

Coordinadora:

MARÍA CONSUELO SÁIZ MANZANARES

SISTEMAS INTELIGENTES APLICADOS A LA PSICOLOGÍA



**UNIVERSIDAD
DE BURGOS**

**SISTEMAS INTELIGENTES
APLICADOS A LA PSICOLOGÍA**

Coordinadora:

MARÍA CONSUELO SÁIZ MANZANARES

**SISTEMAS INTELIGENTES
APLICADOS A LA PSICOLOGÍA**



**UNIVERSIDAD
DE BURGOS**

2025

(Manuales y Prácticas, 50)

© 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: 979-13-87585-19-8 (edición impresa)

ISBN: 979-13-87585-20-4 (ebook)

Depósito legal: BU 308-2025

DOI: <https://doi.org/10.36443/979-13-87585-20-4>

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	
CONCEPTO DE SISTEMAS INTELIGENTES	19
1.1. Concepto de Inteligencia Artificial.....	21
1.2. Inteligencia Artificial e Inteligencia humana desde un paralelismo de funcionamiento	22
1.2.1. Teoría Cognitiva de la inteligencia humana.....	22
1.2.2. Metacognición y metaconciencia	29
1.3. Ejemplo de análisis cognitivo de tareas.....	30
1.4. Teoría de la carga cognitiva.....	31
1.5. Método NASA TLX	33
1.6. Preguntas de autoevaluación Tema 1.....	37
1.7. Práctica Tema 1.....	39
TEMA 2	
UTILIZACIÓN DE LOS SISTEMAS INTELIGENTES TIPO BOT APLICADOS A LA PSICOLOGÍA HUMANA	41
2.1. Definición de <i>bot</i>	43
2.2. Estructura de un <i>bot</i>	43
2.3. Preguntas de autoevaluación Tema 2.....	46
2.4. Práctica Tema 2.....	47
TEMA 3	
UTILIZACIÓN DE LOS SISTEMAS INTELIGENTES TIPO <i>EYE TRACKING</i> APLICADOS EN PSICOLOGÍA	49
3.1. <i>Eye tracking</i> utilizado en Psicología	51

3.1.1. ¿Qué es la tecnología <i>eye tracking</i> ?	52
3.1.2. Métricas de registro en <i>eye tracking</i> y su significado en el procesamiento de la Información.	62
3.1.3. Sincronización de <i>eye tracking</i> con otros registros.....	81
3.1.4. Relación de las medidas de registro encefalográfico con el procesamiento cognitivo.	85
3.1.5. Marcadores biométricos aplicación a la evaluación e intervención psicológica.....	101
3.2. Preguntas de autoevaluación Tema 3.....	112
3.3. Práctica Tema 3.....	113

TEMA 4

UTILIZACIÓN DE LAS TÉCNICAS DE APRENDIZAJE AUTOMÁTICO Y DE INTELIGENCIA ARTIFICIAL APLICADAS A LA PSICOLOGÍA HUMANA (PREDICCIÓN Y CLASIFICACIÓN Y CLUSTERING).....	115
4.1. Datos tabulares en <i>Machine Learning</i>	117
4.2. <i>Machine Learning</i> (ML) en el entorno de la psicología.....	118
4.3. Técnicas de <i>Machine Learning</i>	124
4.3.1. Técnicas de aprendizaje supervisado.	125
4.3.2. Técnicas de aprendizaje no supervisado	131
4.4. Técnicas de evaluación de modelos de <i>Machine Learning</i>	134
4.5. Minería de Datos en educación	136
4.6. Utilización de la Minería de datos con el <i>software Orange</i>	138
4.6.1. Introducción a la Minería de datos.....	138
4.6.2. Utilización del <i>software Orange</i>	140
4.7. Ejemplo práctico del trabajo con el software Orange v. 3.38.1.....	154
4.8. Preguntas de autoevaluación Tema 4.....	176
4.9. Práctica Tema 4.....	177
REFERENCIAS	179
RELACIÓN DE TABLAS.....	193
RELACIÓN DE FIGURAS.	197
RELACIÓN DE ACRÓNIMOS.....	209



PRÓLOGO

El último psicólogo del mundo murió en 2097. Para entonces, las inteligencias artificiales ya eran capaces de diagnosticar trastornos emocionales con una precisión del 99,8 %, diseñar intervenciones personalizadas en cuestión de segundos y ofrecer terapia en cualquier idioma, las 24 horas del día. Nadie necesitaba un psicólogo humano. O al menos, eso creían...

Imaginen un futuro donde los *bots* conversacionales sean los primeros en detectar síntomas de dislexia o disgrafía, donde el análisis de grandes volúmenes de datos anticipe conductas suicidas antes de que ocurran o donde los psicólogos trabajen codo a codo con inteligencias artificiales. Codo con codo como sinónimo de intersección, no de automatización. Ese futuro no está lejos. De hecho, ya está aquí.

Con este escenario de ciencia, de ficción y de ciencia ficción, podríamos arrancar una lección magistral sobre Historia de la Psicología sin ni siquiera cambiar de siglo. Pero la historia de la Psicología y los Sistemas Inteligentes no es una historia de reemplazo, sino de evolución. Futuros psicólogos, profesionales de la psicología, mucho se habla de estudios pioneros y reflexiones necesarias, pero el presente texto, que tengo el honor de prologar, sin duda lo es. Y llega en un momento crítico, cuando estamos en ese punto de inflexión en el que o aprendemos a integrar los sistemas inteligentes en nuestra disciplina o corremos el riesgo de quedarnos atrás.

Al respecto, son muchos los interrogantes que se le plantean a los profesionales de la psicología y se le deben plantear a los futuros psicólogos: ¿Puede una máquina entender la mente humana? ¿Podemos enseñarle a una inteligencia artificial a reconocer emociones, predecir conductas o incluso apoyar terapias psicológicas? Y aún más los que resuelve y (re)plantea este texto a través de sus diferentes capítulos. Tanto si te has planteado estas cuestiones como si no, estás en lugar adecuado. Este manual, que probablemente no tengas entre tus manos, sino entre tus píxeles, explora la intersección entre psicología y Tecnología, un territorio fascinante donde lo humano y lo artificial se entrelazan más que nunca. Y lo hace de una forma accesible, precisa y fiable, tal como nos tienen acostumbrados sus autores en sus trabajos y estudios previos. En este sentido, no puedo dejar de poner en valor la colaboración entre el Departamento de Ciencias de la Salud y el de Ingeniería Informática,

coordinada por la Dra. Sáiz Manzanares, para acometer la ardua tarea de realizar un recorrido integral por los principales sistemas inteligentes aplicados a la Psicología.

Respecto al contenido, el presente manual tiene un sólido enfoque en la aplicación de la inteligencia artificial a la psicología, cubriendo desde fundamentos teóricos hasta herramientas prácticas acerca de *bots*, *eye tracking*, minería de datos y *Machine Learning*. Pero además de ser un texto ágil y didáctico, al final de cada capítulo se sugieren actividades prácticas y preguntas de autoevaluación que, a diferencia de otras referencias, posibilita el saber cómo y no solo el saber qué.

Pero no solo se trata de este manual, sino de la propia incorporación de la asignatura «Sistemas Inteligentes Aplicados a la Psicología» en el Grado en Psicología, absolutamente pionera en la formación de los psicólogos dentro del sistema educativo español, que responde a la necesidad de formar futuros profesionales en el uso y aplicación de la Inteligencia Artificial y otras tecnologías avanzadas dentro del ámbito de la salud en general, y de la mental en particular. Una iniciativa que representa tanto un desafío como una oportunidad. La convergencia entre las Ciencias de la Salud y las Ciencias de la Computación abre un sinfín de posibilidades en el análisis de datos, la automatización de procesos y el desarrollo de herramientas para la evaluación, intervención y tratamiento. Sin embargo, también implica un cambio de paradigma en la formación de los psicólogos y resto de profesionales de salud, quienes deben adquirir competencias en el uso de sistemas inteligentes sin perder de vista el componente humano y ético de su profesión. Este texto se ha atrevido a contribuir sustancialmente a este giro copernicano en la formación de nuestros futuros psicólogos.

Cuando recibí la invitación para prologar este libro recordé las palabras de uno mis profesores: - Un prólogo debe ser breve y conciso, pero lo suficientemente disruptivo como para que el lector quiera seguir leyendo-. En este sentido, teniendo en cuenta la temática que aborda y la trayectoria de la coordinadora y los autores del manual, este libro podría haber visto la luz sin prólogo. Sin embargo, quisiera animar a los estudiantes de psicología a que se adentren en estas páginas. Los insto a abordar la relación entre la Ciencia del Comportamiento y la de la Computación con curiosidad y apertura. La interacción entre Psicología y Sistemas Inteligentes no solo ampliará su comprensión del comportamiento humano, sino que también les dotará de herramientas únicas para afrontar los desafíos del futuro. Es bien sabido que la Psicología, como disciplina, ha evolucionado constantemente en su búsqueda por comprender la mente y el comportamiento humano. Como lo es también que la tecnología lo ha hecho en su búsqueda por aprender de la mente y del comportamiento humano. Pero no solo eso, sino que está redefiniendo la forma en que entendemos la mente humana, y la mente humana está siendo redefinida por la tecnología, los profesionales que sepan integrar ambas disciplinas con criterio y ética estarán en la vanguardia del siglo XXI. Y por qué no, también mejor situados en un mercado laboral cambiante y trepidante.

Reinterpretando a Publio Terencio, a este manual, nada de lo psicológico ni de lo tecnológico le es ajeno. Es una invitación a mirar el futuro de la Psicología desde la tecnología y descubrir cómo está redefiniendo nuestra comprensión del comportamiento humano. Os animo a descubrirlo desde estas páginas, convencida de que se convertirá en una referencia fundamental para quienes deseen explorar el apasionante mundo de los sistemas inteligentes aplicados a la Psicología.

Rebeca Cerezo Menéndez

*Departamento de Psicología
Grupo de Investigación ADIR
Universidad de Oviedo*

Más información [enlace](#)



INTRODUCCIÓN

Dentro de la asignatura «Sistemas Inteligentes Aplicados a la Psicología» del Grado en Psicología de la Universidad de Burgos, se abordará la aplicación de los llamados «Sistemas Inteligentes» al ámbito de la psicología educativa y clínica. El objetivo es analizar la utilidad de estos sistemas tanto en los procesos de diagnóstico como en los de intervención con distintos usuarios (alumnado o pacientes).

En primer lugar, se examinará el concepto de «Sistemas Inteligentes»; seguidamente, el de «Inteligencia Artificial»; y, a continuación, la utilización de los sistemas inteligentes aplicados al análisis del comportamiento humano. Finalmente, se trabajará con técnicas de «Machine Learning» (aprendizaje automático), tanto supervisadas como no supervisadas, aplicadas al análisis e interpretación de datos registrados en distintos dispositivos para la comprensión del comportamiento humano.

TEMA 1

**CONCEPTO DE SISTEMAS
INTELIGENTES**

María Consuelo Sáiz Manzanares

Departamento de Ciencias de la Salud
Facultad de Ciencias de la Salud
Universidad de Burgos

Álvar Arnaiz González

Departamento de Ingeniería Informática
Escuela Politécnica Superior
Universidad de Burgos

Los sistemas inteligentes hacen referencia a los avances de la industria 4.0 y 5.0. Estos tienen como objetivo la mejora de los procesos de automatización y optimización aplicados a distintos contextos. Dentro de los sistemas inteligentes se incluyen la Inteligencia Artificial (IA), la robótica, el Internet de las cosas (*Internet of Things* -IoT-) y el análisis de gran volumen de datos. Actualmente, la industria 5.0 hace referencia a todos los avances conseguidos con la industria 4.0 aplicados especialmente a la interacción hombre-máquina. La idea general es la de mejorar los procesos de automatización y facilitar la vida humana. Específicamente, la industria 5.0 pone un énfasis importante en la fabricación de sistemas cognitivos que aprendan de sus propios errores y que apliquen sistemas metacognitivos de reflexión, es lo que se ha denominado Inteligencia Artificial Generativa. Estos conceptos son independientes entre ellos, si bien pueden tener interrelación en un espacio de simbiosis colaborativa exitosa.

1.1. Concepto de Inteligencia Artificial

Siguiendo a Arnaiz González (2024 p. 229- 230) la IA se puede definir como el estudio de los métodos computacionales que pueden hacer posible percibir, razonar y actuar (Winston, 1992). En un sentido más amplio, se asume que la IA estudia los procesos que permiten a las máquinas tener comportamientos que se observan en la inteligencia humana (Maddox et al., 2019). En general, se entiende que el propósito de la IA es desarrollar: modelos conceptuales, procedimientos de reescritura formal de dichos modelos y desarrollar estrategias de programación y máquinas físicas que reproduzcan las tareas cognitivas de los sistemas biológicos que se consideran inteligentes (Mira et al., 1995). En la última década, los avances en la IA han conseguido superar a los humanos en diversas tareas que antes se suponían computacionalmente intratables. Los avances de los últimos tiempos en el campo han sido posibles gracias al incremento exponencial de la información disponible (grandes bases de datos de las que aprender), combinado con nuevos algoritmos y optimizaciones (Došilović et al., 2018).

Uno de los problemas que se achaca a algunos de los métodos y algoritmos de IA es su interpretabilidad y su falta de transparencia (Markus et al., 2021).

Es frecuente que los mejores métodos (los más precisos) funcionen como cajas negras en las que, a partir de una entrada ofrecen una salida/predicción, pero resulta complicado o imposible poder determinar cómo el sistema ha llegado a dicha conclusión. Por ello, la IA explicable (*explainable AI*) ha cobrado especial interés en la comunidad, especialmente cuando estos métodos se desean utilizar en ámbitos médicos y relacionados con la salud. Para la interpretabilidad y explicabilidad de los métodos, se suelen identificar dos categorías: interpretabilidad integrada (basados en transparencia) y *post-hoc* (Došilović et al., 2018).

1.2. Inteligencia Artificial e Inteligencia humana desde un paralelismo de funcionamiento

En las últimas décadas la base teórica de la explicación de la IA se fundamenta en el funcionamiento del concepto de «inteligencia» en el ser humano (Sáiz-Manzanares, 1994). Este referente ayuda en el diseño de los algoritmos aplicados dentro de la IA (Sáiz-Manzanares, 2019). La idea es la de incrementar el nivel de autonomía de los sistemas inteligentes. Seguidamente, se van a exponer las teorías más representativas sobre el concepto de «inteligencia humana». A continuación, se hará referencia a la aplicación de alguna de ella al concepto de IA.

1.2.1. Teoría Cognitiva de la inteligencia humana

El homo *sapiens* se diferencia del resto de los primates no humanos por su capacidad de pensar y de transmitir el pensamiento a través del lenguaje. Siguiendo a Vygotsky (1962) el lenguaje se puede entender como un vehículo privilegiado de cognición. A lo largo de la historia de la Psicología han existido distintas teorías que han intentado explicar el funcionamiento de la inteligencia humana. En alguna de ellas este constructo se entiende adquirido desde el nacimiento en la carga genética. Por ello, se concibe como un constructo inamovible. No obstante, sobre los años ochenta del siglo pasado distintas corrientes abogaron por la «modificabilidad cognitiva» otorgando a la inteligencia la posibilidad de cambio y de transformación. Entre estas destacan las teorías de Feuerstein (1980), Sternberg (1987; 1990) y las de la Escuela de Ginebra (Doise y Mugny, 1979; Flavell, 1993). La conceptualización de la inteligencia humana con posibilidad de cambio abrió el camino a un aspecto esencial en el estudio del conocimiento humano que es el de la **modificabilidad cognitiva**, este se entiende como una transformación de las habilidades cognitivas a través del entrenamiento. En este entono, distintos autores realizaron propuestas de programas de entrenamiento cognitivo, entre ellos destacan Feuerstein (1980), Bash y Camp (1985), Camp et al., (1985), Meichenbaum (1977), Meichenbaum y Goodman (1969; 1971). Esta forma de entender la inteligencia se apoyaría en la similitud entre la forma de funcionamiento del cerebro humano y el funcionamiento del ordenador, y se denomina **teoría cognitiva del procesamiento de la información**.

Esta tendencia trata de explicar cómo el ser humano procesa información durante la resolución de tareas o de problemas. Esta línea de estudio e investigación ha tenido diversas derivadas y corrientes. Se parte de la idea de que la **mente es computacional** y puede estar mediatizada por las interacciones del sujeto con el medio, tanto con objetos como con iguales (Frawley, 1999).

Específicamente, la **ciencia cognitiva** puede entenderse desde dos corrientes en principio opuestas, la representativa y la conexionista. La primera hace referencia a considerar que la mente se compone de subsistemas, en dominios cognitivos delimitados. De otro lado, la segunda refiere a entender la mente como un sistema de red asociativa de emparejamiento de patrones. Estas son dos arquitecturas diferentes que convergen en «cuatro áreas: *el código interno* (naturaleza y función de la representación mental), *el procesamiento* (estructura de datos y mecanismos de procesamiento), la *arquitectura* (la mente como formato de competencias), y el *hardware* (el sustrato nervioso o *wetware*)» (Frawley, 1999 p. 93).

Asimismo, los procesos de razonamiento pueden dividirse en procesos resolutivos (estos son los aplicados durante la resolución de problemas que implican la utilización del pensamiento hipotético-deductivo) y los procesos ejecutivos implicados en la resolución de tareas o de problemas para su comprensión [estos hacen referencia a los «metacomponentes» (Sternberg, 1986)].

En este entorno la psicología cognitiva se centraría en el ámbito del procesamiento de la información. La teoría más tradicional del procesamiento de la información refiere el procesamiento de forma semejante a programas de *software* y modelos más actualizados refieren conceptos más molares de organización relativamente permanentes del conocimiento desde una teoría de esquemas (Riviére, 2003). Sin embargo, no existe una definición consensuada de sujeto cognitivo. Si se atiende al modelo asociacionista clásico, éste se fundamentaría en el modelo de la memoria de asociación de Anderson y Bower (2014) que subyace al modelo de los sistemas de producciones de Newell y Simon (1972). Este modelo parte de la idea de un procesador central multipropósito y una memoria con límites (Memoria a Corto Plazo -MCP-), más una memoria de trabajo (recursos limitados de atención). De otro lado, Fodor (1986) propuso un modelo basado en una arquitectura más funcional del sistema cognitivo dentro de un modelo computacional representacional. Su idea era que la mente se constituye en módulos o dominios. Estos tienen una función diferenciada que es la de analizar las entradas o *inputs* de la información que serían mecanismos inferenciales que presuponen una memoria de registros sensoriales y de registros del lenguaje relacionados con las funciones cognitivas que son accesibles. Estas se explicarían desde la existencia de esquemas que estarían relacionados con la comprensión y que podrían construir representaciones de *output* de profundidad variable como ocurre en los procesos de razonamiento. Siguiendo a Riviére

(2003) «Ciertamente, ni las relaciones de buena vecindad entre la psicología y la inteligencia artificial, ni la fría descripción del sujeto de conocimiento como una especie de gramática genéticamente definida, ni el arrinconamiento de la psicología entre la lógica y la biología, permiten salir de un cierto recinto solipsista al que parece condenada la psicología cognitiva.» Riviére (2003, p. 19).

Atendiendo a lo anterior, parece más probable que exista tanto una parte modular como una parte de asociación respecto de la información nueva en interacción con la información que ya se tiene a nivel cognitivo. En este proceso, entrarían en juego elementos perceptivos, atencionales, de almacenamiento y de interrelación de la información. Asimismo, dentro de este proceso probablemente la **información previa** (conocimientos previos) tendrá un papel relevante respecto del procesamiento de la información nueva. Además, habría que considerar el momento evolutivo del sujeto (sensoriomotor, preoperacional, operacional u operatorio formal). Por ello, hay que tener en cuenta que **la forma de pensar cambia a lo largo del ciclo vital**. En este contexto la tarea de saber cómo funciona la mente humana es ardua, compleja y actualmente no se tiene una única definición ni explicación del proceso (Carretero y Asensio, 2008). Siguiendo a Kitchener (1983) citado por Carretero y Asensio (2008 p. 52-53) se podrían diferenciar tres niveles de procesamiento cognitivo. En un **primer nivel** los sujetos se ocuparían de tareas cognitivas como percibir, ordenar, memorizar, adquirir lenguaje, leer, etc. En un **segundo nivel** aparecerían las estrategias metacognitivas (estas hacen referencia a la reflexión sobre la propia cognición) y en un **tercer nivel** la reflexión incrementaría el análisis sobre los límites de la propia conciencia logrando un pensamiento alternativo.

De igual modo, en el ámbito de la **ciencia cognitiva** existen diversos paradigmas y actualmente la psicología establece una prioridad de unos sobre otros. Por ello, en esta asignatura se va a utilizar un paradigma mixto.

Los estudios sobre **metacognición** tienen dos referentes importantes. De un lado, los trabajos de Flavell (1979). Estos relacionan la metacognición con el **conocimiento declarativo** (conocimiento metacognitivo, «saber qué») y **conocimiento procedimental** (habilidades metacognitivas, «saber cómo»). La metacognición, incluye **habilidades metacognitivas de orientación, planificación, evaluación y elaboración (reflexión)**. De otro lado, los estudios de Brown y DeLoache (1978) relacionarían la **metacognición y autorregulación con el logro de aprendizajes eficaces** (Cerezo et al., 2019; Veenman, 2007; Veenman, 2011a; Veenman, 2015). Estos autores consideran la autorregulación como una parte de la metacognición y lo relacionan directamente con el aprendizaje profundo frente al aprendizaje superficial. Además, en el contexto autorregulatorio Zimmerman (2008) y Zimmerman y Schunk (2008) consideran que la autorregulación depende de **factores socio-emocionales** que condicionan el desarrollo metacognitivo. Estos autores consideran la metacognición como supraordenada

a la metacognición. Por lo que la definición del término de autorregulación tampoco es unánime. Otras investigaciones (Veenman, 2011a,b) indican que la autorregulación se relaciona directamente con el conocimiento procedimental y que éste posee un mecanismo de *feedback* que ayuda al aprendiz en la construcción del conocimiento (Norman y Furnes, 2016). Igualmente, la adquisición del conocimiento implicaría la utilización de distintas estrategias metacognitivas (Van der Stel y Veenman, 2014):

- a) *Estrategias metacognitivas de Orientación*: guía el proceso de resolución y activa los conocimientos previos necesarios.
- b) *Estrategias metacognitivas de Planificación*: permite la secuenciación en pasos del proceso de resolución.
- c) *Estrategias metacognitivas de Evaluación*: evalúa los pasos dados analizando si son efectivos o no para, en su caso, reorientar la planificación.
- d) *Estrategias metacognitivas de Elaboración*: relaciona las conclusiones encontradas con las cuestiones planteadas en el problema o tarea a resolver.

Siguiendo a Sáiz-Manzanares y Valdivieso-León (2020, p. 51) parece existir un consenso en el ámbito de la ciencia cognitiva sobre que las estrategias metacognitivas facilitan el desarrollo de la autorregulación durante el proceso de aprendizaje (Meijer et al., 2006). Los resultados de distintas investigaciones muestran como aquellos estudiantes que son entrenados en la utilización de **estrategias de aprendizaje autorregulado** mejoran significativamente su **rendimiento académico** y experimentan un **mayor compromiso con la realización de tareas** (Broadbent y Poon, 2015). También, estos perfeccionan sus habilidades de planificación, control y regulación de sus actividades académicas (Ventura et al., 2017). Además, las **estrategias metacognitivas son importantes predictores de los resultados de aprendizaje exitosos** (Van der Stel y Veenman, 2014), ya que **explicarían el 40% de la varianza** (Veenman, 2011b). Por ello, la utilización de las estrategias de autorregulación es muy relevante para guiar los procesos de enseñanza dentro de los contextos de aprendizaje que incluyen sistemáticamente, y cada vez con mayor frecuencia, las nuevas tecnologías (Cerezo, et al, 2016; Järvelä et al., 2016). Concretamente, en el entorno universitario la autorregulación del estudiantado de su propio aprendizaje y el uso de las tecnologías puede potenciar la adquisición de aprendizajes mucho más efectivos para el futuro egreso (Gil-Chaves et al., 2016; Sáiz-Manzanares et al., 2019). Desde esta premisa, los entornos virtuales facilitan el entrenamiento de estrategias de autorregulación, lo cual según Díaz et al. (2017) tiene un impacto favorable sobre el aprendizaje autorregulado. Por otro lado, se observa que el uso de entornos virtuales de aprendizaje y evaluación inciden de forma significativa con el desarrollo del aprendizaje autorregulado en el ámbito universitario (Martínez-Sarmiento y Gaeta, 2019).

Otras teorías relacionan el conocimiento metacognitivo con los procesos de autocontrol. En este marco destaca la teoría de Nelson y Narens (1990; 1994). Estos autores diferenciaron entre el *Object-Level* y el *Meta-Level*. En el primer nivel se ejecutan los procesos cognitivos de nivel más bajo (procesos de memoria, de lectura y de resolución de problemas). Respecto del *Meta-Level*, este refiere a los procesos cognitivos (comparación, razonamiento e inferencias). Estos procesos implican estrategias de planificación y de evaluación que permiten el análisis sobre el *Object-Level*. En la fase cognitiva se hace referencia al conocimiento declarativo de condición y de acción que permite una descripción verbal de la estrategia respondiendo a las cuestiones: qué hacer (*What to do*), cuándo, porqué y cómo (*When, Why y How*) (Veenman et al., 2006 p. 9). Asimismo, el conocimiento metacognitivo, y en particular conocimiento condicional, incluye la regla *if-then*. En las fases iniciales de la resolución de problemas las estrategias metacognitivas precisan desarrollarse paso a paso con el fin de reducir los errores. Posteriormente, en las fases subsiguientes del proceso de resolución, el conocimiento procedimental (procedural) tendrá que ser graduado para mejorar la fluidez y permitir una detección temprana de los errores y la corrección autónoma de los mismos (Veenman, 2015). El esquema de Nelson y Narens (1990), se puede consultar en el Figura 1.

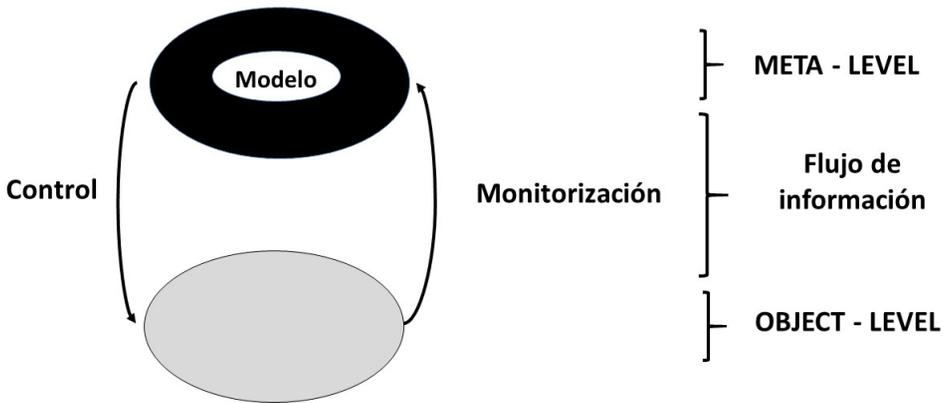


Figura 1. Modelo de Nelson y Narens (1990) (imagen elaboración propia desde el modelo de Nelson y Narens).

En la Tabla 1 se presenta una relación entre las estrategias metacognitivas y su uso durante el proceso de aprendizaje.

Tabla 1. Relación entre los conceptos de conocimiento de la cognición, regulación de la cognición y conocimiento metacognitivo (adaptación de Sáiz-Manzanares, 2019 p. 16).

Estrategias	Antes del aprendizaje	Durante el aprendizaje	Después del aprendizaje
Orientación	<p>Activar los conocimientos previos.</p> <p>Identificar los problemas.</p> <p>Leer las instrucciones.</p> <p>Definir las metas de aprendizaje.</p> <p>Realizar predicciones del posible proceso de resolución.</p>	<p>Relacionar lo nuevo con la información previa sobre la temática.</p> <p>Apoyarse en mapas conceptuales y diagramas de flujo para organizar las ideas.</p>	
Planificación	<p>Realizar un plan de resolución.</p> <p>Realizar auto-preguntas.</p> <p>Elegir estrategias adecuadas en cada uno de los pasos del plan de acción basadas en pensamiento condicional («si entonces»).</p> <p>Efectuar una evaluación final del plan.</p>	<p>Reevaluar los planes.</p>	
Evaluación y auto-supervisión	<p>Detectar errores</p> <p>Auto-corrección</p> <p>Verificar alternativas</p>	<p>Organizar la información.</p> <p>Hacer inferencias.</p> <p>Utilizar protocolos de <i>think aloud</i> y reflexionar sobre su contenido.</p> <p>Construir un <i>metalevel</i> en la propia estructuración mental.</p> <p>Revisar la comprensión.</p> <p>Evaluar el logro de las metas de aprendizaje.</p> <p>Buscar ayuda en aspectos en los que se tienen dudas.</p> <p>Cambiar estrategias.</p> <p>Reevaluar el trabajo.</p>	<p>Comparar los resultados de aprendizaje con la planificación previa y con las evidencias del desarrollo del aprendizaje.</p> <p>Comparación entre los objetivos y los resultados de aprendizaje.</p>
Reelaboración y reflexión	<p>Realizar un resumen del proceso de resolución seguido.</p> <p>Sacar conclusiones de lo aprendido y del proceso de aprendizaje efectuado.</p> <p>Detectar los aspectos generales para generalizar lo aprendido y aplicarlo a la resolución de tareas semejantes.</p>		<p>Proceso de reflexión sobre la propia ejecución.</p>

Asimismo, en la Figura 2 se presenta una relación entre la clasificación de las estrategias metacognitivas propuesto por van der Stel y Veenman (2014) y los procesos que se pueden ejecutar durante la resolución de tareas o de problemas.

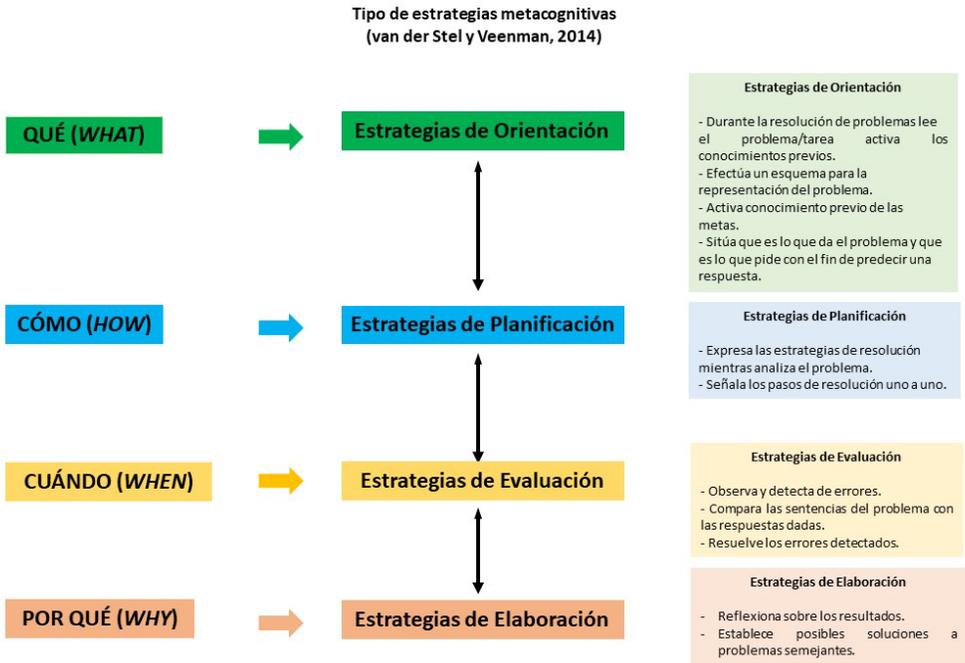


Figura 2. Clasificación de las estrategias Metacognitivas adaptación de van der Stel y Veenman (2014)

En síntesis, se puede concluir que en la resolución de problemas la relación entre el tipo de aprendizaje y la autorregulación (entendida como una parte o componente de la metacognición) es un proceso complejo de interacción entre las variables: tarea, persona y estrategias implicadas en la resolución efectiva de los mismos (Efklides, 2012; Flavell, 1979), un ejemplo de funcionamiento se presenta en la Figura 3. Además, se debe considerar la componente evolutiva del pensamiento, las estrategias de autorregulación no se desarrollan de forma natural en todas las personas. Seguidamente, se presenta un esquema ver Figura 4.

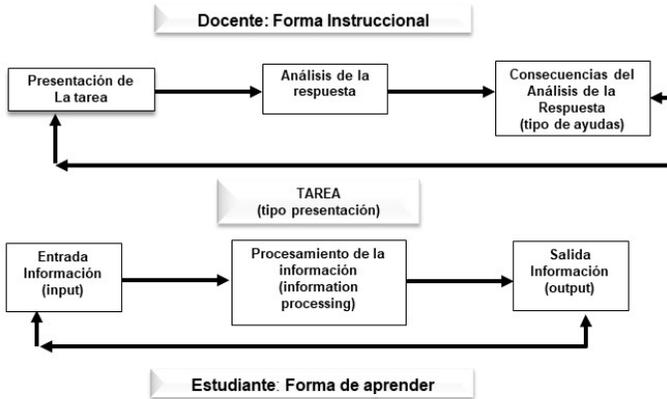


Figura 3. Proceso de enseñanza-aprendizaje (imagen fuente propia).

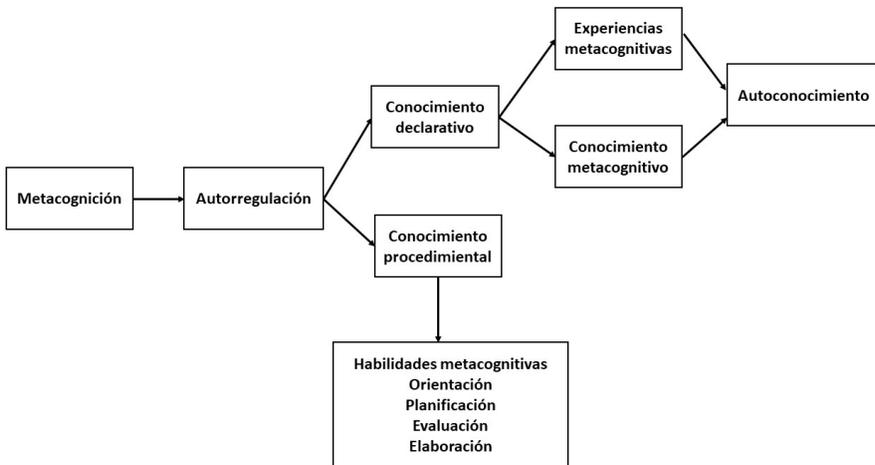


Figura 4. Relación interconceptual en el ámbito metacognitivo (imagen fuente propia).

1.2.2. Metacognición y metaconciencia

La metacognición, esencial para abordar la ejecución de tareas complejas. Esta es la conciencia y la regulación de los propios procesos cognitivos, haciendo hincapié específicamente en las funciones cognitivas autodirigidas (Nelson, 1996; Schraw y Dennison, 1994). La metacognición abarca dos componentes principales: el conocimiento metacognitivo (este refiere a la comprensión de las capacidades cognitivas personales, incluyendo cómo funciona la memoria humana y las estrategias que pueden emplearse para regular los procesos cognitivos). La regulación metacognitiva se refiere a la aplicación real de las estrategias metacognitivas. Según Stephanou y Mpiontini (2017) la regulación metacognitiva es esencial para el éxito académico, ya que permite a los alumnos planificar, supervisar y evaluar de manera competente sus propios procesos de aprendizaje. Asimismo, el modelo propuesto por Nelson y

Narens (1994) esclarece los ciclos de monitorización y regulación metacognitiva durante el aprendizaje. Como ya se ha comentado, este modelo comprende dos niveles jerárquicos: un metanivel y un nivel de objeto. Los procesos del nivel de objeto son supervisados por los del metanivel, y la supervisión metacognitiva implica la transmisión de información del nivel de objeto al metanivel. En el metanivel, la información se evalúa y, posteriormente, se procesa basándose en esta evaluación en el nivel de objeto. El control metacognitivo se refiere a la regulación del procesamiento de la información, que abarca la activación y utilización de estrategias de recuperación (Efklides, 2008; Shimamura, 2000). Asimismo, la metaconciencia sería un componente de la metacognición. Esta, se puede definir como la capacidad de reflexionar sobre el conocimiento y manipularlo, tratando el conocimiento como objeto de pensamiento en lugar de limitarse a repetir lo que se ha aprendido (Woll, 2019). Alcanzar la metaconciencia permite al estudiantado: describir, aplicar e integrar los conocimientos adquiridos con nueva información en diversos contextos. Bourdeaud'hui et al. (2021) investigaron la relación entre la metaconciencia, la motivación para la adquisición de destrezas. Las conclusiones de sus estudios indicaron que la metaconciencia mediaba la relación entre el compromiso del alumnado y las destrezas adquiridas. Otros estudios (Robillos y Bustos, 2022) sugirieron que la utilización de la metaconciencia puede mejorar significativamente las estrategias metacognitivas de aprendizaje.

Además, los procesos cognitivos tienen que considerar la carga cognitiva relevante o germana para desarrollar la metaconciencia de los contenidos de aprendizaje. La monitorización y regulación del esfuerzo (de Bruin et al., 2023) postula que la carga cognitiva impuesta por una tarea de aprendizaje puede servir como señal para regulación del proceso de aprendizaje (de Bruin et al., 2023). Invertir en el aprendizaje es una decisión consciente, a menudo basada en la autoconciencia del aprendiz. Por ello, la inversión de recursos respecto de la carga cognitiva germana en el aprendizaje es una decisión consciente, a menudo basada en la autoconciencia del aprendiz y en la supervisión de su propio proceso de aprendizaje.

Si bien, los procesos de supervisión pueden ayudar al estudiantado a evaluar con precisión el número de recursos germánicos necesarios para completar la tarea. Aunque las tareas complejas pueden resolverse sin utilizar recursos germánicos, es importante aplicar la metaconciencia para evitar la sobrecarga cognitiva cuando el estudiantado se enfrenta a la resolución de tareas complejas. Por consiguiente, las tareas complejas deben potenciar la metaconciencia, especialmente en el caso de aprendices con un alto nivel de metacognición.

1.3. Ejemplo de análisis cognitivo de tareas

En los siguientes artículos se puede consultar la aplicación de un análisis metacognitivo respecto de la resolución de distintas tareas.

- Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Rodríguez-Díez, J.J., Rodríguez-Arribas, S., Díez-Pastor, J.F. (2021). Improve teaching with modalities and collaborative groups in an LMS: an analysis of monitoring using visualisation techniques. *Journal of Computing in Higher Education*, 33, 747-778. <https://doi.org/10.1007/s12528-021-09289-9>
- Sáiz-Manzanares, M.C., Marticorena, R., Rodríguez-Arribas, S., ...Mercado, E. (2021). Teaching and learning styles in Moodle: an analysis of effectiveness of use in STEM and Non-STEM qualifications from a gender perspective. *Sustainability*, 13(3), 1166. <https://doi.org/10.3390/su13031166>
- Sáiz-Manzanares, M.C., Queiruga-Dios, M.Á., García-Osorio, C.I., Montero, E., y 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>

1.4. Teoría de la carga cognitiva

La arquitectura cognitiva humana según la **teoría de la carga cognitiva (Cognitive Load Theory o CLT)** hace referencia a que la capacidad de procesamiento de la memoria de trabajo es limitada cuando se trata de información nueva, mientras que no hay límites conocidos cuando se trata de información familiar almacenada, ya en la memoria a largo plazo (MLP) (Baddeley, 2000). Para mitigar la sobrecarga cognitiva, la CLT aboga por el aumento gradual en la complejidad conceptual y procedimental de las tareas, especialmente en el estudiantado novel (Chen et al., 2018; van Gog y Sweller, 2015). Si bien, la simplificación excesiva de los materiales de aprendizaje puede influir en el potencial cognitivo del alumnado (Chen y Kalyuga, 2020; Hartmann et al., 2020). Concretamente, las tareas que suponen un reto pueden incrementar el compromiso de los estudiantes (van Gog y Sweller, 2015), siempre que el alumnado perciba dicho reto como asumible. En esta línea, la participación del estudiantado en actividades metacognitivas puede facilitar la construcción de esquemas en la memoria de trabajo y mejorar la metaconciencia (Marulis y Nelson, 2021).

Concretamente, la psicología de la instrucción distingue entre conocimiento biológicamente primario y conocimiento biológicamente secundario. El primero se adquiere de forma inconsciente y con un esfuerzo mental mínimo, mientras que el segundo implica la necesidad de una instrucción directa sobre las tareas de resolución de problemas (la búsqueda de la información, la toma de decisiones, el razonamiento relacional, la abstracción, el razonamiento relacional etc.). Estos procesos, dependen de la integración deliberada y el mantenimiento de la información en la memoria de trabajo (Sweller, 2023). Esta teoría ofrece directrices para diseñar tareas de aprendizaje basadas en la arquitectura cognitiva humana, que incluye tanto la memoria de trabajo como la MLP. La memoria de trabajo tiene una capacidad y una duración que son limitadas en el procesamiento de información nueva. Sin embar-

go, estas limitaciones desaparecen una vez que la información se transfiere a MLP (Sweller et al., 2019). Asimismo, la información almacenada en la MLP puede recuperarse sin que ello repercuta negativamente sobre la capacidad de procesamiento de la memoria de trabajo (Ericsson y Kintsch, 1995).

En el aprendizaje, este fenómeno se ejemplifica con el efecto de inversión de la experiencia en el que los métodos de enseñanza eficaces para los aprendices novatos pueden resultar innecesarios o incluso demasiado simplistas para los aprendices expertos (Kalyuga, 2012). Dentro del procesamiento de la información el principal objetivo del diseño didáctico es facilitar la adquisición de conceptual (Sweller et al., 2019). En este ámbito, una estrategia que puede ayudar al aprendiz es la adquisición de formación previa. Dicha adquisición, antes de comenzar la tarea de aprendizaje principal puede reducir las demandas cognitivas durante el aprendizaje y permitir al aprendiz asignar eficazmente recursos de memoria a la nueva información (Mayer, 2010).

La CLT define pues tres tipos de carga cognitiva (Sweller, 2010): intrínseca, extrínseca y germana. La **carga cognitiva intrínseca** (CCI) se refiere a la carga cognitiva fundamental impuesta por la complejidad del material aprendizaje, determinada por el número de elementos que interactúan y el aprendiz. Una mayor pericia suele correlacionarse con una menor complejidad percibida de la tarea (Chen et al., 2023). Por el contrario la **carga cognitiva extrínseca** (CCE) depende de la forma de presentar la información. De otro lado, la **carga cognitiva germana** es la directamente responsable de contribuir al aprendizaje. Esta consiste en la utilización de recursos para construir y automatizar esquemas en la MLP. Se constituye a partir de procesos cognitivos de simbolización o de representación. Este tipo de carga está relacionado con los procesos cognitivos y psicomotores, y su percepción se ve influida por la forma de presentación de la información y el tipo de actividades (Artino, 2008). En síntesis, la carga cognitiva germana refiere al proceso de construcción de esquemas y la comprensión profunda del material. En concreto, la CCE puede reducirse al mínimo mediante el perfeccionamiento de las estrategias de instrucción. La CLT postula que la CCI y CCE tienen efectos acumulativos en la carga cognitiva. A diferencia la CCI representa un esfuerzo cognitivo productivo dirigido a procesar las características intrínsecas de una tarea de aprendizaje, cuando el aprendiz asigna recursos cognitivos que son beneficiosos para el aprendizaje (Klepsch y Seufert, 2020).

La CLT parte de la base de que para facilitar la adquisición de conocimientos, los materiales de aprendizaje deben adecuarse a las capacidades del aprendiz. Por lo tanto, se sugiere aumentar gradualmente la complejidad de las tareas de aprendizaje (p. ej., ejemplos trabajados) reduce la CCE y, por tanto, mejora el rendimiento en comparación con en tareas de resolución de problemas con una alta complejidad constante (Likourezos y Kalyuga, 2017). La instrucción directa ayuda al alumnado a desarrollar estrategias de resolución de problemas y minimiza el riesgo de almacenar

soluciones incorrectas en la memoria de trabajo (Park, 2020). Además, las investigaciones de van Gog y Sweller (2015) indican que a diferencia de las tareas con complejidad elevada de forma constante las tareas con una complejidad baja o que aumenta gradualmente pueden mejorar el rendimiento. Estos estudios sugieren que alumnado con conocimientos previos limitados generan submetas y planes de acción para superar los obstáculos. Esto puede aumentar la CCE y reducir los recursos de memoria de trabajo disponibles para lograr un aprendizaje eficaz. Por lo tanto, se recomienda que la complejidad de la tarea sea baja o aumente gradualmente para facilitar en el aprendiz el procesamiento y la retención de nueva información en la memoria de trabajo (Sweller, 2010).

