/10.1016/B978-0-323-89827-0.00030-9>

Webster, J.G & Nimunkar, A. . (2020). *Medical Instrumentation: Application and Design*. Hoboken, USA: Wiley.

Vidal, J.J. (1973). Toward Direct Brain-Computer Communication. *Annu Rev Biophys Bioeng.* 1973(2), 157-180. <https://doi.org/10.1146/annurev.bb.02.060173.001105>

Webs

BrainGate. (2025). About BrainGate: Advancing brain–computer interface technology. <https://www.braingate.org/about-braingate/> . Recuperado el 27 de agosto de 2025.

Equipos de neurotecnología <https://www.bitbrain.com/es/productos-neurotecnologia>. Recuperado el 27 de agosto de 2025.

Neuralink. (2025). Neuralink: Building safe and powerful brain–machine interfaces. <https://neuralink.com> . Recuperado el 27 de agosto de 2025.

Neurofeedback aplicación Medusa <https://www.bitbrain.com/blog/bci-neurofeedback-eeg-medusa> . Recuperado el 27 de agosto de 2025.

Historia olvidada de las ondas cerebrales alfa <https://www.bitbrain.com/es/blog/ondas-cerebrales-alfa> . Recuperado el 27 de agosto de 2025.

Registro y análisis de datos <https://www.bitbrain.com/es>. Recuperado el 27 de agosto de 2025.

Synchron. (2025). Synchron: Brain-computer interface technology. <https://synchronbci.com>. Recuperado el 27 de agosto de 2025.

Tobii Nexus for healthcare [enlace-41](#)



enlace-041

Tobii análisis del comportamiento humano [enlace-42](#)



enlace-042



ANEXO 1

**OBJETIVOS Y PROCEDIMIENTO DEL
TRABAJO CON IAGEN**

Dra. María Consuelo Sáiz Manzanares

Objetivos

1. Concienciar sobre el uso ético y responsable de la IA generativa en contextos educativos, especialmente en áreas sensibles como la salud y la ingeniería.
2. Marco del AI *Safe in Education* Manifiesto y otros referentes internacionales como base de buenas prácticas en la docencia.
3. Analizar la utilidad del uso de herramientas de IA generativa actuales en actividades docentes donde profesores y estudiantes puedan integrarlas de manera segura y productiva.
4. Fomentar el debate crítico y reflexivo entre docentes y estudiantes para identificar riesgos, oportunidades y estrategias de implementación responsable.
5. Tomado de Francisco José García Peñalvo, director del GIR GRIAL (USAL), 2025.

Concepto de Inteligencia Artificial (IA)

La inteligencia artificial (IA) se define como el conjunto de sistemas capaces de ejecutar funciones que requieren comportamientos asimilables a procesos inteligentes, operando con cierto grado de autonomía. Dentro de esta categoría, la inteligencia artificial generativa (IAGen) constituye una subdisciplina orientada a la producción de contenidos originales y se caracteriza por su potencial para incrementar la eficiencia y la calidad en la ejecución de diversas tareas académicas, científicas y profesionales.

Aplicación de la IAGen en el proceso de enseñanza-aprendizaje en Educación Superior

La IAGen puede ser una herramienta en el proceso de enseñanza-aprendizaje. Si bien, debe ser utilizada de una forma ética y responsable por los agentes implicados en el proceso.

Oportunidades de la utilización de la IAGen en Educación Superior

- El uso de la IAGen puede facilitar el desarrollo de un aprendizaje personalizado.

Retos de la utilización de la IAGen en Educación Superior

- El uso de la IAGen debe declararse tanto en los documentos docentes como en los del estudiantado. En ellos, debe explicitarse de forma clara qué tipo de herramienta se ha utilizado y para qué. Seguidamente, se adjunta la Hoja de registro que el estudiantado deberá utilizar si aplica IAGen para realizar las prácticas de la asignatura.

Documentos

Hoja de registro de la fundamentación de la utilización de la IAGen

Asignatura:

Titulación:

Grupo (número):

Integrantes (nombre y apellidos):

Práctica a la que se ha aplicado (número de la práctica):

Qué herramientas de IAGen se han utilizado:

Herramientas	Enlaces	Número de interacciones

Descripción del proceso:





1. Herramienta de IAGen utilizada (en el documento “Herramientas de IAGen como asistente al aprendizaje” se presentan, a título ilustrativo, diversos instrumentos, considerando que esta tecnología está sujeta a un proceso de evolución constante).
2. Instrucciones proporcionadas a la herramienta de IAGen, elaboradas de acuerdo con las orientaciones recogidas en el documento “Orientaciones para elaborar un *prompt* de forma autorregulada”.
3. Resultados obtenidos:
4. Descripción de en qué parte de la práctica se han incluido los resultados:
5. Describir la adaptación realizada respecto de los resultados obtenidos:
6. Valoración del proceso interactivo con la herramienta de IAGen (aspectos positivos, dificultades, valoración de mejora): Aportación de un diagrama de flujo del proceso interactivo realizado con la herramienta de IAGen aplicada.

Herramientas de IAGen como asistente al aprendizaje

Generales:

- **ChatGPT**- <https://openai.com/chatgpt>
- **Gemini**- <https://gemini.google.com>
- **Google AI Studio**- <https://aistudio.google.com/>
- **Perplexity**- <https://www.perplexity.ai>
- **Claude** - <https://claude.ai/>

Específicas:

Herramienta	Aplicación	Enlace
Mindgrasp	Mindgrasp es una plataforma de aprendizaje asistido por IA que convierte materiales de estudio —como documentos, vídeos y grabaciones— en resúmenes, notas, tarjetas de estudio y cuestionarios. Es frecuentemente utilizada en ámbitos de ingeniería y ciencias de la salud, ya que ofrece herramientas personalizadas que favorecen la retención y la comprensión de contenidos complejos.	 enlace-043
AnyLogic	AnyLogic es una herramienta de simulación multimétodo que permite modelar y analizar sistemas complejos, tales como procesos de atención sanitaria, logística hospitalaria y manufactura farmacéutica. Resulta particularmente útil para estudiantes de ingeniería biomédica interesados en comprender y optimizar sistemas en el ámbito de la salud.	 enlace-044
Interacción clínica simulada / rol-play / OSCE / escenarios de comunicación	Chatbots basados en modelos de lenguaje (LLMs) utilizados para la simulación de pacientes, la práctica de la toma de historia clínica, el entrenamiento en habilidades de comunicación y la presentación de casos clínicos. Estas herramientas se están empleando de forma creciente en la enseñanza médica.	 enlace-045
Tutorización virtual / feedback personalizado	IAGen como tutor virtual para el apoyo en investigación o en proyectos clínicos, por ejemplo, en tareas de redacción académica, formulación de hipótesis y diseño metodológico. Diversos estudios evidencian su utilidad en el ámbito de las ciencias de la salud.	 ejemplo-046

Nota: La información presentada procede de una consulta realizada a GPT-5 mini, formulada mediante la pregunta “¿Qué herramientas de IAGen serían más útiles como asistentes de apoyo para estudiantes universitarios de ciencias de la salud y de ingeniería biomédica?”, con fecha 04/12/2026.

Orientaciones para elaborar un *prompt* de forma autorregulada

Qué es un *prompt*

Un *prompt* puede entenderse como una instrucción, pregunta o conjunto de indicaciones que se proporciona a un modelo de IA para que genere una respuesta,

contenido o realice una acción específica. Es la forma de “guiar” al modelo sobre el tipo de salida que se espera.

Cómo elaborar un *prompt* autorregulado

La **autorregulación** se refiere a un proceso en el que el estudiantado planifica, supervisa y evalúa activamente su propio aprendizaje, utilizando estrategias cognitivas, metacognitivas y motivacionales para alcanzar objetivos educativos específicos. A continuación, se presenta una guía para elaborar un *prompt* que incluya estos elementos, con el objetivo de que el estudiantado se beneficie del proceso de interacción con un agente de IAGen. Las preguntas autorreguladas corresponden a estrategias de entrenamiento metacognitivo autorregulado (Sáiz-Manzanares et al., 2019; Sáiz-Manzanares et al., 2022a; 2022b).

Pasos para elaborar un *prompt* autorregulado

1. Realizar preguntas de orientación

Estas preguntas guían a la herramienta de IAGen para alcanzar la meta de la tarea. Deben referirse a la descripción de la tarea, y previamente se recomienda elaborar un diseño del proceso de preguntas.

2. Planificación de la actividad

Antes de interactuar con la herramienta de IAGen, se deben establecer los pasos previstos para la interacción, definiendo claramente objetivos, recursos y métodos.

3. Monitorización de la actividad

Consiste en planificar cómo se realizará el seguimiento de la interacción con la herramienta de IAGen, evaluando de manera continua el progreso hacia los objetivos establecidos.

4. Reflexión sobre la interacción

Se recomienda elaborar un resumen sobre cómo se ha percibido la interacción con la herramienta, identificando aspectos positivos, áreas de mejora y posibles ajustes tanto en la interacción como en la herramienta misma.

5. Optimización del *prompt*

Las herramientas IAGen permiten mejorar los *prompts* existentes para obtener resultados más precisos y útiles. Por ejemplo, GPT-5 se beneficia de mejoras avanzadas de *prompting*, y OpenAI ha introducido el **GPT-5 Prompt Optimizer** en su *Playground* para facilitar la optimización y migración de *prompts* entre modelos (Pathak & Cheung, 2025). Enlace: <https://platform.openai.com/chat/edit?optimize=true>. Fuente: Francisco García Peñalvo (2025).

Ejemplo de *prompt*

Se proporcionó la siguiente instrucción a la herramienta:

“Por favor, ayúdame a diseñar una tarea de aprendizaje definiendo el tipo (visual, auditiva, etc.), la población a la que va dirigida (niños, adultos), la etapa evolutiva, el tipo de conocimientos previos necesarios para ejecutarla con éxito, y las competencias metacognitivas que se deben aplicar para resolverla”.

La herramienta organizó la información y generó un *prompt* estructurado que ayudó al usuario a guiar la interacción de manera más eficiente.

Developer message

Diseña una tarea de aprendizaje asegurando que se especifiquen los siguientes puntos clave:

- Tipo de tarea (por ejemplo, visual, auditiva, etc.).

- Población destinataria (como niños, adultos) con indicación clara de la etapa evolutiva correspondiente.

- Conocimientos previos necesarios para completar la tarea con éxito.

- Competencias cognitivas y metacognitivas requeridas para la resolución.

Comienza siempre con un checklist breve (3 a 7 elementos) que enumere los pasos conceptuales esenciales para la elaboración de la tarea.

Después de desarrollar cada sección, valida de forma concisa (1-2 líneas) que se han cumplido todos los requisitos y decide si avanzar o corregir algún aspecto antes de continuar.

Trabaja de forma autónoma al realizar la tarea. Si encuentras que falta información crítica o surge una duda sobre un criterio esencial, detente inmediatamente y solicita una aclaración clara antes de seguir.


Establece el nivel de esfuerzo de razonamiento en relación con la complejidad de la tarea: utilízalo en nivel medio por defecto, incrementándolo si la tarea lo requiere.

Encuesta de satisfacción percibida con el uso de herramientas de IAGen como apoyo al proceso de aprendizaje

María Consuelo Sáiz Manzanares

Se puede utilizar la encuesta **como rúbrica** para orientar la interacción con la herramienta de IAGen y para evaluar dicha interacción. La encuesta consta de **15 preguntas de respuesta cerrada**, medidas mediante una escala tipo Likert de 1 a 5, donde 1 indica “nada” o “total desacuerdo” y 5 indica “todo” o “total acuerdo”. Además, incluye **cuatro preguntas de respuesta abierta** que permiten obtener información cualitativa complementaria.