1.5. Método NASA TLX

Seguidamente, se va a presentar la prueba para la evaluación de la carga cognitiva denominada NASA TLX (Hart y Staveland 1988). Según la información facilitada por el Ministerio de Trabajo y Asuntos Sociales del Gobierno de España, los sistemas complejos modernos exigen elevadas demandas de la persona incrementadas por el uso de las nuevas tecnologías. Por ello, ciertos desempeños pueden exigir un **estado de atención** (capacidad de «estar alerta») y de **concentración** (capacidad de estar pendiente de una actividad o un conjunto de ellas durante un periodo de tiempo) cuando se realiza conscientemente y con cierta continuidad, da lugar a un incremento de la carga mental. La propia **tarea puede exigir una atención y concentración elevadas en función de la cantidad de señales a las que el sujeto tiene que atender**; las inferencias que debe realizar; el nivel de precisión de la respuesta, etc. A estos factores de la tarea hay que añadir los **aspectos organizativos**, especialmente los que se refieren a la organización del tiempo de trabajo (ritmos, pausas, etc.). Bajo este punto de vista se puede definir la **carga mental como la cantidad de esfuerzo deliberado que se debe realizar para lograr resolver una tarea**. Por ello, se considera interesante disponer de un **método estandarizado para el diagnóstico de la carga** con el fin de poder realizar una valoración lo más exacta posible. El método *NASA Tact Load Index* es uno de los más utilizados. Este es un **procedimiento de valoración multidimensional** que da una **puntuación global de carga de trabajo**, basada en una **media ponderada de las puntuaciones en seis subescalas**, cuyo contenido es el resultado de la investigación dirigida a aislar de forma empírica y a definir los factores que son de relevancia en la experiencia subjetiva de carga de trabajo. **Se parte de la premisa de que la carga cognitiva es una percepción individual que depende de las características del sujeto y de la tarea**. El marco teórico de NASA se puede consultar en la Figura 5.

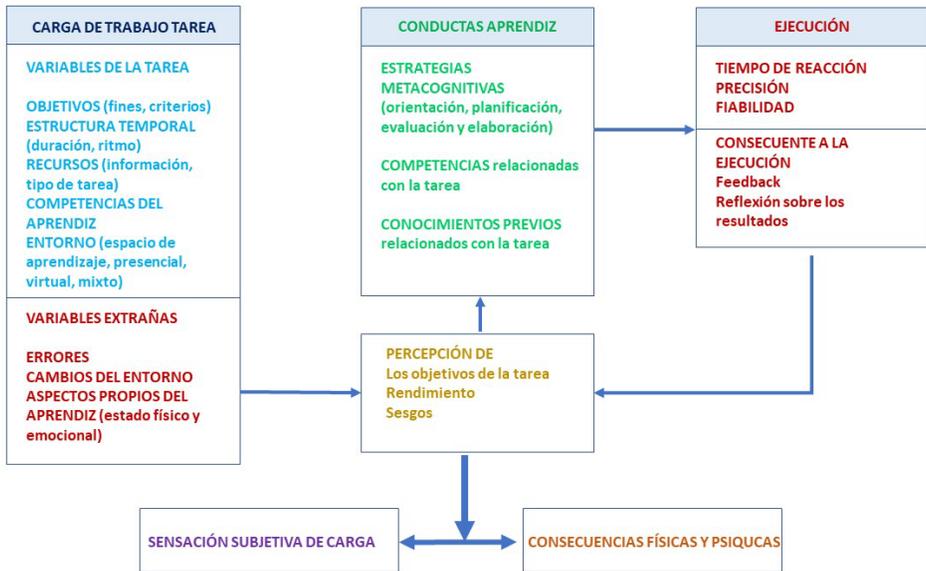


Figura 5. Marco teórico de NASA TLX adaptado a la aplicación en el contexto del proceso de enseñanza-aprendizaje.

La aplicación del instrumento NASA-TLX se lleva a cabo en dos fases: una **fase de ponderación**, en el momento anterior a la ejecución de la tarea y otra **fase de puntuación** que se realiza inmediatamente después de la ejecución de la tarea.

Se parte de la premisa de que la carga de la tarea se relaciona con la sensación subjetiva de carga. Por ello, el requisito previo es que los aprendices hagan una ponderación sobre cada uno de los seis factores respecto de su percepción de la carga cognitiva. El objetivo de esta fase es, pues, la definición de las fuentes de carga (Hanckok y Meshkati, 1988) (ver Tabla 2).

Tabla 2. Factores de carga cognitiva.

Dimensión	Extremos	Descripción	Operativización
1. Exigencia mental de la tarea (M)	Baja/Alta	Cantidad de actividad mental y perceptiva que requiere la tarea	¿Cuánta actividad mental y perceptiva fue necesaria? (pensar, decidir, calcular, etc.). ¿Es una tarea difícil o fácil, simple o compleja, pesada o ligera?
2. Exigencia física (F)	Baja/Alta	Cantidad de actividad física que requiere la tarea	¿Cuánta actividad física fue necesaria? ¿Se trata de una tarea difícil o fácil, lenta o rápida, relajada o cansada?
3. Exigencia temporal (T)	Baja/Alta	Nivel de presión temporal percibida	¿Cuánta presión de tiempo sintió debido al ritmo al cual se sucedían las tareas o elementos de las tareas? ¿Era el ritmo lento y pausado, o rápido y frenético?

Dimensión	Extremos	Descripción	Operativización
4. Rendimiento (R)	Bajo/Alto	Grado de satisfacción con el propio nivel de rendimiento	¿Hasta qué punto cree que ha tenido éxito en los objetivos establecidos por el investigador (o por Ud. mismo)? ¿Cuál es su grado de satisfacción con el nivel de ejecución?
5. Esfuerzo (E)	Buena/Mala	Grado de esfuerzo mental y físico que debe realizar para obtener su nivel de rendimiento	¿En qué medida ha tenido que trabajar (física o mentalmente) para alcanzar su nivel de resultados?
6. Nivel de frustración (Fr)	Bajo/Alto	Grado de inseguridad, estrés, irritación, descontento, etc., sentido durante la realización de la tarea	Durante la tarea, ¿en qué medida se ha sentido inseguro, desalentado, irritado, tenso o preocupado o por el contrario, se ha sentido seguro, contento, relajado y satisfecho?

Asimismo, se les pide a los aprendices que marquen en la plantilla siguiente el aspecto del par que más contribuye a la carga de la tarea (ver Tabla 3).

Tabla 3. Plantilla de carga cognitiva.

M-F	F-T	T-E
M-T	F-R	T-Fr
M-R	F-E	R-E
M-E	F-Fr	R-Fr
M-Fr	T-R	E-Fr

Seguidamente, se le pide al aprendiz que marque en el continuo el punto en el que situaría su percepción de la carga cognitiva sobre la tarea.

Tabla 4. Análisis de percepción del continuo de carga cognitiva en distintas dimensiones.

<p>Exigencia mental ¿Qué exigencia cognitiva demanda la ejecución de la tarea?</p> <p>Baja Alta</p> <input type="text"/>	<p>Exigencia física ¿Qué exigencia física demanda la ejecución de la tarea?</p> <p>Baja Alta</p> <input type="text"/>
<p>Exigencia temporal ¿Qué exigencia sobre el ritmo para la resolución marca la ejecución de la tarea?</p> <p>Baja Alta</p> <input type="text"/>	<p>Rendimiento ¿Cómo de exitoso ha sido el rendimiento?</p> <p>Bajo Alto</p> <input type="text"/>
<p>Esfuerzo ¿Cómo ha sido el grado de trabajo para alcanzar un rendimiento positivo?</p> <p>Bajo Alto</p> <input type="text"/>	<p>Nivel de frustración ¿Qué grado de estrés ha exigido la ejecución de la tarea?</p> <p>Bajo Alto</p> <input type="text"/>

Estos pesos pueden tomar **valores entre 0** (para la dimensión que no ha sido elegida en ninguna ocasión y por tanto no se considera relevante) y **5** (para la dimensión que siempre ha sido elegida y por tanto se considera que es la fuente de carga más importante). El mismo conjunto de pesos puede utilizarse para variaciones de una misma tarea o para un grupo de subtareas. Además, los pesos dan información diagnóstica acerca de la naturaleza de la carga de trabajo impuesta por la tarea ya que proporcionan datos acerca dos fuentes de variabilidad interpersonal:

- a) Las diferencias interpersonales en la definición de carga de trabajo, en cada tarea considerada.
- b) Las diferencias en las fuentes de carga de trabajo entre distintas tareas. El segundo requisito es adjudicar un valor para cada factor, que representa la magnitud de cada factor en una tarea determinada.

En esta fase de puntuación, las personas valoran la tarea o subtarea que acaban de realizar en cada una de las dimensiones, marcando un punto en la escala que se les presenta (ver Tabla 5). Cada factor se presenta en una línea dividida en 20 intervalos iguales (puntuación que es reconvertida a una escala sobre 100) y limitada bipolarmente por unos descriptores (por ejemplo: elevado/bajo, como muestra la Tabla 6) y teniendo presentes las definiciones de las dimensiones.

Tabla 5. *Tabla de Evaluación del Método NASA-TLX.*

VARIABLE	(a) Peso	(b) Puntuación	(c) Puntuación convertida (b x 5)	(d) Puntuación ponderada (c x a)
Exigencia mental				
Exigencia física				
Exigencia temporal				
Rendimiento				
Esfuerzo				
Frustración				
Total	15			

Tabla 6. *Tabla de puntuaciones.*

NASA TLX	Nivel de carga cognitiva
500 puntos o más	Bajo
500-1000 puntos	Medio
Más de 1000 puntos	Alto

Tabla 7. Dimensiones de NASA y relación con la percepción de la carga intrínseca y extrínseca.

Variable	Intrínseco	Extrínseco
Exigencias mentales	<ul style="list-style-type: none"> • Identificación de indicadores, señales para la realización de una tarea. • Análisis de relaciones complejas. • Toma de decisiones en contextos de elevado impacto. • Simultaneidad de acciones y tomas de decisiones complejas. • Responsabilidad sobre personas o equipamientos en condiciones de riesgo. • Todas las acciones que no cuentan con alternativas de soporte o sustitución (automatización) 	La tarea puede ser adaptada a las características del aprendiz.
Exigencia física	<ul style="list-style-type: none"> • La realización de la tarea implica elevada carga física y/o condiciones ambientales exigentes. 	
Exigencia temporal	<ul style="list-style-type: none"> • Implica operar con plazos de respuesta breves, no predecibles o trabajar por períodos prolongados, eventualmente sin o con escasas pausas. Tiene escaso control de sus tiempos de descanso y/o de término de su jornada de trabajo. 	
Rendimiento	<ul style="list-style-type: none"> • Elevadas exigencias de rendimiento. 	
Esfuerzo	<ul style="list-style-type: none"> • Requiere poner permanentemente en juego todos sus recursos intelectuales, físicos y emocionales para la realización de la tarea. 	
Nivel de frustración	<ul style="list-style-type: none"> • Los resultados no son los esperados a pesar del esfuerzo aplicado. 	

1.6. Preguntas de autoevaluación Tema 1

1. Siguiendo a Winston (1992) La Inteligencia Artificial se puede definir como el estudio de métodos computacionales que pueden hacer posible:
 - a) Percibir.
 - b) Razonar.
 - c) Actuar.
 - d) Todos ellos**
2. Siguiendo a Mira et al. (1995) el propósito de la Inteligencia Artificial es desarrollar:
 - a) Modelos conceptuales.
 - b) Estrategias de programación.
 - c) Modelos conceptuales y estrategias de programación que reproduzcan las tareas cognitivas con la analogía con los sistemas biológicos humanos.**
 - d) Modelos conceptuales y estrategias de programación que reproduzcan las tareas cognitivas con la analogía con los sistemas computacionales de la máquina.

3. Los modelos *post-hoc* suelen identificar:
 - a) la interpretabilidad.
 - b) la explicabilidad.
 - c) ambas**
 - d) ninguna de ellas (a, b y c)

4. La modificabilidad cognitiva se puede entender como:
 - a) una transformación de las habilidades cognitivas a través de entrenamiento.**
 - b) una modificación sin transformación.
 - c) un cambio sin entrenamiento
 - d) ninguna de ellas

5. Siguiendo la teoría de Fodor (1986)
 - a) la mente se constituye en módulos.
 - b) los módulos analizan las entradas de la información.
 - c) la existencia de esquemas que podrían construir las representaciones de output.
 - d) Todas ellas son ciertas.**

6. Los conocimientos previos tendrían un papel relevante respecto del procesamiento de la información nueva. Dicho procesamiento:
 - a) permanece estático a lo largo de la vida.
 - b) cambia a lo largo del ciclo vital.**
 - c) viene establecido de forma genética.
 - d) ninguna es cierta.

7. Siguiendo a Flavell (1979) La metacognición se relaciona con el:
 - a) conocimiento declarativo.
 - b) conocimiento procedimental.
 - c) con el «saber qué»
 - d) a, b y c son correctas**

8. Siguiendo a Van der Stel y Veenman (1994) las estrategias metacognitivas son:
 - a) Orientación y Planificación.
 - b) evaluación y elaboración.
 - c) Intervención.
 - d) a y b son correctas**

9. El uso de las estrategias metacognitivas son importantes predictores de los resultados de aprendizaje exitosos, en concreto este uso predice:
- a) el 35% de la varianza de los resultados de aprendizaje.
 - b) el 40% de la varianza de los resultados de aprendizaje.**
 - c) el 60% de la varianza de los resultados de aprendizaje.
 - d) el 42% de la varianza de los resultados de aprendizaje.
10. En el modelo de Nelson y Nares (1990; 1994) se diferencia el *Object-Level* y el *Meta-Level*. El primero hace referencia a:
- a) la ejecución de procesos cognitivos de memoria, lectura y de resolución de problemas.**
 - b) a la ejecución de procesos cognitivos de comparación, razonamiento e inferencias.
 - c) a y b son verdaderas.
 - d) a y b son falsas.
11. La teoría de la carga cognitiva (CLT) refiere que:
- a) la capacidad de procesamiento en la memoria de trabajo es ilimitada.
 - b) la capacidad de procesamiento en la memoria de trabajo es limitada.**
 - c) la capacidad de procesamiento es semejante a la MLP.
 - d) la capacidad de procesamiento es semejante a la memoria asociativa.
12. Según Sweller (2010) la CLT define tres tipos de carga cognitiva: intrínseca, extrínseca y germana. Esta última se puede definir como:
- a) la carga cognitiva impuesta por la complejidad del material de aprendizaje y determinada por el número de elementos que interactúan según cada aprendiz.
 - b) la carga que surge de los procesos cognitivos irrelevantes impuestos por un diseño instruccional no ajustado.
 - c) la carga cognitiva responsable de contribuir al aprendizaje desde la utilización de recursos para construir y automatizar esquemas de la MLP.**
 - d) la carga cognitiva responsable de contribuir al aprendizaje desde la utilización de recursos para construir y automatizar esquemas de la MCP.

1.7. Práctica Tema 1

1. Diseñar una tarea de aprendizaje definiendo el tipo (visual, auditiva, etc.), la población a la que va dirigida (niños, adultos, etc.) y etapa evolutiva (sensoriomotora, preoperacional, operaciones concretas u operaciones formales), el tipo de conocimientos previos necesarios para ejecutarla con éxito, las competencias cognitivas y metacognitivas que se debe aplicar para resolverla.

2. Aplicar la tarea de aprendizaje a tres sujetos.
3. Aplicar el método NASA TLX a los tres sujetos y analizar su percepción de carga cognitiva.
4. Estudiar si hay diferencias y en caso afirmativo argumentar una previsión de la causa o posibles causas.

TEMA 2

UTILIZACIÓN DE LOS SISTEMAS INTELIGENTES TIPO BOT APLICADOS A LA PSICOLOGÍA HUMANA

Raúl Marticorena Sánchez

Departamento de Ingeniería Informática
Escuela Politécnica Superior
Universidad de Burgos

María Consuelo Sáiz Manzanares

Departamento de Ciencias de la Salud
Facultad de Ciencias de la Salud
Universidad de Burgos

La utilización de los denominados sistemas conversacionales inteligentes o *bots* se están utilizando en el ámbito de la psicología o de la medicina, en concreto en la intervención terapéutica desde hace décadas. El origen se sitúa en el test de Alan Turing (Copeland, 2003) que fue desarrollado por este autor sobre los años cincuenta del siglo pasado. La idea era que una máquina (computador) simulase a un humano en una conversación. En 1966 Joseph Weizenbaum desarrolla ELIZA para el IBM 7094, este recurso era un *bot* aplicado a la psicoterapia. El software analizaba las palabras claves y elaboraba respuestas en función de las mismas. En 1975 se desarrolló el software PARRY (Colby, 1975), el cual simulaba la conversación de un paciente con una afectación siguiendo el Manual Diagnóstico y Estadístico de los Trastornos Mentales: DSM-5 (2013) en lo que se tildaría de «Espectro de la esquizofrenia y otros trastornos psicóticos».

2.1. Definición de *bot*

Puede definirse como una aplicación de software programada para automatizar tareas y simular el comportamiento humano. El *bot* puede ser de texto, de voz, multimodal y también pueden incluir figuras tipo avatar con el fin de simular mejor la interacción humana. Los modelos más sofisticados de *bot* utilizan redes neuronales o algoritmos de aprendizaje automático utilizando modelos de lenguaje natural. En la aplicación en psicología se pretende que el *bot* simule a un terapeuta en una intervención.

2.2. Estructura de un *bot*

Un *bot* se fundamenta un *software* ejecutado sobre plataformas *hardware* que lo hospedan. Previamente, en este caso el psicólogo debería de diseñar un banco de pregunta-respuesta. El diseño se debería aplicar al objetivo de la intervención. El *bot*, se podría aplicar en web, en dispositivos móviles o en altavoces inteligentes tipo Alexa. Los *bots* pueden estar basados en reglas o basados en inteligencia artificial generativa. Los primeros son más simples, más económicos y utilizan un flujo predefinido. Un ejemplo sería los que podemos elaborar con aplicaciones como DiagFlow. Los segundos, al aplicar recursos de inteligencia artificial generativa,

es decir algoritmos que facilitan el aprendizaje más autónomo de la maquina y también agilizan el tipo y calidad de las respuestas y por ende de las interacciones. Suelen utilizar algoritmos de árboles de decisión que aplican la premisa de la toma de decisión de «si entonces». Un ejemplo son los recursos de IBM WatsonX. Este funciona con lenguaje natural desde un razonamiento probabilístico. IBM WatsonX *Assistant* es una herramienta en la nube y facilita la creación de agentes virtuales personalizados.

El funcionamiento general de un *bot* se resume en «intenciones», «entidades» y «diálogos». Las primeras tienen como objetivo conocer qué es lo que quiere o necesita el usuario. Las segundas intentan recoger los valores o palabras clave que el usuario ha incluido en la conversación. Referente a los diálogos intentan dar respuesta al usuario en función de las «intenciones» y de las «entidades» detectas.

Un ejemplo de diálogo de flujo con Chatfuel que aplica reglas de decisión se puede consultar en la Figura 6.

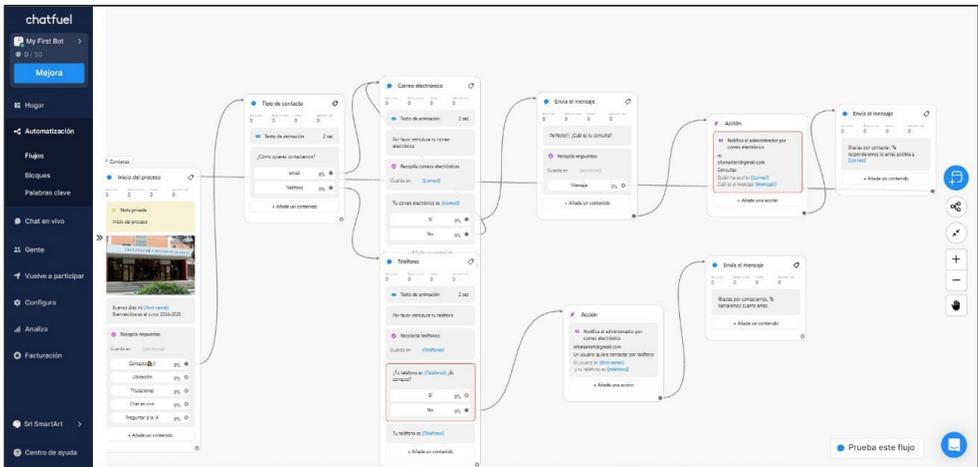


Figura 6. Ejemplo de diálogo de flujo con Chatfuel.

Un ejemplo de diálogo de flujo con IBM WatsonX que aplica inteligencia artificial se puede consultar en la Figura 7.

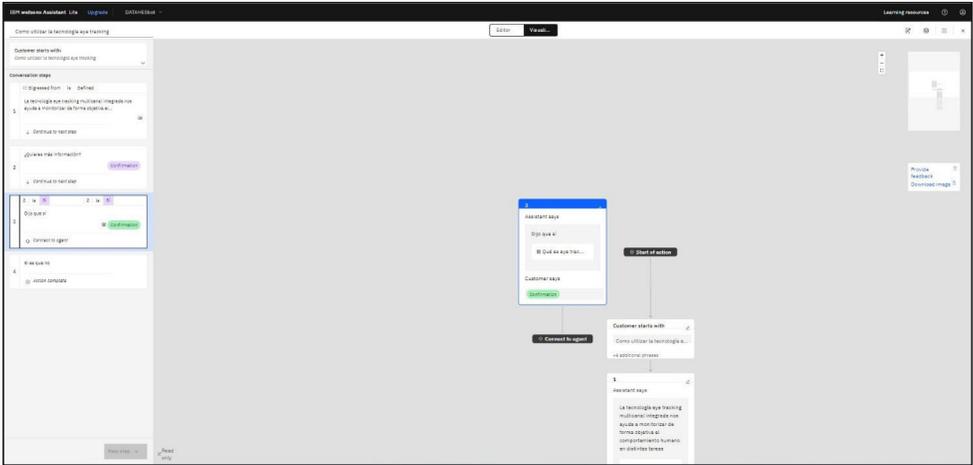


Figura 7. Ejemplo de diálogo de flujo con IBM WatsonX.

Seguidamente, se presentan ejemplos de interfaz en dispositivos móviles de diálogos en aplicaciones tipo *bot* con asistentes con imagen (ver Figura 8).

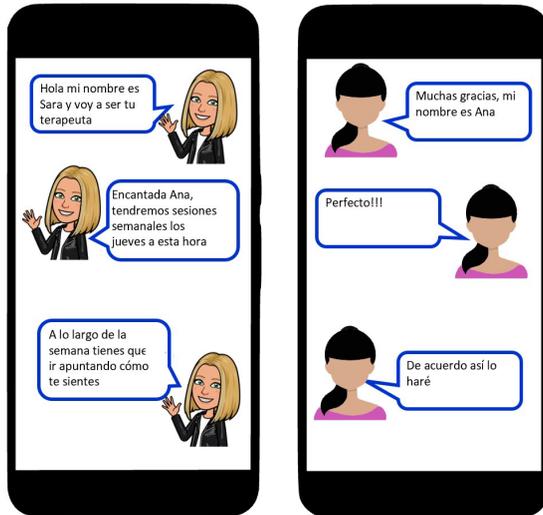


Figura 8. Ejemplos de diálogos en aplicaciones tipo *bot* con asistentes con imagen.

Además, hay que considerar que si se elaboran estos recursos hay que evaluar su funcionalidad y usabilidad. Un ejemplo es el *The Chatbot Usability Questionnaire* (CUQ) de Holmes et al. (2019).

Seguidamente, se presentan varios artículos de investigación que han utilizado aplicaciones tipo *bot* en terapia en psicología:

- Dharrao, D., y Gite, S. (2024). TherapyBot: a chatbot for mental well-being using transformers. *International Journal of Advances in Applied Sciences (IJAAS)*, 13(1), 1-12. <https://doi.org/10.11591/ijaas.v13.i1.pp1-12>
- Jayasuriya, A., Gunarathne, Y., Karawita, S., Abeywickrama, T., y Weerathunga, I. (2023). AI-Based Psychology Experts Centralized Support Platform for Post-Traumatic Stress Disorder, 2023 5th International Conference on Advancements in Computing (ICAC), Colombo, Sri Lanka, 2023, pp. 561-566, <https://doi.org/10.1109/ICAC60630.2023.10417685>
- Oliveira, A.L.S., Matos, L.N., Junior, M.C., Delabrida, Z.N.C. (2021). An Initial Assessment of a Chatbot for Rumination-Focused Cognitive Behavioral Therapy (RFCBT) in College Students. In: Gervasi, O., et al. Computational Science and Its Applications – ICCSA 2021. ICCSA 2021. Lecture Notes in Computer Science(), vol 12954. Springer, Cham. https://doi.org/10.1007/978-3-030-86979-3_39
- Tucker, I. (2024). Digitally mediated psychotherapy: Intimacy, distance, and connection in virtual therapeutic spaces. *European Journal of Psychotherapy & Counselling*, 26 (1–2), 168–179. <https://doi.org/10.1080/13642537.2024.2313193>

Para una ampliación de este capítulo se puede consultar en:

- MÓDULO VII.2 Marticorena Sánchez, R. (2024). Intervención temprana y aplicación de recursos inteligentes: *Intelligent Personal Assistants*. En M.C. Sáiz-Manzanares, M.C. y M. Santamaría Vázquez (Eds.), *Formación y Especialización en Atención Temprana: uso de Recursos Tecnológicos y de Inteligencia Artificial* (235- 357). Burgos: Servicio de Publicaciones de la Universidad de Burgos. <https://doi.org/10.36443/9788418465802>
- Marticorena Sánchez, R., y Sáiz Manzanares, M.C (2024). *Protocolo para la integración de un chatbot en una plataforma virtual de aprendizaje tipo Moodle*. Repositorio Institucional de la Universidad de Burgos. <http://hdl.handle.net/10259/8926>

2.3. Preguntas de autoevaluación Tema 2

1. ¿Sobre qué se ejecuta un *bot*?

- a) Únicamente sobre navegadores web.
- b) Exclusivamente en dispositivos móviles.
- c) **En plataformas hardware que lo hospedan.**
- d) Solo en servidores en la nube.

2. ¿Qué debe diseñar el psicólogo previamente para que funcione el bot?
- a) Un sistema de inteligencia artificial autónomo.
 - b) Una aplicación móvil compatible.
 - c) Un banco de pregunta-respuesta.**
 - d) Un hardware especializado.
3. ¿Cuál es una característica de los *bots* basados en reglas?
- a) Se adaptan automáticamente al lenguaje natural.
 - b) Utilizan un flujo predefinido.**
 - c) Son más complejos y costosos que los basados en IA.
 - d) Solo funcionan con altavoces inteligentes.
4. ¿Cuál es uno de los objetivos del uso de *bots* en psicología?
- a) Sustituir completamente al terapeuta humano.
 - b) Diagnosticar enfermedades físicas.
 - c) Programar citas médicas automáticamente.
 - d) Simular a un terapeuta en una intervención.**
5. ¿Cuáles son algunos de los formatos que puede tener un *bot*?
- a) Solo de texto y código.
 - b) Texto, voz, multimodal y con figuras tipo avatar.**
 - c) Exclusivamente visuales.
 - d) Únicamente en forma de aplicación móvil.

2.4. Práctica Tema 2

Realizar un diálogo terapeuta-paciente para aplicar en una arquitectura de *bot*, se puede realizar el hilo conversacional real utilizando la arquitectura de *Dialogflow* https://cloud.google.com/products/conversational-agents?hl=es_419 o de *IBM Watson* de forma gratuita <https://www.ibm.com/es-es/watson>. No obstante, también se puede presentar solo el hilo conversacional simulado sin incluirlo en ninguna aplicación.

TEMA 3

**UTILIZACIÓN DE LOS SISTEMAS
INTELIGENTES TIPO *EYE TRACKING*
APLICADOS EN PSICOLOGÍA**

María Consuelo Sáiz Manzanares

Departamento de Ciencias de la Salud
Facultad de Ciencias de la Salud
Universidad de Burgos

En primer lugar, se hará un acercamiento al concepto de tecnología *eye tracking* o seguimiento ocular y a su posible aplicación en la evaluación del procesamiento de la información durante la resolución de alguna tarea realizada por personas (con y sin afectaciones) en distintas edades y con diferentes objetivos de estudio. En concreto, en el ámbito de la psicología los investigadores o las investigadoras utilizan el seguimiento ocular para estudiar el comportamiento humano. Específicamente, la utilización de la tecnología *eye tracking* es especialmente relevante en el contexto de la: psicología cognitiva, neuropsicología, psicología del desarrollo, psicología de las emociones y en la psicología de la salud mental, entre otras especialidades psicológicas. Ejemplos de este uso con la tecnología *eye tracking* se pueden consultar en [enlace](#). En este tema se va a hacer referencia preferiblemente al trabajo con la tecnología Tobii. Las razones, nada tienen que ver con difundir una marca, sino con la versatilidad que esta tecnología tiene respecto de la integración de otros dispositivos de respuesta psicogalvánica de la piel o de electroencefalograma. Por ello, es una tecnología ampliamente extendida en distintas universidades en el ámbito de la psicología cognitiva, psicología del comportamiento, psicología del desarrollo, psicología clínica, psicología de la salud y psicología del lenguaje entre otras como son Harvard University, University of Toronto, Princeton University, The University of Sydney, University of Cambridge, University of Hong Kong, The University of Melbourne, Kyoto University, Stanford University, Universidad de Santiago de Chile, Yale University, Aeronautical University y McGill University, entre otras [enlace](#).

3.1. *Eye tracking* utilizado en Psicología

En este apartado se abordará qué es la tecnología *eye tracking*, qué pasos hay que seguir para iniciar el trabajo, qué métricas registra y su significación en el ámbito de la psicología cognitiva y de la Instrucción, la sincronización de la tecnología *eye tracking* con dispositivos de respuesta psicogalvánica de la piel y de registro encefalográfico, junto con los análisis de los biomarcadores conductuales que aporta la tecnología multicanal integrada.

3.1.1. ¿Qué es la tecnología *eye tracking*?

La tecnología *eye tracking* se fundamenta en el seguimiento ocular y en la medición de los movimientos oculares que se producen cuando un sujeto mira a un objeto, a una imagen, a un texto, a un vídeo, etc. La explicación es básicamente la captación del seguimiento ocular mientras el usuario efectúa una tarea a través de un **patrón de luz infrarroja dirigido hacia los ojos**. La luz infrarroja se refleja en los ojos y las reflexiones oculares se captan por las cámaras del dispositivo de seguimiento ocular. A continuación, desde la aplicación de distintos algoritmos el dispositivo de seguimiento ocular reconoce dónde está mirando el usuario. En la Figura 9, se puede observar el funcionamiento, hay un estímulo en la pantalla del ordenador, el ojo percibe la imagen en una posición de ejes de coordenadas (estas pueden ser en 3D, x, y, z , o en 2D x, y) en posición de ojo derecho y ojo izquierdo. También, se puede registrar el movimiento ocular sin necesidad de que el sujeto mire a una pantalla, puede mirar a una pizarra, a un objeto, a una superficie, etc. (ver Figura 10).

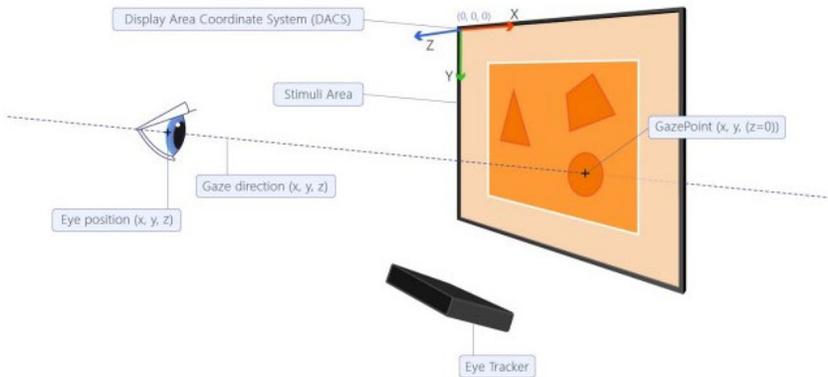


Figura 9. Tomado del Manual Tobii Pro Lab v. 1.194 p. 155.

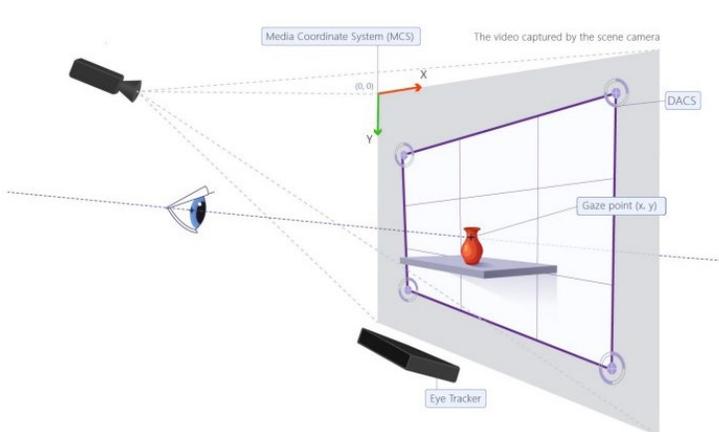


Figura 10. Tomado del Manual Tobii Pro Lab v. 1.194 p. 158.

Esta posibilidad es relevante en el ámbito de la observación específicamente en la valoración de niños o de niñas en edades tempranas o de personas con algún tipo de afectación en el movimiento (parálisis cerebral, Parkinson, etc.). Un ejemplo de esta valoración con la tecnología *spectrum* de Tobii se puede consultar en la Figura 11 y en la Figura 12 (en este caso solo se analizarán las coordenadas en 2D, coordenadas x, y). Estos equipos son muy potentes y tienen una alta capacidad de ajuste de los movimientos de la cabeza. Estos equipos pueden captar datos de movimiento ocular en frecuencias desde 60 Hz hasta 1200 Hz.



Figura 11. Imagen tomada de Tobii información en web [enlace](#)



Figura 12. Imagen tomada de Tobii información en web [enlace](#)

También, la tecnología *eye tracking* se puede utilizar con personas con afectaciones en el movimiento como se ha indicado personas con discapacidad como por ejemplo parálisis cerebral, ELA, Síndrome de Rett o lesión medular. Un ejemplo, es la tecnología que aporta Tobii en *Tobiidynavox* en el dispositivo *TD I-Series* que es un dispositivo de voz liviano, rápido que controla totalmente los ojos, este tiene instalados distintos softwares como *TD Snap* (está basado en pictogramas con herramientas y recursos enfocados a satisfacer las necesidades comunicativas), *Communicator 5*, *TD Control*, *TD Browse*, *TD Talk* y *TD Phone* aporta también una ventana interlocutor que permite conversaciones cara a cara y seguimiento ocular al aire libre que permite utilizar el dispositivo con luz solar. *TD Snap Core First* ofrece un sistema de comunicación con pictogramas y palabras basados en un vocabulario de palabras más frecuentes en cada idioma. Un ejemplo se puede consultar en la Figura 13.



Figura 13. Imagen tomada de Tobii TD Snap [enlace](#)

TD Snap Motor Plan, los comunicadores pueden acceder a palabras en tres selecciones o menos. Viene en tres tamaños de cuadrícula (30, 66 y 40) incluyen vocabulario sólido, cuidadosamente seleccionado para apoyar tanto a aprendices de lenguaje temprano como a comunicadores avanzados. Cada palabra aparece solo una vez con una ruta distintiva, o plan motor, para encontrarla. Con el tiempo, el comunicador localizará las palabras sin esfuerzo, lo que le permitirá al usuario concentrarse más en lo que quiere decir (ver Figura 14).



Figura 14. Tomado de TD Snap Motor Plan [enlace](#)

TD Snap Express es un conjunto de páginas intuitivo diseñado para ser simple y fácil de usar. Este apoya el desarrollo de habilidades de comunicación y lenguaje mediante el uso de frases y palabras para construir mensajes. Con una navegación reducida y un vocabulario fácil de encontrar, cualquier usuario puede aprender a utilizarlo rápidamente, usando páginas temáticas para comunicarse (ver Figura 15).



Figura 15. Imagen tomada de Tobii TD Snap Express [enlace](#)

TD Snap Texto es una opción de CAA dentro de TD Snap. Está diseñado para personas que pueden leer y deletrear sin necesidad de pictogramas o que pueden estar en transición de los pictogramas a la lectoescritura. Las frases están organizadas por temas y los teclados ofrecen predicción de palabras (ver Figura 16). Además, esta opción incluye sistemas inteligentes (ver Figura 17).



Figura 16. Imagen tomada de Tobii TD Snap Express [enlace](#)

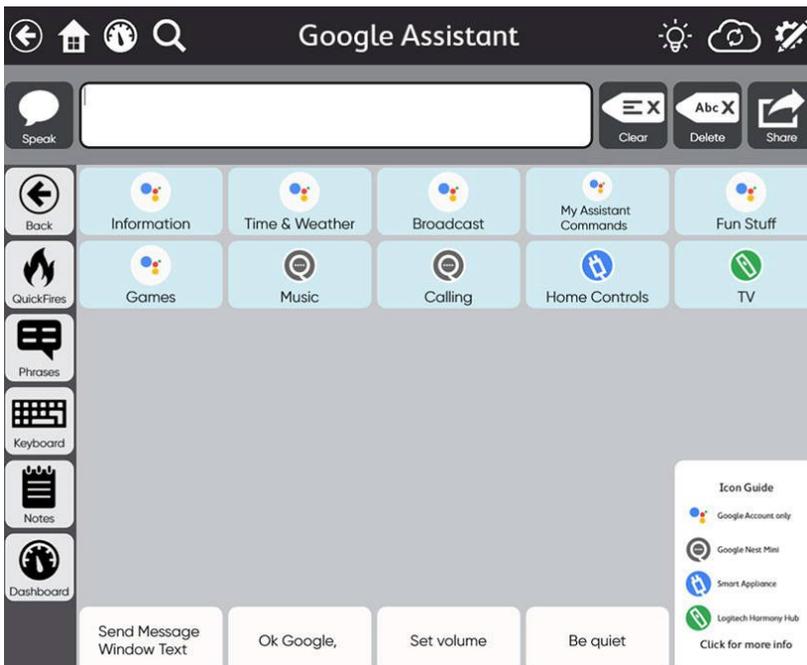


Figura 17. Imagen tomada de Tobii TD Snap Express [enlace](#)

Otra posibilidad es la de utilizar gafas que integran un *software eye tracking* (ver Figura 18). Las gafas pueden registrar información en un sistema de coordenadas 3D. La posición del ojo y los vectores de la mirada se calculan a partir de las imágenes del ojo sobre un modelo 3D. El punto de la mirada se calcula como el punto de vergencia entre los dos vectores de la mirada.

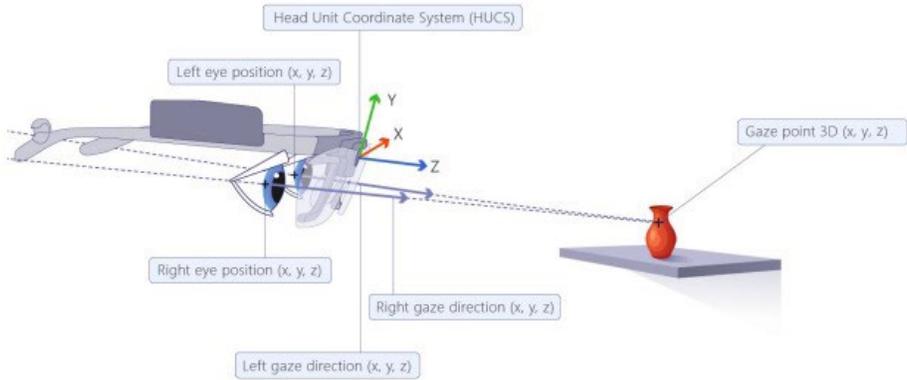


Figura 18. Tomado del Manual Tobii Pro Lab v. 1.194 p. 159.

3.1.1.1. Pasos para iniciar el trabajo con la utilización de la tecnología *eye tracking*

El primer paso será la definición de las preguntas o hipótesis de investigación. En segundo lugar, la calibración del posicionamiento de la mirada del usuario (ver Figura 19). Este era un proceso complejo en momentos anteriores. Si bien, en la actualidad los dispositivos cada vez ofrecen alternativas más precisas de medición sin necesidad que el usuario se encuentre en posiciones demasiado estáticas e incómodas para la realización de la calibración y la posterior ejecución de la tarea.

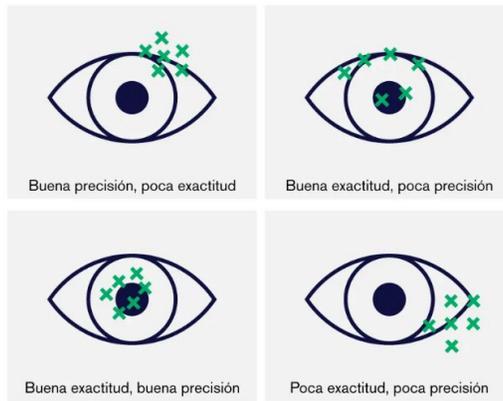


Figura 19. Parámetros para la medición del ajuste en calibración tomado del Tobii dynavox [enlace](#)

Un ejemplo de indicadores de calibración se puede consultar en la Figura 20, como se puede comprobar se establecen indicadores de exactitud (*accuracy*) y de precisión.

Recording	Participant	Timeline	Duration	Date	Resolution	Gaze samples
Recording23	NP_17	Timeline1	00:04:01.825	03/04/2024...	1920 x 1080	91%
 Validation accuracy: 0.52° Validation precision: 0.65°						
Recording22	NP_16	Timeline1	00:04:27.439	03/04/2024...	1920 x 1080	97%
 Validation accuracy: 0.13° Validation precision: 0.29°						
Recording13	NP_07	Timeline1	00:05:23.631	06/03/2024...	1920 x 1080	99%
 Validation accuracy: 0.20° Validation precision: 0.17°						

Figura 20. Indicadores de calibración en un equipo Tobii Pro Lab (fuente propia).

Asimismo, un ejemplo de cómo se traducen estos datos en una visualización de la calibración, se puede comprobar en la Figura 21.

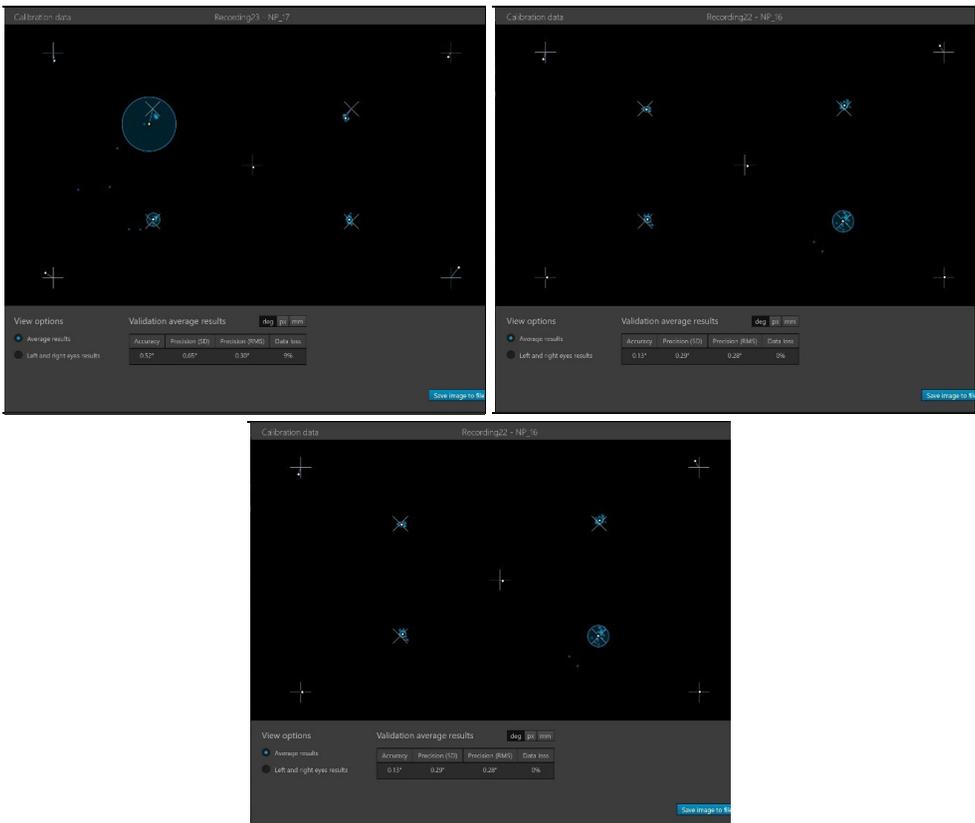


Figura 21. Ejemplos de visualización de los puntos de calibración (fuente propia).

En tercer lugar, se tiene que diseñar la tarea. Es importante definir qué se quiere medir y para qué. Los estímulos utilizados para definir las tareas pueden ser imágenes, documentos, información en web, información en pantalla o bien textos (ver Figura 22)

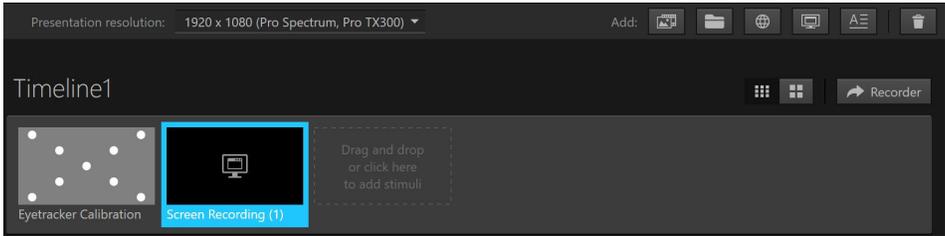


Figura 22. Posibilidades de inclusión de tareas en un dispositivo Tobii Pro Lab v.24.21 (fuente propia).