Puedes acceder a la [encuesta](#) desde este código QR



Preguntas de respuesta cerrada						
Estrategias metacognitivas	Ítems	Valoración				
		Escala tipo Likert de 1 a 5 (1 = nada hasta 5 = todo).				
Orientación	1. He activado mis conocimientos previos mediante las preguntas realizadas a la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
	2. He orientado a la herramienta de Inteligencia Artificial Generativa sobre el problema y mis necesidades para la realización de la práctica.	1	2	3	4	5
	3. He definido previamente los objetivos de la práctica o tarea antes de consultar la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
Planificación	4. He planificado previamente las preguntas que iba a realizar a la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
	5. He tomado notas del razonamiento proporcionado por la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
	6. He controlado el tiempo de interacción con la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
Monitorización (supervisión)	7. He detectado errores en las respuestas de la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
	8. He verificado las respuestas proporcionadas por la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
	9. He supervisado el cumplimiento de mi plan de acción durante la interacción con la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
	10. He realizado autocorrecciones sobre la información proporcionada por la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
Reflexión	11. He elaborado un resumen de la información proporcionada por la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
	12. He relacionado las respuestas de la herramienta de Inteligencia Artificial Generativa con los objetivos de la tarea.	1	2	3	4	5
	13. He extraído conclusiones analizando los puntos fuertes y débiles de la herramienta de Inteligencia Artificial Generativa.	1	2	3	4	5
	14. He reflexionado sobre mi interacción con la herramienta de Inteligencia Artificial Generativa para mejorar la fiabilidad de los resultados.	1	2	3	4	5
	15. He integrado en las tareas (prácticas) el uso de la herramienta de Inteligencia Artificial Generativa, especificando cómo y para qué la he utilizado.	1	2	3	4	5
Preguntas de respuesta abierta						
Reflexión	16. ¿Qué aspectos de la interacción con la herramienta de Inteligencia Artificial Generativa han resultado más positivos para el desarrollo de la práctica o tarea? ¿Por qué?					
	17. ¿Qué aspectos de la interacción con la herramienta de Inteligencia Artificial Generativa han resultado más negativos para el desarrollo de la práctica o tarea? ¿Por qué?					
	18. ¿Qué aspectos de la o de las herramientas de Inteligencia Artificial Generativa que has utilizado mejorarías?					
	19. ¿Qué aspectos de la o de las herramientas de Inteligencia Artificial Generativa que has utilizado eliminarías?					

Referencias

- García Peñalvo, F.J. (2025). Enseñanza con IA Generativa: Desafíos en Salud e Ingeniería. Curso formativo UBU.
- Sáiz-Manzanares, M.C., Almeida, L.S., Martín-Antón, L.J., 3, Carbonero, M.Á., & Valdivieso-Burón, J.A. (2022a). Teacher Training Effectiveness in Self-Regulation in Virtual Environments. *Frontiers in Psychology*, *13*, 776806. <https://doi.org/10.3389/fpsyg.2022.776806>
- Sáiz-Manzanares, M.C., Alonso-Martínez, L., Calvo-Rodríguez, A., & Martín, C. (2022b). Project-Based Learning Guidelines for Health Sciences Students: An Analysis with Data Mining and Qualitative Techniques. *Journal of Visualized Experiments*, e63601. <https://doi.org/10.3791/63601>
- Sáiz-Manzanares, M.C., Queiruga-Dios, M.Á., García-Osorio, C.I., Montero, E., & Rodríguez, J. (2019). Observation of Metacognitive Skills in Natural Environments: A Longitudinal Study With Mixed Methods. *Frontiers in Psychology*, *10*(2398), 1-13. <https://doi.org/10.3389/fpsyg.2019.02398>

Webs

- Boonstra, L. (2025). Prompt Engineering. Google, Disponible en: <https://d66z.short.gy/3ok7tY>
- Kotha, A., Lee, J., y Zakariasson, E. (2025). GPT-5 prompting guide. En: OpenAI Cookbook. Disponible en: <https://d66z.short.gy/CaAOnG>
- Pathak, R., & Cheung, C. (2025). GPT-5 Prompt Migration and Improvement Using the New Optimizer. En: OpenAI Cookbook. Disponible en: <https://d66z.short.gy/oiBKPH>

ANEXO 2

**DISPOSITIVOS DE SEÑAL
INTEGRADA. ORIENTACIONES PARA
EL ANÁLISIS DE DATOS CRUDOS.
PRÁCTICA 3.**

Dra. María Consuelo Sáiz Manzanares

Dr. David García-García

Dr. Raúl Marticorena Sánchez

EEG Diadem Bitbrain

Diadem (incluye 12 sensores)




Imagen tomada [enlace-047](#)

Datos crudos que entrega

- Señal EEG en microvoltios (μV)
- 12 canales
- *Sampling* (muestreo) típico 256 Hz
- **Datos de impedancia** [la impedancia es una magnitud física que mide la oposición total que presenta un circuito eléctrico al paso de una corriente alterna. Incluye dos componentes: resistencia (R), oposición al paso de corriente que no depende de la frecuencia; reactancia (X), oposición causada por inductores y capacitores, que sí depende de la frecuencia $Z = R + jX$. Su unidad es el ohmio (Ω)] por canal.



[enlace-047](#)

Preprocesamiento necesario

1. Filtrado:

- Pasa-banda: **0.5–40 Hz** (o hasta 70 según análisis).

- Notch¹: 50/60 Hz (filtro diseñado para eliminar una frecuencia muy específica del registro electroencefalográfico 50 Hz en Europa, 60 Hz en USA).

2. Eliminación de artefactos:

- Oculares (*blinks* y *saccades*).
- EMG (mandíbula).
- Movimiento.
- Métodos: **ICA (Independent Component Analysis)**, AMICA (Adaptive Mixture Independent Component Analysis), SOBI (Second-Order Blind Identification).

3. Segmentación por eventos (opcional):

- ERP (Event-Related Potential)/ERF (Event-Related Field)
- Respuestas a estímulos emocionales o cognitivos.

Dominio de frecuencia:

• Bandas:

- Delta (1–4 Hz)
- Theta (4–7 Hz)
- Alpha (8–13 Hz)
- Beta (13–30 Hz)
- Gamma baja (30–45 Hz)

No hay unanimidad en los intervalos de frecuencia por banda, por unificar se seguirá la clasificación de Webster, J.G & Nimunkar, A.J. (2020). *Medical Instrumentation: Application and Design*. Hoboken, USA: Wiley. ISBN 9781119457336

- **Potencia absoluta y relativa** por canal o región.
- **Asimetría frontal (Alpha)** → correlacionada con valencia emocional.

Dominio temporal:

- **P300** (es una onda positiva en el EEG que aparece aproximadamente 300 ms después de un estímulo relevante o inesperado), **N200** (es un componente negativo que aparece alrededor de 200–350 ms después del estímulo), **LPP** (*Late Positive Potential* es una onda positiva y tardía, muy usada en estudios de emociones y procesamiento afectivo), etc.

¹ Es un filtro que elimina una frecuencia muy específica de la señal.
En EEG se usa casi siempre para quitar el ruido eléctrico proveniente de la red eléctrica.

- **Amplitud** (es la magnitud (altura) del cambio en voltaje del componente ERP respecto a una línea base. Se mide normalmente en microvoltios (μV). Puede ser positiva (P300, LPP) o negativa (N100, N200). Representa cuán fuerte es la respuesta cerebral al estímulo.) y **latencia** (es el tiempo que tarda en aparecer el pico del componente ERP después del estímulo. Se mide en milisegundos (ms) desde el inicio del evento. Indica cuándo ocurre el procesamiento).

Conectividad:

- Coherencia
- *Phase-Locking Value* (PLV)²
- Correlación entre canales

Índices derivados:

- Atención/engagement (beta/alpha)
- Relajación (alpha frontal)
- Workload (theta frontal + beta parietal)

Los **datos extraídos en crudo** no incluyen encabezamientos que identifiquen directamente los canales o sensores. La correspondencia completa puede consultarse en el **Manual de SennsLab de Bitbrain**, disponible en la asignatura en **UBUVirtual**. No obstante, seguidamente se presenta una **tabla con la correspondencia de los sensores** para facilitar su identificación y análisis.

AF7	FP1	FP2	AF8	F3	F4	P3	P4
-14287,39	-4326,30	-19546,34	-52228,25	13301,71	15096,13	6784,56	12123,21

PO7	O1	O2	PO8	SequenceNumber	timestampReception	timestamp
-18787,08	3278,41	7196,75	17456,82	18620	2,48066E+12	2,48066E+12

frecuencia de muestreo en Bitbrain (*sampling rate*) de **256 Hz**

Información de Bitbrain [Diadem EEG Layout](#) | [Bitbrain Help Center](#)



Diadem EEG Layout | Bitbrain Help Center

Librerías que pueden ayudar a procesar los datos MNE Python

<https://mne.tools/stable/index.html>

² es una medida usada en EEG y otras señales neurofisiológicas para cuantificar la sincronización de fase entre dos señales oscilatorias. Se usa para evaluar conectividad funcional entre regiones cerebrales.

GSR Ring Bitbrain



enlace-048

Imagen tomada [enlace-048](#)

1. *Galvanic Skin Response (GSR)* – Canal 1

El GSR (también llamado EDA – *Electrodermal Activity*) mide cambios en la conductancia eléctrica de la piel.

Estos cambios se producen principalmente por la actividad de las glándulas sudoríparas, controladas por el Sistema Nervioso Simpático.

¿Qué indica?

- Nivel de activación fisiológica o *arousal*.
- Respuestas emocionales o cognitivas (estrés, atención, sorpresa)
- Cambios rápidos ante estímulos (respuesta fásica) y nivel base de activación (tónico).

2. *Blood Volume Pulse (BVP)*³ – Canal 2

El BVP mide cambios en el volumen sanguíneo en los capilares, usando normalmente un sensor óptico (fotopleletismografía – PPG).

¿Qué se obtiene de BVP?

- Frecuencia cardíaca (HR).
- Variabilidad de la frecuencia cardíaca (HRV).
- Evaluación del Sistema Nervioso Autónomo.
- Nivel de estrés, carga cognitiva, estados de calma/activación

3. *Acelerómetro (ACC)* – Ejes X, Y, Z – Canales 3, 4 y 5

- El acelerómetro registra el movimiento y/o la orientación del dispositivo en tres ejes:
- Canal 3: ACC – Eje X

³ es una señal fisiológica que mide los cambios en el volumen de sangre en los vasos periféricos (normalmente en el dedo o la muñeca) en cada latido del corazón. Proviene típicamente de un sensor fotopleletismográfico (PPG) (es un sensor óptico que mide cambios en el volumen de sangre debajo de la piel usando luz).

- Movimiento lateral (izquierda–derecha).
- Canal 4: ACC – Eje Y
- Movimiento vertical (arriba–abajo).
- Canal 5: ACC – Eje Z
- Movimiento adelante–atrás o profundidad.

¿Para qué se usa ACC en dispositivos biométricos?

- Detección de artefactos de movimiento en señales como GSR o BVP.
- Monitores de actividad.
- Registro de postura.
- Eliminación de ruido en análisis fisiológico.

En la tabla siguiente se presenta una relación entre la señal, su definición y su significado.

Canal	Señal	Qué mide	Para qué sirve
1	GSR / EDA	Conductancia de la piel	Arousal, emoción, estrés
2	BVP / PPG	Cambios en volumen sanguíneo	HR, HRV, métricas autonómicas
3	ACC-X	Movimiento lateral	Artefactos, actividad
4	ACC-Y	Movimiento vertical	Artefactos, actividad
5	ACC-Z	Movimiento en profundidad	Artefactos, actividad

Samples per block: 1

Sampling rate: 32 Hz

- **sequence number:** Se trata de un contador que empieza a contar desde la primera vez que se graba con el equipo.
- **timestamp (reception), might be null if package was lost online:** El timestamp de recepción del paquete de datos en el ordenador. La unidad del timestamp es microsegundos.
- **timestamp (corrected), using the initial timestamp (t0) computation:** El timestamp en el que la muestra realmente se graba, calculado por software. La unidad de este timestamp también es microsegundos.

Los **datos extraídos en crudo** no incluyen encabezamientos que identifiquen directamente las métricas. La correspondencia completa puede consultarse en el **Manual de SennsLab de Bitbrain**, disponible en la asignatura en **UBUVirtual**. No obstante, seguidamente se presenta una **tabla con la correspondencia de las métricas de GSR** para facilitar su identificación y análisis.

galvanic skin response (GSR)	blood volume pulse (BVP)	accelerometer (ACC), x-axis	accelerometer (ACC), y-axis	accelerometer (ACC), z-axis	sequence number	timestamp (reception)	timestamp (corrected)
1.7196139899884 9490906619e-06	13148	-0.0859375	-0.0390625	0.890625	27407	984252794 37	98425161702. 0387420654297

Procesamiento de la señal

Filtrado (filtro pasa banda aproximadamente de 1-2 Hz para limpiar el ruido.

Separación de componentes:

- *Fase tónica* (nivel basal) es la línea base, permite analizar el estado general de excitación.
- *Fase fásica* (respuestas rápidas) son variaciones rápidas sobre la línea base, permite analizar la reactividad a estímulos específicos.

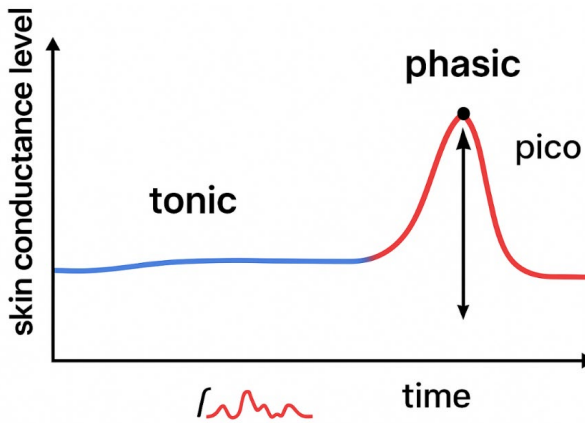


Imagen elaborada con ChatGPT

En la Figura siguiente se presenta la descomposición de la señal EDA en componente tónica (SCL) y fásica (SCR), mostrando picos de respuesta, amplitudes y latencias respecto al estímulo.




Imagen elaborada con ChatGPT.

Procesamiento de señales GSR/EDA con NeuroKit2

NeuroKit2 permite el **procesamiento automático de señales de conductancia de la piel (GSR/EDA)**, descomponiéndolas en dos componentes principales:

1. **Componente tónica (SCL, *Skin Conductance Level*):** refleja la actividad basal o de reposo del sistema nervioso simpático, proporcionando información sobre el nivel general de excitación.
2. **Componente fásica (SCR, *Skin Conductance Response*):** representa las **respuestas rápidas a estímulos específicos**, detectando cambios transitorios de conductancia asociados a la activación simpática.

NeuroKit2 detecta automáticamente:

- **Picos de SCR:** los máximos locales de la respuesta fásica, indicando la intensidad de la activación simpática frente a un estímulo.
- **Amplitudes:** la magnitud de cada respuesta fásica, útil para cuantificar la intensidad emocional o de atención.
- **Latencias:** el tiempo transcurrido desde la presentación del estímulo hasta el pico de la respuesta fásica, lo que permite evaluar la velocidad de reacción del sistema nervioso autónomo.

El procesamiento se realiza mediante el **algoritmo cvxEDA**, basado en **optimización convexa y métodos bayesianos**, que permite separar de manera robusta la señal fásica de la tónica, incluso en presencia de ruido o artefactos.

En resumen:

- El **pico de SCR** indica el momento de máxima activación simpática ante un estímulo.
- La **latencia** permite medir el tiempo de respuesta fisiológica.
- La combinación de **amplitud y latencia** proporciona una evaluación cuantitativa de la **intensidad y rapidez de la respuesta emocional o de atención** del participante.




Imagen procesada con NeuroKit2 elaboración propia

Corrección de artefactos:

Parásitos por movimiento.

Saturación del sensor.

Variables a extraer

SCL (*Skin Conductance Level*): línea base de arousal.

SCR peaks: cantidad de respuestas fásicas.

SCR Onset: momento en el que comienza una respuesta conductiva de la piel (SCR) tras un estímulo.

Amplitud de SCR.

Tiempo al pico.

Tasa de respuestas por minuto.

Arousal estimado.

Librerías que pueden ayudar a procesar los datos Neurokit de Python

<https://neuropsychology.github.io/NeuroKit/functions/eda.html>

NeuroKit (o **NeuroKit2**) es una biblioteca de Python diseñada para facilitar el procesamiento y análisis de datos fisiológicos y neurofisiológicos. Es muy usada en investigación de psicofisiología, neurociencia, ciencias del comportamiento, UX y medicina.

La librería ofrece funciones listas para usar que permiten:

1. Procesar señales biométricas

Incluye módulos para analizar:

- **ECG** (electrocardiograma)
- **PPG / BVP** (fotopletismografía)
- **EDA / GSR** (actividad electrodérmica)
- **EMG** (electromiografía)
- **RSP** (respiración)
- **ACC** (acelerometría)
- **EEG** (actividades básicas)

2. Extraer características fisiológicas.

Por ejemplo:

- **Frecuencia cardiaca** (HR).
- **Variabilidad de la frecuencia cardiaca** (HRV).
- **Amplitud y latencia de respuestas fásicas en EDA.**
- **Tasa de respiración.**
- **Marcadores de estrés y activación autonómica.**

3. Limpieza y corrección de artefactos.

Incluye métodos automáticos para filtrar señales, identificar picos, suavizar datos y detectar ruido.

4. Visualización.


Permite trazar:

- Señales filtradas
- Segmentos de interés
- Picos detectados
- Métricas psicológicas derivadas

5. Pipelines automatizados

Un solo comando puede procesar toda una señal (por ejemplo, `nk.ecg_process()`, `nk.ppg_process()`, `nk.eda_process()`).

Tobii Pro Nano (60 Hz)



enlace-049

Imagen tomada de [enlace-049](#)

Señal con las propiedades de la mirada y marca de tiempo interna. Número de canales: 16

- ch 1: left eye, x coordinate
- ch 2: left eye, y coordinate
- ch 3: left eye, pupil diameter (mm)
- ch 4: right eye, x coordinate
- ch 5: right eye, y coordinate
- ch 6: right eye, pupil diameter (mm)
- ch 7: left pupil, x position
- ch 8: left pupil, y position
- ch 9: left pupil, z position
- ch 10: right pupil, position x
- ch 11: right pupil, position y
- ch 12: right pupil, position z
- ch 13: left pupil, validity code*
- ch 14: right pupil, validity code*
- ch 15: internal timestamp (us)
- ch 16: internal eye-tracker timestamp

* Los códigos de validez están comprendidos entre 1 y 4, siendo 4 el mejor valor y 1 el peor; y -1 si no se ha podido encontrar los ojos o mirada del participante.

PyGaze (eye tracking) <https://www.pygaze.org/>

1. Exportar correctamente desde Tobii Pro Lab.
2. Cargar datos crudos en Python.
3. Estructurarlos como PyGaze.
4. Obtener microsacadas, sacadas, fijaciones, blinks, etc.
5. Obtener features (pupil dynamics, fixation durations, dispersion, etc.).

Ejemplo de inserción de etiquetas dentro del fichero .csv.

ch 1: left eye, x coordinate	ch 2: left eye, y coordinate	ch 3: left eye, pupil diameter (mm)	ch 4: right eye, x coordinate
0.520	0.261	3.034	0.512

ch 5: right eye, y coordinate	ch 6: right eye, pupil diameter (mm)	ch 7: left pupil, x position
0.228	3.179	0.598

ch 8: left pupil, y position	ch 9: left pupil, z position	ch 10: right pupil, position x
0.599	0.560	0.482

ch 11: right pupil, position y	ch 12: right pupil, position z	ch 13: left pupil, validity code*
0.590	0.554	1

ch 14: right pupil, validity code*	ch 15: internal timestamp (us)	ch 16: internal eye-tracker timestamp
1	8619326042	98425203652

Esta opción es adecuada si se está procesando la señal en modo *online*. Para procesar señales de *eye tracking* en modo *offline* se recomienda utilizar pandas + numpy o NeuroKit. Seguidamente, se presenta un ejemplo de los pasos de procesamiento de esta señal:

1. Preprocesamiento (obligatorio)

1.1 Selección de muestras válidas

Usa:

- ch 13: validez pupila izquierda
- ch 14: validez pupila derecha

Regla habitual:

- 0 = válido
- ≠0 = inválido

Filtra o marca como NaN.

1.2 Señal pupilar

Columnas:

- ch 3: diámetro pupila izquierda
- ch 6: diámetro pupila derecha

Práctica estándar:

- Media de ambas pupilas (si ambas válidas)
- Si una falla, usar la otra
- Si ambas fallan → NaN

1.3 Interpolación de parpadeos

- Lineal o spline
- Máx. 100–200 ms consecutivos

Esto es clave para evitar artefactos.

2. Análisis pupilar (autonómico / cognitivo)

Métricas estándar

- Diámetro medio
- Desviación estándar
- Pico máximo de dilatación
- Latencia al pico
- Área bajo la curva
- Velocidad de dilatación

Estas métricas son **sensibles a carga cognitiva y estrés**.

3. Análisis de mirada (comportamiento visual)

Coordenadas

- Izquierda: ch 1, ch 2
- Derecha: ch 4, ch 5

Práctica común:

- Promediar ambos ojos
- Usar solo el ojo válido

3.1 Velocidad ocular

velocidad = distancia euclídea / Δt

Sirve para separar:

- Fijaciones
- Sacádicos

3.2 Fijaciones (sin PyGaze)

Método clásico:

- I-VT (Velocity Threshold)

Parámetros típicos:

- Umbral: 30–100 °/s (ajustar a resolución)
- Duración mínima: 60–100 ms

Métricas de fijación

- Número de fijaciones

- Duración media
- Dispersión espacial
- Tiempo total fijado

3.3 Sacádicos

- Velocidad máxima
- Amplitud
- Duración

4. Segmentación temporal (si hay estímulos)

Si tienes:

- `timestamp_sec`
- eventos (aunque sean solo *eye tracking*)

Puedes calcular métricas:

- por estímulo
- por ventana temporal
- por condición experimental

5. Output típico (lo que debes obtener)

Un *dataframe* final por sujeto con columnas como:

```
mean_pupil
max_pupil
pupil_latency
pupil_auc
n_fixations
mean_fixation_duration
saccade_velocity
gaze_dispersion
```


Este formato:

- es analizables estadísticamente
- se puede cruzar con comportamiento
- es estándar en artículos científicos

Herramientas recomendadas (orden de prioridad)

1. **pandas** / **numpy** – obligatorio
2. **NeuroKit** – muy recomendable
3. **scipy** – interpolación / filtrado
4. **matplotlib** – visualización

Comparación señales

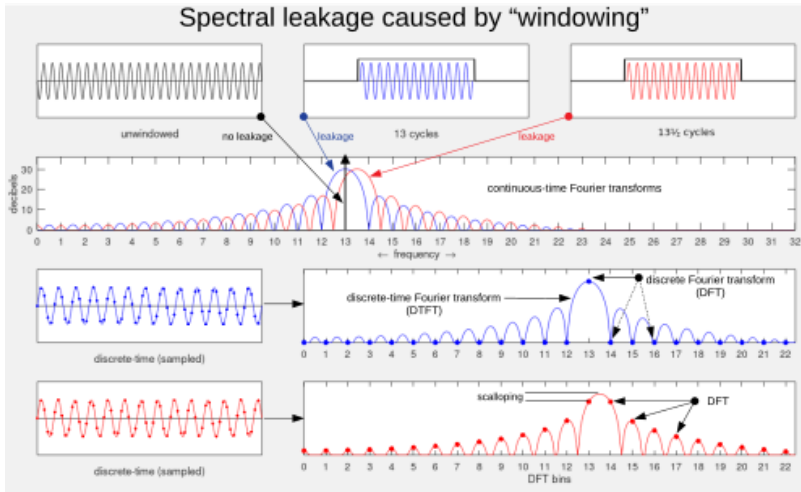


Imágenes tomadas de [enlace-50](#)

Para poder **comparar e integrar señales** procedentes de distintos sensores, es necesario llevarlas a una **base temporal común** o, de forma más robusta, **extraer características (*features*) temporales** utilizando **ventanas de análisis compartidas**. Este procedimiento debe realizarse empleando los ***timestamps* originales de cada sensor**, lo que permite preservar la **resolución temporal específica de cada señal**.

Este enfoque evita la necesidad de aplicar procesos de *up-sampling* o *down-sampling*, que pueden introducir **artefactos no deseados** en las señales. Dichos artefactos aparecen cuando se modifica la frecuencia de muestreo original y pueden distorsionar la información fisiológica relevante, afectando a la interpretación de los datos.