En cuarto lugar, se deben definir las características de los participantes. En la Figura 23 se presenta un ejemplo. En este estudio se tuvieron en cuenta las siguientes variables: Tipo de titulación (Ingeniería vs. Ciencias de la Salud), Género (femenino vs. masculino) y tipo de visualización, en este caso de una web (con audio vs. sin audio).

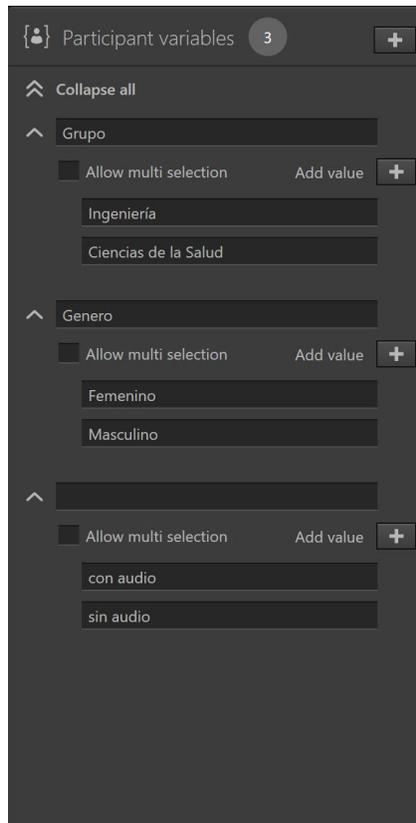


Figura 23. Definición de las variables y de los parámetros en el estudio.

Asimismo, antes de iniciar el estudio se habrá solicitado el consentimiento informado por escrito de los participantes. En este documento se reflejará el objeto del estudio, la autorización previa del Comité de Bioética de la Institución que lo avale y la cláusula de que en cualquier momento, el o la participante podrá dejar de participar en el estudio si es su voluntad. Este es un requisito imprescindible para asegurar el cumplimiento de la legislación sobre protección de datos tanto española como europea.

A continuación, se iniciará la fase experimental propiamente dicha con todos aquellos participantes que han dado su consentimiento. Si bien, en el dispositivo de *eye tracking* nunca se deben introducir datos reales de filiación. Por ello, se debe anonimizar los nombres reales a través de la asignación de códigos. El proceso de anonimización solo lo debe controlar un investigador asignado para ello y esta relación se debe destruir una vez concluya la fase experimental, a fin de preservar la confidencialidad de los participantes (ver Figura 24).

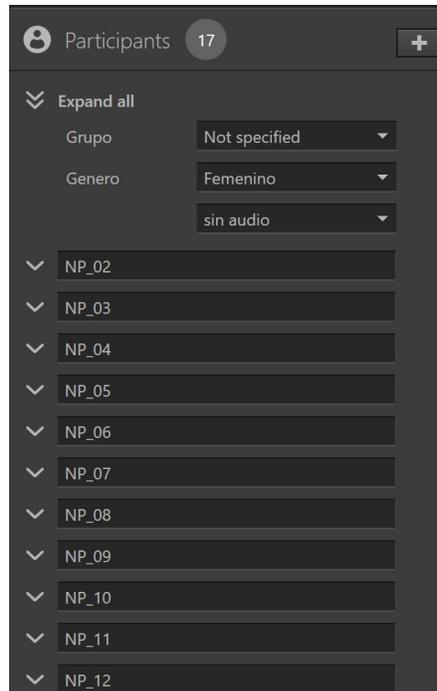


Figura 24. *Proceso de anonimización de los datos de los participantes (fuente propia).*

A continuación, se podría iniciar el desarrollo del experimento con cada participante. Posteriormente, se abordará como se pueden incluir más dispositivos u opciones para obtener más registros de forma integrada o conjunta, como son la imagen de la cara (a través de un software de reconocimiento facial se podrán analizar las expresiones emocionales asociadas a la ejecución la tarea en cada uno de los pasos de realización). También, se puede incluir un dispositivo de registro de respuesta

galvánica de la piel, *galvanic skin response*, (GSR), y de respuesta encefalográfica o, electroencefalograma (EEG), ambas con señal integrada dentro del dispositivo de *eye tracking*. En la Figura 25, se puede comprobar un ejemplo de recogida de datos multicanal integrados de *eye tracker*, facial, voz y GSR. Asimismo, en la Figura 26 se presenta un ejemplo de integración de señales con EEG.

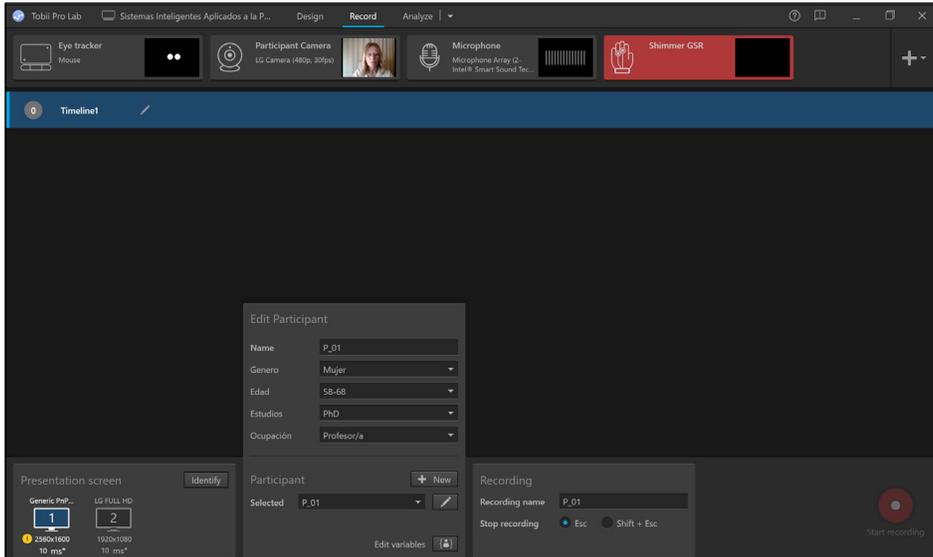


Figura 25. Integración de señales de *eye tracker*, facial, sonido y de GSR (fuente propia).

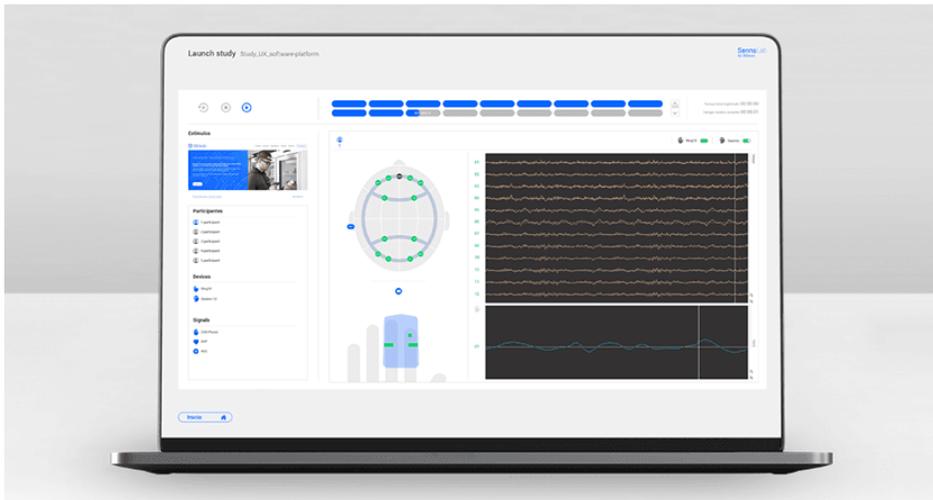


Figura 26. Integración de señales con EEG imagen de acceso abierto tomada de [Bitbrain enlace](#)

Seguidamente, se va a abordar el tipo de métricas que se pueden obtener con la tecnología *eye tracking* multicanal integrada.

3.1.2. Métricas de registro en *eye tracking* y su significado en el procesamiento de la Información.

Las métricas que registra el dispositivo *eye tracking* son diversas. Estas se pueden clasificar en métricas estáticas y dinámicas (Sáiz-Manzanares et al., 2020). Las primeras se relacionan con los parámetros de fijación, sacada y mirada (*glance*). Todas ellas tienen distintas extensiones como son (frecuencia, velocidad, duración media, etc.). Respecto de las segundas, hacen referencia al registro del patrón posicional de seguimiento ocular realizado, dependiendo del tipo de tecnología puede denominarse *scan path*. Los registros que se obtienen en este tipo de dispositivos pueden extraerse en distintos tipos de formatos, y cada uno de ellos aporta unas métricas. A continuación, se van a presentar distintos ejemplos: registros extraídos en un formato *Interval-based Tabulator Separated Valu* (TSV) file (ver Tabla 8); registros extraídos en formato AOI-based TSV file (ver Tabla 9). Esta funcionalidad se basa en la definición previa de las Áreas de Interés (AOI), estas se pueden definir como relevantes vs. no relevantes por el experimentador.

Tabla 8. Métricas posibles extraídas de *eye tracking* Tobii Pro Lab v.24.21 formato *Interval-based TSV file*.

Métrica	Significado	Unidad de medida
General		
Participant variables	Valores de los valores de los participantes	
Timeline name		
Stimulus variables	Valor de los estímulos de cada variable	
Interval metrics		
Duration of interval	La duración de un intervalo	milisegundos
Start of interval	Tiempo en el que empieza un intervalo	milisegundos
Event metrics		
Number of Events	Número de eventos para cada intervalo	frecuencia
Time first Event	Tiempo inicial de cada evento por intervalo	milisegundos
Last key press	El último registro de cada <i>keypress</i> en el intervalo	milisegundos
AOI fixation metrics		
Total duration of fixations	Duración total de cada fijación dentro de una AOI en cada intervalo	milisegundos
Average duration of fixations	Duración media de la fijación dentro de una AOI durante un intervalo	milisegundos
Minimum duration of fixations	La duración de la fijación más corta dentro de un AOI durante un intervalo	milisegundos
Maximum duration of fixations	La duración de la fijación más larga dentro de un AOI durante un intervalo	milisegundos
Number of fixations	Número de fijaciones que ocurren en una AOI durante un intervalo	frecuencia

Métrica	Significado	Unidad de medida
Time to first fixation	El tiempo de la primera fijación dentro de una AOI durante un intervalo	milisegundos
Duration of first fixation	La duración de la primera fijación dentro de una AOI durante un intervalo	milisegundos
Last AOI viewed	La última AOI fijada durante un intervalo	
AOI at Interval end	La fijación en la AOI al final del intervalo	
Average pupil diameter	La media del diámetro de la pupila sin un AOI en un intervalo. Se calcula utilizando el resultado del diámetro de la pupila después de aplicar un filtro de diámetro de la pupila.	milímetros
AOI fixation metrics (exclude partial fixations)		
Total duration of whole fixations	La duración total de fijaciones dentro de una AOI durante un intervalo.	milisegundos
Average duration of whole fixations	La media de duración de las fijaciones dentro de una AOI durante un intervalo	milisegundos
Minimum duration of whole fixations	La duración de la fijación más corta dentro de una AOI durante un intervalo	milisegundos
Maximum duration of whole fixations	La duración de la fijación más larga dentro de una AOI durante un intervalo	milisegundos
Number of whole fixation	Número de fijaciones que ocurren en una AOI durante un intervalo	frecuencia
Time to first whole fixation	El tiempo de la primera fijación dentro de una AOI durante un intervalo	milisegundos
Duration of first whole fixation	La duración de la primera fijación dentro de una AOI durante un intervalo	milisegundos
Average whole-fixation pupil diameter	La media del diámetro de la pupila de toda la fijación en una muestra AOI en un intervalo. Calculada utilizando el resultado del diámetro de la pupila después de aplicar un filtro de diámetro de la pupila.	milímetros
AOI Visit metrics		
Total duration Visit	Total duración de las Visitas dentro de una AOI durante un intervalo	milisegundos
Average duration of Visit	La media de duración de las visitas dentro de una AOI durante un intervalo	milisegundos
Minimum duration of Visit	La duración de la visita más corta dentro de una AOI durante un intervalo	milisegundos
Maximum duration Visit	La duración de la visita más larga dentro de una AOI durante un intervalo	milisegundos
Number of Visits	Número de visitas	frecuencia
Time to first Visit	Tiempo de la primera visita	milisegundos
Duration of first Visit	Duración de la primera visita	milisegundos

Métrica	Significado	Unidad de medida
AOI Glance metrics	AOI métricas mirada	
Total duration of Glances	Duración total de las miradas	milisegundos
Average duration of Glances	Media de duración de las miradas	milisegundos
Minimum duration of Glances	La duración más corta de la mirada dentro de una AOI durante un intervalo	milisegundos
Maximum duration of Glances	La duración más larga de la mirada dentro de una AOI durante un intervalo	milisegundos
Number of Glances	Número de miradas	frecuencia
Time to first Glance	Hora de la primera mirada	milisegundos
Duration of first Glance	Duración de la primera mirada	milisegundos
AOI Click metrics		
Number of mouse clicks	Número de veces que se pulsa el botón izquierdo del ratón en una AOI durante un intervalo.	frecuencia
Time of first mouse click	El tiempo transcurrido hasta que se pulsa por primera vez el botón izquierdo del ratón dentro de una AOI durante un intervalo.	milisegundos
Time from first fixation to mouse click	El tiempo transcurrido desde la primera fijación hasta la primera vez que se pulsa el botón izquierdo del ratón dentro de una AOI durante un intervalo.	milisegundos
Number of mouse clicks & releases	Número de veces que se pulsa y suelta el botón izquierdo del ratón en la misma AOI durante un intervalo.	frecuencia
Time to first mouse click & release	El tiempo transcurrido hasta que se pulsa por primera vez el botón izquierdo del ratón dentro de una AOI durante un intervalo. Esta métrica requiere que también se suelte el botón del ratón dentro de la misma AOI.	milisegundos
Time from first fixations to mouse click & release	El tiempo transcurrido desde la primera fijación hasta la primera vez que se pulsa el botón izquierdo del ratón dentro de una AOI durante un intervalo. Esta métrica requiere que el botón del ratón también se suelte dentro de la misma AOI.	milisegundos
GSR metrics		
Average GSR	La media de la señal galvanic skin response (GSR) después de filtrarse en un intervalo.	microsiemens
Number of SCR	El número de skin conductance response (SCRs) para cada intervalo.	frecuencia
Amplitude of event related SCR	La amplitud de cada evento-related skin conductance response (ER-SCR) en cada intervalo. ER-SCRs se calcula usando los datos filtrados de GSR.	microsiemens

Métrica	Significado	Unidad de medida
Fixation metrics (exclude partial fixations)		
Total duration of whole fixations	Duración total de las fijaciones durante un intervalo.	milisegundos
Average duration of whole fixations	Duración media de las fijaciones durante un intervalo.	milisegundos
Number of whole fixations	Número total de fijaciones durante un intervalo.	frecuencia
Duration of first whole fixation	La duración de la primera fijación durante un intervalo.	milisegundos
Average whole-fixation pupil diameter	La media del diámetro de la pupila de la totalidad de más muestras de la fijación en un intervalo. Calculada usando el resultado del diámetro de la pupila aplicando filtro del diámetro de la pupila.	milímetros
Saccade metrics		
Number of saccades	Número de sacadas que ocurren durante este intervalo.	frecuencia
Average peak velocity of saccades	Media del pico de velocidad de todas las sacadas en este intervalo.	Grados/segundos
Minimum peak velocity of saccades	Mínimo del pico de velocidad de todas las sacadas en este intervalo.	Grados/segundos
Maximum peak velocity of saccades	Máximo del pico de velocidad de todas las sacadas en este intervalo.	Grados/segundos
Standard deviation of peak velocity of saccades	Desviación estándar del pico de velocidad de las sacadas en este intervalo.	Grados/segundos
Average amplitude of saccades	Media de la amplitud de todas las sacadas en este intervalo.	Grados
Minimum amplitude of saccades	La amplitud de la sacada con la amplitud más baja en este intervalo.	Grados
Maximum amplitude of saccades	La amplitud de la sacada con la amplitud más alta en este intervalo.	Grados
Total amplitude of saccades	El total de la amplitud de todas las sacadas durante un intervalo.	Grados
Time to first saccade	La hora de la primera sacada durante el intervalo.	milisegundos
Direction of first saccade	La dirección de la primera sacada en el intervalo.	Grados
Peak velocity of first saccade	Pico de velocidad de la primera sacada.	Grados/segundos
Average velocity of first saccade	La velocidad media de la primera sacada dentro de un intervalo.	Grados/segundos
Amplitude of first saccade	La amplitud de la primera sacada en el intervalo.	Grados

Métrica	Significado	Unidad de medida
AOI saccade metrics		
Number of saccades in AOI	Numero de sacadas durante una AOI durante el intervalo.	frecuencia
Time to entry saccade	La duración hasta el inicio de la primera sacada que termina en un AOI durante un intervalo.	milisegundos
Time to exit saccade	La duración hasta el inicio de la primera sacada que sale en un AOI durante un intervalo.	milisegundos
Peak velocity of entry saccade	Velocidad máxima de la sacada de entrada.	Grados/segundos
Peak velocity of exit saccade	Velocidad máxima de la sacada de salida.	Grados/segundos

Tabla 9. Métricas posibles extraídas de eye tracking Tobii Pro Lab v.24.21 formato AOI-based TSV file.

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

Métrica	Significado	Unidad de medida
Duration of first fixation	La duración de la primera fijación dentro de una AOI durante un intervalo	milisegundos
Last AOI viewed	Última AOI fijada durante un intervalo	
AOI at Interval end	La AOI fijada al final de un intervalo	
Average pupil diameter	La media del diámetro de la pupila de todas las muestras de fijación en una AOI en un intervalo. Calculado utilizando el resultado del diámetro de la pupila aplicando un filtro.	milímetros
AOI fixation metrics (exclude partial fixations)		
Total duration of whole fixations	Duración total de las fijaciones dentro de una AOI durante un intervalo.	milisegundos
Average duration of whole fixations	Duración media de las fijaciones dentro de una AOI durante un intervalo.	milisegundos
Minimum duration of whole fixations	Duración de la fijación más corta dentro de una AOI durante un intervalo.	milisegundos
Maximum duration of whole fixations	Duración de la fijación más larga dentro de una AOI durante un intervalo.	milisegundos
Number of whole fixations	Número de fijaciones que ocurren en una AOI durante un intervalo	frecuencia
Time of first whole fixation	Hora de la primera fijación dentro de una AOI durante un intervalo	milisegundos
Duration of first whole fixation	Duración de la primera fijación dentro de una AOI en un intervalo	milisegundos
Average whole-fixation pupil diameter	Media del diámetro de la pupila de todas las muestras de fijaciones completas en una AOI en un intervalo.	milímetros
AOI visit metrics		
Total duration of Visit	Duración total de visitas dentro de una AOI en un intervalo	milisegundos
Average duration of Visit	Duración total de las visitas dentro de una AOI en un intervalo.	milisegundos
Minimum duration of Visit	Duración de la visita más corta dentro de una AOI en un intervalo.	milisegundos
Maximum duration of Visit	Duración de la visita más larga dentro de una AOI en un intervalo.	milisegundos
Number of Visits	Número de visitas dentro de una AOI en un intervalo	frecuencia
Time to first Visit	Hora de la primera visita dentro de una AOI en un intervalo.	milisegundos
Duration of first Visit	Duración de la primera visita dentro de una AOI en un intervalo.	milisegundos

Métrica	Significado	Unidad de medida
AOI Glance metrics		
Total duration Glances	Duración total de las miradas dentro de una AOI en un intervalo.	milisegundos
Average duration of Glances	La duración media de las miradas dentro de una AOI en un intervalo.	milisegundos
Minimum duration Glances	Duración de la mirada más corta dentro de una AOI en un intervalo.	milisegundos
Maximum duration Glances	Duración de la mirada más larga dentro de una AOI en un intervalo.	milisegundos
Number of Glances	Número de miradas dentro de una AOI en un intervalo.	frecuencia
Time to first Glance	Hora de inicio de la primera mirada dentro de una AOI en un intervalo.	milisegundos
Duration of first Glance	Duración de la primera mirada dentro de una AOI en un intervalo.	milisegundos
AOI Click metrics		
Number of mouse clicks	Número de veces que se pulsa el botón izquierdo del ratón en una AOI durante un intervalo.	frecuencia
Time of first mouse click	Hora hasta que se pulsa el botón izquierdo del ratón en una AOI durante un intervalo	milisegundos
Time from first fixation to mouse click	Hora de la primera fijación en la primera pulsación del botón izquierdo del ratón en una AOI durante un intervalo.	milisegundos
Time from first fixation to mouse click	La hora desde la primera fijación la primera vez en la que se ha pulsado el botón izquierdo del ratón en una AOI durante un intervalo.	milisegundos
Number of mouse clicks & releases	Número de clics en la primera fijación la primera vez en la que se ha pulsado el botón izquierdo del ratón en una AOI durante un intervalo.	frecuencia
Time to first mouse clicks & releases	La hora desde la primera fijación desde la primera vez en la que se ha pulsado el botón izquierdo del ratón en una AOI durante un intervalo.	milisegundos
AOI saccade metrics		
Number of saccades in AOI	Número de sacadas dentro de una AOI en un intervalo.	frecuencia
Time to entry saccade	Hora de la primera sacada dentro de una AOI en un intervalo.	milisegundos
Time to exit saccade	Hora de la última sacada dentro de una AOI en un intervalo.	milisegundos
Peak velocity for entry saccade	Pico de velocidad dentro de la primera sacada dentro de una AOI en un intervalo.	grados/segundos
Peak velocity for exit saccade	Pico de velocidad dentro de la última sacada dentro de una AOI en un intervalo.	grados/segundos

Métrica	Significado	Unidad de medida
AOI reading metrics		
Character index	Índice del AOI a nivel de carácter dentro de su AOI a nivel de palabra	posición
Word index	Índice del AOI a nivel de palabra dentro de su AOI a nivel de palabra	posición
Sentence index	Índice del AOI a nivel de sentencia dentro de su AOI a nivel de palabra	posición
AOI string	Cadena de texto que contiene una AOI	
Text unit type	Tipo de texto de la unidad: gráfico, palabra, sentencia.	
Number of units	Número de unidades	frecuencia
First-pass first fixation duration	Duración de la primera fijación durante la primera pasada dentro de una AOI en un intervalo.	milisegundos
First-pass duration	Duración total de las fijaciones durante la primera pasada dentro de un AOI durante un intervalo	milisegundos
Selective regression-path duration	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 Go-past.	milisegundos
First-pass regression	Indica si el lector sale de la AOI con una regresión (1) o sigue leyendo progresivamente (0).	binaria
Total duration of fixations	La duración total de las fijaciones dentro de la AOI durante un intervalo.	milisegundos
Regression-path duration	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
Re-reading duration	Duración de la trayectoria de regresión excluidas las fijaciones de la primera pasada durante un intervalo	milisegundos

También, se pueden extraer los registros en formato Excel, en este tipo de formato se incluyen métricas de *Interval metrics*, *Event metrics*, *AOI fixation metrics*, *AOI Visit metrics*, *AOI click metrics*. Otros resultados que se pueden hallar son los relativos a datos: de calibración, validación y datos referentes a *eyetracker timestamp*, *Gaze point 2D*, *Gaze direction*, *pupil diameter*, *pupil diameter*, *validity of eye data*, *eye position (3D)* en format DACS, *Gaze point* con datos de las coordenadas normalizados, *Assisted mapping gaze point*, *mouse position*, *Glavanic skin response*; Eventos: *Event*, *Eye movement* en tiempo y en espacio, *AOI hit*, *AOI inactivity*, *AOI visit*, *AOI glance*, *Skin Conductance Response* e información media.

Además, se puede visualizar una ejecución completa de cada participante, ya que graba toda la secuencia en vídeo, un ejemplo se puede consultar en la Figura 27. De igual modo, este dispositivo ofrece imágenes del mapa de calor (*Heat Map*) que se produce durante la ejecución de una tarea (ver Figura 28). Este se conforma con un registro acumulado de las frecuencias de posicionamiento de la mirada sobre el estímulo. Las zonas rojas indican una mayor frecuencia. De otro lado, también se pueden extraer métricas dinámicas tipo *scan path* que dan una imagen fija o dinámica del posicionamiento de la mirada en orden posicional dentro de las coordenadas cartesianas de la pantalla (ver Figura 29).

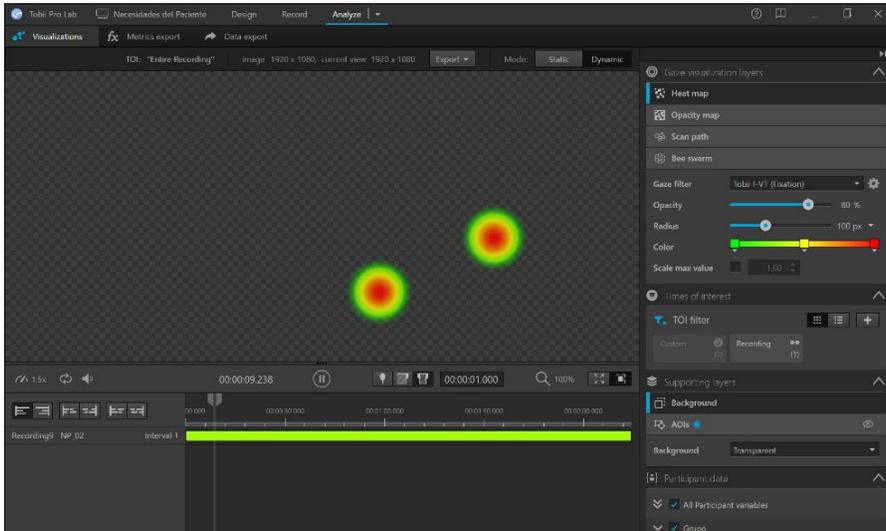


Figura 27. Registro en vídeo del posicionamiento dinámico de la frecuencia dentro del estímulo (fuente propia).

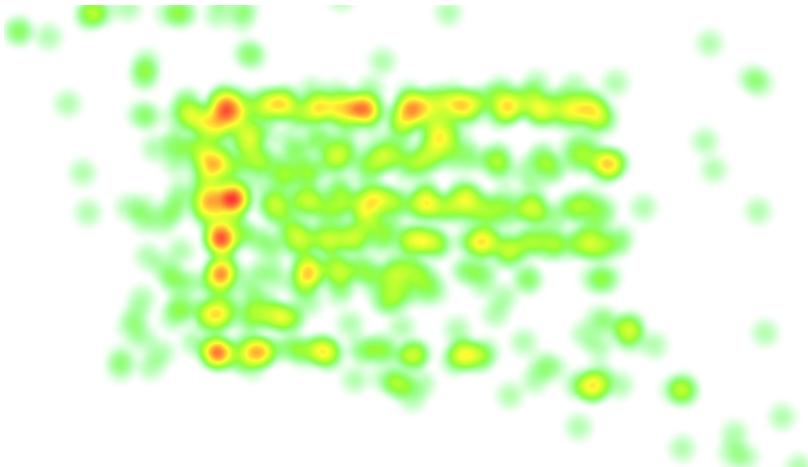


Figura 28. Heat Map obtenido durante la ejecución de una actividad (fuente propia).

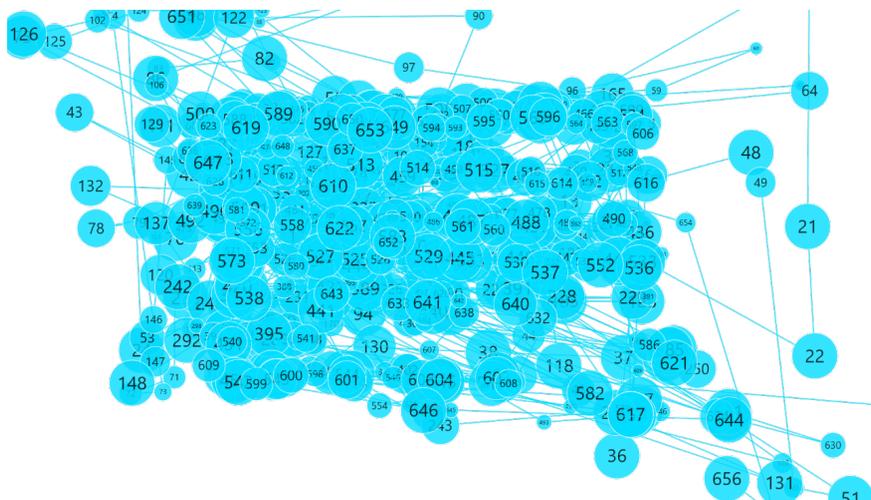


Figura 29. *Scan Path* de la ejecución de un usuario durante una actividad (fuente propia).

3.1.2.1. Significación de las métricas *eye tracking* con la medición de procesos cognitivos y metacognitivos.

Investigadores del GIR DATAHES de la UBU en colaboración con investigadores del GIR ADMIRABLE de la UBU están desarrollando distintos estudios para definir la relación entre las métricas extraídas con el dispositivo *eye tracking* que incluye GSR y la interpretación de las estrategias cognitivas y metacognitivas que se ponen en marcha respecto de la ejecución de distinto tipo de tareas. Seguidamente, se van a exponer los resultados de alguno de ellos.

Sáiz-Manzanares, M.C., Rodríguez-Díez, J.J., Marticorena, R., Zaparaín, M.J., y 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 hace referencia a la utilización de la tecnología *eye tracking* para conocer el procesamiento de la información durante la ejecución de una tarea relacionada con el ámbito de la Historia del Arte, se analizaba si existían diferencias significativas en distintos parámetros de registro en *eye tracking* y en la realización de una prueba de comprobación de conocimientos sobre lo representado en la tarea. Dicha tarea consistía en la visualización de un vídeo autorregulado, dentro del mismo se diferenciaban áreas de interés relevantes vs. no relevantes. También, se utilizó la variable conocimientos previos (personas experimentadas en este ámbito de conocimiento vs. no experimentadas) y la variable edad (personas jóvenes vs. personas de más edad en distintos intervalos). En este estudio se analizaron las métricas dinámicas para ello, se debió de aplicar técnicas de Machine Learning no supervisadas de *clustering*. En concreto, se aplicaron métodos de *string edit*, específicamente los algoritmos de *Uniform Distance model*, *City Block Distance* y *Educlidian Distance*.

En este caso el modelo que resultó más efectivo para la definición de la distancia entre los participantes fue el *Uniform Distance model* (ver Figura 30).

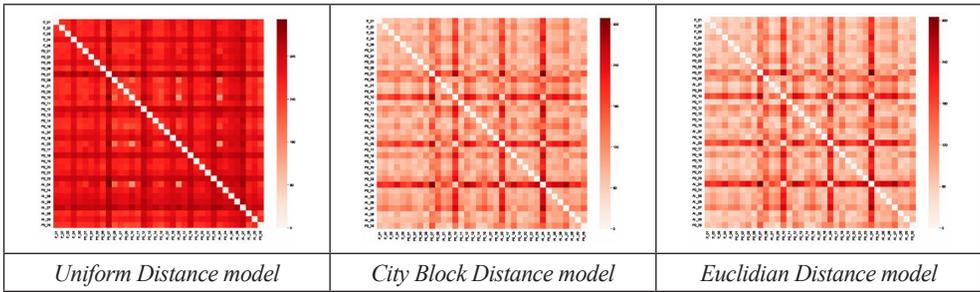


Figura 30. Modelos de análisis de distancia métodos string edit (imágenes tomadas de Sáiz Manzanares et al., 2020) p. 12-13.

También, se aplicó en este estudio un escalamiento multidimensional con los modelos de distancia, se halló en el modelo *Uniform Distance model* una agrupación más nítida de las distancias (ver Figura 31).



Figura 31. Modelos de análisis de distancia métodos string edit (imágenes tomadas de Sáiz Manzanares et al., 2020) p. 14-15.

Las conclusiones en este estudio fueron que la utilización de videos autorregulados para el aprendizaje, en este caso de la Historia del Arte, facilitaba mejores resultados de aprendizaje y mitigaba las diferencias entre los aprendices experimentados vs. noveles. De otro lado, la variable edad en personas experimentadas no tuvo efectos sobre los resultados de aprendizaje.

En este estudio se utilizó un equipo de *eye tracking* iViewXTM, SMIExperimenterCenter3.0ySMI BeGazeTM de 60 Hz. En este caso se extrajeron métricas dinámicas de *gaze point*. Se aplicó un monitor con una resolución de 1680x1050.

Sáiz-Manzanares, M.C., Payo-Hernanz, R., Zaparaín-Yáñez, M.J., Andres-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*, e62103. <https://doi.org/10.3791/62103>

En este estudio se presenta un protocolo para el uso de la tecnología eye tracking durante la ejecución de una tarea. Para ello, se empleó un sistema de eye tracking iViewX™, junto con el software SMI Experimenter Center 3.0 y SMI BeGaze™ a una frecuencia de 60 Hz. En este caso se extrajeron métricas estáticas (fijaciones, sacadas, parpadeos y recorridos de exploración). Se aplicó un monitor con una resolución de 1680x1050. Asimismo, se hace referencia a la extracción de la base de datos y la interpretación de los mismos a través de la utilización de técnicas de *Machine Learning*, en concreto se utilizó el *software* de *data mining* Orange. Los resultados hallados indican que la duración media de la fijación en los estímulos relevantes fue mayor en los participantes con conocimientos previos. Asimismo, el foco de atención de este grupo se centró en los puntos medios de la información. Se hallaron diferencias significativas en el procesamiento de la información. Si bien esta diferencia no siempre coincidió con la clasificación previa de los grupos (aprendices experimentados vs. no experimentados, edad de los participantes o su formación), se identificaron clústeres que revelaron otros tipos de agrupamientos. Asimismo, se comprobó que la forma de presentación de la tarea (vídeo autorregulado a través de voz) facilitaba la homogenización de los resultados de aprendizaje. Este artículo aporta un vídeo explicativo sobre todo el proceso de uso de la tecnología *eye tracking* incluida la extracción y el procesamiento de los datos.

Sáiz-Manzanares, M.C., Ramos Pérez, I., Arnaiz-Rodríguez, Á., Rodríguez-Arribas, S., Almeida, L., y 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>

Este estudio introduce a la relación entre las métricas que se pueden obtener con la tecnología *eye tracking* y las implicaciones en la interpretación en los procesos de aprendizaje, estas se pueden comprobar en la Tabla 3. En este estudio se utilizó un equipo de *eye tracking* iViewXTM, SMIExperimenterCenter3.0ySMI BeGazeTM de 60 Hz. En este caso se extrajeron métricas estáticas (fijaciones, sacadas, parpadeos y recorridos de exploración). Se aplicó un monitor con una resolución de 1680x1050. Se trabajó sobre una tarea de vídeo autorregulado sobre conocimientos de Historia del Arte y se consideraron las variables de conocimientos previos vs. no conocimientos previos; edad, género, nivel educativo, tipo de actividad (empleado, desempleado, estudiante). También, se aplicó una prueba de conocimientos adquiridos durante la tarea que fue la resolución de un puzzle. De igual modo, para la contrastación de hipótesis se utilizaron técnicas de *Machine Learning* supervisadas y no supervisadas. Concretamente, en este estudio se utilizaron técnicas de aprendizaje automático supervisado para la clasificación (se aplicaron los algoritmos *gain ratio*, *symmetrical uncertainty* y *chi-square*) y no supervisado para la agrupación (se aplicaron los algoritmos *k-means ++*, *fuzzy k-means* y *DBSCAN*). Los análisis se realizaron con el lenguaje de programación R. Las conclusiones indican que el uso de la técnica de *eye tracking* proporciona pruebas sobre el procesamiento de la información en distintos tipos de participantes durante la resolución de diferentes tareas. Este hecho facilita la investigación en ciencias del

comportamiento. Trabajar con esta tecnología abre muchos campos de investigación aplicados a numerosos entornos (aprendizaje de la lectoescritura, razonamiento lógico-matemático, física, conducción de vehículos, conducción de máquinas peligrosas, marketing, etc.). También puede utilizarse para averiguar cómo aprenden las personas con diferentes dificultades de aprendizaje (TDAH, TEA, etc.). El objetivo final sería mejorar su estilo de aprendizaje y hacer propuestas de intervención personalizadas en función de las necesidades observadas en cada uno de ellos. Además, esta tecnología puede utilizarse para mejorar las prácticas de conducción y la prevención de accidentes en el manejo de maquinaria peligrosa. Esta formación se está llevando a cabo en escenarios de realidad virtual y/o aumentada que aplican la tecnología de seguimiento ocular. Todas estas posibilidades abren un importante campo a abordar en futuras investigaciones. Otro aspecto relevante a tener en cuenta es la forma en que se presentan las tareas. En este estudio se ha demostrado que el uso de tareas autorreguladas facilita el procesamiento de la información y homogeneiza las respuestas de aprendizaje entre aprendices noveles vs. expertos. Además, este estudio ha demostrado que el uso de diferentes técnicas de *Machine Learning*, como la selección de características, facilita el conocimiento de los atributos que pueden ser más significativos para la investigación. Esta funcionalidad es muy útil en investigaciones en las que se dispone de un gran volumen de datos. Además, si esta técnica se combina con el uso de técnicas de aprendizaje automático y estadística tradicional, los resultados pueden aportar más información, especialmente relacionada con futuras líneas de investigación. De hecho, en este estudio se ha comprobado que algunas de las variables consideradas como independientes en el estudio estadístico también fueron seleccionadas como rasgos relevantes en el estudio que aplicó técnicas de aprendizaje supervisado de selección de instancias [por ejemplo, conocimiento previo, tipo de participante (alumno vs. profesor)]. Sin embargo, las técnicas de selección de rasgos también han proporcionado pistas a tener en cuenta en futuros estudios sobre la influencia de otras variables (por ejemplo, la variable género, la situación laboral, el nivel educativo y el campo de conocimiento). En esta línea, el uso de diferentes algoritmos para probar tanto la selección de características, como el *clustering* en el aprendizaje no supervisado, proporcionará al investigador un repertorio de resultados cuyo ajuste puede ser contrastado con el *Adjusted Rang Index* (ARI). Esto permitirá conocer las agrupaciones entre el estudiantado. Asimismo, facilitaría aislar los patrones de los tipos de aprendices para poder ofrecer respuestas educativas personalizadas. Por otro lado, la utilización de métodos de análisis estadístico permitirá conocer si las variables señaladas como independientes tienen efecto sobre las variables dependientes. En resumen, quizá el procedimiento más útil sea, en primer lugar, aplicar las técnicas de aprendizaje supervisado de selección características y, a continuación, en función de las variables detectadas, plantear las preguntas de investigación y aplicar los análisis estadísticos pertinentes para contrastarlas. Por último, los resultados de este estudio deben tomarse con cautela, ya que presenta una serie de limitaciones. Estas se relacionan principalmente con el tamaño de la muestra, que es pequeño, y con la selección de la muestra, que se llevó a cabo

mediante un muestreo de conveniencia. Sin embargo, hay que tener en cuenta que la utilización de la metodología del *eye tracking* requiere un control muy exhaustivo del desarrollo de las tareas en los espacios del laboratorio, aspecto que dificulta que las muestras sean amplias y aleatorias. Otro de los elementos limitantes de este trabajo es que se ha utilizado una tarea muy específica (adquisición de los conceptos de los orígenes de los monasterios en Europa y verificación de esta adquisición mediante la resolución de un crucigrama) en un entorno de aprendizaje concreto (historia del arte). Por este motivo, en las secciones Discusión y Conclusiones se han indicado posibles estudios futuros. En la Tabla 1º se pueden consultar los parámetros más representativos de las **métricas extraídas con *eye tracking*** y su correspondencia con las fases de procesamiento de la información.