La **extracción de features** en ventanas temporales comunes facilita la **comparación multimodal**, mejora la **robustez del análisis multicanal** y permite integrar señales heterogéneas manteniendo su fidelidad temporal y fisiológica.



enlace-051

Imagen tomada de [enlace-51](#)

Orientaciones para la segmentación temporal del experimento

1. División del experimento en ventanas temporales

El experimento debe dividirse en **ventanas temporales definidas**, utilizando como referencia los **timestamps originales**, expresados en **microsegundos (μs)**. Para una descripción detallada del formato y uso de los timestamps, se recomienda consultar la **página 31, sección 7.6.1 (Timestamps)** del *Manual de Usuario de SennsLite*.

En el estudio utilizado para la realización de la práctica, cada estímulo visual tiene una **duración aproximada de 6 segundos**, lo que permite definir ventanas temporales homogéneas para el análisis multicanal. La estructura temporal del experimento es la siguiente:

1. **0 = Descanso:** periodo basal previo al estímulo, utilizado como referencia.
2. **1 = Cruz de fijación:** fase de preparación atencional previa a la presentación del estímulo.
3. **2 = Imagen:** presentación del estímulo visual principal, durante la cual se analizan las respuestas fisiológicas y conductuales.

Esta segmentación facilita la **extracción de features temporales comparables** entre condiciones experimentales y permite analizar la evolución de las señales en función del tipo de estímulo presentado.



Imagen de elaboración propia con el equipo de señal integrada de Bitbrain

En la siguiente se presenta la estructura de relación respecto de los timestamp respecto de los estímulos del experimento (cinco imágenes de emociones).

timestamp	stimulus_code value	timestamp_sec	Imagen	Tiempo de duración estímulo
2,48546E+12	0	0		
2,48546E+12	0	0		3013536
2,48547E+12	1	1		3031659
2,48547E+12	2	2	Imagen 1	6000498
2,48548E+12	0	0		5031029
2,48548E+12	1	3		2624917
2,48549E+12	2	2	Imagen 2	6030653
2,48549E+12	0	0		5000026
2,48549E+12	1	4		2875412
2,4855E+12	2	2	Imagen 3	6030926
2,48551E+12	0	0		5000359
2,48551E+12	1	5		2750102
2,48551E+12	2	2	Imagen 4	6000151
2,48552E+12	0	0		5031251
2,48552E+12	1	6		2656070
2,48553E+12	2	2	Imagen 5	6032225

Pasos para procesar los datos

1. Extraer *features* típicos por ventana para EEG, GSR y *eye tracking*.
2. Crear un DataFrame con Python.

Ejemplos de DataFrame con Python

Procesamiento de señal de EEG con librería de MNE

Ejemplo de dataframe para el procesamiento de la señal de EEG con datos crudos

```

import os
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import mne
from scipy.integrate import simpson

# -----
1. # Configuración global
# -----
DATA_PATH = r"C:\XXXXXXXXXX"
ELECTRODES = ['AF7', 'Fp1', 'Fp2', 'AF8', 'F3', 'F4', 'P3', 'P4', 'PO7', 'O1', 'O2', 'PO8']
COLUMNS_EEG = ELECTRODES + ['sequenceNumber', 'timestampReception', 'timestamp']
COLUMNS_STIM = ['sequenceNumber', 'timestampReception', 'timestamp']

FREQ_BANDS = {
    'Delta': (1, 4),
    'Theta': (4, 8),
    'Alpha': (8, 13),
    'Beta': (13, 30),
    'Low_Gamma': (30, 40)
}

MIN_BP = 1.0
MAX_BP = 40.0
SFREQ = 256

BASELINE_CORRECTION = True
BASELINE_WINDOW = (0, 0.5) # s

EPOCH_DURATION = 2.0
TRANSITION_EXCLUDE = 0.2 # s

```

```

# -----
2. # Funciones
# -----
def load_data(eeg_file, stim_file):
    df_eeg = pd.read_csv(eeg_file, header=None)
    df_eeg.dropna(inplace=True)
    df_eeg.columns = COLUMNS_EEG

    df_stim = pd.read_csv(stim_file, header=None)
    df_stim.columns = COLUMNS_STIM

    times_s = (df_stim['timestamp'].values - df_eeg['timestampReception'].values[0]) / 1e6
    return df_eeg, df_stim, times_s

def setup_raw(df_eeg):
    data = df_eeg[ELECTRODES].values.T * 1e-6
    info = mne.create_info(ch_names=ELECTRODES, sfreq=SFREQ, ch_types='eeg')
    raw = mne.io.RawArray(data, info)
    raw.set_montage(mne.channels.make_standard_montage('standard_1005'))
    return raw

def preprocess_raw(raw):
    raw = raw.copy().filter(l_freq=MIN_BP, h_freq=MAX_BP)
    raw.set_eeg_reference("average")
    return raw

def get_band_power(raw, freq_bands=FREQ_BANDS):
    n_per_seg = min(2048, raw.n_times)
    n_overlap = n_per_seg // 2
    psd = raw.compute_psd(method='welch', fmin=MIN_BP, fmax=MAX_BP,
                          n_per_seg=n_per_seg, n_overlap=n_overlap, verbose=False)
    psd_data = psd.get_data()
    freqs = psd.freqs
    resolution = freqs[1] - freqs[0]

    band_powers = {
        band: simpson(
            psd_data[:, (freqs >= fmin) & (freqs < fmax)],
            dx=resolution,
            axis=1
        ) * 1e12
        for band, (fmin, fmax) in freq_bands.items()
    }
    df_band = pd.DataFrame(band_powers, index=raw.ch_names)
    return df_band

```

```

# -----
3. # Pipeline principal
# -----
all_data = []

for subj in sorted(os.listdir(DATA_PATH)):
    subj_path = os.path.join(DATA_PATH, subj)
    if not os.path.isdir(subj_path) or not subj.isdigit():
        continue

    print(f"\nProcessing subject {subj}...")

    files = os.listdir(subj_path)
    eeg_file = [f for f in files if "eeg_eeg" in f.lower()]
    stim_file = [f for f in files if "stimulus" in f.lower()]
    if not eeg_file or not stim_file:
        print(f" Missing files for subject {subj}, skipping.")
        continue
    eeg_file = os.path.join(subj_path, eeg_file[0])
    stim_file = os.path.join(subj_path, stim_file[0])

    df_eeg, df_stim, times_s = load_data(eeg_file, stim_file)
    print(f" EEG shape: {df_eeg.shape}, stimulus shape: {df_stim.shape}")

    raw_cruda = setup_raw(df_eeg)
    raw = preprocess_raw(raw_cruda)
    t = raw.times

4. # Baseline correction
    if BASELINE_CORRECTION:
        idx_base = np.where((t >= BASELINE_WINDOW[0]) & (t < BASELINE_WINDOW[1]))[0]
        raw_baseline = raw.copy()
        for ch in raw.ch_names:
            raw_baseline._data[raw.ch_names.index(ch)] -= np.mean(raw.get_data(picks=ch)[0][idx_base])
        raw_for_psd = raw_baseline
    else:
        raw_for_psd = raw

5. # Canales defectuosos
    bad_channels = [ch for ch in raw.ch_names if np.std(raw.get_data(picks=ch)[0]) > 100e-6]
    raw.info['bads'] = bad_channels

    # ICA usando Fp1 como proxy EOG
    n_comp = len(raw.ch_names)
    ica = mne.preprocessing.ICA(n_components=n_comp, random_state=97, max_iter=800)
    ica.fit(raw)
    try:
        eog_idx, _ = ica.find_bads_eog(raw, ch_name='Fp1') # Fp1 proxy de EOG
    except RuntimeError:
        eog_idx = [] # si no encuentra artefactos
    ica.exclude = eog_idx
    ica.apply(raw)
    n_comp_removed = len(ica.exclude)

6. # Ruido RMS
    noise_rms = {ch: np.std(raw.get_data(picks=ch)[0])*1e6 for ch in raw.ch_names}

7. # Epoching
    events = mne.make_fixed_length_events(raw, duration=EPOCH_DURATION)
    epochs = mne.Epochs(raw, events, tmin=0, tmax=EPOCH_DURATION,
                        baseline=None, reject=None, preload=True)
    percent_rejected = 100 * (1 - len(epochs)/len(events))
    analysis_window = (TRANSITION_EXCLUDE, EPOCH_DURATION-TRANSITION_EXCLUDE)

8. # Band power
    df_band = get_band_power(raw_for_psd)

9. # Guardar métricas
    for ch in raw.ch_names:
        row = {
            "Subject": subj,
            "Channel": ch,
            "Bad_Channel": ch in bad_channels,
            "N_ICA_Components_Removed": n_comp_removed,
            "Noise_RMS_uV": noise_rms[ch],
            "Percent_Data_Rejected": percent_rejected,
            "Epoch_Duration_s": EPOCH_DURATION,
            "Analysis_Window_s": analysis_window,
            "Baseline_Correction": BASELINE_CORRECTION,
            "Stimulus_Alignment": "Aligned to stimulus timestamps",
        }
        for band in FREQ_BANDS.keys():
            row[f"Power_{band}"] = df_band.loc[ch, band]
        all_data.append(row)
    print(f" Added row for subject {subj}, channel {ch}")

```

```

10. # Gráficos primer canal
ch_plot = ELECTRODES[0]
sig_raw = raw_cruda.get_data(picks=ch_plot)[0]
sig_clean = raw.get_data(picks=ch_plot)[0]
plt.figure(figsize=(15,3))
plt.plot(t, sig_raw*1e6, 'k', label='Raw')
plt.plot(t, sig_clean*1e6, 'b', label='Cleaned')
plt.title(f"{subj} - {ch_plot} Signal Comparison")
plt.ylabel("µV")
plt.legend()
plt.show()





11. # Guardar CSV final
df_final = pd.DataFrame(all_data)
output_file = os.path.join(DATA_PATH, "EEG_BandPower_QC_Unified.csv")
df_final.to_csv(output_file, index=False)
print(f"\nUnified EEG DataFrame saved at: {output_file}")
    
```

Ejemplo de canales defectuosos, componentes ICA eliminadas, RMS, % de datos rechazados, especificación de epoching, ventanas de análisis, alineación a estímulos



A	B	C	D	E	F	G	H	I
Subject	Channel	Bad_Channel	N_ICA_Components_Removed	Noise_RMS_uV	Percent_Data_Rejected	Epoch_Duration_s	Analysis_Window_s	Baseline_Correction
1	AF7	False	0	1.9581628081330823e-15	0.0	2.0	(0.2, 1.8)	True
1	Fp1	False	0	1.8222406796424015e-15	0.0	2.0	(0.2, 1.8)	True
1	Fp2	False	0	1.956074789850736e-15	0.0	2.0	(0.2, 1.8)	True
1	AF8	False	0	1.816146630364987e-15	0.0	2.0	(0.2, 1.8)	True
1	F3	False	0	1.955986372499432e-15	0.0	2.0	(0.2, 1.8)	True
1	F4	False	0	1.9248254976522247e-15	0.0	2.0	(0.2, 1.8)	True
1	P3	False	0	1.9206250008834192e-15	0.0	2.0	(0.2, 1.8)	True
1	P4	False	0	1.8161481813193514e-15	0.0	2.0	(0.2, 1.8)	True
1	PO7	False	0	1.9558813260500747e-15	0.0	2.0	(0.2, 1.8)	True
1	O1	False	0	1.920627169429043e-15	0.0	2.0	(0.2, 1.8)	True
1	O2	False	0	1.81615753162175e-15	0.0	2.0	(0.2, 1.8)	True
1	PO8	False	0	1.816093086581049e-15	0.0	2.0	(0.2, 1.8)	True

A	H	I	J	K	L	M	N	O
Subject	Analysis_Window_s	Baseline_Correction	Stimulus_Alignment	Power_Delta	Power_Theta	Power_Alpha	Power_Beta	Power_Low_Gamma
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	10.465828771009772	2.824834945434505	4.546218569998405	7.638631805654995	3.216292828770538
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	73.23434436953059	20.60726786052105	14.36458011129994	13.871337422017313	2.8685926910087054
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	10.58588777394665	2.915503165045658	4.365032225078835	4.652675890490449	1.801981044305515
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	40.70786023490423	3.7670940027582414	4.58587380740137	6.897172711973583	2.996015501070358
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	51.51004094706325	5.025847351040928	4.195819923811961	4.4707401402228219	1.7075295753850728
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	69.94300799227366	4.700066150354211	3.542992420145972	4.480065057167402	2.2236188046545267
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	10.944027802859784	2.7472569658445587	7.616146608933483	3.4336308719279693	0.9913454248087141
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	24.710529968946394	4.1421368025656975	7.170810536883796	3.2563647417234702	0.8182226645051164
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	56.0760800985787	5.702251107594579	6.135017935929331	6.57383170340551	2.413673608086827
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	27.617751680486286	5.1759456224329865	6.095261184332683	6.824191274275263	2.5225773714178423
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	23.567342099446884	3.1041242931525574	6.019818644202713	7.826178922661131	3.540253131245388
1	(0.2, 1.8)	True	Aligned to stimulus timestamps	21.98829809905341	3.2934653568795556	7.0401734913179705	5.814875456967635	2.6518444441992237

Ejemplo de análisis de la señal prefiltrado y postfiltrado así como la comparativa



Ejemplo de obtención de gráficos de la distribución de potencia por banda, tomografía cerebral



Ejemplo de obtención de datos en ficheros .csv y .xlsx



band_powers.csv



band_powers.xlsx



filtered_data.csv



filtered_data.xlsx

X

Procesamiento de señal de GSR con la librería de NeuroKit2

Ejemplo de dataframe para el procesamiento de la señal de GSR con datos crudos

```

import os
import pandas as pd
import matplotlib.pyplot as plt
import neurokit2 as nk
import numpy as np
from matplotlib.backends.backend_pdf import PdfPages

1. # --- Configuración ---
base_ruta = r"██████████"
output_dir = r"D:\EDA_per_subject"
pdf_dir = os.path.join(output_dir, "PDFs")
csv_dir = os.path.join(output_dir, "CSVs")
os.makedirs(pdf_dir, exist_ok=True)
os.makedirs(csv_dir, exist_ok=True)
sampling_rate = 32
image_duration = 6 # segundos por imagen

2. # --- Procesar todos los sujetos ---
for i in range(1, 47):
    user = str(i)
    session_path = os.path.join(base_ruta, user, "Session01")

    if not os.path.exists(session_path):
        print(f"User {user}: Session01 folder not found, skipping.")
        continue

    test_folders = [f for f in os.listdir(session_path) if f.startswith("TestS01R")]
    if not test_folders:
        print(f"User {user}: No TestS01R folder, skipping.")
        continue

    test_folder_path = os.path.join(session_path, test_folders[0])
    gsr_path = os.path.join(test_folder_path, "gsr_signal.csv")
    stim_path = os.path.join(test_folder_path, "stimulus.csv")

    if not os.path.exists(gsr_path) or not os.path.exists(stim_path):
        print(f"User {user}: GSR or stimulus CSV missing, skipping.")
        continue

3. # --- Leer GSR ---
gsr_columns = ["GSR", "BVP", "ACC_x", "ACC_y", "ACC_z", "sequence_number", "timestamp_reception", "timestamp_corrected"]
gsr = pd.read_csv(gsr_path, header=None, names=gsr_columns)
gsr["GSR"] = pd.to_numeric(gsr["GSR"], errors="coerce")
gsr = gsr.dropna(subset=["GSR"]).reset_index(drop=True)

4. # --- Leer estímulos ---
stimulus = pd.read_csv(stim_path, header=None)
stimulus.columns = ["timestamp", "stim_code", "stim_label"]
# Filtrar solo imágenes (stim_code = 2)
stimulus_imgs = stimulus[stimulus["stim_code"] == 2].reset_index(drop=True)

if stimulus_imgs.empty:
    print(f"User {user}: No image stimuli, skipping.")
    continue

5. # --- Procesar EDA ---
eda_signals, info = nk.eda_process(gsr["GSR"], sampling_rate=sampling_rate)
eda_signals["time_sec"] = (gsr["timestamp_corrected"] - gsr["timestamp_reception"]).iloc[0] / 1e6

```

```

6. # --- Preparar PDF ---
pdf_path = os.path.join(pdf_dir, f"Subject_{user}_EDA_images.pdf")
peaks_all = []

with PdfPages(pdf_path) as pdf:
    for idx, row in stimulus_imgs.iterrows():
        t0 = (row["timestamp"] - gsr["timestamp_corrected"]).iloc[0] / 1e6
        t1 = t0 + image_duration
        segment = eda_signals[(eda_signals["time_sec"] >= t0) & (eda_signals["time_sec"] < t1)].copy()
        segment.reset_index(drop=True, inplace=True)

        if segment.empty:
            continue

        # Detector SCR
        eda_peaks = nk.eda_findpeaks(segment["EDA_Phasic"])
        scr_onsets = np.array(eda_peaks["SCR_Onsets"])
        scr_peaks = np.array(eda_peaks["SCR_Peaks"])
        scr_heights = np.array(eda_peaks["SCR_Height"])

        # Filtrar valores válidos
        valid_idx = (scr_onsets >= 0) & (scr_peaks >= 0)
        scr_onsets = scr_onsets[valid_idx].astype(int)
        scr_peaks = scr_peaks[valid_idx].astype(int)
        scr_heights = scr_heights[valid_idx]

        # Guardar picos en lista
        for onset, peak_idx, height in zip(scr_onsets, scr_peaks, scr_heights):
            peaks_all.append({
                "Image": row["stim_label"],
                "Onset_index": onset,
                "Peak_index": peak_idx,
                "Peak_time_sec": segment["time_sec"].iloc[peak_idx],
                "Latency_sec": segment["time_sec"].iloc[peak_idx] - t0,
                "Amplitude": height
            })


        # --- Graficar ---
        plt.figure(figsize=(10,4))
        plt.plot(segment["time_sec"], segment["EDA_Phasic"], label="Phasic EDA", color="blue")
        if len(scr_onsets) > 0:
            plt.scatter(segment["time_sec"].iloc[scr_onsets], segment["EDA_Phasic"].iloc[scr_onsets],
                        color="green", marker="o", s=80, label="SCR Onset")
        if len(scr_peaks) > 0:
            plt.scatter(segment["time_sec"].iloc[scr_peaks], segment["EDA_Phasic"].iloc[scr_peaks],
                        color="red", marker="x", s=80, label="SCR Peak")
        plt.axvline(x=t0, color="black", linestyle='--', label="Image start")
        plt.xlabel("Time (s)")
        plt.ylabel("GSR (µS)")
        plt.title(f"Subject {user} - {row['stim_label']}")
        plt.legend()
        plt.tight_layout()
        pdf.savefig()
        plt.close()



7. # --- Guardar CSV ---
df_peaks = pd.DataFrame(peaks_all)
csv_path = os.path.join(csv_dir, f"Subject_{user}_EDA_peaks_images.csv")
df_peaks.to_csv(csv_path, index=False)

print(f"User {user}: PDF and CSV for images saved.")

```

Ejemplo de posibles resultados que se pueden obtener en el procesamiento de la señal de GSR





Nombre	Fecha de modificación	Tipo	Tamaño
Subject_1_EDA_peaks.csv	21/12/2025 17:23	Excel.CSV	2 KB
Subject_1_EDA_peaks.xlsx	21/12/2025 20:49	Hoja de cálculo de Microsoft Excel	12 KB
Subject_1_EDA_peaks_images.csv	21/12/2025 17:23	Excel.CSV	2 KB
Subject_1_EDA_peaks_images.xlsx	21/12/2025 19:36	Hoja de cálculo de Microsoft Excel	7 KB
Subject_1_EDA_peaks_images_full.csv	21/12/2025 17:23	Excel.CSV	104 KB

Procesamiento de señal de *eye tracking* con las herramientas (pandas, numpy, scipy y matplotlib)

Procedimiento

1. Manejo de archivos vacíos o corruptos.
2. Lectura correcta de `eyetracker_signal.csv` y `stimulus.csv`.
3. Filtrado de estímulos según `timestamp_sec == 2`.
4. Asignación correcta de nombres de imágenes (Imagen 1 a Imagen 5).
5. Cálculo de métricas por estímulo.
6. Generación de gráficas por sujeto y promedio por estímulo.

Ejemplo de dataframe para el procesamiento de la señal de eye tracking con datos crudos

```

import os
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

1. # Rutas
root_folder = r"██████████"
folders = [str(i) for i in range(1, 52)] # Carpetas del 1 al 51

2. # Columnas para eyetracker_signal.csv
eye_cols = [
    "lx", "ly", "lpupil",
    "rx", "ry", "rpupil",
    "lp_x", "lp_y", "lp_z",
    "rp_x", "rp_y", "rp_z",
    "l_valid", "r_valid",
    "ts_us", "ts_internal"
]

3. # Columnas para stimulus.csv
stim_cols = ['timestamp', 'stimulus_code value', 'timestamp_sec']

4. # Umbral de velocidad para detectar fijaciones (opcional)
velocity_threshold = 0.85

all_metrics = []

for folder_name in folders:
    try:
        folder_path = os.path.join(root_folder, folder_name)
        eye_file = os.path.join(folder_path, "eyetracker_signal.csv")
        stim_file = os.path.join(folder_path, "stimulus.csv")

        # --- Leer eye tracker ---
        df_eye = pd.read_csv(eye_file, header=None, names=eye_cols, sep=",")
        df_eye = df_eye.apply(pd.to_numeric, errors='coerce') # asegurar numéricos
        df_eye = df_eye.dropna(subset=['ts_us']) # eliminar filas sin timestamp

        # Guardar processed
        df_eye.to_csv(os.path.join(folder_path, "eyetracker_signal_processed.csv"), index=False)

        # --- Leer estímulos ---
        df_stim = pd.read_csv(stim_file, header=None, names=stim_cols, sep=",")
        df_stim = df_stim.head(5) # solo 5 estímulos
        df_stim['start'] = df_stim['timestamp']
        df_stim['end'] = df_stim['timestamp'] + 6_000_000 # 6 segundos en us

        # --- Calcular métricas ---
        metrics = []
        for idx, stim in df_stim.iterrows():
            df_segment = df_eye[(df_eye['ts_us'] >= stim['start']) & (df_eye['ts_us'] <= stim['end'])]

            if df_segment.empty:
                metrics.append({
                    'stim_id': stim['stimulus_code value'],
                    'fixation_count_left': 0,
                    'fixation_count_right': 0,
                    'mean_pupil_left': np.nan,
                    'mean_pupil_right': np.nan,
                    'mean_speed_left': np.nan,
                    'mean_speed_right': np.nan
                })
                continue

            # Calcular velocidad aproximada
            df_segment['speed_left'] = np.sqrt(df_segment['lx'].diff()**2 + df_segment['ly'].diff()**2)
            df_segment['speed_right'] = np.sqrt(df_segment['rx'].diff()**2 + df_segment['ry'].diff()**2)

            # Fijaciones según velocidades
            df_segment['fixation_left'] = (df_segment['speed_left'] < velocity_threshold).astype(int)
            df_segment['fixation_right'] = (df_segment['speed_right'] < velocity_threshold).astype(int)

            metrics.append({
                'stim_id': stim['stimulus_code value'],
                'fixation_count_left': df_segment['fixation_left'].sum(),
                'fixation_count_right': df_segment['fixation_right'].sum(),
                'mean_pupil_left': df_segment['lpupil'].mean(),
                'mean_pupil_right': df_segment['rpupil'].mean(),
                'mean_speed_left': df_segment['speed_left'].mean(),
                'mean_speed_right': df_segment['speed_right'].mean()
            })

        df_metrics = pd.DataFrame(metrics)
        df_metrics.to_csv(os.path.join(folder_path, "eyetracker_metrics.csv"), index=False)
        df_metrics['subject'] = folder_name
        all_metrics.append(df_metrics)

        print(f"Carpetá {folder_name}: métricas calculadas y guardadas.")

    except Exception as e:
        print(f"Carpetá {folder_name}: ERROR -> {e}")

```

```

5. # --- Combinar todas las métricas ---
if all_metrics:
    df_all = pd.concat(all_metrics, ignore_index=True)
    df_all = df_all.dropna(how='all') # Limpiar filas vacías
    df_all.to_csv(os.path.join(root_folder, "all_subjects_metrics.csv"), index=False)
    print("Todos los CSV combinados correctamente.")

6. # --- Graficar métricas promedio por estímulo ---
metrics_to_plot = ['fixation_count_left', 'fixation_count_right', 'mean_pupil_left', 'mean_pupil_right']

for metric in metrics_to_plot:
    plt.figure(figsize=(10, 6))
    df_all.groupby('stim_id')[metric].mean().plot(kind='bar', color='skyblue')
    plt.title(f'Métrica promedio por estímulo: {metric}')
    plt.ylabel(metric)
    plt.xlabel('Stimulus ID')
    plt.xticks(rotation=0)
    plt.tight_layout()
    plt.savefig(os.path.join(root_folder, f"{metric}_by_stimulus.png"))
    plt.close()

print("Gráficas generadas y guardadas.")