Tabla 10. *Parámetros más representativos que pueden obtenerse con la técnica de seguimiento ocular y su importancia en el tratamiento de la información (información traducida y adaptada de Sáiz-Manzanares et al. (2021) p. 3-4.*

Métrica	Acrónimo	Significado de la métrica	Implicaciones en el aprendizaje
Fixation Count	FC	Cuenta el número de enlaces específicos en AOIs en todos los estímulos	El mayor número y frecuencia de fijaciones en un estímulo puede indicar que aprendiz tiene menos conocimientos sobre la tarea o dificultades para discriminar la información relevante frente a la no relevante. Se trata de medidas del rendimiento global de la búsqueda (Shen et al., 2007).
Fixation Frequency count	FFC		
Fixation Duration	FD	Duración de la fijación	Da una indicación del grado de interés y de los tiempos de reacción del aprendiz. Una mayor duración suele asociarse a un procesamiento cognitivo más profundo y un mayor esfuerzo. Para los 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 (Shen et al., 2007).
Fixation Duration Average	AFD	Media de duración de la fijación	Las fijaciones más largas hacen referencia a que el aprendiz pasa más tiempo analizando e interpretando el contenido de la información dentro de las diferentes Áreas de Interés (AOI). Se considera que la duración media oscila entre 200 ms y 260 ms.
Fixation Duration Maximum	FDMa	Duración mínima de la fijación	Se refieren a los tiempos de reacción.
Fixation Duration Minimum	FDMi	Duración máxima de la fijación	

Métrica	Acrónimo	Significado de la métrica	Implicaciones en el aprendizaje
Fixation Dispersion Total	FDT	Suma de todas las dispersiones de las fijaciones en X e Y	Se refiere a la percepción de la información en diferentes componentes de la tarea.
Fixation Dispersion Average	FDA	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.
Saccades Count	SC	Número total de sacadas en cada uno de los estímulos	Un mayor número de sacadas implica mayores estrategias de búsqueda. Cuanto mayor es la amplitud de la sacada, menor es el esfuerzo cognitivo. También puede referirse a problemas de comprensión de la información.
Saccade Frequency count	SFC	Suma de todas las sacadas	Se refieren a la frecuencia de uso de sacadas relacionadas con estrategias de búsqueda..
Saccade Duration Total	SDT	Suma de la duración de todas las sacadas	
Saccades Duration Average	SDA	Duración media de las sacadas en cada AOI	Permite discriminar entre aprendices dependientes del campo vs. no dependientes.
Saccade Duration Maximum	SDMa	Duración máxima de la sacada	Se refieren a la percepción de la información en diferentes componentes de la tarea.
Saccade Duration Minimum	SDMi	Duración mínima de la sacada	
Saccade Amplitude Total	SAT	Suma de la amplitud de todas las sacadas	Los aprendices noveles tienden a tener sacadas más cortas.
Saccade Amplitude Maximum	SAMa	Máximo de amplitud sacádica	
Saccade Amplitude Minimum	SAMi	Mínimo de la amplitud sacádica	
Saccade Velocity Total	SVT	Suma de la velocidad de todas las sacadas	Están directamente relacionados con la velocidad de procesamiento de la información al pasar de un elemento a otro dentro de un estímulo.
Saccade Velocity Maximum	SVMa	Valor máximo de la velocidad sacádica	
Saccade Velocity Minimum	SVMi	Valor mínimo de la velocidad sacádica	

Métrica	Acónimo	Significado de la métrica	Implicaciones en el aprendizaje
Saccade Latency Average	SLA	Es igual al tiempo transcurrido entre el final de una sacada y el inicio de la siguiente	Está directamente relacionada con los tiempos de reacción en el procesamiento de la información. La latencia sacádica inicial proporciona información temporal detallada sobre el proceso de búsqueda (Shen et al., 2007).
Blink Count	BC	Número de parpadeos en la prueba	Está relacionada con la velocidad de procesamiento de la información. Los aprendices noveles presentan una frecuencia más alta. Los parpadeos están relacionados con el procesamiento de la información durante la exposición a un estímulo para generar la siguiente acción. Los aprendices 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. Habrá que comparar estos resultados con los obtenidos en las otras métricas para ajustar la explicación de estos resultados dentro del análisis de un patrón de aprendizaje.
Blink Frequency count	BFC	Número de parpadeos de todas las pruebas seleccionadas por segundo dividido por el número de pruebas seleccionadas	
Blink Duration Total	BDT	Suma de la duración de todos los parpadeos de las pruebas seleccionadas dividida por el número de pruebas seleccionadas	
Blink Duration Average	BDA	La suma de la duración de todos los parpadeos de todas las pruebas seleccionadas dividida por el número de pruebas seleccionadas	
Blink Duration Maximum	BDMa	Duración máxima de los parpadeos registrados	
Blink Duration Minimum	BDMi	La duración más corta de los parpadeos registrados	
Scan Path Length	SPL	Proporciona un patrón de comportamiento de aprendizaje para cada usuario	
			El estudio de los patrones de comportamiento del aprendizaje facilitará las orientaciones del profesor en relación con la forma de aprender. La longitud de la trayectoria de exploración proporciona información sobre los tiempos de reacción en tareas sin duración predeterminada

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. *Appl. Sci.*, 14(16), 7017. <https://doi.org/10.3390/app14167017>

Este estudio hace referencia a la utilización de la tecnología *eye tracking* multicanal integrada. En concreto, aplica *eye tracking* junto con GSR. Asimismo, utiliza para el análisis técnicas de fusión de datos. Estas refieren al registro de datos desde distintas fuentes y el procesamiento de los mismos. De igual, modo esta investigación incluye la novedad de analizar la carga de trabajo percibida por el estudiantado participante. Dicha carga se mide a través de biomarcadores (fijaciones, sacadas, diámetro de la pupila, GSR). También, se incluyen datos sobre los resultados de aprendizaje. En este trabajo se trabaja con estudiantes de ciencias de la salud y de ingeniería biomédica. Además, se analiza la satisfacción percibida de estudiantado con la tarea. En este caso, se hallaron diferencias significativas entre el alumnado en algunos de los biomarcadores relacionados con la duración del tiempo de ejecución, los resultados de aprendizaje y la forma de visualización de la tarea (auditiva y visual vs. visual). La satisfacción percibida por la utilización de entornos virtuales autorregulados para el aprendizaje fue alta. Referente al análisis entre las métricas integradas (*eye tracking* y GSR), su significado, las implicaciones neurológicas y las implicaciones cognitivas y metacognitivas se puede comprobar en la Tabla 4. En este estudio se utilizó un dispositivo *eye tracking* Tobii pro lab version 1.194 with 64 Hz y un dispositivo de GSR Shimmer3 GSR+ (*galvanic skin response*) que era compatible con el dispositivo de Tobii. Esta integración ofrece la extracción de métricas de *single-channel galvanic skin response data acquisition* (Electrodermal Resistance Measurement—EDR/electrodermal activity (EDA)). *The GSR+ unit is suitable for measuring the electrical characteristics or conductance of skin.*

Tabla 11. *Indicadores de registro multimodal en el tratamiento de la información. (información traducida y adaptada de Sáiz-Manzanares et al. (2024) p. 3.*

Tipo de instrumento para la medición	Sensor	Significado	Implicaciones neurológicas	Implicaciones cognitivas y metacognitivas
<i>Electrodermal activity</i>	Electrodos en distintas partes del cuerpo (por ejemplo, los dedos). La respuesta psicogalvánica de la piel (GSR) No invasiva.	Variación eléctrica de la conductancia cutánea. Cambios en el nivel de sudoración de la piel causados por respuestas emocionales	Changes in the parasympathetic nervous system	Carga cognitiva y nivel de activación
<i>Eye tracking</i>	Los rayos infrarrojos registran el movimiento de los ojos. No es invasivo. Sin embargo, no se recomienda a las personas que sufren epilepsia.	Se pueden registrar varias métricas Fijaciones (frecuencia, duración, velocidad, etc.) Sacadas (frecuencia, duración, velocidad, etc.) Diámetro de la pupila	Son indicadores de entrada de información visual, auditiva y/o escrita. La duración, la velocidad, etc., de cada parámetro son indicadores indirectos del procesamiento de esa información Procesamiento de un estímulo. Las fijaciones indican la frecuencia, duración, velocidad, etc., del posicionamiento de los ojos en las coordenadas x e y del estímulo Procesamiento de un estímulo. Las sacadas indican el paso de la fijación de un estímulo a otro Dilatación o constricción de la pupila del ojo	Atención selectiva Carga cognitiva Pueden ser indicadores de interés o de esfuerzo en el procesamiento Una mayor amplitud de la sacada puede indicar un menor esfuerzo cognitivo o problemas para comprender la información Un mayor diámetro de la pupila se asocia a una mayor carga cognitiva y puede denotar mayores problemas para procesar la información de los estímulos

Tipo de instrumento para la medición	Sensor	Significado	Implicaciones neurológicas	Implicaciones cognitivas y metacognitivas
<i>Electroencephalographic recording</i>	<p>Los electrodos que recogen la actividad cerebral pueden ser secos (diadema) o semisecos (electrodos que hay que humedecer). Los primeros son menos invasivos.</p>	<p>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).</p> <p>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 invasivo. Sin embargo, los usuarios deben ser conscientes de que se está grabando su rostro y deben dar su consentimiento</p>	<p>Ruta de seguimiento en un proceso de aprendizaje</p> <p>Asociación emocional con el procesamiento de la información</p>	<p>Los patrones de procesamiento de la información son diferentes para cada aprendiz, aunque se pueden encontrar similitudes o diferencias que proporcionan información sobre los estilos de aprendizaje</p> <p>La expresión de las emociones</p>
		<p>Software de reconocimiento facial</p> <p>Se trata de un registro de la actividad eléctrica del cerebro en sus distintas áreas.</p>	<p>Actividad cerebral en diferentes áreas (frontal, prefrontal, temporal, parietal). La actividad puede ser excitatoria o inhibitoria</p>	<p>Procesamiento de la información a partir del análisis de la activación cerebral en distintas áreas. Las áreas frontal y prefrontal están especialmente relacionadas con la planificación y la resolución de problemas</p>

3.1.3. Sincronización de *eye tracking* con otros registros

a) Registro de la Respuesta Psicogalvánica de la piel (GSR)

En la actualidad la tecnología *eye tracking* permite la sincronización de la información del seguimiento visual con otros canales de registro como son la Respuesta Psicogalvánica de la Piel (GSR). La teoría tradicional del análisis de la respuesta galvánica de la piel está basada en la suposición de que la resistencia de la piel varía con el estado 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 está muy excitada, la actividad de la glándula sudorípara también aumenta, lo que a su vez incrementa la conductancia de la piel, y viceversa. De esta forma, la conductancia de la piel puede ser una medida de las respuestas del SNS humano. Este sistema está directamente involucrado en la regulación del comportamiento emocional. Otros estudios han destacado la relación entre la señal GSR y algunos estados físicos que pueden influir en los estados mentales, como por ejemplo el estrés, el cansancio y el compromiso con la actividad. La señal GSR se registra con dos electrodos colocados en el segundo y tercer dedo de una mano. La variación de una corriente aplicada de bajo voltaje entre los dos electrodos se utiliza como medida de la actividad electrodérmica (EDA). La tecnología Bitbrain para GSR, compatible con los sistemas Tobii, permite la integración de señales y ofrece las siguientes medidas:

Activación. Definición: 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.

Impacto. Definición: El **impacto emocional** mide el número de **cambios puntuales y la intensidad de los mismos en el estado emocional producido por un estímulo**, un acontecimiento externo o en la realización de una tarea. En otras palabras, el impacto **identifica algo que es sorprendente o produce emoción o estrés**. El impacto se expresa como un porcentaje. Un valor del **0 % significa que no hay impacto**. El **100 % equivale al valor medido en respuesta a los medios de calibración**. Es posible que el valor sea superior al 100 % si la reacción calculada supera la medida durante la calibración.

En la Figura 32 se muestra un ejemplo del dispositivo de GSR, el posicionamiento de los dedos para el registro de la señal de respuesta psicogalvánica y en análisis de la señal recogida con la tecnología de Bitbrain.

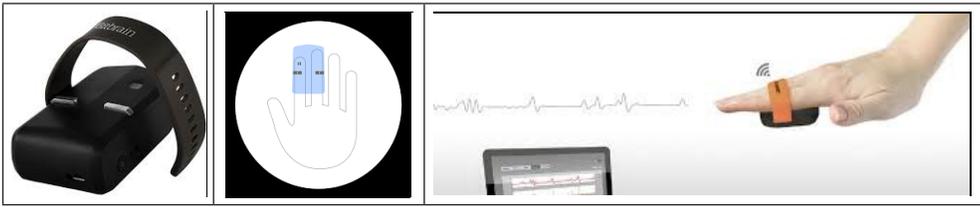


Figura 32. *Dispositivo GSR, posición de los dedos para el registro, ejemplo de registro tomado de Bitbrain.*

b) Registro Encefalográfico (EEG).

Dependiendo del dispositivo los registros EEG pueden registrar información de 8, 16, 32 y 64 canales a través de electrodos secos o semisecos. Estos sensores están diseñados para la monitorización versátil respecto de una gran variedad de entornos incluyendo un alto nivel de precisión incluso en situaciones de movimiento. Un ejemplo de las áreas de registro se puede comprobar en la Figura 32, tomada de una información libre de Bitbrain. En concreto, en esta imagen se incluyen 16 canales en áreas de desarrollo, frontal, prefrontal y occipital.

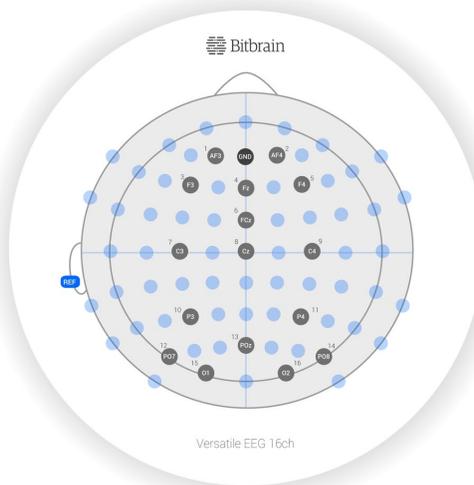


Figura 33. *Imagen del registro en EEG con 16 canales tomado de Bitbrain [enlace](#)*

Las métricas que se pueden extraer de EEG son:

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**.

Valencia. Definición: 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.

Memorización. Definición: 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.

Workload. Definición: 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**.

En la Figura 34 se presenta un ejemplo de dispositivo EEG de 12 canales en tipología diadema de electrodos secos y la recogida de señal en métricas de *engagement*, valencia, memorización y *workload*.

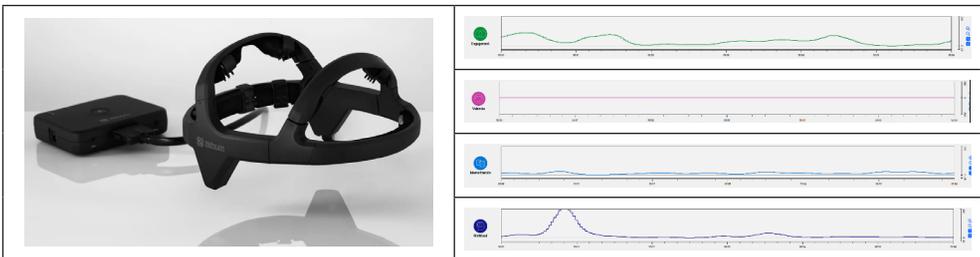


Figura 34. Dispositivo tipo diadema con electrodos secos tecnología de Bitbrain y registro de señales.

Todas las métricas se pueden integrar y analizar en el registro de los distintos canales de registro, un ejemplo se puede consultar en la Figura 34.

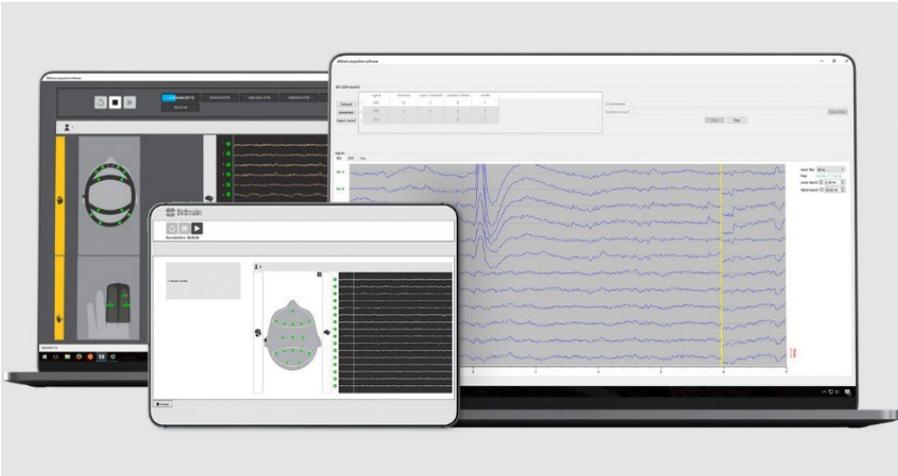


Figura 35. Análisis de registro multicanal tomado de Bitbrain web.

En este enlace se puede acceder a registros en acceso abierto <https://www.bitbrain.com/es/science/eeg-datasets>

Otros análisis de interés

<https://www.bitbrain.com/es>

<https://www.bitbrain.com/es/productos-neurotecnologia/software>

<https://www.bitbrain.com/es/blog/category/investigacion>

<https://www.bitbrain.com/blog/how-to-select-dry-eeeg-headset>

Seguidamente, se presentan estudios científicos en los que se ha utilizado esta tecnología de canales integrados en el ámbito de la clínica y la rehabilitación:

Escolano, C., López-Larraz, E., Mínguez, 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

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>

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>

También, en este enlace se pueden consultar distintos proyectos de investigación <https://www.bitbrain.com/es/science>

3.1.4. Relación de las medidas de registro encefalográfico con el procesamiento cognitivo.

Siguiendo a Serman y Chartier (2023) p. 104 señalan que la electroencefalografía es una ciencia relativamente joven. Hace cien años, aún no se había establecido que existiera actividad eléctrica en el cerebro humano. En 1875, Richard Caton fue el primero en informar de una observación de actividad eléctrica en los cerebros de monos y conejos, aunque las técnicas disponibles en ese momento no le permitieron registrar estas formas de onda para la posteridad. Caton realizó sus observaciones utilizando un dispositivo llamado galvanómetro de espejo de Thomson (Caton, 1877). Posteriormente, Hans Berger, se considera el padre de la electroencefalografía moderna ya que fue el primero en registrar el EEG en humanos (Figura 35) durante su trabajo como profesor de Psiquiatría en la Universidad de Jena en Alemania. Asimismo, su trabajo anterior había ya incluido mediciones precisas de las pulsaciones cerebrales tanto en animales como en humanos y, más tarde, la medición de la temperatura cerebral (Libenson, 2024). Hans Berger fue un Neurólogo alemán discípulo de Otto Ludwig Binswanger (1852-1929) en la clínica psiquiátrica de la universidad junto con Oskar Vogt (1870-1959) y Korbinian Brodmann (1868-1918). Berger fue jefe de la Unidad de Psiquiatría de la Universidad de Jena. En su investigación inicial, el objetivo principal fue la búsqueda de la correlación entre la actividad objetiva del cerebro y los fenómenos psíquicos subjetivos. Investigó la influencia de los latidos del corazón, la respiración, las funciones vasomotoras y la posición de la cabeza y el cuerpo sobre las pulsaciones cerebrales. Posteriormente, el Dr. Berger intentó descubrir una correlación entre la temperatura del cerebro y los procesos psíquicos. Seguidamente, se centró en la demostración de la actividad eléctrica en el cerebro humano. A partir de 1925, Berger modificó su metodología y se especializó en registrar las fluctuaciones espontáneas en el potencial eléctrico. Su primera publicación sobre electroencefalografía fue el 22 de abril de 1929, y la fecha del descubrimiento del electroencefalograma humano se data 6 de julio de 1924. En la Figura 36 se puede consultar la máquina utilizada por Berger y su trabajo docente en neuropsiquiatría.

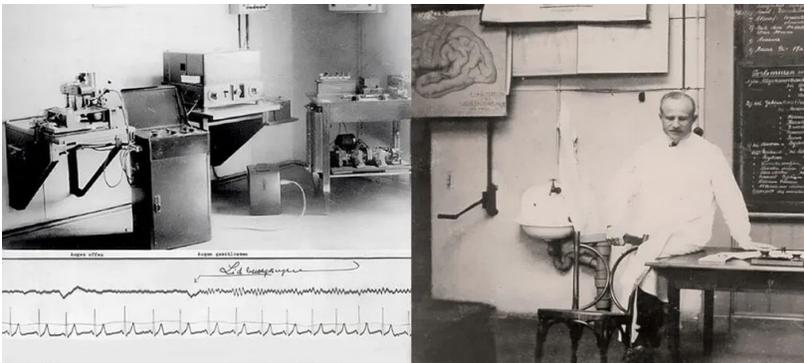


Figura 36. Hans Berger en estudios de neuropsiquiatría (imágenes tomadas de acceso libre).

Este recurso supuso un hito en el estudio del cerebro humano tanto en su funcionamiento «normal» como en su funcionamiento patológico y también ha servido para estudiar el funcionamiento diferencial en distintos procesos de resolución de problemas dependiendo de las características personales de los usuarios. Seguidamente, se describirá de forma breve las funciones asociadas al funcionamiento de los distintos lóbulos cerebrales. Para ello, se ha consultado la información en los siguientes manuales:

Pérez Pérez, D. (1978). Fundamentos neurológicos de la conducta. Madrid: Ediciones del Castillo

Kahle, W., Leonhardt, H., Platzer, W. (1977). Sistema nervioso y órganos de los sentidos. Barcelona: Omega

Lóbulo frontal funciones:

El lóbulo frontal tiene una localización rostral a la cisura central y dorsal a la cisura lateral. Este es el lóbulo de mayor tamaño y ocupa aproximadamente un tercio del hemisferio. Dicho lóbulo incluye las circunvoluciones: precentral, localizada verticalmente y tres circunvoluciones organizadas horizontalmente. Su función es la de activar y controlar los movimientos en la mitad contralateral del cuerpo. El área situada inmediatamente rostral a la cisura precentral es la corteza premotora, que hace referencia a los movimientos complejos y hábiles. La porción anterior restante del lóbulo es la corteza prefrontal, esta hace referencia al razonamiento, pensamiento abstracto, el autocontrol, la toma de decisiones, la planificación y las habilidades pragmáticas. En el lóbulo frontal hay 3 tres grandes circunvoluciones organizadas horizontalmente: la superior, la media y la inferior. Se encuentran situadas las en el lóbulo prefrontal las áreas 9, 10, 11, 12, 44, 46 de Broca, relacionadas con el lenguaje, las áreas 44 y 45 se relacionan con la función motora del lenguaje. El lóbulo frontal alberga las áreas cerebrales 4 (relacionada con motores), 6 y 8 (relacionadas con los movimientos oculares) y las áreas 1, 2 y 3 (relacionadas con aspectos sensitivos). Se relaciona con funciones motoras excitatorias e inhibitorias y supresoras. Una representación de las áreas de Brodmann se puede consultar en la Figura 37.

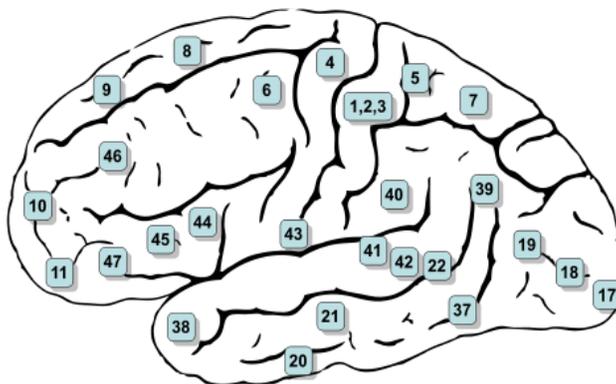


Figura 37. Áreas de Brodmann
(esta foto de Autor desconocido está bajo licencia CC BY-SA).

Lóbulo Frontal y Prefrontal funciones

Asimismo, en la Figura 38 se puede consultar el posicionamiento de los electrodos en los lóbulos frontales y prefrontales. En la Figura 39 se presenta el posicionamiento de los electrodos en los lóbulos parietales y parietooccipitales. Finalmente, en la Figura 40 se puede consultar el posicionamiento de los electrodos en los lóbulos parietooccipitales y occipitales, todos ellos descritos con la tecnología Bitbrain.

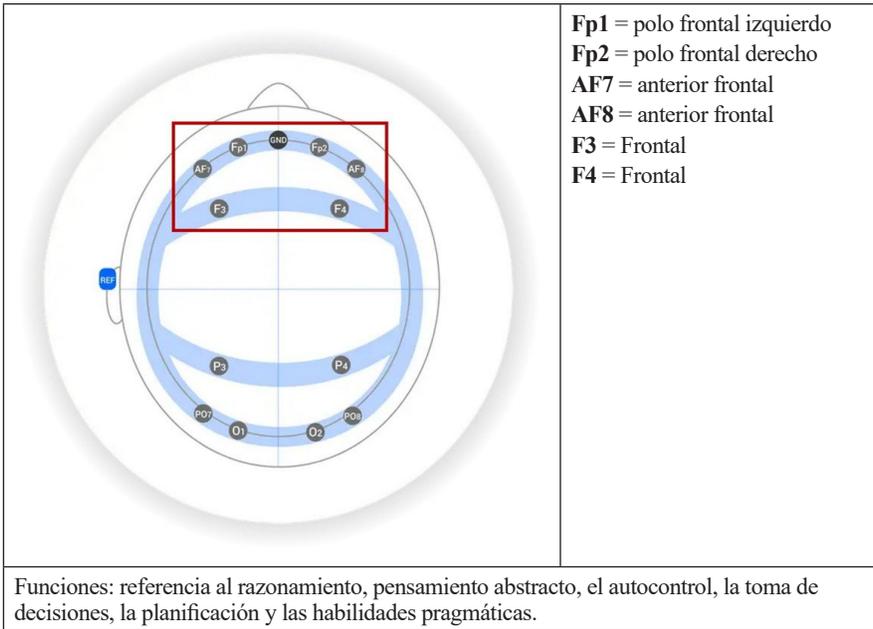


Figura 38. *Lóbulos frontal y prefrontal, canales de registro en EEG formulación internacional y resumen de las funciones cognitivas (imagen de acceso libre tomada de Bitbrain, destacado propio)*

Lóbulo parietal funciones

El lóbulo parietal, está localizado entre el lóbulo frontal y el occipital. Este, está especialmente relacionado con la sensibilidad somática (áreas 5 y 7). El análisis y la integración de la información sensitiva en el lóbulo parietal inferior hace referencia a las experiencias perceptivas complejas.

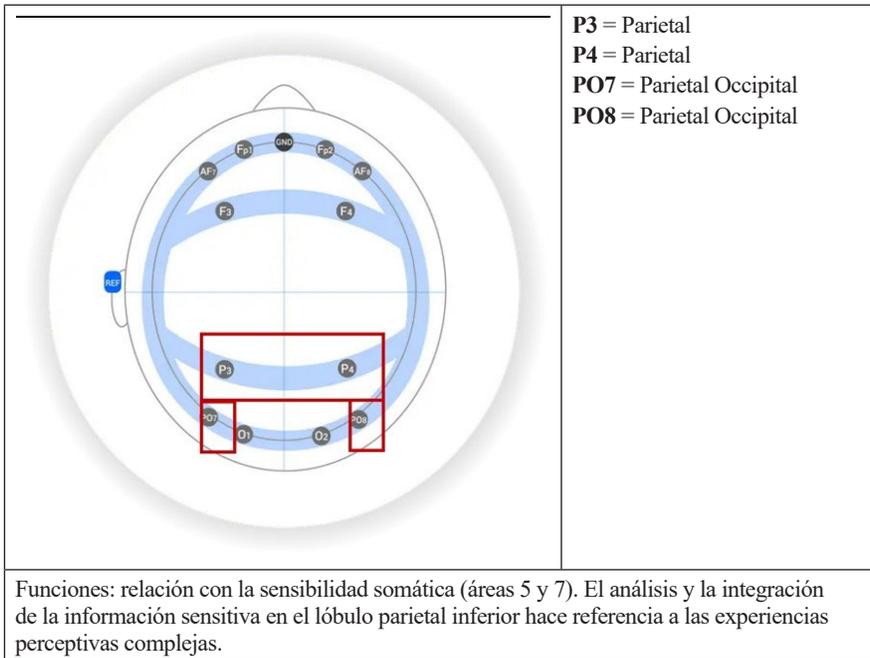


Figura 39. *Lóbulos parietal y parietooccipital, canales de registro en EEG formulación internacional y resumen de las funciones cognitivas (imagen de acceso libre tomada de Bitbrain estacado propio)*

Lóbulo occipital funciones

El lóbulo occipital, hace referencia a las áreas visuales primaria y secundaria. Su situación se enmarca desde la cisura parietoccipital hasta la escotadura preoccipital. Se sitúan las áreas 17 y 18 de Brodmann, comparte el área 19 con el lóbulo parietal. 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. Dominancia con el lóbulo izquierdo e interrelación entre prefrontalidad y occipitalidad con dominio de la primera.

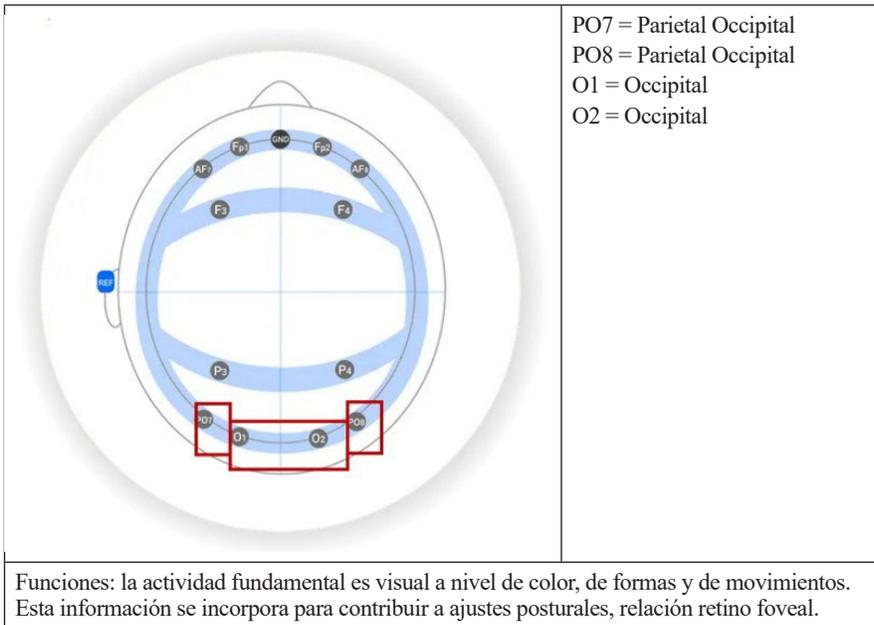


Figura 40. *Lóbulos parietooccipital y occipital, canales de registro en EEG formulación internacional y resumen de las funciones cognitivas (imagen de acceso libre tomada de Bitbrain estacado propio)*

Además, es este posicionamiento en la arquitectura cerebral se puede obtener información acerca de las ondas cerebrales que se producen durante la realización de diferentes tareas. El análisis de los registros de EEG que habitualmente se registran en microvoltios (μV). Seguidamente, se pueden transformar a ondas cerebrales si se dispone de los *timestamps* a través de la Transformada de Fourier.

Una vez transformadas las señales, es posible identificar qué tipo de onda cerebral utiliza el usuario durante la resolución de una tarea o la realización de una actividad. A continuación, se repasará la información relativa a las ondas cerebrales. **Ondas gamma** (γ) son un patrón de oscilación neuronal que tiene lugar en los seres humanos, cuya frecuencia oscila entre los **30 Hz-100 Hz**, aunque su presentación más habitual es de 40 Hz. Estas podrían estar implicadas en el **proceso de percepción consciente**, pero no hay acuerdo unánime al respecto. En la Figura 41 se puede consultar una representación gráfica de las mismas.

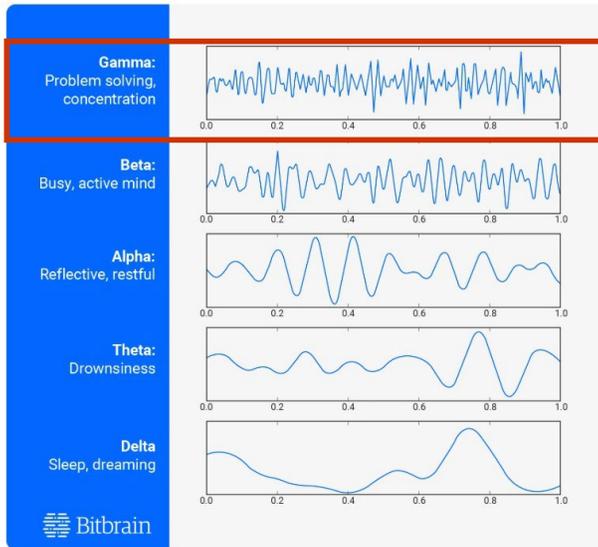


Figura 41. Representación gráfica de las ondas gamma tomada de Bitbrain.

Ondas beta (β) son oscilaciones electromagnéticas en el segundo rango más alto de frecuencia **13 Hz-30 Hz**, siendo ondas gamma las del primer rango, y se detectan en el cerebro humano a través de un electroencefalograma. Están **asociadas con etapas de «sueño nulo»**, donde se está despertando y consciente. Las ondas beta son más frecuentes en comparación con las ondas delta, alfa y theta. En la Figura 42 se puede consultar una representación gráfica de las mismas.

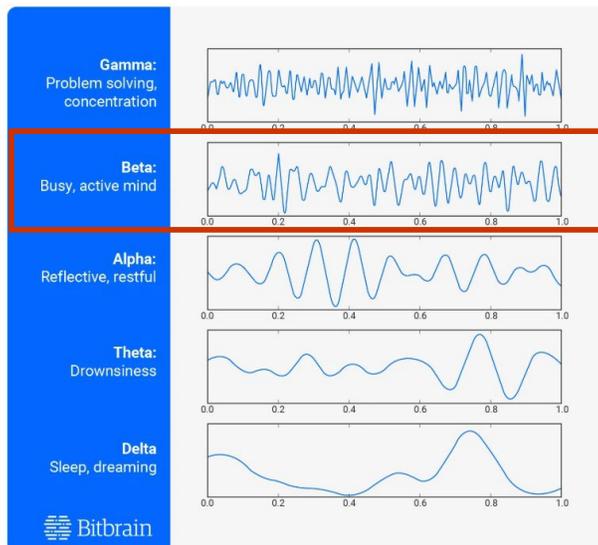


Figura 42. Representación gráfica de las ondas beta tomada de Bitbrain.

Ondas alpha (α) son oscilaciones electromagnéticas en el rango de **frecuencias de 8 Hz-13 Hz** que surgen de la actividad **eléctrica sincrónica y coherente**, también son llamadas «**ondas de Berger**», en memoria de Hans Berger, el primer investigador que aplicó la electroencefalografía a seres humanos. Las ondas alfa son comúnmente detectadas usando un electroencefalograma (EEG) o un magnetoencefalograma (MEG), y se originan sobre todo en el **lóbulo occipital durante períodos de relajación, con los ojos cerrados, pero todavía despierto**. Se piensa que **representan la actividad de la corteza visual en un estado de reposo**. Estas ondas se **enlentecen al quedarse dormido y se aceleran al abrir los ojos, al moverse o incluso al pensar en la intención**. En la Figura 43 se puede consultar una representación gráfica de las mismas.

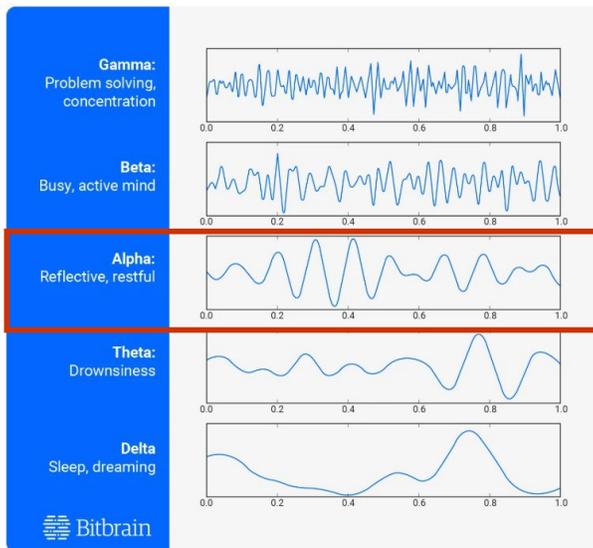


Figura 43. Representación gráfica de las ondas alpha tomada de Bitbrain.

Ondas theta (θ) refieren la actividad entre **4 Hz-8 Hz**. Las ondas en el rango theta generalmente se consideran anormales en el EEG adulto durante la vigilia; sin embargo, la aparición de ondas theta es uno de los sellos distintivos del **inicio de la somnolencia normal**. Las ondas theta suelen ser de bajo voltaje y pueden aparecer en cualquier área del cerebro. Las ondas theta también pueden verse en las regiones temporales durante la somnolencia y, en otros, pueden verse de forma difusa. En general, se generan tras la interacción entre los lóbulos temporal y frontal. Los sonidos binaurales basados en ondas theta están recomendados para **asimilar nueva información**, sobre todo en estudiantes de edad avanzada, aunque puede aplicarse también a adolescentes. Las ondas theta, promueven la relajación y el sueño, tanto despierto como dormido. En la Figura 44 se puede consultar una representación gráfica de las mismas.

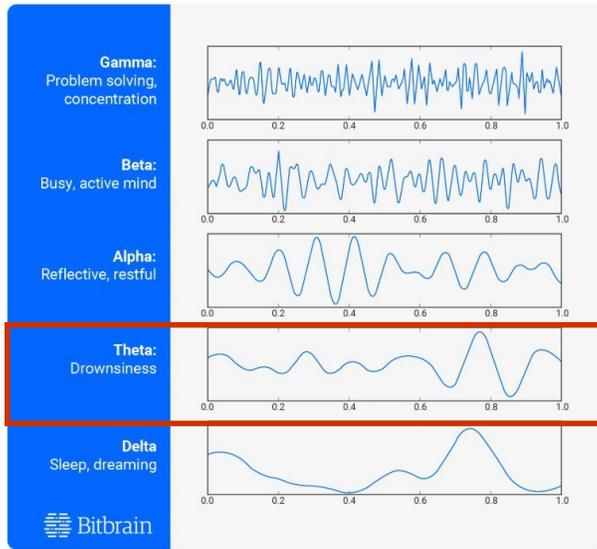


Figura 44. Representación gráfica de las ondas Theta tomada de Bitbrain.

Ondas delta (δ) son resultado de la representación de la actividad cerebral frente al **tiempo de sueño**. Estas, presentan una periodicidad en rango de frecuencias de **0,5 Hz-4 Hz**. Normalmente se asocian con etapas de **sueño profundo**. En la Figura 45 se puede consultar una representación gráfica de las mismas.

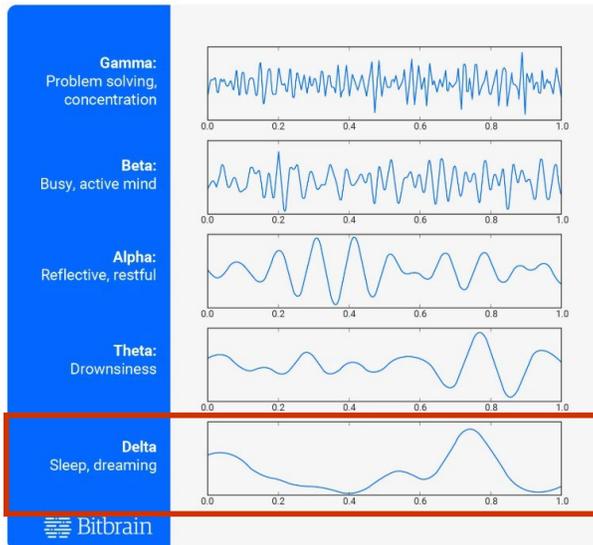


Figura 45. Representación gráfica de las ondas Delta tomada de Bitbrain.

En síntesis, los datos que se desprenden de los registros multicanal integrados precisan un preprocesamiento realizando acciones de limpieza y de eliminación de ruido y posteriormente un procesamiento de dicha información para su transformación en señales interpretables. En la Figura 46, se presenta un resumen del proceso.

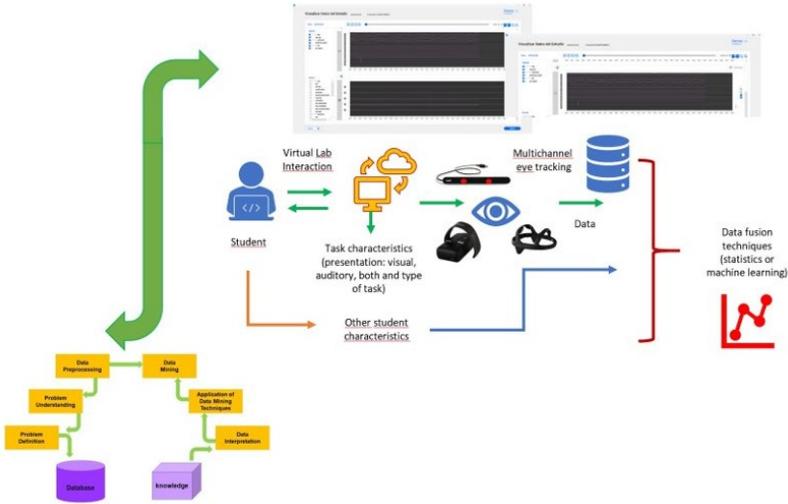


Figura 46. Procesamiento de datos en el análisis de señales multicanal integradas.

No obstante, el uso de estos dispositivos de señal integrada puede ofrecer al investigador o al terapeuta información ya procesada de una forma más sencilla. Seguidamente, se van a presentar ejemplos.

Se parte de una tarea sobre reconocimiento de emociones, se trabaja con imágenes de emociones que pueden tener diversa interpretación por parte de distintos usuarios (ver Figura 47).



Figura 47. Representación de emociones imágenes fuente propia Sáiz-Manzanas (2025).
propia <http://hdl.handle.net/10259/10225>

En la Figura 48, se presenta un análisis de los biosensores en distintas métricas de GSR respecto de la medición de impacto recogido en las cinco diapositivas en las que se representaban las cinco emociones en cinco sujetos experimentales representado en un gráfico de barras con análisis de la desviación típica.

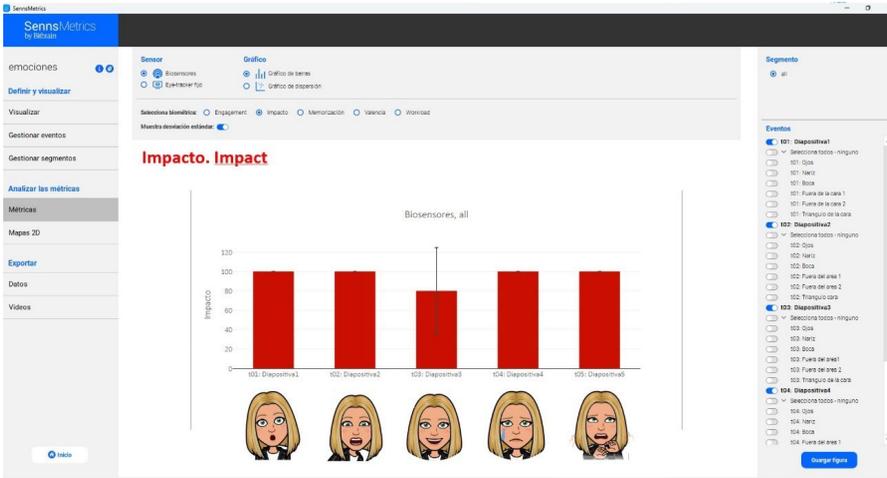


Figura 48. Representación del análisis del impacto en la percepción de distintas emociones (imagen fuente propia)

En las Figuras 49, 50, 51 y 52 se presenta el mismo análisis respecto de las métricas de *engagement*, memorización, valencia y carga de trabajo recogidas con EEG.

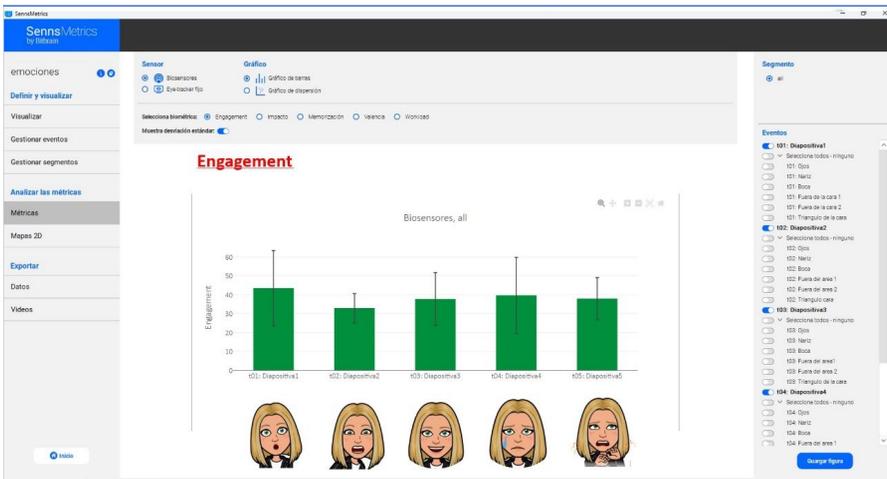


Figura 49. Representación del análisis del engagement en la percepción de distintas emociones (imagen fuente propia)

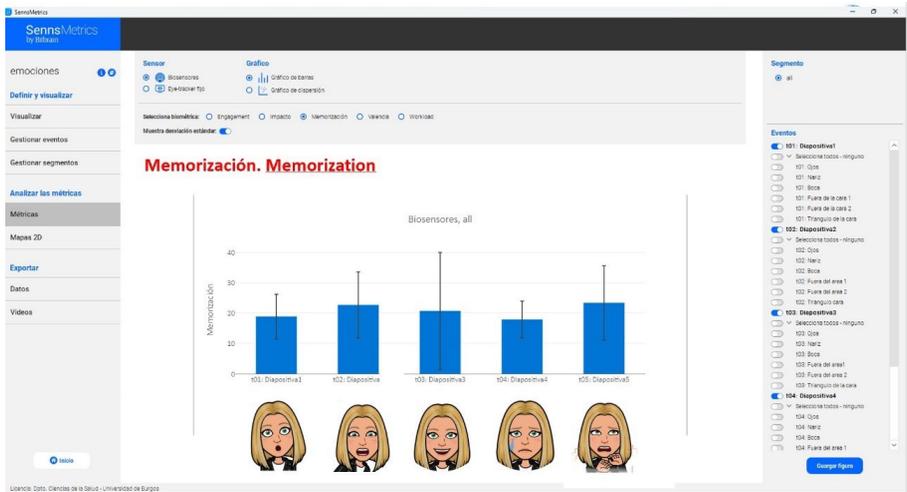


Figura 50. Representación del análisis de la memorización en la percepción de distintas emociones (imagen fuente propia)

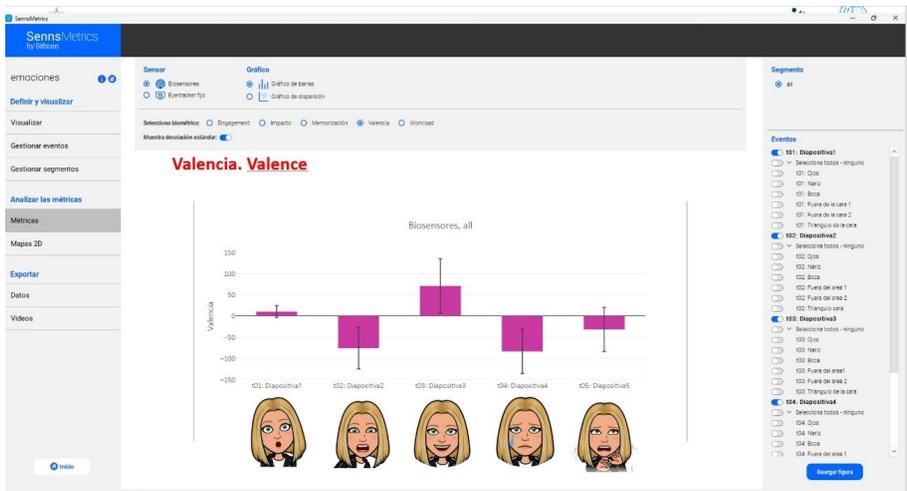


Figura 51. Representación del análisis de la valencia en la percepción de distintas emociones (imagen fuente propia)

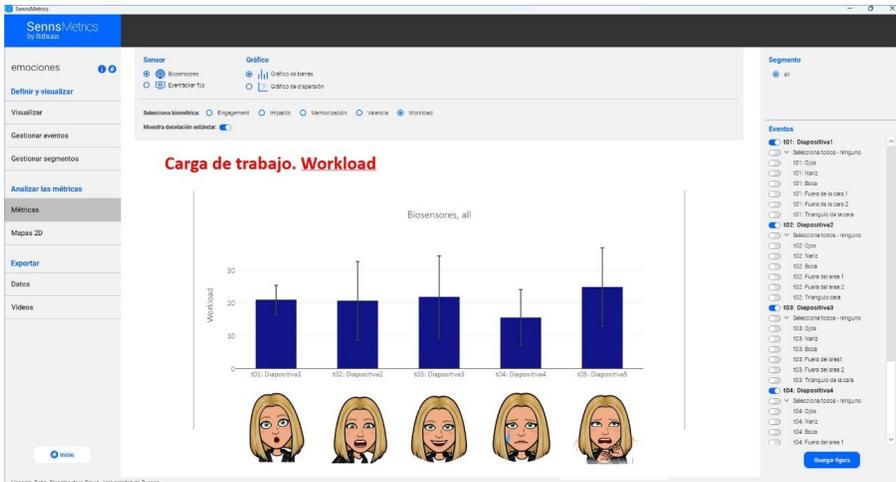


Figura 52. Representación del análisis de la carga de trabajo en la percepción de distintas emociones (imagen fuente propia)

Asimismo, dentro de cada tarea, en este caso imagen, se pueden establecer distintas áreas de interés. Estas son la delimitación de elementos relevantes vs. no relevantes en la percepción de las imágenes de la representación de emociones. Se puede conocer la frecuencia de acceso a cada área de interés. Por ejemplo, en las Figuras 53-57 se puede ver el análisis de las distintas emociones en las distintas áreas de interés.

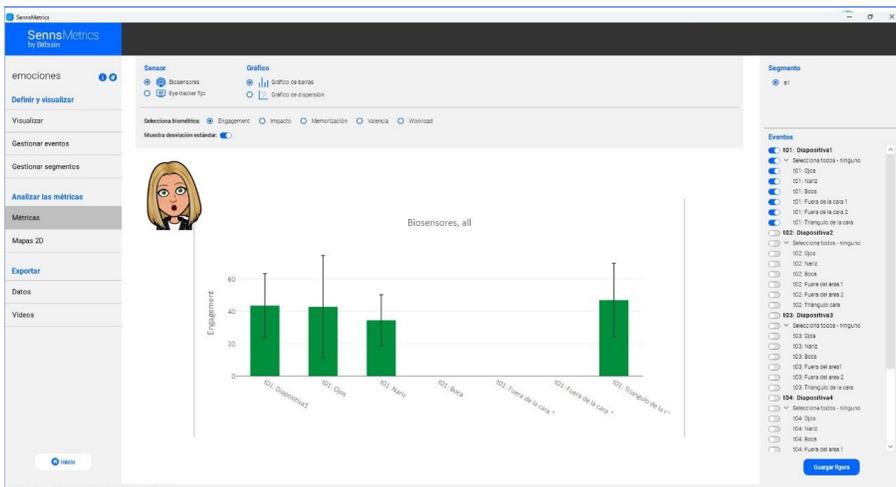


Figura 53. Análisis de las áreas de interés en la emoción 1 (imagen fuente propia)

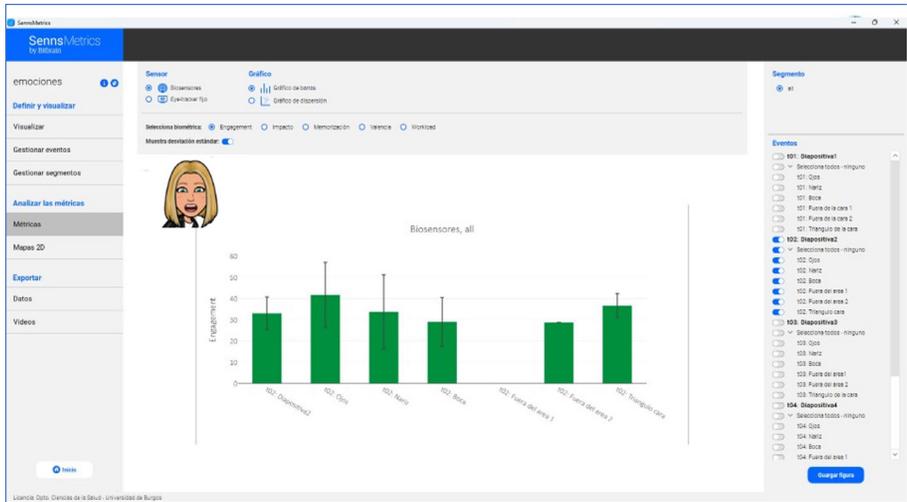


Figura 54. Análisis de las áreas de interés en la emoción 2 (imagen fuente propia).

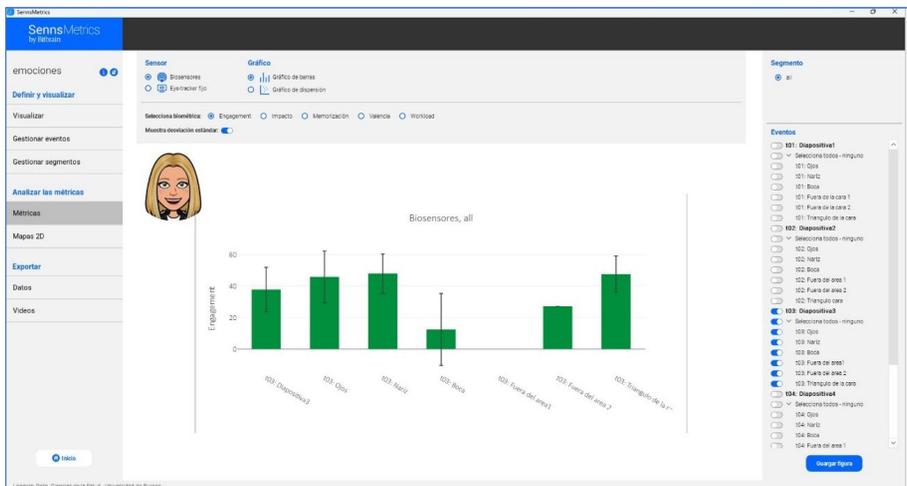


Figura 55. Análisis de las áreas de interés en la emoción 3 (imagen fuente propia).

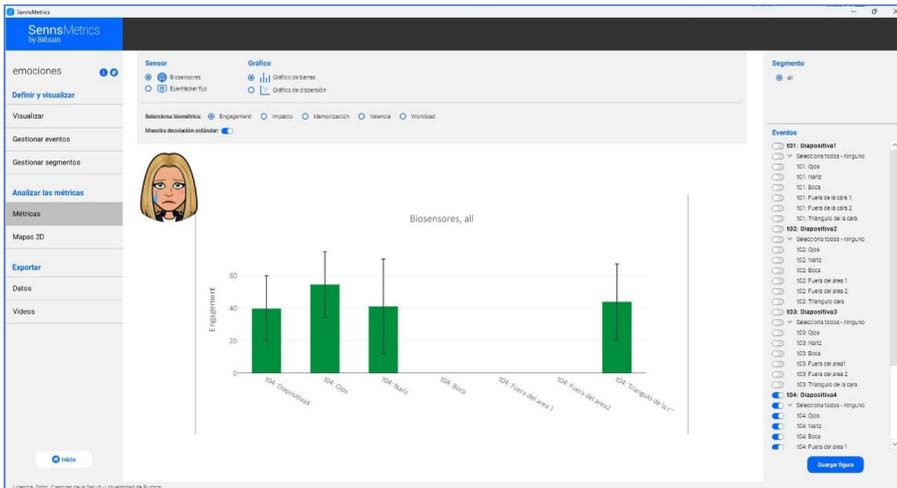


Figura 56. Análisis de las áreas de interés en la emoción 4 (imagen fuente propia).

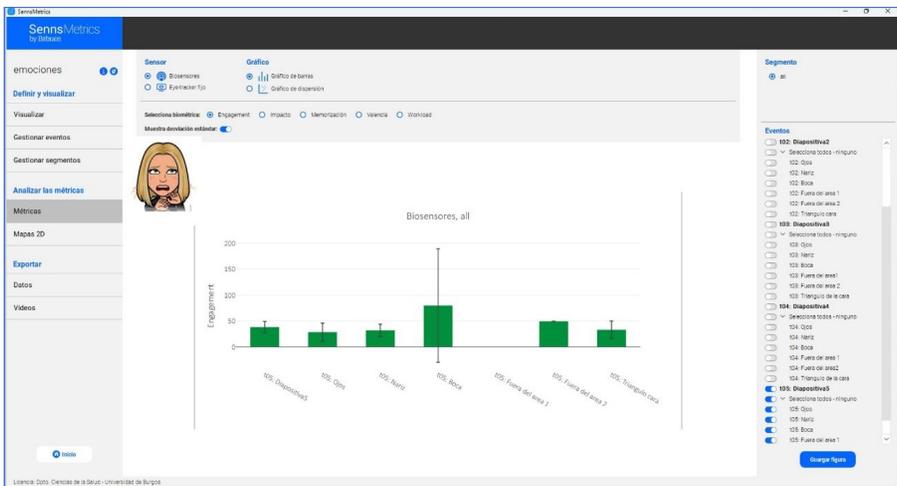


Figura 57. Análisis de las áreas de interés en la emoción 5 (imagen fuente propia).

Respecto del sensor de *eye tracking* fijo se pueden extraer distintos gráficos: mapa de calor (ver Figura 58), mapa de focalización (ver Figura 59), mapa de trayectoria (ver Figura 60), mapa de biométricas (ver Figura 61) y mapa de tiempo (ver Figura 62).

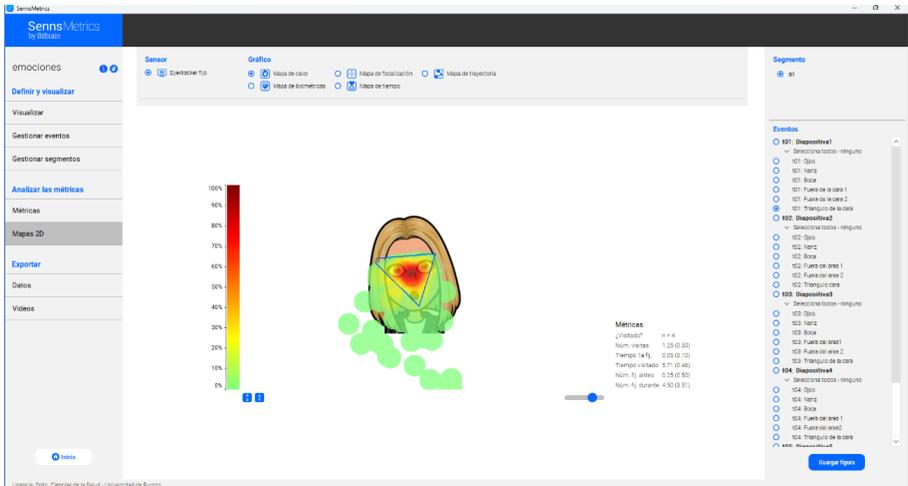


Figura 58. Mapa de calor en el área de interés de triángulo facial (imagen fuente propia).

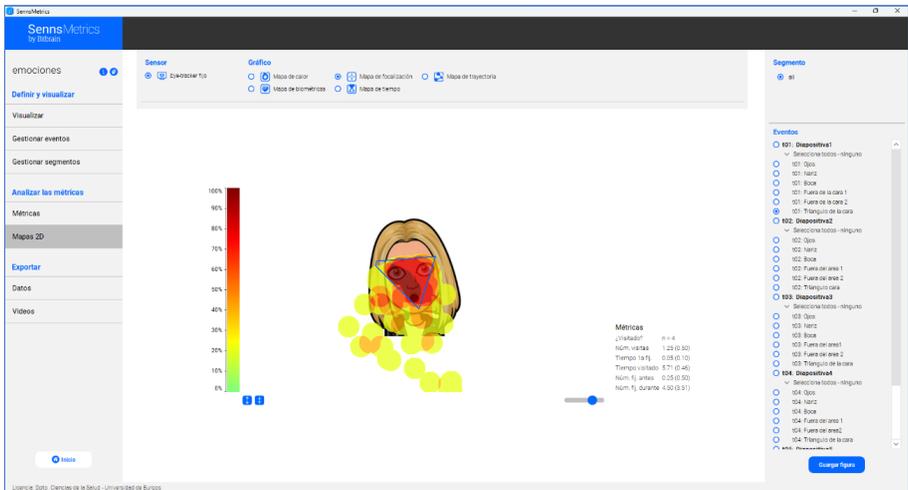


Figura 59. Mapa de focalización en el área de interés de triángulo facial (imagen fuente propia).

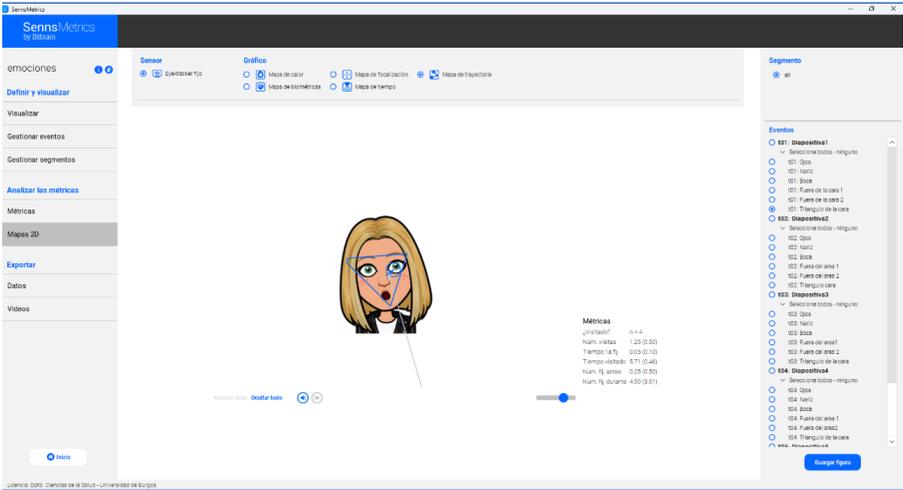


Figura 60. Mapa de trayectoria en el área de interés de triángulo facial (imagen fuente propia).

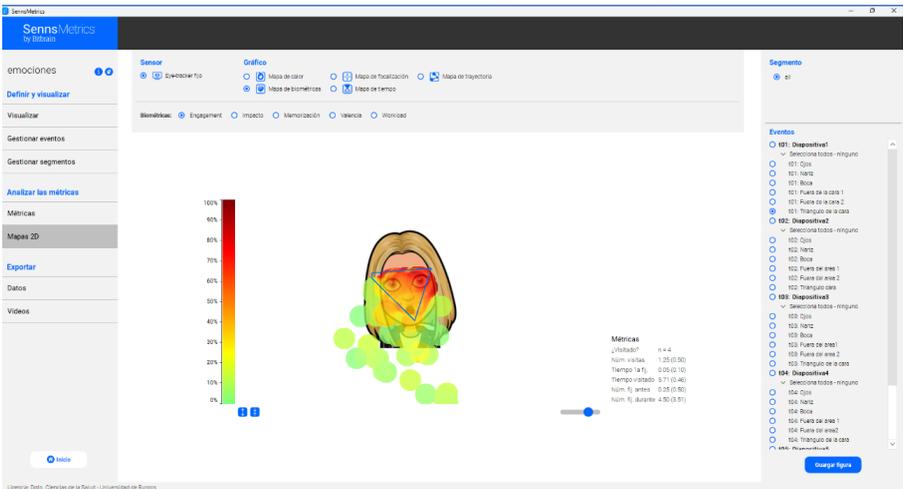


Figura 61. Mapa de biométricas en el área de interés de triángulo facial (imagen fuente propia).

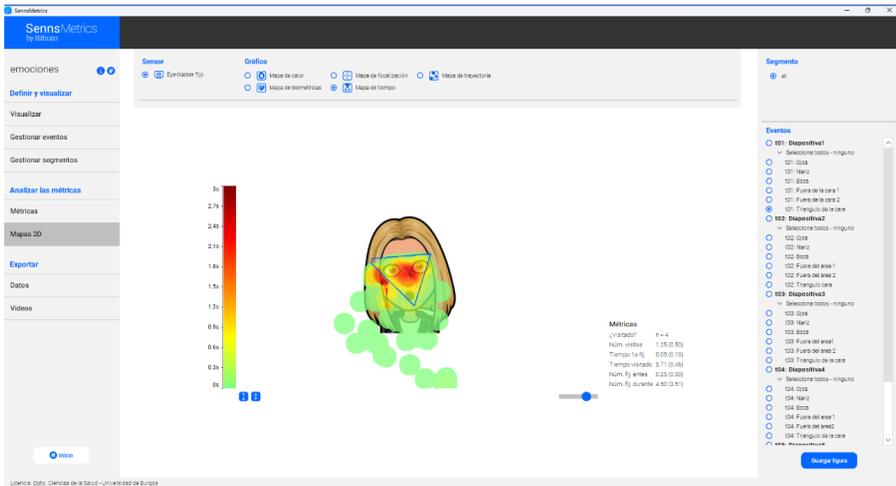


Figura 62. Mapa de tiempo en el área de interés de triángulo facial (imagen fuente propia).

3.1.5. Marcadores biométricos aplicación a la evaluación e intervención psicológica.

Los resultados de estudios recientes sobre el uso de medidas biométricas aplicadas al análisis del procesamiento de la información son prometedores. Las medidas biométricas permiten capturar los comportamientos inconscientes e involuntarios de las personas (Borgianni y Maccioni, 2020). El uso de las medidas biométricas es útil para conocer las formas de procesamiento de la información y las respuestas emocionales en humanos. También, se están realizando distintos estudios para comprobar la efectividad de la aplicación de diferentes técnicas de *Machine Learning* respecto de la precisión en el análisis de los resultados de los distintos registros biométricos (Borgianni y Maccioni, 2020). Concretamente, se ha encontrado una alta efectividad de las técnicas de aprendizaje automático de regresión respecto del uso de los algoritmos Naive Bayes y los algoritmos de árbol de decisión J48 y Random Forest (ver Módulo IV.1).

Seguidamente, se presentan una serie de estudios que pueden orientar el trabajo de los psicólogos en este campo.

Wadhwa, H., Dhir, K., y Deswal, L. (2025). Applicability of eye tracking technology in virtual keyboard for human-computer interactions. *Next Generation Computing and Information Systems - Proceedings of the 2nd International Conference on Next-Generation Computing and Information Systems, ICNGCIS 2023*, pp. 80–87.

Abstract

The vast field of Human-Computer Interaction, or HCI, which is primarily concerned with the interactions between people and computers, used to be solely con-

cerned with scientific testing in the past. But nowadays it also designs user-focused interfaces and aids in the creation of smart surroundings. We have discussed the detailed applications of HCI. However, a lot of difficulties arise in implementing environment friendly solutions as a result of these advancements in HCI. It has been related to eudaimonia, which is the concept of feeling meaningfulness, realizing one's potential. Moreover, practically any area may now apply HCI, including industrial design, psychology, sociology, and computer science. Further, we analyzed the evolution of HCI over the past decade. Developments in HCI research have also led to the invention of the eye tracking control-based system. The use of an eye-tracking system to enhance learning processes and facilitate accurate and efficient visual recognition of geospatial data has also been covered in this study. In addition, a typing experiment is carried out where participants are given access to a virtual keyboard in order to better understand how this technology might improve users' accuracy and speed when typing. The Technology Acceptance Model (TAM), which is used in this experiment, allows us to determine whether or not consumers are adopting the suggested technology based on responses to the TAM questionnaire. The majority of users deemed this system to be helpful, simple to use, and understandable, based on the experiment's outcomes and the TAM questionnaire. The investigation revealed that while female participants' average accuracy was lower than male participants', male participants' average speed was higher. Later in the paper, we have elaborated challenges of HCI, a few of which are ethics, privacy, security, accessibility, learning and creativity, etc.

Golbabaei, S., y Borhani, K. (2024). Nearsighted empathy: exploring the effect of empathy on distance perception, with eye movements as modulators. *Sci Rep*, 14, 25146 <https://doi.org/10.1038/s41598-024-76731-0>

Abstract

Empathy, a cornerstone of social interaction, involves shared representation, eliciting vicarious emotions. However, its influence on shared perceptual representations, particularly in foundational domains such as distance perception, remains unexplored. In this study, we introduce a novel adaptation of the empathy for pain task to investigate empathy's influence on distance perception. We also examine how two personality traits, trait empathy and alexithymia, modulate this relationship. Utilizing eye-tracking technology, we examine how attention allocation to different facial and bodily features affects empathy's impact on distance perception. Our findings indicate that empathy biases individuals to perceive targets as closer, with trait empathy reinforcing this effect and alexithymia attenuating it. Furthermore, we demonstrate that heightened attention to eyes and face correlates with perceiving targets as closer, while attention to hand shows the opposite trend. These results underscore the broader influence of empathy beyond shared emotions, revealing its capacity to alter perceptual processes. By elucidating the interplay between personality traits and visual inputs in shaping these alterations, our study offers valuable

insights for future research exploring the role of shared representation in empathy across various perceptual domains.

Stevens, E.M., Lee, D.N., Stevens, H. et al. The role of mood in shaping reactions to smoking cessation messages among adults who smoke: a multimodal investigation. *BMC Public Health* 24, 2872 (2024). <https://doi.org/10.1186/s12889-024-20140-5>

Abstract

Introduction: Mood-tailored communications may help increase the effectiveness of smoking cessation messaging interventions. We used both self-report and psychophysiological measures to test the impact of mood on responses to cessation messages in adults who smoke. **Methods:** In a two-part (crowdsourcing and psychophysiological studies) study, the impact of 30 smoking cessation messages comprised of five themes (i.e., financial, health, quality-of-life, challenges in quitting, motivation to quit) were tested. In a crowdsourcing study, participants (N=600) were randomly placed into one of three mood induction tasks (i.e., positive, negative, neutral), and then viewed the smoking cessation messages. After each message, they were asked to self-report their motivation to quit, message receptivity, and the perceived relevance of the messages. In an in-lab, psychophysiological study, participants (N=42) completed the same tasks as the crowdsourcing participants but were monitored for heart rate, skin conductance, and eye-tracking while viewing the cessation messages. Using a multi-attribute decision-making model (MADM) using outcomes from both studies, messages were ranked for each mood state. **Results:** The top messages for participants in the positive mood condition included the challenges in quitting, financial costs/rewards, and motivations to quit themes. The top messages for participants assigned to the negative mood condition included the challenges in quitting, quality-of-life, and financial costs/rewards themes. For participants in the neutral mood condition, messages in the challenges in quitting and quality of life themes performed best. **Conclusions:** Variations in the preferences of messages and themes by mood condition suggest that mood-tailored communication may increase the effectiveness of smoking cessation messages.

Silvestri, F., Odisho, N., y Kumar, A. et al. Examining gaze behavior in undergraduate students and educators during the evaluation of tooth preparation: an eye-tracking study. *BMC Med Educ*, 24, 1030 (2024). <https://doi.org/10.1186/s12909-024-06019-4>

Abstract

Background: Gaze behavior can serve as an objective tool in undergraduate pre-clinical dental education, helping to identify key areas of interest and common pitfalls in the routine evaluation of tooth preparations. Therefore, this study aimed to investigate the gaze behavior of undergraduate dental students and dental educators while evaluating a single crown tooth preparation. **Methods:** Thirty-five participants

volunteered to participate in the study and were divided into a novice group (dental students, $n=18$) and an expert group (dental educators, $n=17$). Each participant wore a binocular eye-tracking device, and the total duration of fixation was evaluated as a metric to study the gaze behavior. Sixty photographs of twenty different tooth preparations in three different views (buccal, lingual, and occlusal) were prepared and displayed during the experimental session. The participants were asked to rate the tooth preparations on a 100 mm visual analog rating scale and were also asked to determine whether each tooth preparation was ready to make an impression. Each view was divided into different areas of interest. Statistical analysis was performed with a three-way analysis of the variance model with repeated measures. Results: Based on the participants' mean rates, the "best" and the "worst" tooth preparations were selected for analysis. The results showed a significantly longer time to decision in the novices compared to the experts ($P=0.003$) and a significantly longer time to decision for both the groups in the best tooth preparation compared to the worst tooth preparation ($P=0.002$). Statistical analysis also showed a significantly longer total duration of fixations in the margin compared to all other conditions for both the buccal ($P<0.012$) and lingual ($P<0.001$) views. Conclusions: The current study showed distinct differences in gaze behavior between the novices and the experts during the evaluation of single crown tooth preparation. Understanding differences in gaze behavior between undergraduate dental students and dental educators could help improve tooth preparation skills and provide constructive customized feedback.

Kim, M., Lee, J., Lee, S.Y. et al. (2024). Development of an eye-tracking system based on a deep learning model to assess executive function in patients with mental illnesses. *Sci Rep*, 14, 18186. <https://doi.org/10.1038/s41598-024-68586-2>

Abstract

Patients with mental illnesses, particularly psychosis and obsessive-compulsive disorder (OCD), frequently exhibit deficits in executive function and visuospatial memory. Traditional assessments, such as the Rey-Osterrieth Complex Figure Test (RCFT), performed in clinical settings require time and effort. This study aimed to develop a deep learning model using the RCFT and based on eye tracking to detect impaired executive function during visuospatial memory encoding in patients with mental illnesses. In 96 patients with first-episode psychosis, 49 with clinical high risk for psychosis, 104 with OCD, and 159 healthy controls, eye movements were recorded during a 3-min RCFT figure memorization task, and organization and immediate recall scores were obtained. These scores, along with the fixation points indicating eye-focused locations in the figure, were used to train a Long Short-Term Memory + Attention model for detecting impaired executive function and visuospatial memory. The model distinguished between normal and impaired executive function, with an F1 score of 83.5%, and identified visuospatial memory deficits, with an F1 score of 80.7%, regardless of psychiatric diagnosis. These findings suggest that this eye tracking-based deep learning model can directly and rapidly identify

impaired executive function during visuospatial memory encoding, with potential applications in various psychiatric and neurological disorders.

Öztürk, D., Aydoğan, S., Kök, İ. et al. (2024). Linguistic summarization of visual attention and developmental functioning of young children with autism spectrum disorder. *Health Inf Sci Syst*, 12, 39. <https://doi.org/10.1007/s13755-024-00297-4>

Abstract

Diagnosing autism spectrum disorder (ASD) in children poses significant challenges due to its complex nature and impact on social communication development. While numerous data analytics techniques have been proposed for ASD evaluation, the process remains time-consuming and lacks clarity. Eye tracking (ET) data has emerged as a valuable resource for ASD risk assessment, yet existing literature predominantly focuses on predictive methods rather than descriptive techniques that offer human-friendly insights. Interpretation of ET data and Bayley scales, a widely used assessment tool, is challenging for ASD assessment of children. It should be understood clearly to perform better analytic tasks on ASD screening. Therefore, this study addresses this gap by employing linguistic summarization techniques to generate easily understandable summaries from raw ET data and Bayley scales. By integrating ET data and Bayley scores, the study aims to improve the identification of children with ASD from typically developing children (TD). Notably, this research represents one of the pioneering efforts to linguistically summarize ET data alongside Bayley scales, presenting comparative results between children with ASD and TD. Through linguistic summarization, this study facilitates the creation of simple, natural language statements, offering a first and unique approach to enhance ASD screening and contribute to our understanding of neurodevelopmental disorders.

Wang, J., Zhang, J., Xu, P. et al. (2024). Is game-based therapy effective for treating cognitive deficits in adults with schizophrenia? Evidence from a randomized controlled trial. *Transl Psychiatry*, 14, 291 (2024). <https://doi.org/10.1038/s41398-024-02920-0>

Abstract

Cognitive deficits in schizophrenia are a major contributor to poor functional outcomes and everyday functioning, making them a promising therapeutic target. Recent years have witnessed a dramatic increase in the use of digital interventions, such as game-based therapy, targeting various domains of cognition to treat mental disorders. Game-based digital interventions have been suggested to have therapeutic value in health care for people with schizophrenia. To support this idea, a novel, online training program (Komori Life) that targets cognitive deficits in schizophrenia was tested for feasibility of use and initial efficiency. Inpatients with schizophrenia were randomized to complete 20 sessions of either Komori Life (N = 40 completers) or treatment as usual (N = 40 completers). Cognitive and clinical assessments

were performed at enrollment and after completion of the training intervention for all patients. In addition, 32 healthy volunteers were recruited as controls, and an eye-tracking paradigm was employed to assess attentional biases to emotional information before and after game intervention for all subjects. The results showed that there were no group differences in cognitive or clinical assessments at baseline between the two patient groups. After game training, there were still no group \times time interactions on cognitive or clinical assessment scores. Regarding eye movement measurements, both patient groups showed increased attention to threatening stimuli compared to healthy controls in terms of attentional maintenance at baseline. After game training, the game training group revealed greater improvement in attentional bias towards threatening scenes (decreased percentage of total duration and percentage of total fixations towards threatening stimuli) relative to the treatment as usual group. Moreover, our results partially indicated that training effectiveness was associated with cognitive improvement and that heightened attentional maintenance to threats was associated with worse cognitive performance. This study provides initial evidence that a remote, online cognitive training program is feasible and effective in improving cognitive function in schizophrenia. This form of training may serve as a complementary therapy to existing psychiatric care. Clinical trial registration: the trial is registered at <http://www.chictr.org.cn>, identifier ChiCTR2100048403.

Rollins, L., Khoo, A. y Bennett, K. (2024). Event-related potentials during encoding coincide with subsequent forced-choice mnemonic discrimination. *Sci Rep*, 14, 15859 <https://doi.org/10.1038/s41598-024-66640-7>

Abstract

Computational models and eye-tracking research suggest that encoding variability accounts for the reduced recognition of targets (A) when paired with non-corresponding lures (B') relative to corresponding lures (A'). The current study examined whether neural activity during learning coincided with subsequent performance on the forced-choice Mnemonic Similarity Task (MST). Event-related potential responses were collected during encoding while young adults completed A–B' and A–A' trials of the forced-choice MST. Consistent with previous research, performance was lower on A–B' trials than A–A' trials. The subsequent memory effect was not significant for the A–A' test format. However, for A–B' trials, we observed a significant Accuracy \times Stimulus interaction 1000–1200 ms poststimulus onset across frontal and fronto-central electrodes. As hypothesized, subsequently correct A–B' trials were associated with a larger amplitude response at encoding to the target (A) than the original version of the non-corresponding lure (B). However, subsequently incorrect trials were associated with a larger amplitude response to the non-corresponding lure (B) than the target stimulus (A). These findings provide additional support for the effect of encoding variability on mnemonic discrimination.

Lee, Y.T., Chang, Y.H., Tsai, H.J. et al. (2024). Altered pupil light and darkness reflex and eye-blink responses in late-life depression. *BMC Geriatr*, 24, 545 <https://doi.org/10.1186/s12877-024-05034-w>

Abstract

Background: Late-life depression (LLD) is a prevalent neuropsychiatric disorder in the older population. While LLD exhibits high mortality rates, depressive symptoms in older adults are often masked by physical health conditions. In younger adults, depression is associated with deficits in pupil light reflex and eye blink rate, suggesting the potential use of these responses as biomarkers for LLD. **Methods:** We conducted a study using video-based eye-tracking to investigate pupil and blink responses in LLD patients (n = 25), older (OLD) healthy controls (n = 29), and younger (YOUNG) healthy controls (n = 25). The aim was to determine whether there were alterations in pupil and blink responses in LLD compared to both OLD and YOUNG groups. **Results:** LLD patients displayed significantly higher blink rates and dampened pupil constriction responses compared to OLD and YOUNG controls. While tonic pupil size in YOUNG differed from that of OLD, LLD patients did not exhibit a significant difference compared to OLD and YOUNG controls. GDS-15 scores in older adults correlated with light and darkness reflex response variability and blink rates. PHQ-15 scores showed a correlation with blink rates, while MoCA scores correlated with tonic pupil sizes. **Conclusions:** The findings demonstrate that LLD patients display altered pupil and blink behavior compared to OLD and YOUNG controls. These altered responses correlated differently with the severity of depressive, somatic, and cognitive symptoms, indicating their potential as objective biomarkers for LLD.

Frenkel, J., Cajar, A., Engbert, R. et al. (2024). Exploring the impact of nonverbal social behavior on learning outcomes in instructional video design. *Sci Rep*, 14, 12867. <https://doi.org/10.1038/s41598-024-63487-w>

Abstract

Online education has become increasingly popular in recent years, and video lectures have emerged as a common instructional format. While the importance of instructors' nonverbal social cues such as gaze, facial expression, and gestures for learning progress in face-to-face teaching is well-established, their impact on instructional videos is not fully understood. Most studies on nonverbal social cues in instructional videos focus on isolated cues rather than considering multimodal nonverbal behavior patterns and their effects on the learning progress. This study examines the role of instructors' nonverbal immediacy (a construct capturing multimodal nonverbal behaviors that reduce psychological distance) in video lectures with respect to learners' cognitive, affective, and motivational outcomes. We carried out an eye-tracking experiment with 87 participants (Mage = 24.11, SD = 4.80). Results of multilevel path analyses indicate that high nonverbal immediacy substan-

tially increases learners' state motivation and enjoyment, but does not affect cognitive learning. Analyses of learners' eye movements show that learners allocate more attention to the instructor than to the learning material with increasing levels of non-verbal immediacy displayed by the instructor. The study highlights the importance of considering the role of multimodal nonverbal behavior patterns in online education and provides insights for effective video lecture design.

Imbert, L., Neige, C., Moirand, R. et al. (2024). Eye-tracking evidence of a relationship between attentional bias for emotional faces and depression severity in patients with treatment-resistant depression. *Sci Rep*, 14, 12000 <https://doi.org/10.1038/s41598-024-62251-4>

Abstract

In a retrospective study, 54 patients with treatment-resistant major depressive disorder (TRD) completed a free-viewing task in which they had to freely explore pairs of faces (an emotional face (happy or sad) opposite to a neutral face). Attentional bias to emotional faces was calculated for early and sustained attention. We observed a significant negative correlation between depression severity as measured by the 10-item Montgomery-Åsberg Depression Rating Scale (MADRS) and sustained attention to happy faces. In addition, we observed a positive correlation between depression severity and sustained attention to sad faces. No significant correlation between depression severity and early attention was found for either happy or sad faces. Although conclusions from the current study are limited by the lack of comparison with a control group, the eye-tracking free-viewing task appears to be a relevant, accessible and easy-to-use tool for measuring depression severity through emotional attentional biases in TRD.

Chvátal, R., Slezáková, J., y Popelka, S. (2024). Analysis of problem-solving strategies for the development of geometric imagination using eye-tracking. *Educ Inf Technol*, 29, 12969–12987. <https://doi.org/10.1007/s10639-023-12395-z>

Abstract

In the realm of mathematics education, geometry problems assume a pivotal role by fostering abstract thinking, establishing a connection between theory and practice, and offering a tangible portrayal of reality. This study focuses on comprehending problem-solving methodologies by observing the eye movements of 45 primary and multi-year grammar school pupils, aged 11 to 14, as they tackled pictorial geometry problems without computation. The utilization of eye-tracking technology, specifically the OGAMA tool, was essential in unveiling the nuanced strategies employed by students. Visual attention metrics were determined through fixations on predefined areas of interest, identified using the ScanGraph tool. Through an analysis of eye movements, participants were categorized into three distinct groups based on their problem-solving strategies. This categorization facilitated an exploration of the correlation between the chosen strategy and the success rate in solving geome-

try problems without computational aids. The findings underscore the imperative for continued investigation into strategies for solving geometry problems without computation. Additionally, the research aims to broaden its scope by delving into the metacognitive strategies applied in solving imaginative geometric tasks.

Liang, Z., Ga, R., Bai, H., Zhao, Q., Wang, G., Lai, Q., Chen, S., Yu, Q., y Zhou, Z. (2024). Teaching expectancy improves video-based learning: Evidence from eye-movement synchronization. *British Journal of Educational Technology*, 00, 1–19. <https://doi.org/10.1111/bjet.13496>

Abstract

Video-based learning (VBL) is popular, yet students tend to learn video material passively. Instilling teaching expectancy is a strategy to promote active processing by learners, but it is unclear how effective it will be in improving VBL. This study examined the role of teaching expectancy on VBL by comparing the learning outcomes and metacognitive monitoring of 94 learners with different expectancies (teaching, test or no expectancy). Results showed that the teaching expectancy group had better learning outcomes and no significant difference in the metacognitive monitoring of three groups. We further explored the visual behaviour patterns of learners with different expectancies by using the indicator of eye-movement synchronization. It was found that synchronization was significantly lower in both the teaching and test expectancy groups than in the no expectancy group, and the test expectancy group was significantly lower than the teaching expectancy group. This result suggests that both teaching and test expectancy enhance the active processing of VBL. However, by sliding window analysis, we found that the teaching expectancy group used a flexible and planned attention allocation. Our findings confirmed the effectiveness of teaching expectancy in VBL. Also, this study provided evidence for the applicability of eye-tracking techniques to assess VBL.

Otros estudios

Borgianni Y, y Maccioni L. (2020). Review of the use of neurophysiological and biometric measures in experimental design research. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 34(2), 248-285. <https://doi.org/10.1017/S0890060420000062>

Chvátal, R., Slezáková, J., y Popelka, S. (2024). Analysis of problem-solving strategies for the development of geometric imagination using eye-tracking. *Educ Inf Technol*, 29, 12969–12987. <https://doi.org/10.1007/s10639-023-12395-z>

Frenkel, J., Cajar, A., Engbert, R. et al. (2024). Exploring the impact of nonverbal social behavior on learning outcomes in instructional video design. *Sci Rep*, 14, 12867. <https://doi.org/10.1038/s41598-024-63487-w>

- Golbabaie, S., y Borhani, K. (2024). Nearsighted empathy: exploring the effect of empathy on distance perception, with eye movements as modulators. *Sci Rep*, *14*, 25146 <https://doi.org/10.1038/s41598-024-76731-0>
- Imbert, L., Neige, C., Moirand, R. et al. (2024). Eye-tracking evidence of a relationship between attentional bias for emotional faces and depression severity in patients with treatment-resistant depression. *Sci Rep*, *14*, 12000 <https://doi.org/10.1038/s41598-024-62251-4>
- Kim, M., Lee, J., Lee, S.Y. et al. (2024). Development of an eye-tracking system based on a deep learning model to assess executive function in patients with mental illnesses. *Sci Rep*, *14*, 18186. <https://doi.org/10.1038/s41598-024-68586-2>
- Lee, YT., Chang, YH., Tsai, HJ. et al. (2024). Altered pupil light and darkness reflex and eye-blink responses in late-life depression. *BMC Geriatr*, *24*, 545 <https://doi.org/10.1186/s12877-024-05034-w>
- Liang, Z., Ga, R., Bai, H., Zhao, Q., Wang, G., Lai, Q., Chen, S., Yu, Q., y Zhou, Z. (2024). Teaching expectancy improves video-based learning: Evidence from eye-movement synchronization. *British Journal of Educational Technology*, *00*, 1–19. <https://doi.org/10.1111/bjet.13496>
- Öztürk, D., Aydoğan, S., Kök, İ. et al. (2024). Linguistic summarization of visual attention and developmental functioning of young children with autism spectrum disorder. *Health Inf Sci Syst*, *12*, 39. <https://doi.org/10.1007/s13755-024-00297-4>
- Rollins, L., Khuu, A., y Bennett, K. (2024). Event-related potentials during encoding coincide with subsequent forced-choice mnemonic discrimination. *Sci Rep*, *14*, 15859 <https://doi.org/10.1038/s41598-024-66640-7>
- Sáiz-Manzanares, M.C. (2024). MÓDULO VII.3. Intervención temprana y aplicación de recursos inteligentes: *Intelligent Personal Assistants*. En M.C. Sáiz-Manzanares, M.C., M. Santamaría Vázquez (Eds.), *Formación y Especialización en Atención Temprana: uso de Recursos Tecnológicos y de Inteligencia Artificial* (357- 381). Burgos: Servicio de Publicaciones de la Universidad de Burgos. <https://doi.org/10.36443/9788418465802>
- Sáiz-Manzanares, M. C., Marticorena-Sánchez, R., Sáez-García, J., y González-Díez, I. (2024). Analysing Virtual Labs Through Integrated Multi-Channel Eye-Tracking Technology: A Proposal for an Explanatory Fit Model. *Appl. Sci.*, *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. *Appl. Sci.*, 14(16), 7017. <https://doi.org/10.3390/app14167017>

Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Martín-Antón, L.J., González-Díez, I., y 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., y 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., González Díez, I., y Varela Vázquez, C. (2023). Eye-Tracking Technology Applied to the Teaching of University Students in Health Sciences. In P. García Bringas et al. (Eds.), *International Joint Conference 16th International Conference on Computational Intelligence in Security for Information Systems (CISIS 2023) 14th International Conference on European Transnational Education (ICEUTE 2023) Proceedings. Lecture Notes in Networks and Systems N° 748* (pp. 261-272). ISSN 2367-3370 ISSN 2367-3389 (electronic) Lecture Notes in Networks and Systems. Switzerland: Springer.

Sáiz-Manzanares, M.C., Marticorena-Sánchez, R., Escolar-Llamazares, M.C., Rodríguez-Arribas, S., y Andrés López, G. (2023). Digitalización y Psicología Instruccional. En F. Alcantud, J. Fernández Sánchez y Y. Alonso Esteban. *Bienestar Psicológico en la Escuela y la Familia* (pp. 301-313). Madrid: Síntesis

Sáiz-Manzanares, M.C., Ramos Pérez, I., Arnaiz-Rodríguez, Á., Rodríguez-Arribas, S., Almeida, L., y 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., Payo-Hernanz, R., 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*, e62103 <https://doi.org/10.3791/62103>

Sáiz-Manzanares, M.C., Rodríguez-Díez, J.J., Díez-Pastor, J.F., Rodríguez-Arribas, S., Marticorena, R., y Ji, P.Y. (2021). Monitoring of Student Learning in Learning Management Systems: An Application of Educational Data Mining Techniques. *Applied Sciences*, 11, 2677, 1-16. <https://doi.org/10.3390/app11062677>

- Sáiz-Manzanares, M.C., Rodríguez-Díez, J.J., Marticorena, R., Zaparaín, M.J., y 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>
- Shen, J., Elahipanah, A., y Reingold, E.M. (2007). Effects of context and instruction on the guidance of eye movements during a conjunctive visual search task. *Eye Mov.* 597–615. <https://doi.org/10.1016/B978-008044980-7/50030-6>
- Silvestri, F., Odisho, N., y Kumar, A. et al. Examining gaze behavior in undergraduate students and educators during the evaluation of tooth preparation: an eye-tracking study. *BMC Med Educ*, 24, 1030 (2024). <https://doi.org/10.1186/s12909-024-06019-4>
- Stevens, E.M., Lee, D.N., Stevens, H. et al. The role of mood in shaping reactions to smoking cessation messages among adults who smoke: a multimodal investigation. *BMC Public Health* 24, 2872 (2024). <https://doi.org/10.1186/s12889-024-20140-5>
- Wadhwa, H., Dhir, K., y Deswal, L. (2025). Applicability of eye tracking technology in virtual keyboard for human-computer interactions. Next Generation Computing and Information Systems - Proceedings of the 2nd International Conference on Next-Generation Computing and Information Systems, ICNGCIS 2023, pp. 80–87.
- Wang, J., Zhang, J., Xu, P. et al. (2024). Is game-based therapy effective for treating cognitive deficits in adults with schizophrenia? Evidence from a randomized controlled trial. *Transl Psychiatry*, 14, 291 (2024). <https://doi.org/10.1038/s41398-024-02920-0>

3.2. Preguntas de autoevaluación Tema 3.

Respuesta (se marca en negrita la respuesta verdadera)

1. Las métricas que registra la tecnología *eye tracking* pueden ser
 - a. Oscilantes.
 - b. Estáticas.
 - c. Dinámicas.
 - d. Tanto b como c.**

2. Las métricas dinámicas en *eye tracking* son:
 - a. Gaze Point.**
 - b. Sacadas.
 - c. Fijaciones.
 - d. Glance.

3. Las métricas estáticas en *eye tracking* son:
 - a. Fijaciones.
 - b. Sacadas.
 - c. Tanto a como b.**
 - d. Scan Path.

4. La Respuesta Psicogalvánica de la piel (GSR) puede medir
 - a. Activación.
 - b. Valencia.
 - c. Impacto.**
 - d. Tanto a como c.

5. Las medidas biométricas aplicadas al análisis de las conductas de resolución de tareas en humanos pueden medir:
 - a. Comportamientos conscientes y voluntarios.
 - b. Comportamientos inconscientes e involuntarios.**
 - c. Comportamientos conscientes e involuntarios.
 - d. Comportamientos inconscientes y voluntarios.

3.3. Práctica Tema 3.

Dado un registro de *eye tracking* multicanal integrado, realizar una interpretación de la medición de cada métrica y de sus posibles implicaciones psicológicas estableciendo hipótesis o preguntas de investigación.

TEMA 4

UTILIZACIÓN DE LAS TÉCNICAS DE APRENDIZAJE AUTOMÁTICO Y DE INTELIGENCIA ARTIFICIAL APLICADAS A LA PSICOLOGÍA HUMANA (PREDICCIÓN Y CLASIFICACIÓN Y CLUSTERING)

David García

Departamento de Ingeniería Informática
Escuela Politécnica Superior
Universidad de Burgos

María Consuelo Sáiz Manzanares

Departamento de Ciencias de la Salud
Facultad de Ciencias de la Salud
Universidad de Burgos

Alicia Olivares Gil

Departamento de Ingeniería Informática
Escuela Politécnica Superior
Universidad de Burgos

En este tema se va a abordar qué son las técnicas de *Machine Learning* o aprendizaje automático y su aplicación a la psicología en la intervención, la terapia y la investigación.

4.1. Datos tabulares en *Machine Learning*

Antes de comenzar con las técnicas de *Machine Learning* y con el objetivo de facilitar la comprensión de los conceptos que se explican en este tema, se van a introducir algunos conceptos clave sobre los datos, y cómo referirse a ellos.