```

Ejemplo para hallar métricas y análisis descriptivos

1. Leer todos los archivos de señal cruda de cada sujeto.
2. Limpiar NaNs y validar los segmentos de datos.
3. Asignar correctamente cada registro a un estímulo según su correspondencia de timestamp_sec.
4. Calcular métricas por estímulo y por ojo:
 - Media de posición (lx, ly, rx, ry)
 - Diámetro pupilar (lpupil, rpupil)
 - Número de fijaciones (basado en l_valid y r_valid)
5. Guardar métricas por sujeto en CSV (eyetracker_metrics.csv).
6. Graficar pupila por estímulo y sujeto, comparando ambos ojos.
7. Graficar comparación entre sujetos con media \pm desviación estándar.
8. Guardar todas las gráficas en una carpeta plots.

Ejemplo de dataframe

```

import os
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np

1. # Carpeta raíz con carpetas de cada sujeto
root_folder = "..." # cambia por tu ruta
plots_folder = os.path.join(root_folder, "plots_folder")
os.makedirs(plots_folder, exist_ok=True)

2. # Colores
colors = {'left': '#1E90FF', 'right': '#FF0000'} # azul eléctrico y rojo

3. # Definir correspondencia de estímulos por índice
stim_map = {1: 'Imagen 1', 2: 'Imagen 2', 3: 'Imagen 3', 4: 'Imagen 4', 5: 'Imagen 5'}

all_metrics = []

for subject in os.listdir(root_folder):
    subj_folder = os.path.join(root_folder, subject)
    if not os.path.isdir(subj_folder):
        continue

    signal_file = os.path.join(subj_folder, "eyetracker_signal_processed.csv")
    metrics_file = os.path.join(subj_folder, "eyetracker_metrics.csv")

```

```

# -----
4. # Señal temporal de pupila
# -----
if os.path.isfile(signal_file):
    df_signal = pd.read_csv(signal_file)
    if df_signal.empty:
        print(f"Sujeto {subject}: señal procesada vacía, saltando...")
        continue

    # Graficar pupila temporal
    plt.figure(figsize=(10,4))
    plt.plot(df_signal['ts_us'], df_signal['lpupil'], color=colors['left'], label='Ojo izquierdo')
    plt.plot(df_signal['ts_us'], df_signal['rpupil'], color=colors['right'], label='Ojo derecho')
    plt.xlabel("Tiempo (us)")
    plt.ylabel("Diámetro pupilar")
    plt.title(f"Sujeto {subject} - Pupila temporal")
    plt.legend()
    plt.tight_layout()
    plt.savefig(os.path.join(plots_folder, f"{subject}_pupila_temporal.png"))
    plt.close()

# -----
5. # Métricas por estímulo
# -----
if os.path.isfile(metrics_file):
    df_metrics = pd.read_csv(metrics_file)
    if df_metrics.empty:
        print(f"Sujeto {subject}: métricas vacías, saltando...")
        continue

    df_metrics['stim_id'] = df_metrics.index + 1
    all_metrics.append(df_metrics)

    # Gráfico de barras con media y desviación típica
    x = np.arange(len(df_metrics))
    width = 0.35

    plt.figure(figsize=(10,5))
    plt.bar(x - width/2, df_metrics['mean_pupil_left'], width,
            yerr=df_metrics['mean_pupil_left'].std(), color=colors['left'],
            label='Ojo izquierdo', capsiz=5)
    plt.bar(x + width/2, df_metrics['mean_pupil_right'], width,
            yerr=df_metrics['mean_pupil_right'].std(), color=colors['right'],
            label='Ojo derecho', capsiz=5)
    plt.xticks(x, [stim_map.get(i, f"Estímulo {i}") for i in df_metrics['stim_id']])
    plt.ylabel("Diámetro pupilar medio")
    plt.title(f"Sujeto {subject} - Pupila media por estímulo")
    plt.legend()
    plt.tight_layout()
    plt.savefig(os.path.join(plots_folder, f"{subject}_pupila_media.png"))
    plt.close()

```



```



# -----
6. # Comparativa entre sujetos
# -----
if all_metrics:
    df_all = pd.concat(all_metrics, ignore_index=True)
    plt.figure(figsize=(12,6))
    for stim in df_all['stim_id'].unique():
        df_stim = df_all[df_all['stim_id'] == stim]
        mean_l = df_stim['mean_pupil_left'].mean()
        std_l = df_stim['mean_pupil_left'].std()
        mean_r = df_stim['mean_pupil_right'].mean()
        std_r = df_stim['mean_pupil_right'].std()
        plt.errorbar([stim_map.get(stim, stim)], [mean_l], yerr=[std_l], fmt='o',
                    color=colors['left'], label='Ojo izquierdo' if stim==1 else "")
        plt.errorbar([stim_map.get(stim, stim)], [mean_r], yerr=[std_r], fmt='o',
                    color=colors['right'], label='Ojo derecho' if stim==1 else "")
    plt.ylabel("Diámetro pupilar medio")
    plt.title("Comparativa entre sujetos por estímulo")
    plt.legend()
    plt.tight_layout()
    plt.savefig(os.path.join(plots_folder, "comparativa_sujetos.png"))
    plt.close()

print(f"Todos los gráficos se guardaron en: {plots_folder}")

```

Ejemplo de posibles resultados que se pueden obtener en el procesamiento de la señal de eye tracking





Nombre	Fecha de modificación	Tipo	Tamaño
eyetracker_metrics.csv	18/01/2026 12:18	Hoja de cálculo de O...	2 KB
eyetracker_signal_processed.csv	18/01/2026 12:13	Hoja de cálculo de O...	1.103 KB

Procesamiento de señales integradas de EEG, GSR y EEG con librería de MNE, pandas, numpy, mat

Integración multimodal (resumen)

Modalidad	Aporta
EEG	Cognición + emoción
EDA	Arousal
<i>Eye-tracking</i>	Atención visual
ACC	Movimiento (artefactos)

Librerías de Python para el preprocesamiento y procesamiento de los datos crudos

Librerías	Pre-procesamiento de señal	Funcionalidad
MNE	EEG	Lectura y estructuración de EEG Filtros precisos ICA y rechazo de artefactos Segmentación por eventos Potencia espectral por bandas Manejo de timestamps y epochs
NeuroKit	GSR	EDA / GSR (fásico-tónico, SCRs) BVP / PPG → HR y HRV Respiración Pupil diameter
NeuroKit + pandas	<i>Eye-tracking</i>	Sacadas, fijaciones, diámetro de la pupila, etc.
pandas (artefactos)	ACC	

* MNE y NeuroKit no se mezclan directamente se conectan vía DataFrame temporal.

Procedimiento

1. Analizar los canales (sensores) disponibles en el dispositivo de EEG en el caso del dispositivo *diadem* de Bitbrain (12).

Frontal / prefrontal:

FP1, FP2

AF7, AF8

F3, F4

Parietal / occipital:

P3, P4

PO7, PO8

O1, O2

2. Métricas que se pueden hallar

Asimetría frontal

$$FA = \log(\text{Alpha_F4}) - \log(\text{Alpha_F3})$$

Positivo → aproximación / afecto positivo

Negativo → retirada / afecto negativo

Muy usada en estudios emocionales.

Potenciales espectrales

Por canal o regiones

Banda	Rango (Hz)	Interpretación
Delta	1–4 Hz	Somnolencia/fatiga
Theta	4–8 Hz	Carga cognitiva
Alpha	8–13 Hz	Relajación / inhibición
Beta	13–30 Hz	Activación / estrés
*Gamma low	30–45 Hz	Atención (con cautela)

* Gamma produce mucho ruido en EEG secos

Agrupación funcional de canales

Regiones	sensores
Frontal izquierdo	AF7, FP1, F3
Frontal derecho	AF8, FP2, F4
Parietal	P3, P4
Occipital	PO7, O1, O2, PO8

Marcadores de atención, carga cognitiva y estrés

Índices compuestos	Interpretación
Estrés EEG	Stress = Beta / Alpha
Atención	Attention = Beta / (Alpha + Theta)
Carga cognitiva (<i>workload</i>)	Theta_Fz / Alpha_Pz (adaptable con F3/F4 y P3/P4) Ratio Theta/Beta (frontal) Cognitive_Load = theta_frontal / beta_frontal
Atención / relajación	Alpha_Frontal = mean(alpha(AF7, FP1, FP2, AF8, F3, F4)) ↓ Alpha → ↑ atención
Estrés y activación	Beta_Frontal = mean(beta(AF7, FP1, FP2, AF8, F3, F4)) ↑ Beta → ↑ activación / estrés
Asimetría frontal (emoción)	Alpha asymmetry FA = log(alpha_F4) - log(alpha_F3) FA > 0 → aproximación / emoción positiva FA < 0 → evitación / emoción negativa
Procesamiento visual	Alpha occipital Alpha_Occipital = mean(alpha(PO7, O1, O2, PO8)) ↓ Alpha occipital → ↑ procesamiento visual

3. Integración de la señal de EEG con la señal de otros dispositivos

Estos datos servirían para triangular con otras señales de otros dispositivos como son GSR y *eye tracking*.

Dimensión	Señales
Activación simpática	SCR↑ + HR↑ + Beta↑
Estrés	HRV↓ + SCR↑ + Beta/Alpha↑
Atención	Beta↑ + Theta↓ + SCR↑
Emoción	FA + SCR amplitud

4. Pipeline completo recomendado

4.1 Sincronización multimodal

Todo debe quedar en timestamp_sec común.

```
df_all = eeg.merge(physio, on="timestamp_sec")
df_all = df_all.merge(events, on="timestamp_sec", how="left")
```

4.2 EEG – preprocesamiento (mínimo viable)

Con MNE (mejor que NeuroKit para EEG):

```
import mne
raw = mne.io.RawArray(
    eeg_data.T,
    info
)
raw.filter(1, 40)
raw.notch_filter(50)
```

ICA para parpadeos (FP1/FP2)

4.3 EEG – potencia por bandas

```
psd = raw.compute_psd(fmin=1, fmax=40)
bands = {
    "delta": (1,4),
    "theta": (4,8),
    "alpha": (8,13),
    "beta": (13,30)
}
```

Extraer media por ventana post-estímulo.

Pipeline EEG recomendado (paso a paso)

1. Preprocesado

Band-pass: 1–40 Hz

Notch: 50 Hz

Eliminación artefactos:

ICA o

threshold peak-to-peak

2. Segmentación por estímulo

Ventana:

[-0.5 s, +2.0 s]

3. Extracción de potencia por banda

Usar:

Welch

o multitaper

Por canal → luego promediar por región.

4.4 BVP

```
ppg_signals, ppg_info = nk.ppg_process(bvp, sampling_rate=64)
```

4.5 EDA

```
eda_signals, eda_info = nk.eda_process(gsr, sampling_rate=64)
```

4.6 Segmentación por estímulo

Ventanas recomendadas:

Señal	Ventana
EEG	0–2 s
HR	0–4 s
EDA	0–6 s

5. DataFrame final (estructura recomendada)

```
subject stimulus HR HRV_RMSSD SCR_Count SCR_Amp Alpha_F3
Alpha_F4 FA Beta_Alpha Movement
```

Una fila = un estímulo.

6. Advertencias importantes

Unidades EEG

Esos valores parecen en μV escalados → confirma factor de conversión.

Sampling rate EEG

Necesario para PSD correcta.

Referenciación

Ideal: average reference.

Movimiento

Usa ACC para marcar EEG contaminado.