- Todas las tareas de *Machine Learning* que se deseen plantear necesitan de datos para llevarse a cabo. Estos datos pueden provenir de cualquier campo del conocimiento, pero siempre deben representarse de forma que los algoritmos sean capaces de trabajar con ellos. Los tipos de datos más comunes son los siguientes: Datos estructurados: tablas con filas y columnas (como bases de datos).
- Datos no estructurados: textos, imágenes, audios, vídeos, etc.
- Datos semiestructurados: XML, JSON, logs, etc.

Actualmente existen multitud de algoritmos capaces de trabajar directamente con datos no estructurados o semiestructurados. Sin embargo, comprender cómo representar datos en tablas es el primer paso fundamental para introducirse en el campo del *Machine Learning*.

Los datos tabulares presentan la siguiente estructura básica:

- Cada fila de la tabla corresponde con una unidad de dato que representa un caso individual dentro del conjunto de datos. Cada fila también se puede denominar instancia, ejemplo, registro u observación. Todos estos términos son sinónimos y pueden usarse indistintamente. En términos matemáticos, cada fila suele definirse como un vector \vec{x} de atributos.
- Cada columna de la tabla corresponde con una propiedad, campo o característica de las instancias. Las columnas también se pueden denominar atributos, características, variables o *features*. En ocasiones contaremos con una columna

especial que denominaremos etiqueta, la cual se explicará más adelante al hablar de Aprendizaje Supervisado.

Como ejemplo, podemos imaginar una tabla donde cada fila corresponda con un participante de un estudio, y cada columna corresponda con una característica del mismo (edad, género, horas de sueño, nivel de estrés, etc.).

	ATRIBUTOS				
	Edad	Género	Horas de sueño	...	Nivel de Estrés
INSTANCIAS	21	F	6	...	Alto
	23	F	7.5	...	Bajo
	20	M	5.5	...	Muy alto
	33	M	8.5	...	Medio
	29	M	9	...	Alto
	31	F	8	...	Muy alto

	24	M	7.5	...	Medio

En general, podemos distinguir entre los siguientes tipos de atributos según el tipo de dato con el que se representan:

- Datos categóricos o nominales: representan categorías que identifican grupos diferentes. Por ejemplo, la columna *Género* puede tomar como valor dos categorías diferentes: F ó M.
- Datos numéricos o cuantitativos: representan cantidades medibles y se pueden hacer operaciones matemáticas con ellos. Por ejemplo, la columna *Edad* se representa mediante valores numéricos discretos (sin decimales), y la columna *Horas de sueño* se representa mediante valores numéricos continuos (puede tener decimales).
- Datos ordinales: representan categorías con un orden lógico y semántico, es decir, las diferencias entre categorías no son necesariamente iguales. Por ejemplo, la columna *Nivel de Estrés* puede tomar como valor cinco categorías diferentes: Muy bajo, Bajo, Medio, Alto y Muy alto. Este ejemplo se diferencia de un dato categórico o nominal en que la diferencia entre los valores Muy bajo y Bajo; es distinta que la diferencia entre los valores Muy bajo y Alto, ya que estos últimos están más lejos dentro de su ordenación lógica.

4.2. *Machine Learning* (ML) en el entorno de la psicología.

En este apartado se describirán pormenorizadamente los procesos de extracción y de análisis de los datos. Partiendo del supuesto de que se ha planificado un escenario de interacción, seguidamente se va a señalar cómo se pueden extraer, depurar y procesar los datos registrados en distintos entornos de registro de la información como pueden ser dispositivos (*eye tracking* multicanal integrados, plataformas, etc.).

Previamente a la extracción de los datos, el profesional tendrá que intentar dar respuesta a distintas preguntas de investigación (García, Luengo, y Herrera, 2015) y que están relacionadas con los siguientes aspectos (ver Figura 63):

- *Especificación del problema*: se realiza teniendo en cuenta estudios anteriores que revelan el estado del arte en cada disciplina.
- *Comprensión del problema*: esta fase incluye la comprensión de la selección de datos dirigidos hacia el enfoque de conocimiento concreto con el fin de alcanzar un alto grado de fiabilidad.
- *Preprocesamiento de los datos*: este estadio contempla operaciones de depuración de las bases de datos. Esta depuración se realiza eliminando ruido o datos inconsistentes para el objeto de la investigación, integrando datos que vienen de varias fuentes y transformando datos. La transformación en muchos casos significará una reducción y en otros una adaptación a las técnicas de *Machine Learning* que se van a aplicar teniendo en cuenta los *softwares* donde se van a introducir las bases de datos para su posterior procesamiento.
- *Aplicación de técnicas de Machine Learning*: son técnicas de análisis de datos que pueden ser supervisadas o no supervisadas. En dichas técnicas se emplean distintos algoritmos para distintos fines u objetivos. Además, se evalúa el rendimiento de los distintos algoritmos de minería de datos para obtener un valor cuantificable de la calidad del modelo predictivo construido. El objetivo final es la extracción de patrones de comportamiento de los datos que servirán para comprobar las hipótesis de investigación.
- *Aplicación de técnicas de evaluación*: estas estiman e interpretan los patrones hallados.
- *Explotación de los resultados*: implica hacer uso del conocimiento alcanzado en un campo de aplicación específico directamente o simplemente reportar los descubrimientos haciendo uso de herramientas de visualización e interpretación.

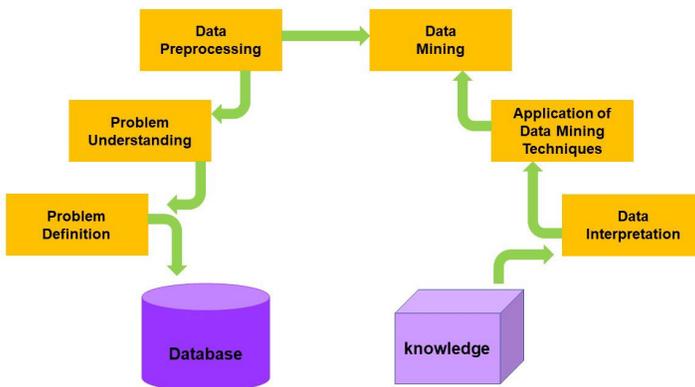


Figura 63. Imagen adaptada del original de García, Luengo, y Herrera (2015) p. 3 sobre Knowledge Discovery in Databases (KDD).

A todo este proceso en su totalidad nos referiremos como minería de datos (*Data Mining*). Algunos autores también se refieren a él como *Knowledge Discovery in Databases* (KDD).

En este proceso es especialmente importante la fase de preparación de los datos o de preprocesamiento, siguiendo a García, Luengo, y Herrera (2015, p.10-13) se pueden distinguir las siguientes fases (ver Figura 64):

- *Fase de depuración de los datos (data cleaning)*. Las bases de datos requieren un análisis de los valores y una detección, en su caso, de los valores que faltan, así como un análisis de toda aquella información que no es relevante para el propósito de la investigación.
- *Fase de Transformación de los datos (data transformation)*. Los datos tienen que prepararse para poder aplicar sobre ellos distintos algoritmos de Minería de Datos. Para ello, el investigador tiene que saber cuál es el objetivo de su investigación y, en función de ello, qué datos necesita. Además, de conocer las limitaciones de los distintos algoritmos en cuanto al tipo de datos con el que puede trabajar.
- *Fase de integración de los datos (data integration)*. Implica la fusión de datos desde múltiples bases. Este proceso debe realizarse con mucha precisión, con el fin de evitar redundancias e inconsistencias en el resultado final. Las operaciones más usuales son: identificación y unificación de variables y detección de conflictos entre los valores que proceden de distintas fuentes.
- *Fase de normalización de los datos (data normalization)*. La unidad de medida utilizada puede afectar al análisis de datos. Por ello, todos los atributos¹ deben ser expresados en las mismas unidades de medida para poder realizar comparaciones entre ellos. La normalización de los datos intenta dar a todos los atributos el mismo peso. Por ejemplo, si tenemos un atributo numérico *Horas de sueño* con valores entre 0 y 10, y otro atributo numérico *Edad* con valores entre 0 y 100, al hacer operaciones con ellos la magnitud afectará a la importancia que se da a cada uno de ellos. Para evitar esto, es habitual normalizar todas las columnas de atributos para que se representen mediante valores entre 0 y 1.
- *Fase de análisis de los valores perdidos (missing data)*. Los valores perdidos hacen referencia a datos para los que no se tiene un valor almacenado. Los datos pueden perderse debido a muchas causas: una entrada incompleta, fallos del equipo, pérdida de archivos, etc. Muchos algoritmos de *Machine Learning* no son capaces de trabajar con valores en blanco, en cuyo caso se pueden plantear dos opciones:

¹ Un atributo se entiende como la categorización que hacen las Técnicas de Machine Learning desde la fijación de valores y la predefinición de las características o de los atributos (Witten y Eibe, 2005).

- Eliminar todas las filas con datos perdidos. Es posible que haciendo esto eliminemos demasiados datos y no tengamos suficientes instancias para entrenar un modelo de *Machine Learning* adecuado.
- Realizar estimaciones mediante distintas técnicas. A estas técnicas también se las conoce como técnicas de interpolación o imputación de datos perdidos. A continuación, se listan las técnicas más simples, aunque existen muchas otras.
 - Media/moda: sustituye los valores perdidos con la media de la columna completa (si el atributo es numérico) o la moda (si el atributo es categórico).
 - Media de puntos cercanos: sustituye los valores perdidos por la mediana de los valores pertenecientes a las instancias más cercanas (más similares).
 - Interpolación lineal: sustituye los valores perdidos utilizando una interpolación lineal.
- *Fase de identificación del ruido (noise identification)*. Este paso se entiende como un paso de limpieza de datos. Podemos considerar el ruido como valores almacenados dentro de los datos originales que no tienen sentido. De nuevo, este ruido puede deberse a muchas causas: una medida imprecisa, una entrada incorrecta, fallos en el preprocesamiento, etc. Proporcionar este tipo de datos directamente a los algoritmos de *Machine Learning* puede provocar que el conocimiento logrado o los patrones encontrados en los datos sean imprecisos, ya que han aprendido a partir de información incorrecta. Por esta razón es necesario detectar las entradas ruidosas para filtrarlas o corregirlas.

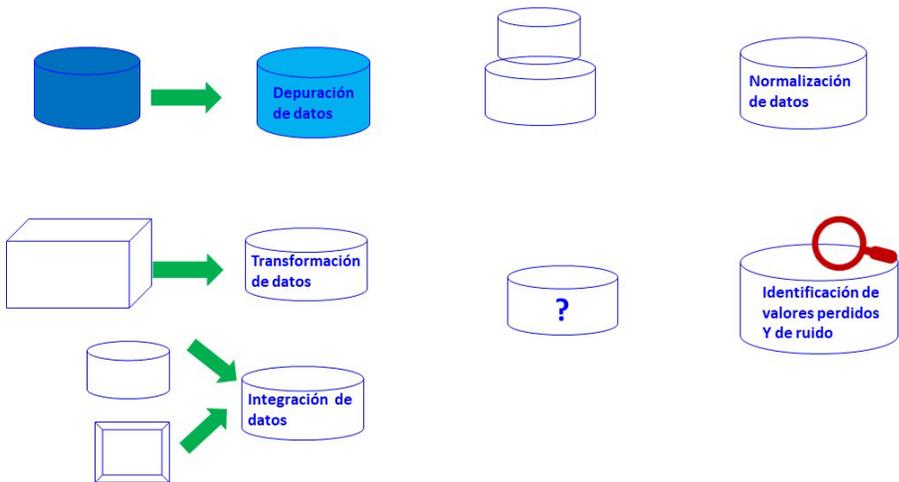


Figura 64. Imagen adaptada del original de García, Luengo, y Herrera (2015) preparación de los datos p. 12.

- *Fase de reducción de datos.* Esta incluye un conjunto de técnicas que permite la representación reducida de los datos originales. Aunque este es en muchos casos un paso opcional, es extremadamente útil en multitud de situaciones:
 - Muchos algoritmos de *Machine Learning* presentan tiempos de ejecución que escalan con el tamaño de los datos. Si este tamaño es excesivamente grande, la ejecución de dichos algoritmos puede ser prohibitiva.
 - En ocasiones varios atributos de nuestros datos presentan información altamente correlacionada o información duplicada. Por ejemplo, podemos tener una columna Edad y otra Año de nacimiento. Este caso es muy evidente ya que sabemos que ambas representan la misma información, y por lo tanto debemos quedarnos con una. Sin embargo, en ocasiones la correlación entre dos o más columnas no es tan evidente, y debemos usar técnicas específicas para detectarla y filtrarlas.
 - Es posible que tengamos atributos que no sean informativos para la tarea que queremos resolver. Un ejemplo común son las columnas de identificador único, como por ejemplo el DNI del participante o cualquier otro tipo de identificación numérico. Estas columnas no nos proporcionan información real sobre el participante, por lo que no serán útiles a la hora de extraer conocimiento. Al contrario, pueden introducir ruido en el proceso de aprendizaje, por lo que siempre deben ser eliminadas.
 - También podemos tener columnas cuyos valores presenten una varianza baja, o incluso que sean constantes. Dado que estos valores no nos proporcionan información discriminativa entre instancias, la decisión habitual será eliminarlas.

Entre las técnicas de reducción de los datos destacan la selección de características y la selección de instancias², aunque también existen otra como el *data squashing*³ y la discretización (Liu, Hussain, Tan, y Dash, 2002).

- La selección de instancias se puede realizar a través de distintos métodos: muestreo, Boosting⁴, selección de prototipos, aprendizaje basado en instancias, aprendizaje activo, etc. Habitualmente su objetivo será reducir el coste de ejecución de los algoritmos o la reducción de ruido.

² Una instancia es el conjunto de atributos que forman las entidades para las que se dispone de datos de entrada, son las instancias las que hay que clasificar, asociar o agrupar (Witten y Eibe, 2005).

³ Se define como la construcción de una base de datos más pequeña que proporciona aproximadamente los mismos resultados que con la base larga (DuMouchel, 2002).

⁴ Boosting es un meta-algoritmo de aprendizaje automático que reduce el sesgo y varianza en un contexto de aprendizaje supervisado. Boosting está basado en el cuestionamiento planteado por Kearns y Valiant (1989) sobre si un conjunto de clasificadores débiles pudiera crear un clasificador robusto. Un clasificador débil está definido para ser un clasificador el cual está solo débilmente correlacionado con la clasificación correcta (el mismo clasifica mejor que un clasificador aleatorio). En contraste, un clasificador robusto es un clasificador que tiene un mejor desempeño que el de un clasificador débil, ya que sus clasificaciones se aproximan más a las verdaderas clases.

- Por otro lado, la selección de atributos abarca principalmente los métodos de filtrado y los métodos envolventes (*wrapper*). Los métodos de filtrado se centran en calcular ciertas medidas indicativas del nivel de correlación y/o varianza de las columnas. Teniendo en cuenta estas medidas (Correlación de Pearson, Chi-cuadrado, ANOVA, varianza, etc) se eliminan las columnas con demasiada correlación y/o muy poca varianza. Por otro lado, los métodos envolventes evalúan varias combinaciones de atributos para encontrar la que funciona mejor. Suelen ser más precisos, pero más costosos, ya que el número de posibles combinaciones de atributos escala exponencialmente.

Un posible esquema de distribución de las distintas Técnicas de aprendizaje es el que diferencia entre técnicas de *Machine Learning* de aprendizaje supervisado (*supervised learning*) y de aprendizaje no supervisado (*unsupervised learning*) (ver Figura 66).

- El *aprendizaje supervisado* puede aplicarse cuando los datos están etiquetados, es decir, cuando presentan un atributo especial conocido como objetivo, clase, etiqueta o *target*. Siguiendo a García, Luengo, y Herrera (2015), el objetivo de las técnicas de aprendizaje supervisado es el descubrimiento de las relaciones entre los atributos de entrada (también llamados variables) y la etiqueta. En términos matemáticos, cada instancia de entrada suele representarse como un vector \vec{x} de atributos de entrada (variables independientes), y su etiqueta suele representarse con la variable y (variable dependiente). El proceso de aprendizaje supervisado consta habitualmente de dos fases:

1. *Entrenamiento del modelo predictivo*: el algoritmo aprende estas relaciones a partir de los datos etiquetados, es decir, a partir de las instancias con una etiqueta conocida. El producto final de esta fase es un modelo predictivo entrenado listo para usar.
2. *Predicción*: el modelo predictivo ya entrenado se usa para predecir la etiqueta de futuras instancias no etiquetadas que no han sido utilizadas durante el proceso de entrenamiento.

Dependiendo del tipo de dato asociado a la etiqueta de los datos, se puede hablar de varios tipos de predicción:

- *Clasificación* (si es de tipo categórico, con valores finitos). En este caso la etiqueta se conoce usualmente como clase. Por ejemplo: dados unos atributos de un paciente queremos predecir si éste padece una enfermedad o no. Por lo tanto, tenemos un atributo clase con dos posibles valores categóricos: «enfermedad sí» y «enfermedad no».
- *Regresión* (si es de tipo numérico, con valores infinitos). En este caso la etiqueta se conoce usualmente como valor objetivo, valor de regresión o valor de salida. Por ejemplo: dada una serie de variables del paciente como las horas de sueño, el nivel de estrés percibido, el consumo de caféina, el nivel de apoyo social... se quiere predecir su puntaje en la escala GAD-7 de ansiedad.

- *Clasificación ordinal* (si es de tipo categórico, pero las distintas clases tienen un orden lógico). En este caso los posibles valores de las clases están ordenados. Por ejemplo: dados unos atributos del entorno de un paciente, queremos predecir su grado de autoestima: «muy baja», «baja», «media», «alta», «muy alta». Estas clases tienen un orden lógico relevante, es decir, la diferencia entre «muy baja» y «baja» es menor que entre «muy baja» y «alta».
- El *aprendizaje no supervisado* suele aplicarse cuando los datos no están etiquetados. En estos casos no conocemos (o no existe) una variable objetivo o clase que queramos predecir. Por lo tanto, y siguiendo a García et al. (2015), en este caso los algoritmos no cuentan con supervisión, sino que solo disponen de datos de entrada, y por lo tanto no pueden generar un modelo predictivo. El objetivo es encontrar regularidades, irregularidades, relaciones, similitudes y asociaciones en los datos de entrada. Se puede diferenciar entre distintos tipos de tarea:
 - *Clustering (o agrupamiento)*. Es el más común y consiste en dividir un conjunto de datos en grupos o clústers de forma que las instancias dentro de cada grupo sean más similares entre sí que con los elementos de otros grupos.
 - *Reglas de asociación*. Los algoritmos tratan de encontrar relaciones de asociación entre datos. Por ejemplo: se busca modelar la probabilidad de que, si un cliente presenta una afección X, también presente otra afección Y.
 - *Detección de anomalías (o outliers)*. Los algoritmos tratan de detectar instancias anómalas con características y/o comportamientos que se desvían de los esperados o de las características y comportamientos generales del resto de los datos. Puede considerarse como un tipo especial de *clustering* donde se trata de dividir los datos entre «instancias típicas» e «instancias anómalas». (ver Figura 65).

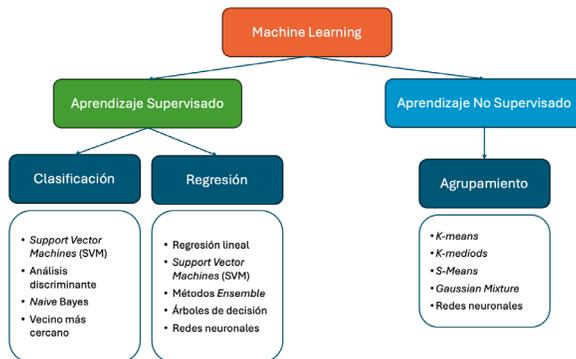


Figura 65. Clasificación de las Técnicas de Machine Learning.

4.3. Técnicas de *Machine Learning*.

Seguidamente, se exponen una serie de técnicas de *Machine Learning* utilizadas en trabajos de psicología educativa. Técnicas de aprendizaje supervisado de clasificación y de regresión, y de aprendizaje no supervisado de *clustering*.

4.3.1. Técnicas de aprendizaje supervisado.

Seguidamente, se presentan algunas de las técnicas de aprendizaje supervisado usadas en distintos artículos de investigación sobre aprendizaje.

4.3.1.1. Técnicas del vecino más cercano (Nearest Neighbor *k*-nn).

Es un método de aprendizaje supervisado que puede usarse tanto para clasificación como para regresión. Dados unos datos de entrenamiento etiquetados, la predicción de la etiqueta para una instancia nueva se calcula en base a su distancia con las *k* instancias de entrenamiento más cercanas a ella. Para calcular la distancia entre dos instancias, consideramos cada una como un vector $\vec{x}_i = (x_{i1}, x_{i2}, \dots, x_{ip})$, siendo *p* el número de atributos de entrada.

La distancia entre dos vectores puede calcularse mediante la distancia euclídea:

$$d(\vec{x}_i, \vec{x}_j) = \sqrt{(x_{i1} - x_{j1})^2 + (x_{i2} - x_{j2})^2 + \dots + (x_{ip} - x_{jp})^2}$$

Con esta definición de distancia entre instancias podemos calcular cuáles son las *k* instancias de entrenamiento más cercanas a la instancia nueva cuya etiqueta queremos predecir. El valor de *k* debe ser escogido por el usuario. En la Figura 66 se muestra un ejemplo de clasificación con dos clases: «azul» y «rojo». La instancia nueva se muestra en verde. Observamos que para *k* = 3 el vecindario contiene dos instancias rojas y una azul, por lo que se asignaría la clase «roja» a la nueva instancia. Sin embargo, si consideramos un vecindario de tamaño *k* = 5, este contiene tres instancias azules y dos rojas, por lo cual, se asignaría la clase «azul» a la nueva instancia. (ver Figura 66)

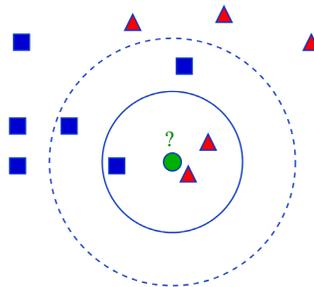


Figura 66. Tomada de Antti Ajanki AnA.

En el caso de la regresión, cada instancia de entrenamiento tendrá asignado un valor numérico en lugar de un color o clase. Por lo tanto, la etiqueta de la nueva instancia será la media de las etiquetas asociadas a cada instancia en el vecindario (en lugar de la moda).

Este tipo de técnicas se conocen como técnicas de aprendizaje vago o *lazy learning*, ya que su fase de entrenamiento consiste únicamente en almacenar los datos de entrenamiento para poder calcular su distancia con la nueva instancia en la fase de predicción.

Como hemos podido observar en el ejemplo, nuestro modelo predictivo se comportará de forma diferente dependiendo del valor de k que escojamos. La elección del valor de k dependerá del número total de datos de entrenamiento. Los valores altos de k reducen el efecto del ruido en la clasificación, ya que consideran más instancias. Sin embargo, también pueden perder detalles importantes. Los mejores valores de k (que producen modelos predictivos más precisos) se pueden encontrar mediante diversas técnicas de optimización.

Resumen del funcionamiento del algoritmo:

- Fase de entrenamiento del modelo predictivo: Simplemente se almacenan las instancias de entrenamiento (*lazy learning*).
- Fase de predicción: Para una nueva instancia con etiqueta desconocida y un tamaño de vecindario k definido, se buscan sus los k vecinos más cercanos. La etiqueta predicha corresponderá con la moda (clasificación) o la media (regresión) de las etiquetas asociadas a las instancias en el vecindario.

Ejemplo de aplicación en psicología:

Un ejemplo de procesamiento del vecino más cercano con el paquete estadístico SPSS v.24 se puede observar en la Figura 67. Se analiza la variable tipo de *Blended Learning* empleado en tres opciones de entrenamiento (1 = *Supplemental Blended (face to face)* F2F; 2 = *Replacement Blended 1*, 3 = *Replacement Blended 2*) sobre las variables de predicción que son en este caso los resultados de aprendizaje en distintas pruebas (Defensa del ABP, Elaboración del ABP y Pruebas tipo test) y en los resultados finales.

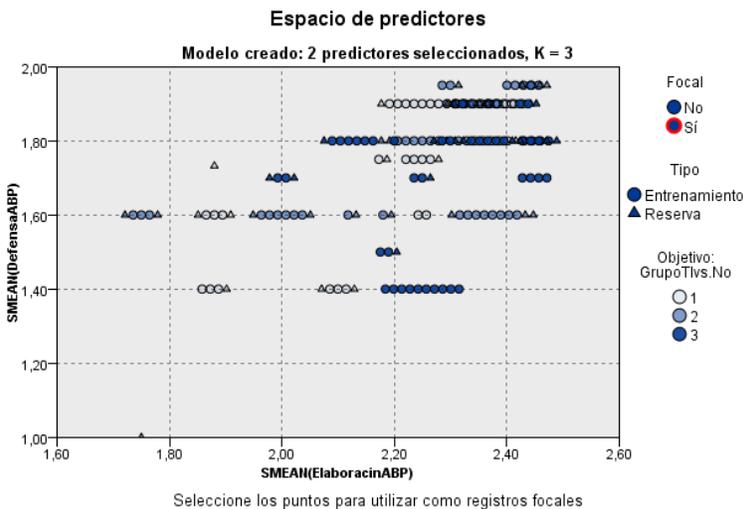


Figura 67. Aplicación de la técnica del vecino más cercano con el paquete estadístico SPSS (fuente propia).

El identificador focal permite marcar los casos que tienen un especial interés. Este método utiliza especialmente en casos clínicos, los casos focales muestran los vecinos más próximos a la variable especificada, estos valores siempre son positivos.

4.3.1.2. Regresión lineal

Es un modelo matemático que se utiliza para aproximar la relación entre dos o más variables, una que se considera la dependiente y otras que se consideran independientes o regresores y una variable de error.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \xi$$

Y sería la variable dependiente, las $\beta_i : 1 \leq i \leq n$ serían las pendientes de la recta sobre las variables independientes, n sería el número de ellas, β_0 un desplazamiento y ξ sería el error asociado.

Las rectas de regresión más satisfactorias son las que mejor se ajustan a la nube de puntos o diagrama de dispersión que se genera por la distribución binomial. Para dos variables, la recta de regresión de y sobre x sería:

$$y = \bar{y} + \frac{\sigma_{xy}}{\sigma_x^2} (x - \bar{x})$$

Puede hallarse una Regresión Lineal simple (una sola variable dependiente) o múltiple (varias variables dependientes).

Resumen del funcionamiento del algoritmo:

- Fase de entrenamiento del modelo predictivo: el algoritmo encuentra los valores de los coeficientes β_i que mejor se adaptan a los datos de entrenamiento. El resultado de esta fase es una fórmula lineal lista para usar.
- Fase de predicción: para una nueva instancia con etiqueta desconocida, los valores de sus atributos se introducen en la fórmula lineal. El resultado de aplicar dicha fórmula es el valor de regresión predicho.

Ejemplo de aplicación en psicología:

Un ejemplo con cuatro variables independientes se puede observar en la Figura 68 y la regresión sobre cada una de las variables independientes se puede comprobar en la Figura 69.

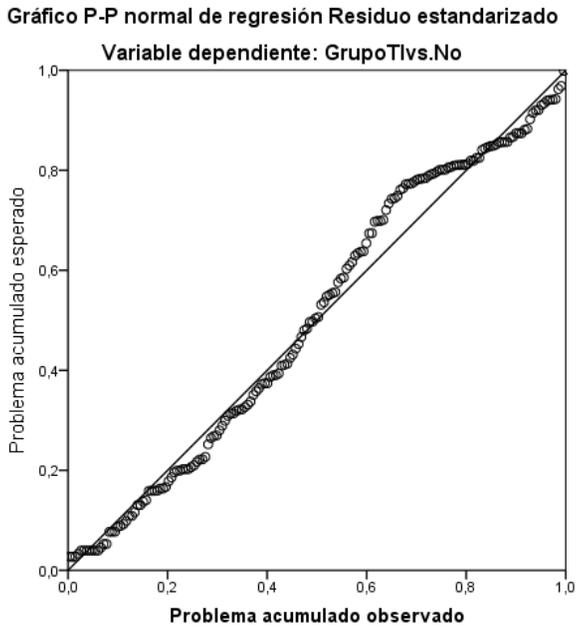


Figura 68. Gráfico de regresión de residuo estandarizado realizado con el paquete estadístico SPSS (fuente propia).

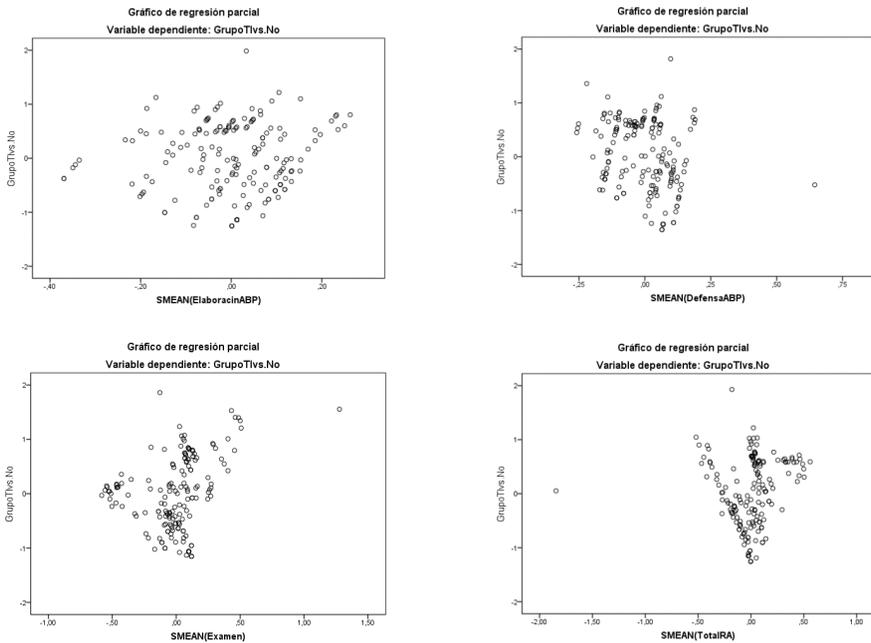


Figura 69. Gráficos de regresión parcial realizado con el paquete estadístico SPSS (fuente propia).

Asimismo, hay que tener en cuenta otros dos índices: la *Tolerancia*, o probabilidad de entrada, indica si los valores de una variable independiente son redundantes respecto de las otras variables dependientes. Si el valor de alguna de ellas es próximo a 0, habrá que eliminarla ya que dicha variable será una combinación lineal de las otras; y el Valor de Inflación de la Varianza (VIF), cuantifica la multicolinealidad en un análisis de regresión normal de mínimos cuadrados, indica hasta qué punto el cuadrado de la desviación estándar estimada se incrementa por razones de colinealidad los valores entre 1-10 se consideran adecuados. Un ejemplo de análisis de Regresión Lineal múltiple realizado con el paquete estadístico SPSS v.24 se presenta en la Figura 70.

Modelo	Coeficientes no estandarizados		Coeficientes estandarizados		t	p	Orden cero	Correlaciones		Estadísticas de colinealidad	
	B	Error estándar	Beta					Parcial	Parte	Tolerancia	VIF
1	(Constante)	-.611	.799		-.765	.446					
	SMEAN(ElaboracinABP)	.524	.420	.113	1.246	.214	.148	.095	.077	.455	2.199
	SMEAN(DefensaABP)	-1.538	.437	-.335	-3.514	.001	-.125	-.260	-.216	.415	2.407
	SMEAN(Examen)	.850	.202	.438	4.204	.000	.550	.306	.258	.347	2.881
	SMEAN(TotalRA)	.226	.201	.169	1.126	.262	.329	.086	.069	.168	5.970

a. Variable dependiente: GrupoSTI

Figura 70. Modelo de Regresión lineal Múltiple realizado con el paquete estadístico SPSS (fuente propia).

Nota. Coeficientes no estandarizados = son los coeficientes de regresión parcial que definen la ecuación de regresión en puntuaciones directas. Coeficiente estandarizado = β ayudan a determinar cuál de las variables independientes tiene mayor efecto sobre la variable dependiente y definen la ecuación de regresión en puntuaciones típicas. Colinealidad es la propiedad según la cual un conjunto de puntos está situado sobre la misma línea recta.

4.3.1.3. Árboles de decisión (*Decision Tree*).

Un árbol de decisión es un algoritmo en el que se utilizan preguntas organizadas de forma jerárquica, para guiar el proceso de asignación de clase o calcular el valor de salida. El proceso comienza en el nodo raíz, donde se pide utilizar el valor de uno de los atributos de la instancia a clasificar (o el valor de salida que desea determinar). Dependiendo del resultado de esta comparación, el proceso se dirigirá a una de entre varias ramas (normalmente, solo a dos), donde se hallará un nodo con una nueva prueba, y nuevas ramas a seguir en función del resultado. El proceso continúa hasta que se alcanza un nodo hoja (un nodo sin más ramas), donde se asigna una clase a la instancia o existe una fórmula para calcular el valor de salida de esa instancia.

El algoritmo de entrenamiento del modelo consistirá en encontrar aquella estructura de nodos (preguntas) que mejor separe las instancias de entrenamiento en sus clases o etiquetas (hojas del árbol). El proceso de construcción de un árbol de decisión también comienza en el nodo raíz. En cada nodo se dividirá el conjunto de entrenamiento, por lo que es necesario determinar cuál es el mejor atributo de división.

Si el atributo es categórico, se añadirán tantas ramas como posibles valores pueda tomar. Si por el contrario el atributo es numérico, será necesario encontrar un valor umbral que proporcione una división óptima (si se utiliza sólo un valor umbral, la división será de dos subconjuntos, es decir, dos ramas). El criterio para la selección de atributos y valores es la optimización de una función (Breiman et al., 2017; Quinlan, 2014) que mida de alguna forma la calidad de las divisiones. Una vez seleccionados el atributo y el valor del umbral, se utilizan para determinar a través de qué ramas pasa cada instancia de entrenamiento, y en los nodos de llegada correspondientes se repite el proceso iterativamente (escogiendo un nuevo atributo y construyendo nuevas ramas). Dicho proceso concluye cuando el número de instancias de entrenamiento en el nodo generado es menor que un valor determinado, o cuando se cumple cualquier otro criterio de parada. A los nodos hoja se les asigna la clase mayoritaria de las instancias que han llegado a ese nodo (o se utilizan para calcular una función que dará el valor de salida cuando el árbol se utiliza en problemas de regresión).

Los árboles de decisión son muy populares en la minería de datos y en el aprendizaje automático por varias razones: son rápidos de construir, interpretables e inestables (es decir, pequeños cambios en el conjunto de entrenamiento darán como resultado árboles muy diferentes). Esta última propiedad ha hecho que se utilicen profusamente para la construcción de «multi-clasificadores» (Maudes et al., 2012; Díez-Pastor et al., 2014) y de regresores (Pardo et al., 2013; Arnaiz-González et al., 2016b).

Resumen del funcionamiento del algoritmo:

- Fase de entrenamiento del modelo predictivo: se encuentran los atributos y valores umbral óptimos que conforman la estructura de árbol que mejor divide los datos de entrenamiento.
- Fase de predicción: para una nueva instancia con etiqueta desconocida, se hacen las preguntas empezando desde el nodo, que continuarán hasta llegar a una hoja. El valor predicho corresponderá con la etiqueta asociada a dicha hoja.

Ejemplo de aplicación con SPSS:

Un ejemplo de aplicación de árboles de decisión realizado con SPSS se puede consultar en la Figura 71 y en la Figura 72.

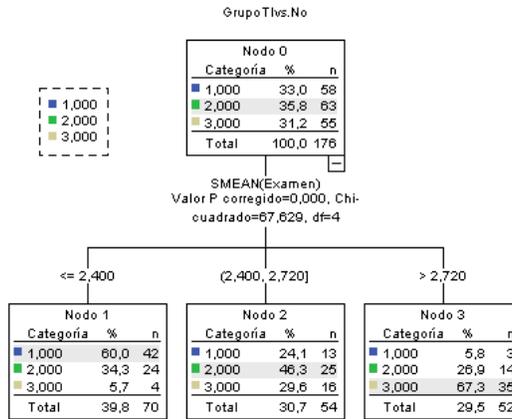


Figura 71. Árbol de decisión realizado con el paquete estadístico SPSS (fuente propia).

Nodo	1		2		3		Total		Categoría pronosticada	Nodo padre	Variable	p ^a	Chi-cuadrado	gl	Valores de división
	N	Porcentaje	N	Porcentaje	N	Porcentaje	N	Porcentaje							
0	58	33.0%	63	35.8%	55	31.3%	176	100.0%	2						
1	42	60.0%	24	34.3%	4	5.7%	70	39.8%	1	0	SMEAN(Examen)	.000	67.629	4	<= 2,400
2	13	24.1%	25	46.3%	16	29.6%	54	30.7%	2	0	SMEAN(Examen)	.000	67.629	4	(2,400, 2,720]
3	3	5.8%	14	26.9%	35	67.3%	52	29.5%	3	0	SMEAN(Examen)	.000	67.629	4	> 2,720

Figura 72. Resultados del Árbol de decisión realizado con el paquete estadístico SPSS (fuente propia).

4.3.2. Técnicas de aprendizaje no supervisado

Las técnicas de agrupamiento o *clustering* se utilizan cuando no hay información de clase que predecir, pero se busca dividir los datos en grupos naturales o clústeres. Dichos grupos reflejan subgrupos de ejemplos que comparten algunas propiedades o tienen algunas similitudes. Trabajan calculando una medida de distancia multivariada entre observaciones que están más estrechamente relacionadas (ver definición aprendizaje no supervisado). Seguidamente, se va a analizar la técnica de *k-means*.

4.3.2.1. Utilización de la técnica de clustering de *k-means*

Sea un conjunto X y una medida de distancia $d: X \times X \rightarrow \mathbb{R}$. La salida del algoritmo *k-means* es un conjunto de centros $C = \{c_1, c_2, \dots, c_k\}$ que están definiendo implícitamente un conjunto de clústeres en el que cada punto pertenece al clúster representado por el centro más cercano, $\Phi_c(x) = \text{argmin} C d(x, c)$ y del objetivo es buscar el conjunto C que minimice:

$$\sum_{x \in X} d(\Phi_c(x), x)^2$$

Lo que implica que cada punto se asignará al centro más cercano para lo que se minimizará el cuadrado de las distancias de los puntos al centro asignado.

El proceso de entrenamiento es el siguiente (Fox y Guestrin, 2018):

- El usuario decide un valor de k , que corresponde con el número de grupos o clústeres que se quieran encontrar en los datos.
- El algoritmo escoge aleatoriamente k instancias que pasarán a considerarse como los centros de los clústeres.
- Para todo el resto de instancias, se buscará su centro más cercano, asociándola a su clúster correspondiente.
- De entre todas las instancias que hayan sido asociadas a un mismo clúster, se calcula su centroide (como la media de los puntos), el cual pasará a ser el nuevo centro del clúster.
- El proceso se repite hasta que al calcular los nuevos centroides, estos no se modifican, lo que significa que el algoritmo ha convergido.

Asimismo, el método *k-means++* que tiene una calidad de optimización local. La inicialización inteligente o Smart implica la elección de un primer centro de clúster de forma uniforme desde la aleatorización de los puntos de los datos. Esto hace que los centros iniciales sean más representativos que aquellos que puedan seleccionarse aleatoriamente. Esto ayuda a acelerar el proceso de entrenamiento y a encontrar clústeres de mejor calidad.

Una vez descrita la versión más simple del algoritmo, a continuación, se exponen una serie de variantes más sofisticadas del mismo que tratan de dar solución a distintas dificultades computacionales y técnicas. El problema es computacionalmente difícil (NP-hard). Sin embargo, hay eficientes heurísticas que se emplean comúnmente y convergen rápidamente a un óptimo local. Estos suelen ser similares a los algoritmos *expectation-maximization* de mezclas de distribuciones gaussianas por medio de un enfoque de refinamiento iterativo empleado por ambos algoritmos. Además, los dos algoritmos usan los centros que los grupos utilizan para modelar los datos. Sin embargo, *k-means* tiende a encontrar grupos de extensión espacial comparable, mientras que el mecanismo *expectation-maximization* permite que los grupos tengan formas diferentes.

Dado un conjunto de observaciones o valores (x_1, x_2, \dots, x_n) cada una de ellas es un vector real de d dimensiones, *k-means* realiza una partición de las observaciones en k conjuntos ($k \leq n$) para minimizar la suma de los cuadrados dentro de cada grupo $S = \{S_1, S_2, \dots, S_n\}$ donde μ_i es la media de puntos en S_i .

$$\operatorname{argmin}_S \sum_{i=1}^k \sum_{x_j \in S_i} \|x_j - \mu_i\|^2$$

El algoritmo que se utiliza es una técnica de refinamiento iterativo o algoritmo Lloyd. Se parte de un conjunto inicial de k centroides $m_1^{(1)}, \dots, m_k^{(1)}$, el algoritmo se alterna en dos pasos.

Paso de asignación, en el que se asigna cada observación al grupo con la media más cercana, implica la partición de las observaciones respecto del diagrama de Voronoi⁵, generado por los centroides.

$$S_i^t = \{x_p :$$

Cada x_p se sitúa en un centroide $S_i^{(t)}$ aunque podría situarse en dos pasos:

Paso de actualización, se calculan los nuevos centroides como el centroide de las observaciones dentro del grupo. El algoritmo se considera que ha convergido cuando las asignaciones no cambian.

$$m_i^{(t+1)} = \frac{1}{|S_i^{(t)}|} \sum_{x_j \in S_i^{(t)}} x_j$$

En las figuras siguientes se presenta la demostración del algoritmo. (Figuras 73-76)

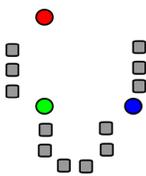


Figura 73. Centroides iniciales en este caso $k = 3$ se generan de forma aleatoria dentro de un conjunto de datos. Tomado de Weston.1 (2018).

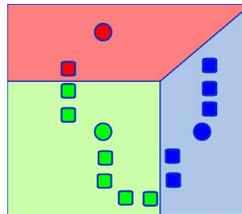


Figura 74. Los k grupos son generados asociando el punto con la media más cercana. Se realiza a través del diagrama de Voronoi generado por los centroides Weston.2 (2018).

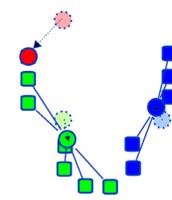


Figura 75. El centroide de cada uno de los k grupos se recalcula Weston.3 (2018).

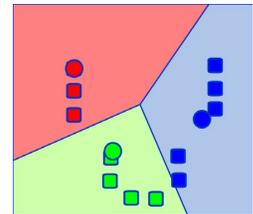


Figura 76. Los pasos 2 y 3 se repiten hasta que se logra la convergencia. Weston.4 (2018).

El número de grupos k es un parámetro de entrada y es necesario una elección adecuada del número de los grupos en un conjunto de datos. El ejemplo de Weston indica la estructura de k grupos, las cruces son los centroides y el algoritmo converge en cinco interacciones (ver Figura 77).



Figura 77. Ejemplo de convergencia del algoritmo k -means tomado de Agor (2018).

⁵ Es un método de interpolación basado en la distancia euclidiana que es especialmente adecuada cuando los datos son cualitativos. Se unen los puntos entre las distancias trazando las mediatrices de los segmentos de unión, las intersecciones de las mediatrices determinan unos polígonos en un espacio bidimensional alrededor de un conjunto de puntos de control, el perímetro de los polígonos generados es equidistante a los puntos vecinos en un área de influencia.

Una limitación de k -means es el modelo de agrupamiento, ya que esta técnica tiende a formar grupos de tamaños parecidos. En cambio un algoritmo de expectación-maximización (EM) alterna pasos de esperanza de la verosimilitud (E) mediante la inclusión de variables latentes y un paso de maximización (M), donde se computan estimadores de máxima verosimilitud mediante la maximización de la verosimilitud esperada en el paso E, Los parámetros que se encuentran en el paso M se emplean para comenzar el paso E siguiente y así sucesivamente. En la Figura 78 se puede comprobar las comparaciones de agrupamiento entre un modelo de *clustering k-mean* y uno EM.

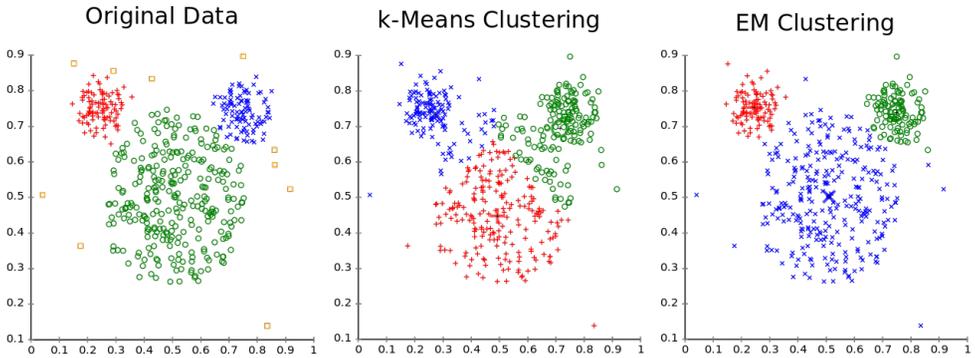


Figura 78. Comparación de agrupamiento entre un modelo de clustering *k-mean* y uno EM, tomado de Chire (2018).