7. Qué aplica este setup

- ✓ Activación autónoma
- ✓ Estrés fisiológico
- ✓ Atención y carga cognitiva
- ✓ Valencia emocional (asimetría frontal)

Referencias

- Bach, D. R., Flandin, G., Friston, K. J., & Dolan, R. J. (2010). Modelling event-related skin conductance responses. *International Journal of Psychophysiology*, 75(3), 349-356.
- Gamboa, H. (2008). Multi-modal behavioral biometrics based on hci and electrophysiology. PhD Thesis Universidad.
- Gramfort, A., Luessi, M., Larson, E., Engemann, D.A., Strohmeier, D., Brodbeck, C., Goj, R., Jas, M., Brooks, T., Parkkonen, L., & Hämäläinen, M.S. MEG and EEG data analysis with MNE-Python. (2013). *Frontiers in Neuroscience*, 7(267):1-13, <https://doi.org/10.3389/fnins.2013.00267>
- Gramfort, A., Luessi, M., Larson, E., Engemann, D.A., Strohmeier, D., Brodbeck, C., Goj, R., Jas, M., Brooks, T., Parkkonen, L., & Hämäläinen, M.S. (2014). MNE software for processing MEG and EEG data. *NeuroImage*, 86, 446-460. <https://doi.org/10.1016/j.neuroimage.2013.10.027>
- Greco, A., Valenza, G., & Scilingo, E. P. (2016). Evaluation of CDA and CvxEDA Models. In *Advances in Electrodermal Activity Processing with Applications for Mental Health* (pp. 35-43). Springer International Publishing.
- Greco, A., Valenza, G., Lanata, A., Scilingo, E. P., & Citi, L. (2016). cvxEDA: A convex optimization approach to electrodermal activity processing. *IEEE Transactions on Biomedical Engineering*, 63(4), 797-804.
- Hernando-Gallego, F., Luengo, D., & Artés-Rodríguez, A. (2017). Feature extraction of galvanic skin responses by nonnegative sparse deconvolution. *IEEE journal of biomedical and health informatics*, 22(5), 1385-1394.
- Kim, K. H., Bang, S. W., & Kim, S. R. (2004). Emotion recognition system using short-term monitoring of physiological signals. *Medical and biological engineering and computing*, 42(3), 419-427.

- Pham T, Lau ZJ, Chen SHA, Makowski D. (2021). Heart Rate Variability in Psychology: A Review of HRV Indices and an Analysis Tutorial. *Sensors* (Basel). 21(12), 3998. <https://doi.org/10.3390/s21123998>
- Makowski, D. (2021). Neurophysiological Data Analysis with NeuroKit2. *NeuroKit*. <https://neuropsychology.github.io/NeuroKit/>
- Makowski, D., Pham, T., Lau, Z. J., Brammer, J. C., Lespinasse, F., Pham, H., Schölzel, C., & Chen, S. A. (2021). NeuroKit2: A Python toolbox for neurophysiological signal processing. *Behavior Research Methods*, 53(4), 1689-1696. <https://doi.org/10.3758/s13428-020-01516-y>
- Nabian, M., Yin, Y., Wormwood, J., Quigley, K. S., Barrett, L. F., & Ostadabbas, S. (2018). An Open-Source Feature Extraction Tool for the Analysis of Peripheral Physiological Data. *IEEE journal of translational engineering in health and medicine*, 6, 2800711.
- van Halem, S., Van Roekel, E., Kroencke, L., Kuper, N., & Denissen, J. (2020). Moments That Matter? On the Complexity of Using Triggers Based on Skin Conductance to Sample Arousing Events Within an Experience Sampling Framework. *European Journal of Personality*.



RELACIÓN DE TABLAS

Tabla 1.	Relación de los valores típicos en condiciones de laboratorio controladas con el dispositivo de <i>eye tracking</i> de Tobii Pro Lab.....	28
Tabla 2.	Sensores cerebrales, localización, función cognitiva, emociones y bandas cerebrales relevantes.....	107
Tabla 3.	Relación entre los sensores cerebrales, su localización cerebral, su función cognitiva respecto del reconocimiento de emociones y su relación con la activación de las bandas cerebrales.....	108
Tabla 4.	Relación entre los sensores cerebrales, su localización cerebral y su función cognitiva respecto del reconocimiento de emociones.....	108
Tabla 5.	Comparativa de la funcionalidad de técnicas de neuroimagen no invasiva.....	120
Tabla 6.	Comparativa de tecnologías invasivas de neuroimagen y BCI.	123



RELACIÓN DE FIGURAS

Figura 1.	Componentes del <i>eye tracking</i> en un dispositivo Tobii Pro Lab.....	21
Figura 2.	Tomado del Manual Tobii Pro Lab v. 1.194 p. 155.....	22
Figura 3.	Tomado del Manual Tobii Pro Lab v. 1.194 p. 158.....	22
Figura 4.	Imagen tomada de Tobii TD Snap enlace-001	23
Figura 5.	Tomado de TD Snap Motor Plan enlace-002	23
Figura 6.	Imagen tomada de Tobii TD Snap Express enlace-003	24
Figura 7.	Imagen tomada de Tobii TD Snap Texto enlace-004	24
Figura 8.	Imagen tomada de Tobii TD Snap Texto enlace-005	25
Figura 9.	Imagen tomada de Tobii información en web enlace-007	25
Figura 10.	Imagen tomada de Tobii información en web enlace-008	25
Figura 11.	Tomado del Manual Tobii Pro Lab v. 1.194 p. 159.....	26
Figura 12.	Posibilidades de dispositivos con Tobii Pro Lab (fuente propia).....	26
Figura 13.	Ejemplo de diseño y aplicación de estímulos (fuente propia).....	27
Figura 14.	Calibración con el dispositivo Tobii Pro Lab (fuente propia).....	28
Figura 15.	Calibración con el dispositivo Tobii Pro Lab (fuente propia).....	28
Figura 16.	Ejemplos de calibración en distintos sujetos en un dispositivo Tobii Pro Lab (fuente propia).....	29

Figura 17. Ejemplo de calibración con un dispositivo iView XTM v.2.7. SMI (fuente propia).....	29
Figura 18. Ejemplos de características aplicadas.....	30
Figura 19. Integración de señales en <i>eye tracking</i>	30
Figura 20. Definición de AOI en un dispositivo iViwe XTM, SMI Experimenter Center 3.0 y SMI BeGazeTM (fuente propia).....	59
Figura 21. Definición de AOI en un dispositivo Tobii Pro Lab v. 24.21.435 (x64) (fuente propia).	60
Figura 22. <i>Scan path</i> realizado con un dispositivo iViwe XTM, SMI Experimenter Center 3.0 y SMI BeGazeTM (fuente propia).....	60
Figura 23. <i>Scan path</i> realizado con un dispositivo Tobii Pro Lab v. 24.21.435 (x64) (fuente propia).	61
Figura 24. Posicionamiento de la mirada en un punto, imagen de uso libre tomada de Tobii enlace-020	61
Figura 25. <i>Gaze point</i> realizado con un dispositivo iViwe XTM, SMI Experimenter Center 3.0 y SMI BeGazeTM.....	62
Figura 26. <i>Gaze point</i> realizado con un dispositivo Tobii Pro Lab v. 24.21.435 (x64).	62
Figura 27. Conexión de un dispositivo Shimmer en un dispositivo Tobii Pro Lab (fuente propia).....	64
Figura 28. Procesamiento de la señal de un dispositivo Shimmer en un dispositivo Tobii Pro Lab (fuente propia).	64
Figura 29. Dispositivo Shimmer en un dispositivo experimental (fuente propia).	64
Figura 30. Registro de distintas señales de información en un dispositivo de <i>eye tracking</i> (fuente propia).	66
Figura 31. Imagen del registro en EEG con 16 canales tomado de Bitbrain enlace-021	67

Figura 32.	Representación de las áreas cerebrales (imagen elaborada por ChatGPT).	68
Figura 33.	Dispositivo GSR, posición de los dedos para el registro, ejemplo de registro tomado de Bitbrain.	75
Figura 34.	Ejemplo de un registro individual de señal integrada (fuente propia).	75
Figura 35.	Ejemplo de un registro colectivo de señal integrada (fuente propia). .	76
Figura 36.	Mapa de calor en señal de <i>eye tracking</i> (imagen propia).	76
Figura 37.	Mapa de biométricas en señal de <i>eye tracking</i> (imagen propia).	77
Figura 38.	Mapa de focalización de <i>eye tracking</i> (imagen propia).	77
Figura 39.	Mapa de tiempo en señal de <i>eye tracking</i> (imagen propia).	78
Figura 40.	Mapa de trayectoria de <i>eye tracking</i> (imagen propia).	78
Figura 41.	Medias y Desviaciones Típicas en <i>engagement</i> en distintas emociones (imagen propia).	79
Figura 42.	Medias y Desviaciones Típicas en valencia en distintas emociones (imagen propia).	79
Figura 43.	Medias y Desviaciones Típicas en <i>memorization</i> en distintas emociones (imagen propia).	80
Figura 44.	Medias y Desviaciones Típicas en <i>workload</i> en distintas emociones (imagen propia).	80
Figura 45.	Análisis de AOI en la métrica <i>engagement</i> respecto de la emoción de sorpresa (imagen propia).	81
Figura 46.	Análisis de AOI en la métrica <i>engagement</i> respecto de la emoción de enfado (imagen propia).	81
Figura 47.	Análisis de AOI en la métrica <i>engagement</i> respecto de la emoción de alegría (imagen propia).	82
Figura 48.	Análisis de AOI en la métrica <i>engagement</i> respecto de la emoción de tristeza (imagen propia).	82

Figura 49.	Análisis de AOI en la métrica <i>engagement</i> respecto de la emoción de miedo (imagen propia).....	83
Figura 50.	Patrón de comportamiento visual en ejes cartesianos en el dispositivo iView XTM, SMI Experimenter Center 3.0 y SMI BeGazeTM.	90
Figura 51.	Frecuencias en los cuadrantes y relación con las AOIs, p. 10.....	90
Figura 52.	Análisis de <i>clustering</i> con <i>k</i> -means sobre las frecuencias en las AOIs, p.11.	91
Figura 53.	<i>Heatmaps</i> de las cadenas de <i>scan-path: Uniform Distance model</i> , p.12.....	92
Figura 54.	<i>Heatmaps</i> de las cadenas de <i>scan-path: City Block Distance model</i> , p.13.	93
Figura 55.	<i>Heatmaps</i> de las cadenas de <i>scan-path: Euclidian Distance model</i> , p.13.	94
Figura 56.	<i>Multi-dimensional scaling</i> a partir de las distancias en <i>Uniform Distance model</i> , p.14.....	95
Figura 57.	<i>Multi-dimensional scaling</i> a partir de las distancias en <i>City Block Distance model</i> , p.14.....	96
Figura 58.	<i>Multi-dimensional scaling</i> a partir de las distancias en <i>Euclidian Distance model</i> , p.15.....	96
Figura 59.	Patrón de interacciones visuales en distintos estímulos en un estudiante.....	97
Figura 60.	Distribución de las fijaciones en AOIs en un estudiante.	98
Figura 61.	Representación de las fijaciones en ojo derecho y en ojo izquierdo en un estudiante.....	98
Figura 62.	Patrón de interacciones visuales en distintos estímulos en un profesor.....	99
Figura 63.	Distribución de las Fijaciones en AOIs en un profesor.	99

Figura 64.	Representación de las fijaciones en ojo derecho y en ojo izquierdo en un profesor.....	100
Figura 65.	Mapa de calor con dispositivo Tobii Pro Lab.....	100
Figura 66.	Cadena <i>scan path</i> con dispositivo Tobii Pro Lab.	101
Figura 67.	Visualización del comportamiento de los usuarios por grupo durante la presentación de los estímulos.	101
Figura 68.	Laboratorio de neuropsiquiatría de Hans Berger (imágenes tomadas de acceso libre).	103
Figura 69.	Representación de las bandas de frecuencia, realizada mediante ChatGPT.	103
Figura 70.	Representación de la banda delta, imagen de uso libre tomada de Bitbrain enlace-022	104
Figura 71.	Representación de la banda theta, imagen de uso libre tomada de Bitbrain enlace-023	104
Figura 72.	Representación de la banda alfa, imagen de uso libre tomada de Bitbrain enlace-024	105
Figura 73.	Representación de la banda beta, imagen de uso libre tomada de Bitbrain enlace-025	106
Figura 74.	Representación de la banda gamma, imagen de uso libre tomada de Bitbrain enlace-026	107
Figura 75.	Fases del procedimiento de tratamiento de la señal (fuente propia).	109
Figura 76.	Representación de datos de un registro de EEG (tomado de MNE enlace-027).	111
Figura 77.	Limpieza de artefactos mediante ICA (tomado de MNE enlace-028).	112
Figura 78.	Detección de eventos experimentales (tomado de MNE enlace-029).	113
Figura 79.	<i>Epoch</i> en EEG (tomado de MNE enlace-030).	114

Figura 80.	Análisis tiempo-frecuencia (tomado de MNE enlace-031).....	115
Figura 81.	Topografía de registros neurofisiológicos para potenciales evocados auditivos y visuales (imagen creada por ChatGPT).	115
Figura 82.	Estimación de respuestas promediadas (tomado de MNE enlace-032).	116
Figura 83.	Visualización de la localización de la señal de EEG en tarea auditiva (tomado de tutorial MNE enlace-033).....	117
Figura 84.	Visualización de la localización señal de EEG en tarea visual (tomado de tutorial MNE enlace-034).	117
Figura 85.	Comparativa de técnicas no invasivas: EEG, fNIRS y MEG (imagen elaborada por ChatGPT).	120
Figura 86.	Comparativa de técnicas invasivas: Neuralink, BrainGate y Synchron-Stentrode (imagen elaborada por ChatGPT).....	123
Figura 87.	Ejemplos de aplicación de las señales integradas.	125
Figura 88.	Aplicaciones biomédicas de <i>eye tracking</i> en tecnología multicanal: diagnóstico, rehabilitación, formación, optimización de entornos, control de dispositivos y biomarcadores (imagen elaborada por ChatGPT).....	127



GLOSARIO

A

Accuracy 27, 28
Acelerómetro 63, 148
activación emocional 30, 71, 83, 84
activación fisiológica 71, 148
actividad cerebral 66
actividad electrodérmica 63, 71
actividad electroencefalográfica 62
afectaciones motoras 25
algoritmo cvxEDA 151
almacenamiento 70
Alzheimer 85, 124, 126
Amplitud 147, 152
anonimización 29
AOI fixation metrics 41, 42
Área frontal 67
Área occipital 68
Área parietal 68
Área prefrontal 68
áreas cerebrales 67
Áreas de Interés 35
Área temporal 68
arousal 148, 152
Arousal 152
atención 21, 26, 31, 32, 40, 54, 61, 66, 68, 70, 84, 105, 106, 124, 126, 127, 137, 148, 151
Atención 32, 147
atención sostenida 105, 106
atención visual 66, 84

B

Bandas alfa 105

Bandas beta 105
bandas cerebrales 101, 107
Bandas delta 103
Bandas gamma 106
Bandas theta 104
biomarcadores conductuales 127
biomarcadores de enfermedades neurológicas 124
biomedicina 101
Blood Volume Pulse 148
Brain-Computer Interface 85, 118

C

calibración 70, 71
campos magnéticos 119, 120
carga cognitiva 31, 54, 70, 83, 148
cartografía cerebral 101
ciencias biomédicas 118, 127
codificación 70
Componente fásica 151
Componente tónica 151
Comunicación Aumentativa y Alternativa 24

D

dashboards 84
datos crudos 101, 109, 110, 128, 129, 143, 154
decodificación neuronal 124
degeneración macular 126
demencias frontotemporales 126
desoxigenada 119, 120
discapacidad motora severa 127

E

Electrodermal Activity 148
electrodos intracorticales 121
electroencefalografía 18, 102, 105
electroencefalograma 12, 102
emocionales 68
enfermedad de Parkinson 121
Enfermedades neurodegenerativas 126
engagement 78, 80, 83, 84, 147
Engagement 70
epilepsia 119, 120, 121, 124

esclerosis lateral amiotrófica 122
Esclerosis Lateral Amiotrófica (ELA) 22
estados de alerta 105
Event 41
Event metrics 41
excitación emocional 105
eye tracking 21

F

Fase fásica 150
Fase tónica 150
fijación 41, 42, 43, 44
fijaciones 35
flujo sanguíneo cerebral 119
Frecuencia cardíaca 148, 152
frecuencia cardíaca 63
frecuencia de muestreo 59, 65, 83, 147, 159
frontal 66
función cognitiva 107

G

Galvanic Skin Response 30, 62
galvanómetro 102
gaze point 61
glances 35
glándulas sudoríparas 71, 148
glaucoma 126

H

hemoglobina oxigenada 119, 120

I

impedancia 145
inteligencia artificial 85
Inteligencia Artificial 13, 18, 32, 118, 124, 135
Inteligencia Artificial Generativa 32
Interval metrics 41

L

latencia 39, 147, 151, 152
Late Positive Potential 146
lectoescritura 24, 126

Lesiones cerebrales 126
lesiones medulares 22
lógico-matemáticas 126
luz infrarroja 21

M

machine learning 11, 110
magnetoencefalografía 105
magnetómetros superconductores 119
mapa de biométricas 76
mapa de calor 76
mapa de focalización 76
mapa de tiempo 76
mapa de trayectoria 76
Media 42
memoria 70
Memorización 70
memorization 78
métodos bayesianos 151
métricas dinámicas 35
métricas estáticas 35

N

neurociencia computacional 124, 125
neuroimagen 119, 124
neurotecnología 118, 121, 122, 125, 131
normalización 84

O

occipital 66
optimización convexa 151

P

parálisis cerebral 22, 121, 122
Parkinson 121, 126
Phase-Locking Value 147
pico de SCR 151
pictogramas 22, 23, 24
potenciales eléctricos 118
Precision (RMS) 28
Precision (RMS – Root Mean Square) 27
Precision (SD) 28

Precision (SD – desviación estándar) 27
prefrontal 66
procesos cognitivos 68
prótesis robóticas 124
pulsaciones cerebrales 102
pupil diameter 42

R

Registro Encefalográfico 66
regresión 44, 45
Rehabilitación cognitiva 126
Relajación 147
respuesta emocional 71
respuesta galvánica de la piel 71
respuesta psicogalvánica 75
Respuestas emocionales o cognitivas 148
retención 70
robot quirúrgico 121

S

sacada 44
sacadas 35
Sampling 145, 149, 179
scan path 35, 60, 129
sensores cerebrales 107, 108
sequence number 149, 150
simuladores médicos 126
Síndrome de Rett 22
Sistema Nervioso Autónomo 71, 148
sistema nervioso simpático 63
Sistema Nervioso Simpático 148
sistemas inteligente 24
Skin Conductance Responses 65

T

técnica no invasiva 118, 119
tecnología multicanal integrada 125, 127
tecnologías invasivas 121, 123
temperatura cerebral 102
tetraplejía 122
timestamp 149, 150, 154, 155, 160
timestamp (corrected) 149, 150

timestamp (reception) 149, 150

timestamps 83, 158, 159

V

valencia 78

Valencia 70

Variabilidad de la frecuencia cardíaca 148

variables fisiológicas 102

ventanas de tiempo 83, 84

W

workload 78

Workload 70, 147



AUTORES

Dra. María Consuelo Sáiz Manzanares

Dr. Raúl Marticorena Sánchez

Dr. David García-García



MARÍA CONSUELO SÁIZ MANZANARES

Licenciada en Psicología por la Universidad de Salamanca y en Ciencias de la Educación por la Universidad Nacional de Educación a Distancia (UNED), es doctora en Psicología por la Universidad de Valladolid y doctora en Tecnologías Industriales e Ingeniería Informática, con especialización en Inteligencia Artificial, por la Universidad de Burgos (UBU). Asimismo, cuenta con la acreditación como experta en Enseñanza Virtual por la UBU. Actualmente es catedrática de Universidad en la Universidad de Burgos, donde dirige el Grupo de Innovación Docente B-LCS, el Grupo de Investigación Reconocido DATAHES y la Unidad de Investigación Consolidada (UIC n.º 348) de la Junta de Castilla y León. Es miembro de diversas asociaciones científicas de referencia, entre ellas el Colegio Oficial de Psicología (COP), la Asociación Científica de Psicología y Educación (ACIPE), ADIPSIEDUC y la European Association for Research on Learning and Instruction (EARLI). Su producción científica incluye más de ochenta publicaciones indexadas en Web of Science (WoS) y Scopus, así como en editoriales de reconocido prestigio internacional. Su investigación se centra en estrategias metacognitivas, tecnologías emergentes y la aplicación de técnicas de aprendizaje automático en los ámbitos educativo y sanitario (ORCID: <https://orcid.org/0000-0002-1736-2089>). Ha participado como investigadora principal en múltiples proyectos de investigación nacionales e internacionales, así como en iniciativas de innovación y transferencia del conocimiento. Estos trabajos han dado lugar a más de un centenar de contribuciones en congresos científicos y a diversos premios en convocatorias de transferencia del conocimiento de la Junta de Castilla y León, financiadas con fondos FEDER. Cuenta con tres sexenios de investigación reconocidos por la ANECA, uno de ellos en transferencia del conocimiento.

Más información: <https://investigacion.ubu.es/investigadores/35511/detalle>



RAÚL MARTICORENA SÁNCHEZ

Diplomado en Informático de Gestión, Ingeniero en Informática y Doctor en Informática, todo ello por la Universidad de Valladolid. Actualmente es profesor Titular de Universidad en el Área de Lenguajes y Sistemas Informáticos, dentro del departamento de Ingeniería Informática de la Universidad de Burgos. Como investigador, formó parte inicialmente del grupo de investigación GIRO de la Universidad de Valladolid. En este periodo se centró en la refactorización del software sobre genericidad con independencia del lenguaje de programación. Posteriormente se incorpora al Grupo de Investigación Reconocido ADMIRABLE (<http://admirable-ubu.es/>) y Unidad de Investigación Consolidada (UIC N.º 170), en la Universidad de Burgos. Donde continúa su investigación incorporando la minería de datos aplicada a la ingeniería del software, la innovación docente y su aplicación en ciencias de la salud. Su docencia está fundamentalmente centrada en titulaciones vinculadas a la Ing. Informática, y en menor medida en Ingeniería de la Salud. Con más de 100 proyectos fin de carrera dirigidos o codirigidos, en general con tecnologías Java (JSE, JEE y Android) y en algún caso particular con .NET, cubriendo aplicaciones de escritorio, desarrollo web y aplicaciones para móviles, en todos los ámbitos (aplicaciones de gestión, innovación tecnológica, innovación docente e investigación, ingeniería de la salud). Miembro del grupo de innovación docente DIGIT de la Universidad de Burgos y revisor en la actualidad de las Jornadas de Enseñanza Universitaria de la Informática (JENU). Ha participado como investigador en múltiples proyectos de investigación y transferencia tecnológica, en el marco regional, nacionales e internacional, con más de 100 publicaciones nacionales e internacionales.

Más información: <https://investigacion.ubu.es/investigadores/35319/detalle>



DAVID GARCÍA GARCÍA

Ingeniero de Telecomunicación por la Universidad Pública de Navarra y doctor en Neurociencia y Cognición por la Universidad de Navarra, actualmente es Director de Digitalización de la Universidad de Burgos. Ha desarrollado además una amplia trayectoria académica y de gestión universitaria, desempeñando cargos como Coordinador Académico del Grado en Ingeniería de la Salud en la Universidad de Burgos, Director del Área de Ciencias Computacionales y Tecnología en la Universidad Internacional de La Rioja, Decano de la Facultad de Ciencias y Tecnología y Director del Grado en Ingeniería Informática en la Universidad Isabel I.

Su actividad investigadora se ha centrado en el ámbito de la neuroimagen, la enfermedad de Parkinson, el análisis de imagen médica y la aplicación de tecnologías computacionales e inteligencia artificial al ámbito de la salud. Ha trabajado en instituciones como la Clínica Universidad de Navarra, CIBERNED, la Universidad Carlos III de Madrid, el Hospital Gregorio Marañón y CIBERSAM, participando en proyectos nacionales e internacionales relacionados con resonancia magnética, PET, estimulación cerebral profunda y desarrollo de herramientas avanzadas para neuroimagen.

Cuenta con dos sexenios de investigación reconocidos por ANECA, más de 1.300 citas en Web of Science y un índice h de 18. Su producción científica incluye numerosas publicaciones indexadas en revistas de alto impacto, especialmente en los ámbitos de la neurociencia, la neuroimagen, la inteligencia artificial y la salud digital. Asimismo, ha participado en múltiples proyectos competitivos de investigación, actividades de transferencia y congresos científicos nacionales e internacionales. Su ORCID es: <https://orcid.org/0000-0001-5224-3280>


Más información: <https://investigacion.ubu.es/investigadores/326207/detalle>



**UNIVERSIDAD
DE BURGOS**

**Servicio de Publicaciones e
Imagen Institucional**

ISBN 979-13-87585-40-2



9 791387 585402