El algoritmo de EM, es un algoritmo iterativo, en un primer paso estima los clústeres posibles respecto de los parámetros presentes estimados.

$$\mathbf{r} = \frac{\pi N(\mathbf{x}_i | \mu_k, \epsilon_k)}{\sum_{j=1}^k \pi_j N(\mathbf{x}_i | \mu_j, \epsilon_j)}$$

Seguidamente, se realiza *Maximum Likelihood* sobre los parámetros que presentan responsabilidades.

$$\pi_k, \mu_k, \Sigma_k | \{r_{ik}, \mathbf{x}_i\}$$

4.4. Técnicas de evaluación de modelos de *Machine Learning*.

Hasta ahora, se ha descrito cómo distintos algoritmos pueden generar modelos predictivos (ya sean de clasificación o de regresión) así como modelos de *clustering* capaces de dividir conjuntos de datos no etiquetados en *clústeres* informativos.

A continuación, se va a abordar cómo evaluar la calidad de los modelos predictivos generados, la cual hace referencia a la calidad de sus predicciones, y que dependerá del algoritmo utilizado, de la calidad y cantidad de datos de entrenamiento y de los parámetros escogidos.

Para saber si un modelo predictivo está realizando predicciones correctas, es necesario comparar dicha predicción con el valor real de la etiqueta. Sin embargo, normalmente no conocemos la etiqueta de las instancias nuevas, y esa es la razón por la que acudimos a los modelos predictivos. Si conocemos la etiqueta de las instancias que hemos usado para el entrenamiento del modelo. Sin embargo, usar dichas instancias para evaluar el modelo nos llevará a evaluaciones demasiado optimistas, ya que el objetivo es comprobar la calidad predictiva del modelo sobre datos que no haya visto antes.

Existen varias estrategias que nos permiten abordar esta problemática. La más sencilla es la división de los datos originales en **datos de entrenamiento** y **datos de test** (o validación). Al entrenar un modelo, usamos la mayoría de las instancias en el conjunto de datos original (por ejemplo, el 80%), mientras que reservamos una pequeña cantidad de instancias (por ejemplo, el 20%) para evaluación. Una vez entrenado el modelo, se utilizará para predecir la etiqueta de las instancias reservadas. Esta predicción se compara con el valor real de su etiqueta. Si la mayoría de las predicciones coincide con la etiqueta real, se considera que la capacidad predictiva del modelo es buena. Esto se puede cuantificar mediante una serie de métricas de evaluación.

Para problemas de clasificación, la métrica más simple es la exactitud (o *accuracy*). Esta se calcula como el ratio entre el número de predicciones correctas y el número total de predicciones. Si la mayoría de predicciones es correcta este ratio tendrá valores cercanos al 1, y en caso contrario tendrá valores cercanos al 0. Aunque es fácil de calcular y comprender, el *accuracy* en ocasiones proporciona evaluaciones demasiado optimistas (por ejemplo, cuando el conjunto de clases está desbalanceado). Por esa razón, existen muchas otras métricas más avanzadas que se pueden considerar en función de las características del problema concreto: precisión, *recall*, F1 score, área bajo la curva ROC, etc.

Para problemas de regresión, no sería correcto comprobar simplemente si la predicción corresponde con la etiqueta real, sino más bien si la predicción se acerca. Por ejemplo, si la etiqueta real de una instancia es 7.8 y un modelo predice un valor de 8.0, esta predicción será mejor que la de un modelo que predice un valor de 123,5. Esto se puede medir mediante una serie de métricas como el error absoluto medio (*MAE*), el error cuadrático medio (*MSE*), el coeficiente de determinación (R^2), etc.

En cuanto al uso de particiones de entrenamiento y test, aunque esta técnica es sencilla y fácil de comprender, también presenta una serie de limitaciones. En primer lugar, las instancias que entran en una partición u otra se escogen de forma aleatoria. Sin embargo, el modelo predictivo variará dependiendo de cuales de ellas se han usado para el entrenamiento. Si por casualidad, en el conjunto de entrenamiento hubieran caído las instancias «más informativas», las métricas de-

volverían valores de calidad más altos que hubieran caído las instancias «menos informativas». Podemos solucionar este sesgo de varias formas:

- Repitiendo el proceso de entrenamiento y test con varias particiones aleatorias diferentes, y calculando un valor de la métrica de calidad para cada una de ellas. Al promediar todos los valores de la métrica calculados, obtendremos una estimación de la calidad del modelo, menos sesgada y, por lo tanto, más fiable.
- Usando técnicas de validación cruzada. Esta técnica consiste en dividir el conjunto de datos original en k subconjuntos del mismo tamaño (por ejemplo, $k=10$). Uno de los subconjuntos se reserva como conjunto de test mientras que el resto se unen para conformar el conjunto de entrenamiento. Esto se repite k veces, cada una de ellas considerando un subconjunto diferente como conjunto de test. Al finalizar, se promedian todos los valores de la métrica calculados. Esta técnica garantiza que todas las instancias se han usado como instancias de entrenamiento y de test al menos una vez, reduciendo el sesgo y proporcionando una estimación de la calidad del modelo más fiable.

4.5. Minería de Datos en educación

Entre los diversos campos de aplicación de la minería de datos, encontramos el *Educational Data Mining* (EDM). Esta es una disciplina emergente que se centra en desarrollar métodos para analizar datos provenientes de entornos de educación, normalmente de plataformas de aprendizaje (por ejemplo, Moodle), con el objetivo de entender el proceso de aprendizaje de los alumnos, modelar y predecir la tasa de éxito, etc.

Como ejemplo de aplicación, se han usado técnicas de *clustering* a partir de logs para detectar, categorizar y analizar perfiles de alumnos y su relación con su desempeño en la asignatura (Cerezo, et al, 2016). (ver Figura 79)

Otros marcos de trabajo más amplios como el *Process Mining* también han sido aplicados a contextos de educación. A diferencia del *Educational Data Mining*, que se centra principalmente en el resultado y la relación de las distintas variables sobre el mismo, el *Educational Process Mining* permite realizar un análisis en el que el proceso tienen un papel central. Esta disciplina tiene como objetivo extraer conocimiento de logs de eventos provenientes de plataformas de aprendizaje, e incorpora técnicas de *Machine Learning* e inteligencia de negocio para proporcionar un conjunto de procesos de trabajo más eficientes y mejor comprendidos.

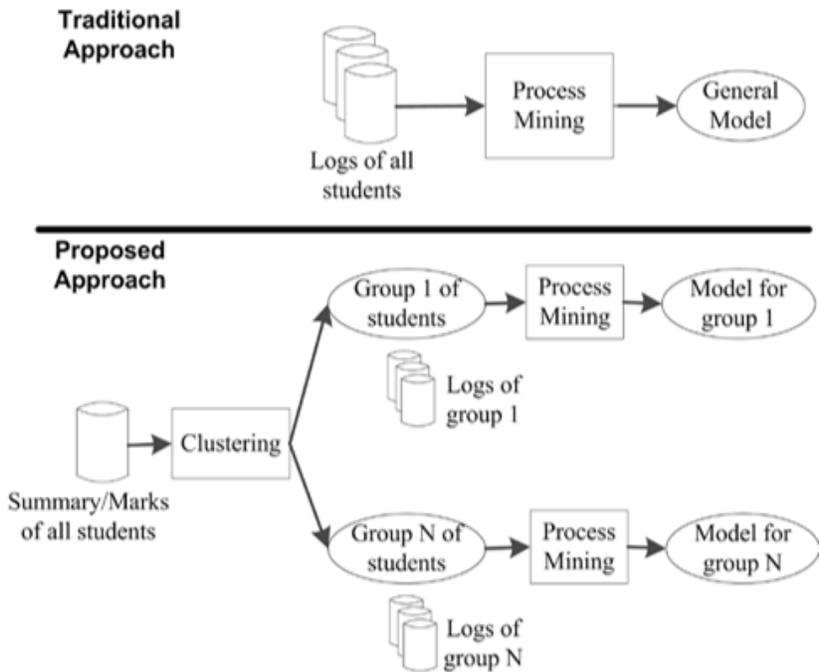


Figura 79. Esquema de análisis de datos con un procedimiento tradicional y con uno de Process Mining. Tomado de Bogarín, Romero, y Cerezo (2016) p. 77. Reproducido con permiso de los autores.

Previamente al análisis de los datos, se deberá de realizar una depuración de la base de datos con el fin de eliminar aquellos datos que no son relevantes para el estudio (ver la información recogida en este punto). Seguidamente, se podrá aplicar un algoritmo de ProM y también técnicas de ajuste como *Goodness-of-fit indices* o Índice de ajuste. Estas técnicas indican la diferencia entre el comportamiento observado en el registro y el comportamiento descrito por el modelo de proceso, una secuencia de actividades que pertenecen a un mismo caso se denomina traza, las trazas pueden estar asociadas a rutas de ejecución especificadas por el modelo de minería de procesos. También, podría utilizar EMD de aprendizaje supervisado de clasificación y de regresión. Para ello se pueden emplear distintas herramientas (Bogarín, Romero, y Cerezo, 2017a, 2017b):

- SPSS en sus paquetes de *clustering*.
- WEKA aplicando la técnica de *clustering*.
- ProM (Van Der Aalst, 2011) *Heuristics Miner*, analiza la probabilidad desde el cálculo de frecuencias o relaciones entre las tareas y los constructos de dependencia/frecuencia en tablas y en gráficos.
- *Medidas de la teoría de grafos* (número total de nodos y número total de enlaces) para analizar el nivel de complejidad de los modelos obtenidos.

- *Intention Mining (IM)* es un análisis de procesos que se focaliza en el análisis del razonamiento a través del análisis de las actividades.
- *Alpha Miner (AM)* descubre cuál será el mejor algoritmo, si bien las limitaciones de esta técnica es que no usa frecuencias y por ello sólo es adecuado cuando analiza eventos con ruido, es muy poco frecuente en el aprendizaje de datos.
- *Sequence Pattern Mining (SPM)* es una técnica común en DM y descubre las subsecuencias comunes, encuentra relaciones entre acontecimientos sucesivos. Puede analizar *episode mining (EP)* se basan en los *t-pattern analysis* de los modelos de Markov. SPM se utiliza para analizar las conductas de aprendizaje de los estudiantes.
- *Graph Mining (GM)* también denominada sub-graph mining hay que diferenciar esta técnica de la de *network analysis (SNA)* esta última puede ser considerada una parte de GM.
- *Genetic algorithm* proporciona modelos de proceso construido sobre matrices causales (entrada y salida) y dependencias para cada actividad. Este enfoque aborda problemas tales como ruido, datos incompletos, constructos de libre elección, actividades ocultas, concurrencia y actividades duplicadas. Los algoritmos genéticos son un método de optimización que maximiza o minimiza una función $f(x_1, x_2, x_3, \dots)$ ->.
- *Fuzzy miner* es un proceso de descubrimiento de algoritmos se utiliza para abordar problemas con un número grande de números y actividades que no están muy estructuradas.
- *Social Network Analysis Technique (SNA)* es una técnica sociométrica que analiza las redes de interacción social, consiste en nodos que representan la organización en entidades y arcos.
- *Visualización de procesos* permite desarrollar una interfaz de visualización del análisis de datos.

Esta forma de análisis permite el seguimiento de cada uno de los grupos detectados y por ende la puesta en marcha de orientaciones personalizadas para cada uno de ellos. Asimismo, la combinación de las técnicas de EDM y de ProM va a servir al docente para estudiar el proceso de comportamiento de todos los estudiantes desde el inicio del desarrollo de la docencia, con el objetivo último de poder adaptarla a las necesidades de cada grupo.

4.6. Utilización de la Minería de datos con el *software Orange*.

4.6.1. Introducción a la Minería de datos.

La inteligencia Artificial se puede entender como la creación de sistemas informáticos con un comportamiento inteligente. La Minería de datos se relacionaría

con la creación de sistemas que aprenden por sí mismos o que extraen conocimiento de los datos. El *Deep Learning* se puede definir como el uso de redes neuronales profundas que trabajan con grandes conjuntos de datos. Un gráfico que resume estos conceptos se puede consultar en la Figura 80.

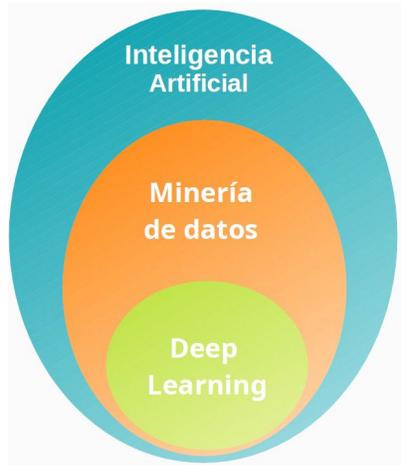


Figura 80. Inteligencia Artificial, Minería de Datos y Deep Learning.

Actualmente, la Minería de datos se utiliza en muchos ámbitos (Salud, Educación, Márquetin, Banca, Medioambiente). Minería de datos y *Machine Learning* no son conceptos exactamente iguales. La diferencia estriba en la participación humana en el proceso, hay una mayor participación en el proceso de Minería de Datos y menos en las Técnicas de *Machine Learning* donde la máquina tiene un mayor protagonismo y autonomía.

Los datos incluyen atributos (características, también denominadas variables en estadística). Estos pueden ser nominales o categóricos, numéricos o binarios (0 y 1). Estos registran también instancias o participantes. Un ejemplo, se puede consultar en la Figura 81.

Outlook	Temperature	Humidity	Windy	Class
sunny	65	85	false	Don't play
sunny	80	90	true	Don't play
overcast	83	78	false	Play
rain	70	96	false	Play
rain	68	80	false	Play
rain	65	70	true	Play

Una clase

6 instancias o ejemplos

Figura 81. Ejemplo de clases, instancias y atributos.

4.6.2. Utilización del *software Orange*

Seguidamente, se señalan los pasos para descargar el software Orange:

Paso 1. Descargar el fichero comprimido [datos.zip](#).

Paso 2. Descomprimir el fichero en una carpeta local (ejemplo: Escritorio).

Paso 3. Descargar la versión portable de [Orange](#) para Windows.

Paso 4. Descomprimir su contenido y ejecutar la aplicación Orange.

Paso 5. Seguir las instrucciones de la presentación.

Una vez descargado y ejecutado la interfaz de Orange será la que se puede comprobar en la Figura 82.

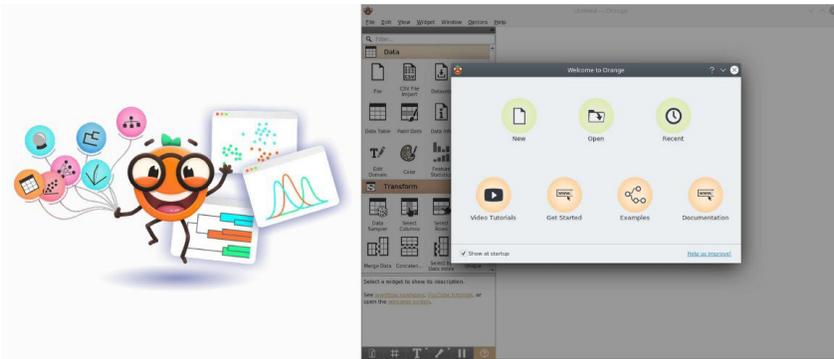


Figura 82. *Software de Data Mining Orange.*

En el menú de la izquierda se pueden consultar los *widgets* que ofrece Orange (ver Figura 83).

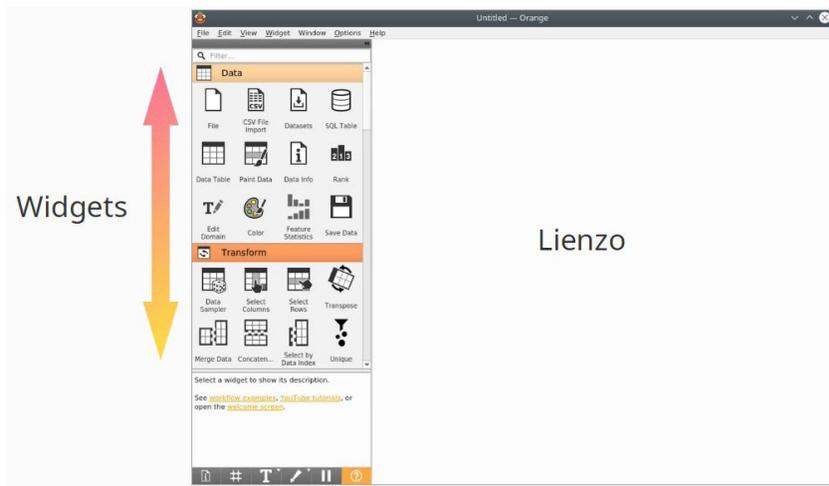


Figura 83. *Widgets que ofrece Orange.*

Para iniciar el trabajo con Orange hay que seguir los pasos de:

Paso 1. Cargar, visualizar y guardar el conjunto de datos.

Paso 2. Modificar o Transformar el conjunto de datos.

Paso 3. Visualizar el conjunto de datos y los resultados.

Paso 4. Aplicar modelos de clasificación y/o de regresión.

Paso 5. Aplicar opciones para evaluar los modelos.

Paso 6. Aplicar modelos de aprendizaje no supervisado.

Un resumen de estos pasos con los iconos de Orange se puede consultar en la Figura 84.

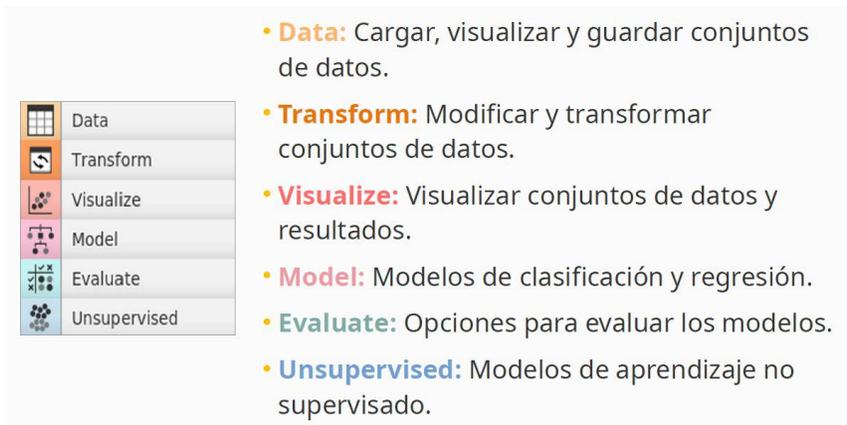


Figura 84. Carga de datos en Orange.

Para importar las bases de datos hay que tener en cuenta que antes se debe comprobar si están en un formato *Comma separated values* (.csv), para ello si se tiene la base de datos en un formato Excel español primero se debe cambiar a formato .csv y después se debe sustituir el carácter ; que separa las variables por comas.

Paso 1 base de datos en formato Excel (ver Figura 85).

	A	B	C	D	E	F	G	H
	Participant	Gender	Degree	Responses	video with or without voice	Mean duration	FixationPointX	PointY
2	P_01	1	1	2	1	173,51	1368,02	1222,54
3	P_02	1	1	2	1	159,80	797,29	690,28
4	P_03	1	1	1	1	189,97	1105,53	1079,58
5	P_04	1	1	1	1	117,79	781,62	697,35
6	P_05	1	1	1	2	109,05	750,66	679,65
7	P_06	1	1	1	1	214,43	1924,86	875,73
8	P_07	1	1	1	1	175,21	1191,76	1012,34
9	P_08	1	1	1	1	172,44	994,84	921,50
10	P_09	1	1	1	1	180,36	1263,64	1077,03
11	P_10	1	1	1	2	116,10	899,48	802,19
12	P_11	1	1	2	2	119,46	1098,46	980,13
13	P_12	1	1	2	1	105,33	1335,33	1206,77
14	P_13	1	1	1	2	224,75	766,79	641,18
15	P_14	1	1	2	2	119,50	1390,98	1247,70
16	P_15	1	1	1	1	168,17	940,09	828,76
17	P_16	1	1	1	1	140,58	930,66	836,89
18	P_17	1	1	1	2	139,57	866,19	786,50
19	P_18	1	1	1	2	140,72	1023,01	866,17
20	P_19	1	1	1	2	149,32	1137,33	1019,15

Figura 85. Base de datos en formato Excel.

Paso 2 pasar los datos a formato .csv (ver Figura 86).

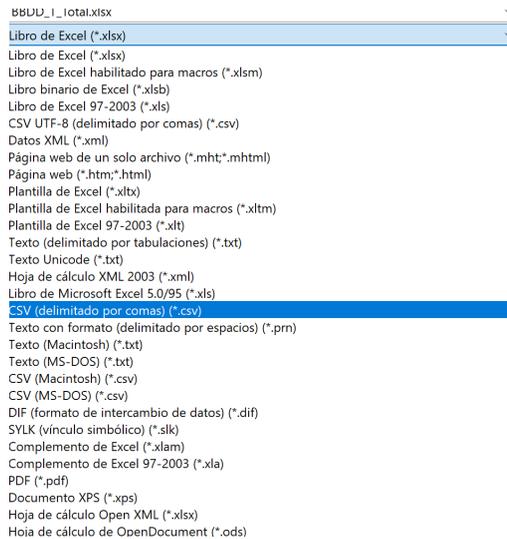


Figura 86. Datos en formato CSV.

Paso 3. Se tiene que abrir la base en formato .csv en un Notepad (ver Figura 87).

```

BDD0_T_Total_csv: Bloc de notas
Archivo Edición Formato Ver Ayuda
Participant:Gender;Degree;Responses;video with or without voice;Mean duration;FixationPointX;PointY;Average_pupil_diameter;Saccade_direction;Average_velocity
P_01;1;1;2;1173,51;1368,02;1222,54;6278,79;165771,84;7295904,95;765783,53;2020,85;1,47;10,8;9,5;10;19;11;19;5;5;1
P_02;1;1;1;159,80;799,29;690,28;4277,89;255765,83;187173,26;252184,71;473,07;1,47;10,9;9,3;3;10;20;10;17;5;4;1
P_03;1;1;1;1189,97;1105,53;1079,58;6438,40;315143,36;330385,94;499240,89;9917,40;1,47;10,9;9,3;10;18;24;8;16;4;3;2
P_04;1;1;1;1117,79;781,62;697,35;3973,83;240699,59;152868,39;236599,05;5999,68;1,47;10,11;9,3;3;10;10;27;12;23;3;5;3
P_05;1;1;1;1209,05;750,66;679,65;4401,53;266215,21;176162,50;246411,64;6173,42;1,47;10,12;8,4;10;10;17;11;17;5;2;1
P_06;1;1;1;1214,43;1024,86;875,73;7991,97;292708,31;367491,48;505115,67;7570,10;1,47;10,13;5,9;19;28;13;23;5;3;2
P_07;1;1;1;1175,21;1191,76;1012,34;5118,47;249138,00;424994,09;487305,37;4020,91;1,47;10,14;6,1;9;23;12;18;4;3;2
P_08;1;1;1;1172,44;904,84;921,50;6156,46;130426,22;1260657,37;1398529,00;2861,72;1,47;10,15;8,8;7;9;3;24;10;16;5;2;2
P_09;1;1;1;1188,36;1263,64;1077,03;6629,43;343546,21;344422,73;506602,47;10407,48;1,47;10,16;6,7;9,3;27;11;20;5;3;1
P_10;1;1;1;1216,10;899,48;802,19;4869,67;290420,51;222635,90;312534,52;6143,57;1,47;10,17;9,6;7;9,3;22;11;21;4;4;2
P_11;1;1;1;1219,46;1098,46;980,13;5555,53;331840,40;233191,56;336697,42;7671,37;1,47;10,18;7,7;9,9;3;25;9;17;4;2;1
P_12;1;1;1;1105,33;1335,33;1206,77;7465,13;405009,40;334449,85;480755,44;10354,90;1,47;10,19;6,6;9,9;3;22;11;22;4;3;1
P_13;1;1;1;1224,75;766,79;641,18;4251,65;233651,42;188450,85;270607,76;5257,00;1,47;10,2;8,9;7,9;3;24;10;18;4;3;2
P_14;1;1;1;1221,109,50;1390,98;1247,70;6784,91;431882,91;292178,34;409674,02;9793,14;1,47;10,21;7,7;9,9;3;24;10;19;4;3;2
P_15;1;1;1;1168,17;940,09;828,76;5311,03;285739,20;200085,79;278091,81;5914,27;1,47;10,22;9,1;9,9;3;28;12;20;3;3;5
P_16;1;1;1;1140,58;930,66;836,49;4399,63;278133,97;225599,73;306557,45;6703,85;1,47;10,23;9,8;9,9;3;28;11;18;4;3;1
P_17;1;1;1;12139,57;866,19;786,50;4198,94;255779,40;172290,77;230621,84;4650,01;1,47;10,24;8,2;9,9;3;21;11;16;3;2;2
P_18;1;1;1;12140,72;1023,81;866,17;6487,46;327485,25;248665,25;366871,42;8506,00;1,47;10,25;6,2;9,9;3;26;10;21;5;3;2
P_19;1;1;1;12149,32;1137,33;1181,70;1253,26;7529,81;376939,22;382706,45;537397,30;9646,79;0,02;10,10;10;26;10;11;6;4;3;2
P_20;2;1;1;12131,67;792,89;635,68;3715,67;217068,43;179853,50;248554,36;5312,31;0,58;9,00;9,5;10;10;22;10;16;4;2;2
P_21;1;1;1;12111,71;799,16;687,46;4432,55;235943,57;188488,77;280755,86;6712,06;0,01;0,00;9,5;8,8;6;19;11;20;4;4;2
P_22;1;1;1;1212,22;136,26;1119,89;1132,69;6771,37;365109,77;266353,23;398652,17;8208,04;2,60;14,00;9,5;8,0;8,6;25;12;19;4;4;2
P_23;1;1;1;12147,78;1008,85;951,40;6371,50;375132,14;219394,92;313684,60;8285,77;3,17;38,00;6,9;10,8;6;15;13;18;5;4;2
P_24;1;1;1;1148,73;1381,70;1253,26;7529,81;376939,22;382706,45;537397,30;9646,79;0,02;10,10;10;26;10;11;6;4;3;2
P_25;1;1;1;1158,96;909,70;796,27;4432,29;267580,33;201651,54;272005,44;5714,81;1,99;11,00;10,10;10;27;8;18;5;4;2
P_26;1;1;1;1135,97;1276,17;1067,30;7298,63;350534,91;323528,57;432335,20;7739,54;1,10;18,00;10,10;10;26;11;5;4;2;2
P_27;2;2;1;12136,26;1119,89;1132,69;6771,37;365109,77;266353,23;398652,17;8208,04;2,60;14,00;9,5;8,0;8,6;25;12;19;4;4;2
P_28;1;1;1;12147,78;1008,85;951,40;6371,50;375132,14;219394,92;313684,60;8285,77;3,17;38,00;6,9;10,8;6;15;13;18;5;4;2
P_29;2;2;1;1173,51;1158,17;162,18;1132,41;41797,90;49784,31;64173,60;989,92;0,01;0,00;8,9;1,9;0,28;13;14;24;4;2
P_30;1;2;1;1159,80;1121,98;934,62;6092,95;314421,73;258239,58;342779,31;6209,06;0,98;6,00;9,9;1,9;0,28;10;15;5;2;2
P_31;1;2;1;1153,58;1006,84;849,83;6145,67;319974,78;199910,41;294438,18;7372,37;1,17;8,00;9,9;1,9;0,28;10;15;5;2;2
P_32;1;1;1;1237,41;2424,80;2023,44;19140,53;104967,57;86077,42;117928,38;2608,73;1,8;16,00;9,5;9,4;24;11;19;3;4;1;2
P_33;2;3;5;2;1163,95;959,91;11358,53;51991,7;51017,96;649971300,68;2,811,00;5,9;6,11;0,00;9,9;5,9;6,26;11;20;4;2;2
P_34;1;3;4;2;276,96;2046,35;2507,55;27419,48;149285,16;88484,12;118372,64;2617,37;2,6;23,00;6,11;0,00;9,9;2,9;6,9;6,26;11;20;4;2;2
P_35;1;3;3;2;296,53;2015,78;1869,83;31266,25;106460,18;84465,25;107297,45;1844,66;0,6;11,00;9,2;9,3;26;11;21;4;4;2
P_36;2;3;2;2;321,68;4117,06;3968,60;26363,48;130553,88;112615,52;152861,24;2952,87;0,9;13,00;7,7;3,9;2,9;6,14;13;19;5;5;1
P_37;1;3;3;2;296,53;2015,78;1869,83;31266,25;106460,18;84465,25;107297,45;1844,66;0,6;11,00;9,2;9,3;26;11;21;4;4;2
P_38;2;3;2;2;321,68;4117,06;3968,60;26363,48;145586,13;121059,84;140208,22;20,77;23,00;6,11;0,00;9,9;6,9;6,26;11;20;4;2;2
P_39;1;3;1;2;241,84;4396,10;3350,83;40122,79;93213,51;101172,39;137627,01;2717,86;6,7;21,00;6,8;9,2;9,3;28;12;19;4;4;2
    
```

Figura 87. Base de datos en formato CVS.

Seguidamente se tiene que seleccionar todo y sustituir las comas por puntos (ver Figura 88).

```

BDD0_T_Total_csv: Bloc de notas
Archivo Edición Formato Ver Ayuda
P_11;1;1;2;119,46;1098,46;980,13;5555,53;331840,40;233191,56;336697,42;7671,37;1,47;10,18;7,7;9,9;3;25;9;17;4;2;1
P_12;1;1;1;105,33;1335,33;1206,77;7465,13;405009,40;334449,85;480755,44;10354,90;1,47;10,19;6,6;9,9;3;22;11;22;4;3;1
P_13;1;1;1;1224,75;766,79;641,18;4251,65;233651,42;188450,85;270607,76;5257,00;1,47;10,2;8,9;7,9;3;24;10;18;4;3;2
P_14;1;1;1;1221,109,50;1390,98;1247,70;6784,91;431882,91;292178,34;409674,02;9793,14;1,47;10,21;7,7;9,9;3;24;10;19;4;3;2
P_15;1;1;1;1168,17;940,09;828,76;5311,03;285739,20;200085,79;278091,81;5914,27;1,47;10,22;9,1;9,9;3;28;12;20;3;3;5
P_16;1;1;1;1140,58;930,66;836,49;4399,63;278133,97;225599,73;306557,45;6703,85;1,47;10,23;9,8;9,9;3;28;11;18;4;3;1
P_17;1;1;1;12139,57;866,19;786,50;4198,94;255779,40;172290,77;230621,84;4650,01;1,47;10,24;8,2;9,9;3;21;11;16;3;2;2
P_18;1;1;1;12140,72;1023,81;866,17;6487,46;327485,25;248665,25;366871,42;8506,00;1,47;10,25;6,2;9,9;3;26;10;21;5;3;2
P_19;1;1;1;12149,32;1137,33;1181,70;1253,26;7529,81;376939,22;382706,45;537397,30;9646,79;0,02;10,10;10;26;10;11;6;4;3;2
P_20;2;1;1;12131,67;792,89;635,68;3715,67;217068,43;179853,50;248554,36;5312,31;0,58;9,00;9,5;10;10;22;10;16;4;2;2
P_21;1;1;1;12111,71;799,16;687,46;4432,55;235943,57;188488,77;280755,86;6712,06;0,01;0,00;9,5;8,8;6;19;11;20;4;4;2
P_22;1;1;1;1212,22;136,26;1119,89;1132,69;6771,37;365109,77;266353,23;398652,17;8208,04;2,60;14,00;9,5;8,0;8,6;25;12;19;4;4;2
P_23;1;1;1;12147,78;1008,85;951,40;6371,50;375132,14;219394,92;313684,60;8285,77;3,17;38,00;6,9;10,8;6;15;13;18;5;4;2
P_24;1;1;1;1148,73;1381,70;1253,26;7529,81;376939,22;382706,45;537397,30;9646,79;0,02;10,10;10;26;10;11;6;4;3;2
P_25;1;1;1;1158,96;909,70;796,27;4432,29;267580,33;201651,54;272005,44;5714,81;1,99;11,00;10,10;10;27;8;18;5;4;2
P_26;1;1;1;1135,97;1276,17;1067,30;7298,63;350534,91;323528,57;432335,20;7739,54;1,10;18,00;10,10;10;26;11;5;4;2;2
P_27;2;2;1;12136,26;1119,89;1132,69;6771,37;365109,77;266353,23;398652,17;8208,04;2,60;14,00;9,5;8,0;8,6;25;12;19;4;4;2
P_28;1;1;1;12147,78;1008,85;951,40;6371,50;375132,14;219394,92;313684,60;8285,77;3,17;38,00;6,9;10,8;6;15;13;18;5;4;2
P_29;2;2;1;1173,51;1158,17;162,18;1132,41;41797,90;49784,31;64173,60;989,92;0,01;0,00;8,9;1,9;0,28;13;14;24;4;2
P_30;1;2;1;1159,80;1121,98;934,62;6092,95;314421,73;258239,58;342779,31;6209,06;0,98;6,00;9,9;1,9;0,28;10;15;5;2;2
P_31;1;2;1;1153,58;1006,84;849,83;6145,67;319974,78;199910,41;294438,18;7372,37;1,17;8,00;9,9;1,9;0,28;10;15;5;2;2
P_32;1;1;1;1237,41;2424,80;2023,44;19140,53;104967,57;86077,42;117928,38;2608,73;1,8;16,00;9,5;9,4;24;11;19;3;4;1;2
P_33;2;3;5;2;1163,95;959,91;11358,53;51991,7;51017,96;649971300,68;2,811,00;5,9;6,11;0,00;9,9;5,9;6,26;11;20;4;2;2
P_34;1;3;4;2;276,96;2046,35;2507,55;27419,48;149285,16;88484,12;118372,64;2617,37;2,6;23,00;6,11;0,00;9,9;2,9;6,9;6,26;11;20;4;2;2
P_35;1;3;3;2;296,53;2015,78;1869,83;31266,25;106460,18;84465,25;107297,45;1844,66;0,6;11,00;9,2;9,3;26;11;21;4;4;2
P_36;2;3;2;2;321,68;4117,06;3968,60;26363,48;130553,88;112615,52;152861,24;2952,87;0,9;13,00;7,7;3,9;2,9;6,14;13;19;5;5;1
P_37;1;3;3;2;296,53;2015,78;1869,83;31266,25;106460,18;84465,25;107297,45;1844,66;0,6;11,00;9,2;9,3;26;11;21;4;4;2
P_38;2;3;2;2;321,68;4117,06;3968,60;26363,48;145586,13;121059,84;140208,22;20,77;23,00;6,11;0,00;9,9;6,9;6,26;11;20;4;2;2
P_39;1;3;1;2;241,84;4396,10;3350,83;40122,79;93213,51;101172,39;137627,01;2717,86;6,7;21,00;6,8;9,2;9,3;28;12;19;4;4;2
    
```

Figura 88. Cambio de puntos a comas.

Posteriormente, se tiene que volver a seleccionar todo y sustituir los puntos y coma por comas (ver Figura 89).

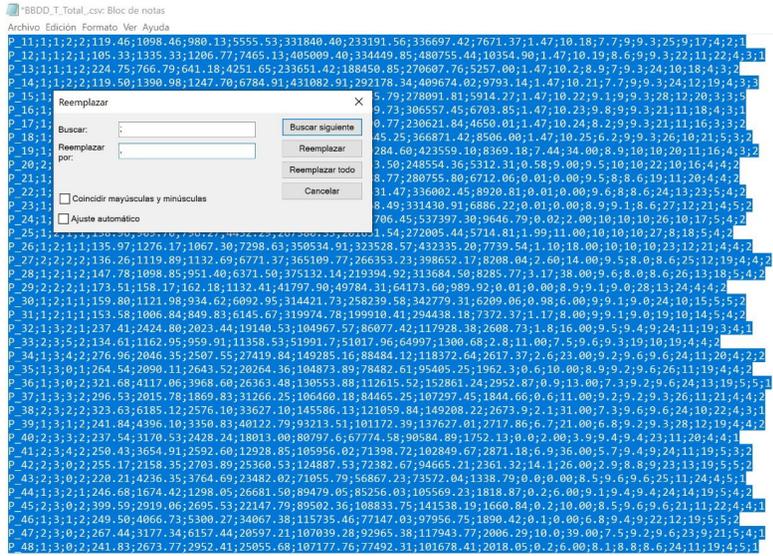


Figura 89. Cambio de los separadores de tabulación de comas a punto y coma.

Después hay que guardar los cambios. Ahora ya estaría lista la base de datos para importarse en Orange en una *data csv file* (ver Figura 90).

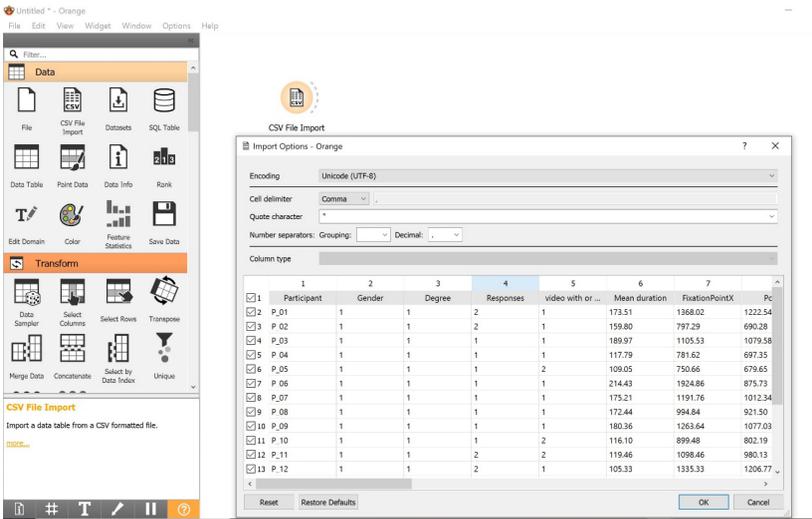


Figura 90. Importación de la base de datos en el software Orange.

Una vez se tenga ya la base de datos importada para visualizar los datos de «File» en formato tabular hay que conectar con un *widget* «File» con «Data Table», después se hará un doble *click* en el icono de «Data Table» para visualizar los datos. Un ejemplo, se puede consultar en la Figura 91.

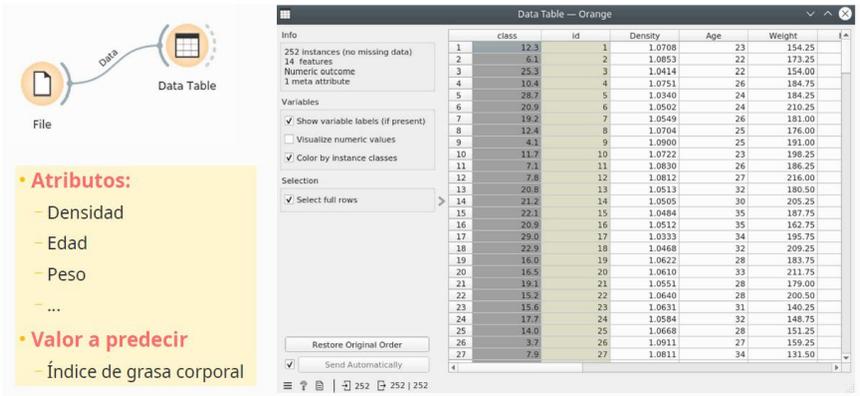


Figura 91. Visualización de los datos en un formato tabular.

Para visualizar la distribución se puede utilizar el icono de «Scatter Plot» y el de «Distribution», ver Figura 92.

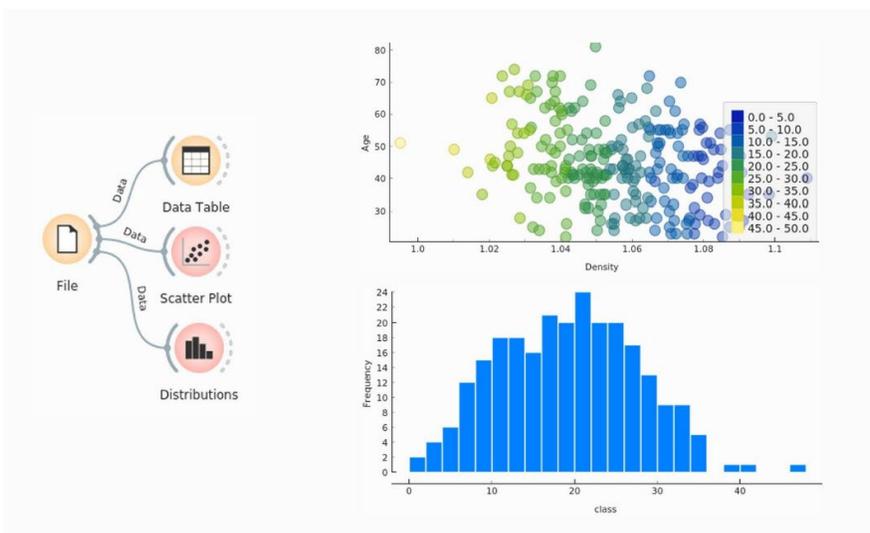


Figura 92. Visualización del «Scatter Plot» y el de «Distribution» en el software Orange.

Los tipos de tareas que se pueden realizar con Orange son propios de aprendizaje supervisado, aprendizaje no supervisado y Otras (aprendizaje semisupervisado, aprendizaje por refuerzo, sumarización y visualización) (ver Figura 93).



Figura 93. Tipos de tareas que se pueden realizar con Orange.

Respecto de la aplicación de algoritmos de aprendizaje supervisado, esta se realiza cuando se conoce la clase (ver Figura 94).

Conocemos la clase

↓

Outlook	Temperature	Humidity	Windy	Class
sunny	65	85	false	Don't play
sunny	80	90	true	Don't play
overcast	83	78	false	Play
rain	70	96	false	Play
rain	68	80	false	Play

Figura 94. Aplicación de algoritmos de aprendizaje supervisado conociendo la clase.

4.6.2.1. Utilización aprendizaje supervisado aplicando el algoritmo de Regresión con Orange

Dentro de los algoritmos de aprendizaje supervisado está la Regresión (ver Figura 95).

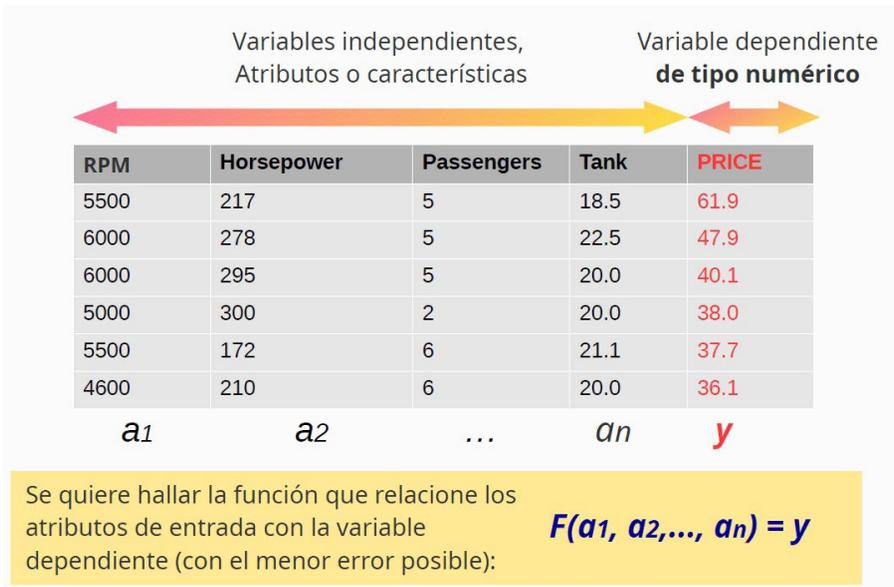


Figura 95. Aprendizaje supervisado. Regresión.

Ejemplos de esta aplicación sería por ejemplo la predicción de un salario en función de los atributos de formación, edad, experiencia, ciudad y el valor de la predicción sería el salario mensual. Aplicado al ámbito de la psicología por ejemplo en el ámbito del aprendizaje, sería la predicción de los resultados académicos en función de los atributos del uso de las estrategias metacognitivas, del tiempo dedicado al estudio y de los conocimientos previos de la materia. Los algoritmos de regresión que se pueden aplicar con Orange son diversos, se van a estudiar dos ejemplos del algoritmo del vecino más cercano (k -NN) y del de regresión lineal. En el primer caso se une el widget «File» con el widget « k -NN» (ver Figura 96).

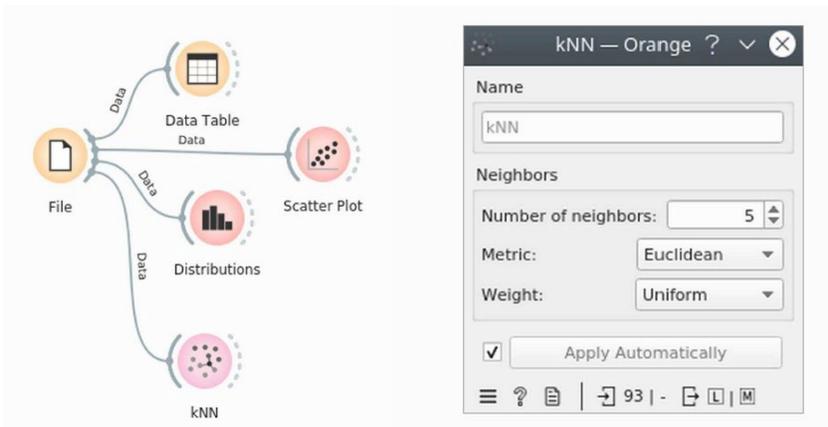


Figura 96. Utilización del algoritmo k -NN con Orange.

Para hallar la regresión Orange se presenta un ejemplo de predicción del índice de grasa corporal respecto de personas no observadas. En este caso se une el widget «*k*-NN» con el widget «Predictions», un ejemplo se puede consultar en la Figura 97.

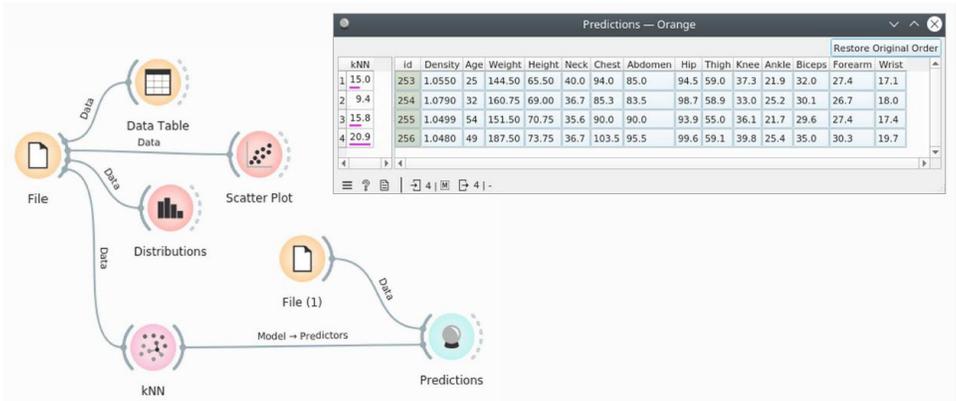


Figura 97. Utilización del algoritmo de regresión con Orange.

También, se puede aplicar un modelo de *Linear Regression*, para ello se une al widget *Predictions* el widget *Linnear Regression* con el fin de hallar si las predicciones son iguales o diferentes que las del modelo «*k*-NN» (ver Figura 98).

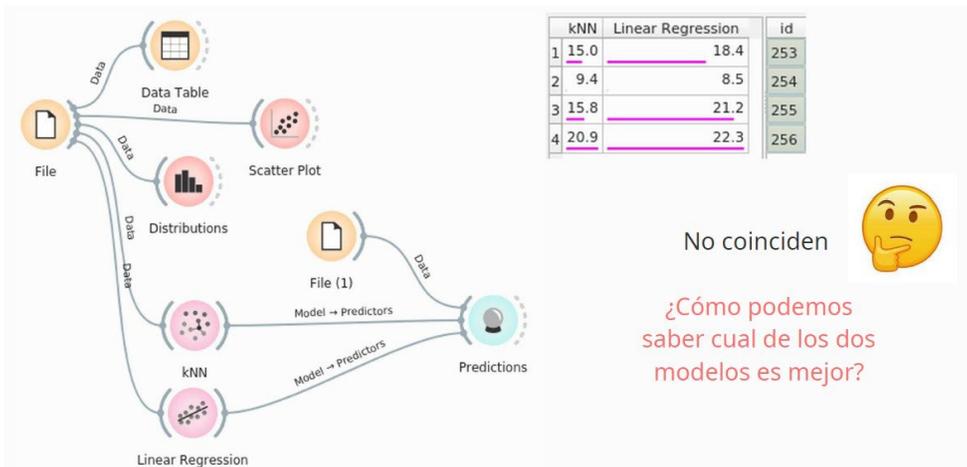


Figura 98. Modelo de Linear Regression con Orange.

Para saber cuál de los dos modelos ejecuta una mejor predicción, en este ejemplo habría que saber el índice de grasa corporal real de los sujetos y compararla con la predicción hallada en cada uno de los modelos. No obstante, si se utiliza para evaluar el conjunto de datos del entrenamiento va dar un error muy bajo e interesa que sea capaz de predecir en datos no entrenados previamente. Para mitigar este problema se puede dividir el conjunto de datos en datos de entrenamiento y datos de test (ver Figura 99).

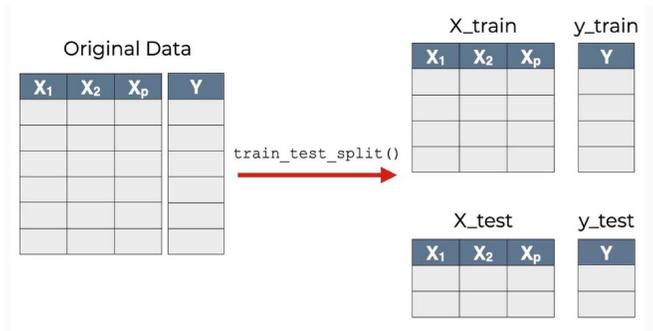


Figura 99. División del conjunto de datos.

Para ejecutarlo en Orange se carga primero el fichero con el que se esté trabajando y se crea en el lienzo la estructura añadiendo el widget «Test and Score». Para hacer una partición «Train-Test» se selecciona la opción de «Random sampling» (ver Figura 99)

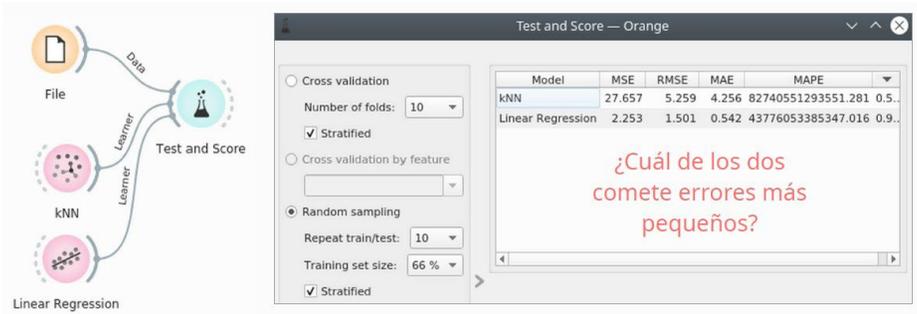


Figura 100. Evaluar errores en Orange.

Otra opción para mitigar el problema descrito es realizar una validación cruzada (ver Figura 101).



Figura 101. Validación cruzada.

Para aplicarla en Orange se cambia a la opción de «cross Validation», se puede marcar en las opciones de configuración de los algoritmos los modelos k -NN y «Linear Regression» con el fin de ver si se puede reducir más el error (ver Figura 102).

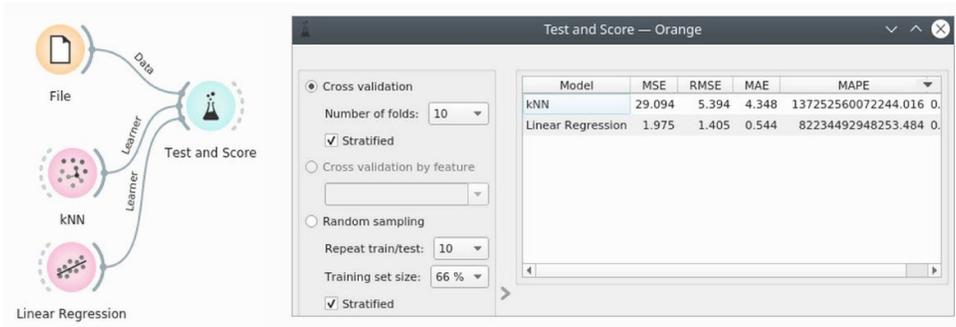


Figura 102. Test and Score en Orange.

4.6.2.2. Utilización aprendizaje supervisado aplicando el algoritmos de Clasificación con Orange

Un ejemplo de aplicación del algoritmo de clasificación sería por ejemplo la predicción del diagnóstico de un paciente. En este caso los atributos serían los valores de una analítica de sangre, de orina, etc. La clase Lupus (Si/NO). Existen muchos algoritmos para entrenar modelos de clasificación, entre ellos se ha elegido k -NN, los árboles de decisión y los «Ensembles» («Bagging» y «Boosting»). El algoritmo del vecino más cercano (k -NN) funciona igual que en la Regresión, pero el valor predicho es la moda en vez de la media. El espacio se divide en regiones en las que cada dato pertenece a una clase diferente. Dichas regiones dependen del valor concreto de k aplicado. Un ejemplo se puede consultar en la Figura 103.

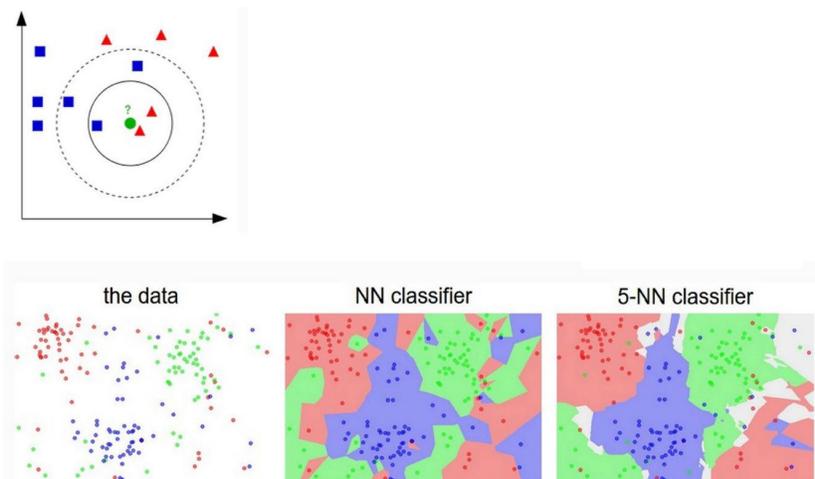


Figura 103. Representación del vecino más cercano (k -NN).

Referente a los árboles de decisión parten el espacio en subconjuntos y tienen nodos de bifurcación (se corresponde con una pregunta de un atributo concreto), y nodos de hoja (son la predicción). Este algoritmo también funciona en regresión, devuelve la media de los ejemplos que caen de la hoja, un ejemplo de su visualización se puede consultar en la Figura 104.

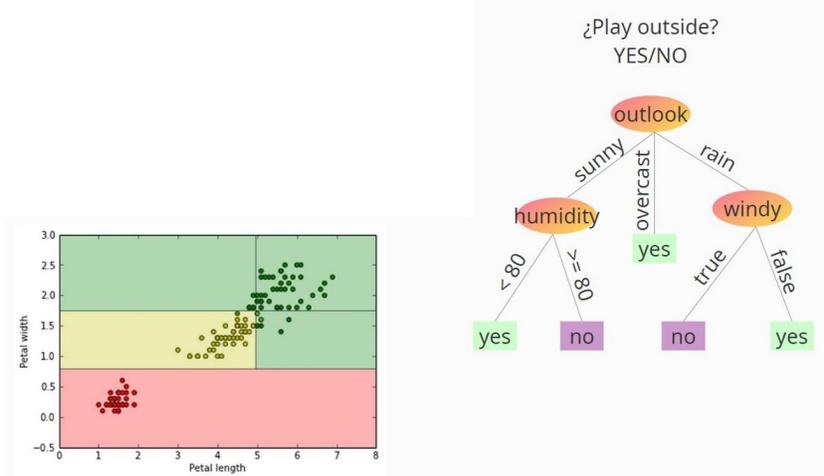


Figura 104. Representación de un árbol de decisión.

En el primer paso del entrenamiento, si todos los ejemplos son de la misma clase se hará solo una hoja. Si no bifurca en ramas se escoge el atributo que mejor divide los ejemplos y se repite el proceso desde arriba con ejemplos 1 y con ejemplos 2. El segundo paso se hacen preguntas de cada bifurcación hasta llegar a una hoja. Para aplicarlo con Orange primero se abre el fichero, y después se construye una estructura para entrenar el árbol de decisión. Para ello, se utiliza el widget «Tree Viewer» con el fin de visualizar las bifurcaciones que se generarán (ver Figura 105).

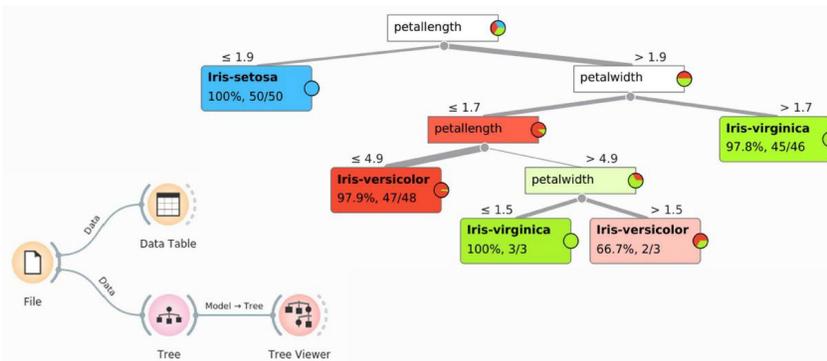


Figura 105. Visualización de las bifurcaciones en Orange.

Asimismo, se puede validar la calidad de un clasificador aplicando la validación cruzada o particiones de «Train-Test». Las métricas de evaluación son diferentes, ya que en este caso se aborda un problema de clasificación y no de regresión (ver Figura 106).

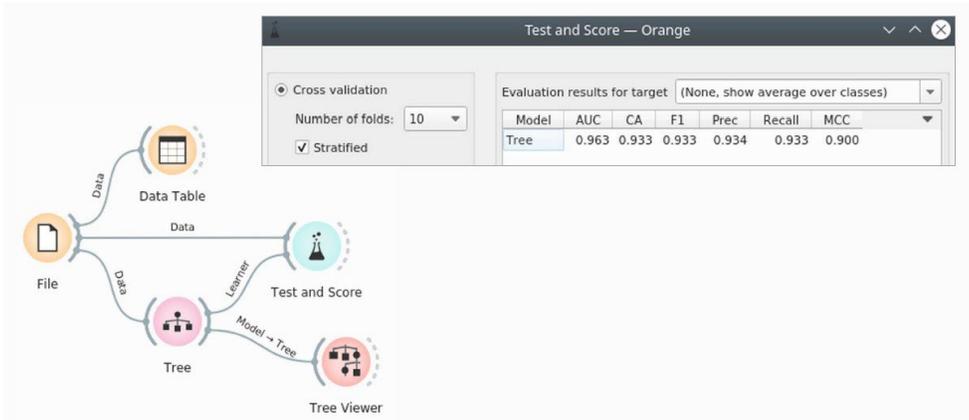


Figura 106. Validación cruzada con Orange.

4.6.2.3. Utilización aprendizaje supervisado aplicando *Ensembles* con Orange

Los *Ensembles* incluyen muchos clasificadores y cada uno es un experto, las claves son que los expertos tienen que ser precisos y diversos. Para conseguir que los expertos sean diversos existen varias opciones:

- Cada experto es un modelo diferente (k -NN, árbol de decisión, SVM, *Naïve Bayes*, etc.).
- Cada experto se ha entrenado con ejemplos diferentes.
- Cada experto se ha entrenado con todos los ejemplos, pero teniendo en cuenta solo algunas características.

La máxima es que es más fácil entrenar muchos clasificadores buenos y combinarlos en uno muy bueno que intentar hacer un clasificador muy bueno desde el inicio.

4.6.2.4. Utilización aprendizaje no supervisado con Orange

El aprendizaje no supervisado indica que no se conoce la clase. Los algoritmos de *clustering* agrupan los ejemplos en grupos con características parecidas. Una representación gráfica se puede consultar en la Figura 107.

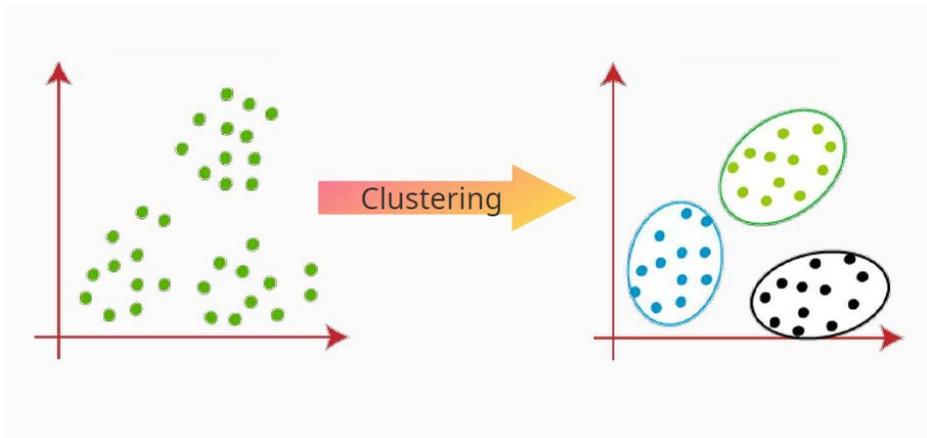


Figura 107. Representación de Clustering.

Un ejemplo de aplicación en el contexto de las Ciencias de la Salud puede ser la segmentación de imágenes médicas. Una visualización del algoritmo de *clustering* se puede consultar en *k-means clustering*. Para ejecutar el algoritmo en Orange, primero se carga el fichero y se elige el widget «Select Columns» (ver Figura 108).

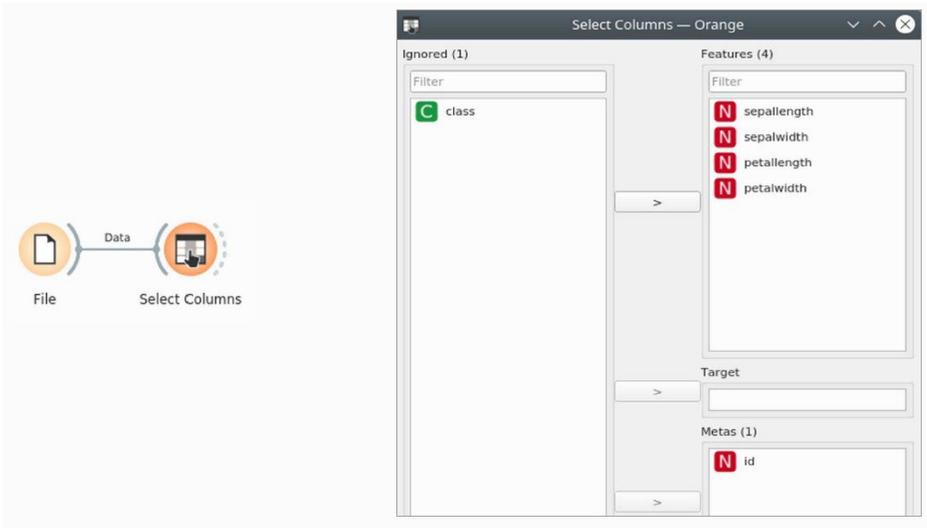


Figura 108. «Select Columns» en Orange.

Seguidamente, las columnas seleccionadas se relacionan con el widget «*k*-Means», después se configura el número de clústeres. Los clústeres se pueden visualizar mediante un «Scatter Plot» (ver Figura 109).



Figura 109. *k-Means en Orange.*

Para una ampliación de este capítulo se puede consultar:

Sáiz Manzanares, M.C. (2019). *Metacognición e inteligencia artificial: más allá del paralelismo de funcionamiento*. Repositorio Institucional. Universidad de Burgos. <https://doi.org/10.36443/10259/5357> . Recuperado de <http://hdl.handle.net/10259/5357> (acceso 2/11/2024).

Arnaiz González, Á., Díez Pastor, J.F., y Rodríguez Arribas, S. (2024). MÓDULO. IV Técnicas de observación y evaluación a partir de recursos inteligentes: introducción a la minería de datos, en Sáiz-Manzanares, M.C., y Santamaría Vázquez, M. (Eds.), *Formación y Especialización en Atención Temprana: uso de Recursos Tecnológicos y de Inteligencia Artificial* (145- 155). Burgos: Servicio de Publicaciones de la Universidad de Burgos. <https://doi.org/10.36443/9788418465802>

4.7. Ejemplo práctico del trabajo con el software Orange v. 3.38.1

En este caso se elige la importación de datos desde un fichero *CSV File Import* (ver Figura 110)

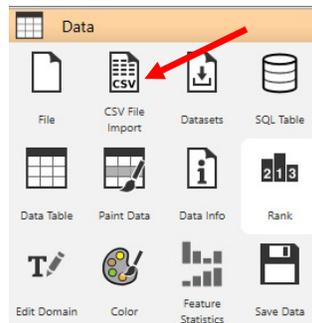


Figura 110. *Selección archivo csv.*

Seguidamente, se realiza un análisis de datos descriptivos este se puede hacer con *Feature Statistics* (ver Figura 111) primero se elige el *widget* color para dar valor del color a cada grupo en este caso se distinguen dos grupos, grupo 1 grupo 2 son estudiantes de dos titulaciones distintas en distintas variables (estrategias metacognitivas medidas con ACRA), *learning outcomes* totales, y valoraciones de resultados de aprendizaje en distintas pruebas de evaluación continua, accesos a la plataforma virtual y satisfacción percibida con la enseñanza). Se obtienen estadísticos descriptivos de Media, Mediana, Dispersión, valores máximos y mínimos y valores perdidos (ver Figura 112).

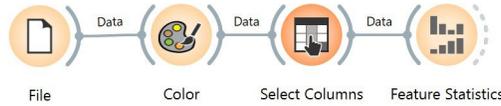


Figura 111. *Feature Statistics*

Feature Statistics										Sat Mar 29 25, 18:14:10	
Name	Distribution	Mean	Mode	Median	Dispersion	Min.	Max.	Missing			
N Total sujetos		29.34	1	29	0.59	1	66	0 (0 %)			
N Total RA		9.2972	10.00	9.50	0.1056	0.10	10.00	0 (0 %)			
N Suma Autoconocimiento		20.02	20	20	0.12	9	24	0 (0 %)			
N Suma autom/Planif		12.77	13	13	0.16	5	16	0 (0 %)			
N Suma automanejo y evaluación		19.13	19	19	0.12	8	24	0 (0 %)			
N Información CT		67.31	24	55	0.76	0	295	0 (0 %)			
N Orientaciones ABP		23.32	20	20	0.78	0	108	0 (0 %)			
N CA Prácticas		32.73	33	32	0.95	0	212	0 (0 %)			
N Co-evaluación		31.29	0	31	0.61	0	91	0 (0 %)			
N Feedback		183.49	143	180	0.49	0	430	0 (0 %)			
N Accesos a la plataforma		769.28	476	721	0.42	6	2045	0 (0 %)			
N Media visitas por día		12.2108	7.56	11.44	0.4184	0.10	32.46	0 (0 %)			
N Satisfacción		4.180	4.2	4.2	0.092	1.9	5.0	0 (0 %)			
C Grupo			2		0.685			0 (0 %)			

Figura 112. *Estadísticos descriptivos de las variables seleccionadas.*

También, se puede obtener un *widget* de *Rank*, este hace referencia a la puntuación de las variables según su correlación con la variable objetivo discreta o numérica, basándose en los evaluadores internos aplicables (como ganancia de información, ji-cuadrado y regresión lineal) y en cualquier modelo externo conectado que admita la puntuación, como la regresión lineal, la regresión logística, el bosque aleatorio, el SGD, etc. El *widget* también puede manejar datos no supervisados, pero solo por evaluadores externos, como el PCA. En este caso se ha elegido 5 valores. En síntesis, *Rank*, clasifica atributos en conjuntos de datos de clasificación o regresión.

El *widget Rank* puntúa las variables según su correlación con la variable objetivo discreta o numérica, basándose en los *scorers* internos aplicables (como ganancia de información, chi-cuadrado y regresión lineal) y en cualquier modelo externo conectado que admita puntuación, como regresión lineal, regresión logística, bosque aleatorio, SGD, etc. El *widget* también puede manejar datos no supervisados, pero solo mediante *scorers* externos, como PCA.

Métodos de puntuación (clasificación)

Gain Ratio (Relación de ganancia): una relación entre la ganancia de información y la información intrínseca del atributo, que reduce el sesgo hacia las características multivalor que se produce en la ganancia de información.

Gain (Ganancia): la cantidad esperada de información (reducción de la entropía).

Gini: la desigualdad entre los valores de una distribución de frecuencia.

ANOVA: la diferencia entre los valores medios de la característica en diferentes clases.

Chi2: dependencia entre la característica y la clase medida por la estadística chi-cuadrado.

ReliefF: la capacidad de un atributo para distinguir entre clases en instancias de datos similares

FCBF (filtro rápido basado en correlación): medida basada en la entropía, que también identifica la redundancia debida a correlaciones por pares entre características.

Además, *Rank* puede conectar ciertos algoritmos de aprendizaje que permiten puntuar las características según su importancia en los modelos que construyen (por ejemplo, regresión logística, bosque aleatorio, SGD). Se debe tener en cuenta que los datos se normalizan (ver Figura 113) antes de la clasificación (ver Figura 114).



Figura 113. Normalización de datos.

Rank - Orange

Scoring Methods

- Information Gain
- Information Gain Ratio
- Gini Decrease
- ANOVA
- χ^2
- ReliefF
- FCBF

Select Attributes

- None
- All
- Manual
- Best ranked: 5

#	Info. gain	Gain ratio	Gini	ANOVA	χ^2	ReliefF	FCBF
1	0.538	0.299	0.285	81.415	108.990	0.061	0.630
2	0.351	0.178	0.213	33.190	8.103	0.031	0.311
3	0.186	0.093	0.119	72.373	40.180	0.092	0.142
4	0.171	0.089	0.111	2.503	7.232	0.044	0.000
5	0.169	0.084	0.109	38.107	29.582	0.091	0.000
6	0.069	0.035	0.047	1.524	2.576	0.013	0.000
7	0.069	0.035	0.047	1.525	2.576	0.013	0.000
8	0.037	0.021	0.025	7.093	5.067	0.006	0.000
9	0.029	0.015	0.019	8.876	4.738	0.005	0.000
10	0.018	0.011	0.012	4.714	2.150	0.022	0.000
11	0.016	0.010	0.011	0.082	0.597	0.009	0.000
12	0.013	0.008	0.009	0.035	0.409	0.000	0.000
13	0.011	0.006	0.008	0.074	0.160	0.013	0.000

Figura 114. Resultado de la normalización.

También, se pueden utilizar de transformación *widjet* de *Transformation*. Por ejemplo, se puede utilizar *widjet* de *Pivot Table* pueden seleccionar columnas y filas y elegir la variable Target sobre la que se quiere analiza el comportamiento de la transformación. En resumen, *Pivot Table*, es una tabla de contingencia que puede proporcionar distintos datos descriptivos sobre variables. Si bien, los datos con una sola variable numérica no se pueden mostrar en la tabla la variable de agrupación tiene que ser una variable discreta. Se pueden obtener distintas combinaciones de los datos y valores de estadísticos descriptivos. Por ejemplo, se va a estudiar la distribución de los grupos en las tres subescalas de la *Escala de Estrategias Metacognitivas* de ACRA (Autoconocimiento, Planificación, y Automanejo). (ver Figuras 115-118)

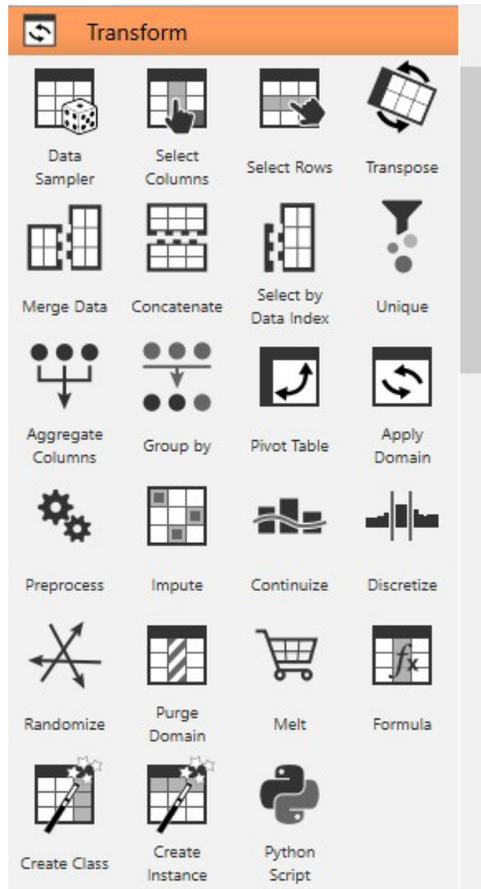


Figura 115. Selección Tabla pivote.

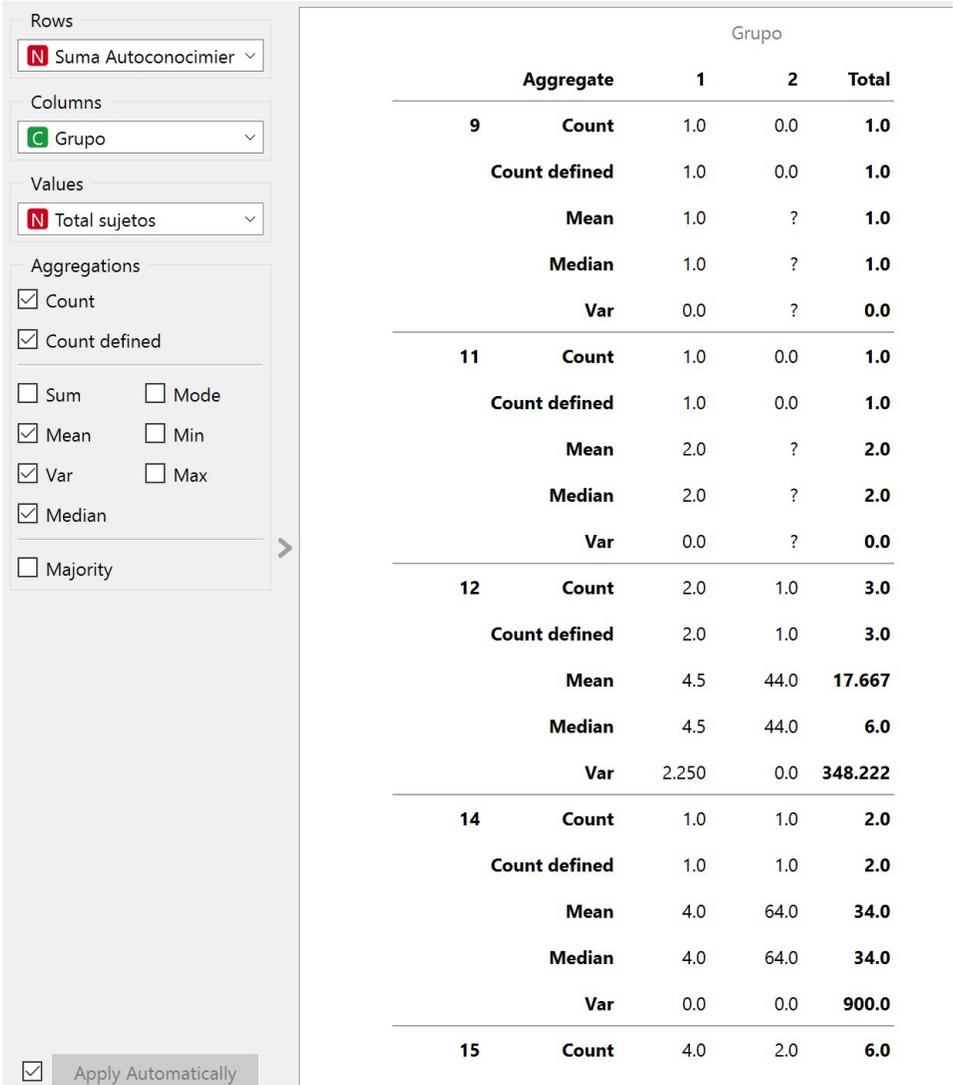


Figura 116. Tabla pivote subescala de autoconocimiento

Pivot Table - Orange

Rows: Suma autom/Planif

Columns: Grupo

Values: Total sujetos

Aggregations:

- Count
- Count defined
- Sum
- Mode
- Mean
- Min
- Var
- Max
- Median
- Majority

Apply Automatically

		Grupo		
	Aggregate	1	2	Total
5	Count	2.0	0.0	2.0
	Count defined	2.0	0.0	2.0
	Mean	3.5	?	3.5
	Median	3.5	?	3.5
	Var	6.250	?	6.250
6	Count	1.0	1.0	2.0
	Count defined	1.0	1.0	2.0
	Mean	45.0	53.0	49.0
	Median	45.0	53.0	49.0
	Var	0.0	0.0	16.0
7	Count	3.0	0.0	3.0
	Count defined	3.0	0.0	3.0
	Mean	22.667	?	22.667
	Median	27.0	?	27.0
	Var	237.556	?	237.556
8	Count	2.0	2.0	4.0
	Count defined	2.0	2.0	4.0
	Mean	3.5	32.0	17.750
	Median	3.5	32.0	8.5
	Var	0.250	361.0	383.688
9	Count	1.0	7.0	8.0

Figura 117. Tabla pivote subescala de planificación.

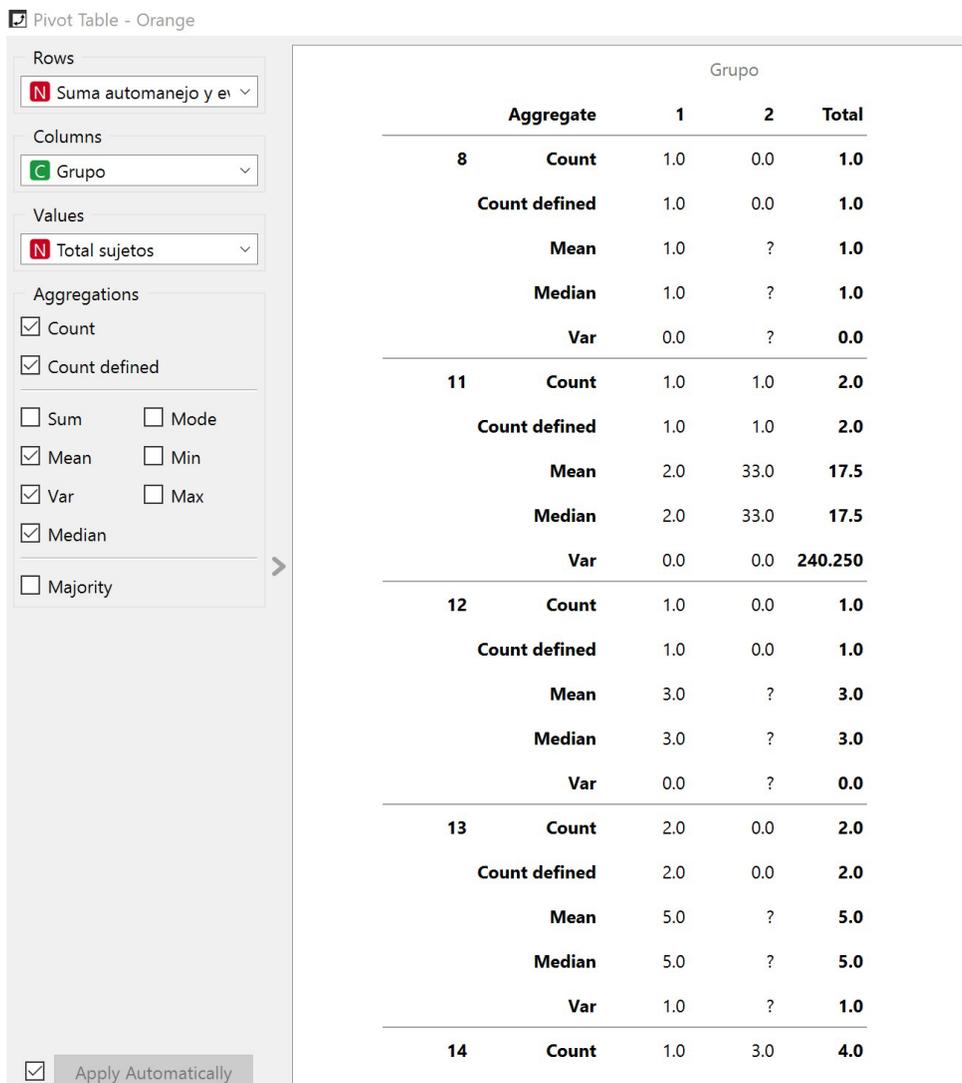


Figura 118. Tabla pivote subescala de automanejo.

Asimismo, se puede visualizar los datos aplicando el *widget* de *Box Plot* (ver Figura 119). Esta muestra las distribuciones de los valores de los atributos. Es una buena práctica comprobar cualquier dato nuevo con este *widget* para descubrir rápidamente cualquier anomalía, como valores duplicados (por ejemplo, *gray* y *grey*), valores atípicos y similares. Se pueden seleccionar barras, por ejemplo, valores para datos categóricos o el rango cuantitativo para datos numéricos. (ver Figura 120).

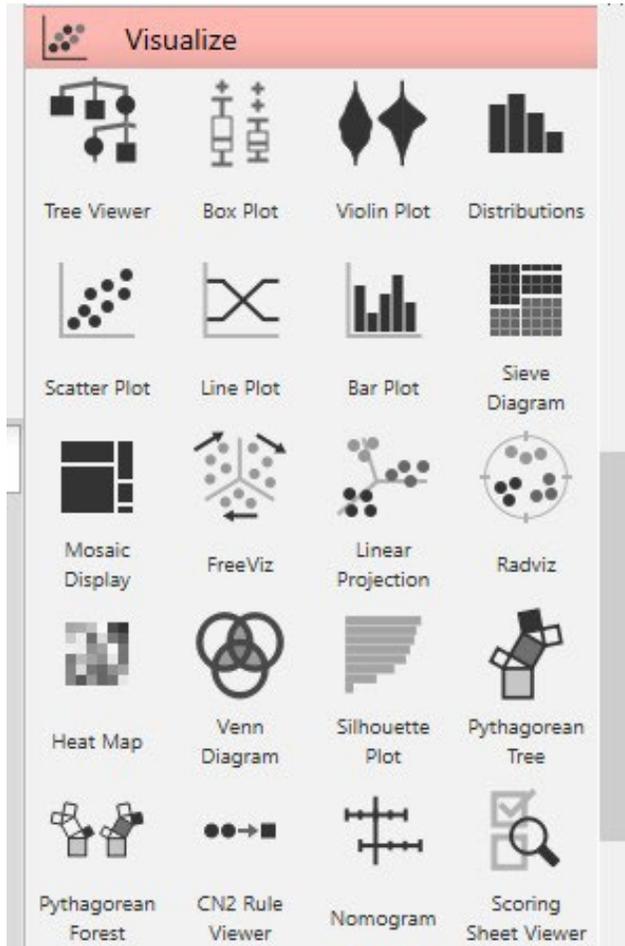


Figura 119. *Box Plot*.



Figura 120. *Box Plot*.

Por ejemplo, se puede realizar una comparación de medias entre el Grupo 1 y el Grupo 2 respecto de la media de visitas por días realizadas a lo largo del semestre (ver Figura 121).

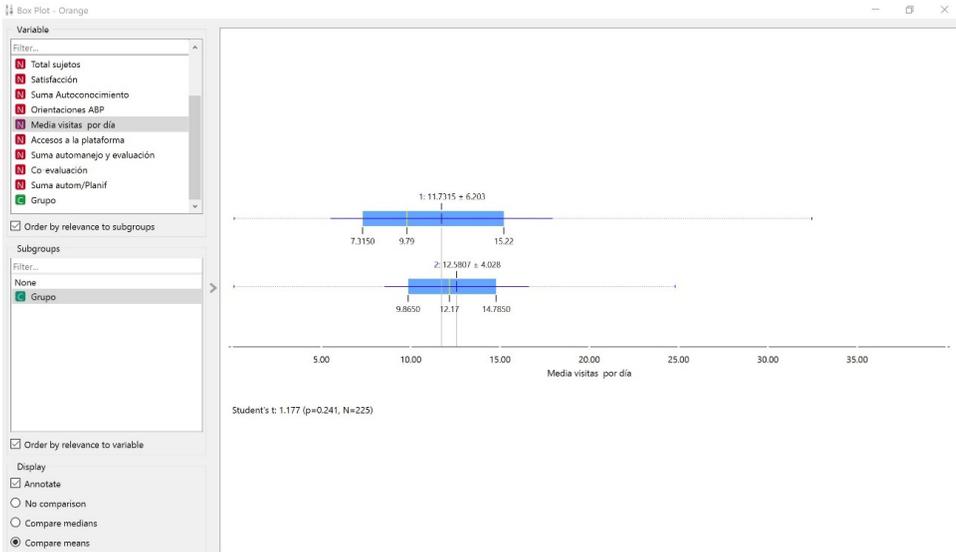


Figura 121. Box Plot comparación de medias.

También, se puede aplicar un *widget* de *Line Plot* (ver Figura 122). Este es un tipo de diagrama que muestra los datos como una serie de puntos, conectados por segmentos de línea recta. Solo funciona para datos numéricos, mientras que el diagrama de categorías puede utilizarse para agrupar los puntos de datos. En este caso se visualizan los datos en el Grupo 1 y en el Grupo 2 respecto a las distintas variables respecto del Grupo 1 y del Grupo 2 (ver Figura 123).



Figura 122. Selección Line Plot

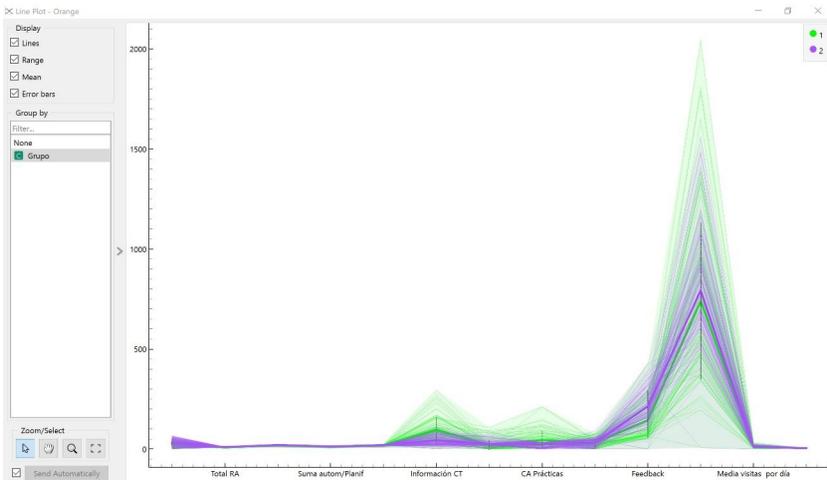


Figura 123. Ejemplo de Line Plot.

De igual modo, se puede aplicar el *widjet* de *Violin Plot*. Este desempeña una función similar a la del diagrama de caja. Muestra la distribución de datos cuantitativos en varios niveles de una variable categórica, de modo que esas distribuciones puedan compararse. A diferencia del diagrama de caja, en el que todos los componentes del diagrama corresponden a puntos de datos reales, el diagrama de violín presenta una estimación de la densidad del núcleo de la distribución subyacente. El *Kernel* se utiliza para estimar la densidad. Los *kernels* posibles son: Normal, *Epanechnikov* y Lineal. También, podría utilizarse para la detección de valores atípicos. En este caso se utiliza para visualizar la comparativa de frecuencias entre el Grupo 1 y el Grupo 2 en distintas variables seguidamente se presenta un ejemplo en la comparativa en la variable de Planificación de la «Escala de Estrategias Metacognitivas» de ACRA. (ver Figura 124)

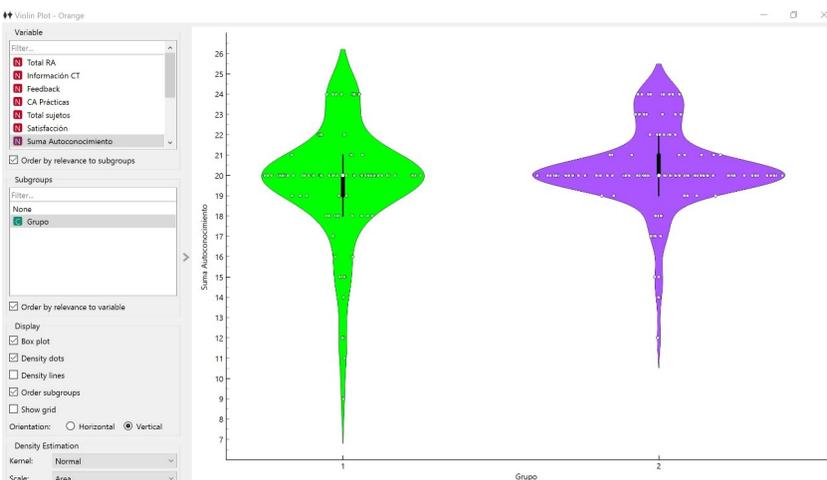


Figura 124. Ejemplo Violin Plot.

También, se pueden visualizar el *widget* de *Scatter Plot*. Este es un diagrama de dispersión con análisis exploratorio. Proporciona una visualización de diagrama de dispersión bidimensional. Los datos se muestran como una colección de puntos, cada uno con el valor del atributo del eje x que determina la posición en el eje horizontal y el valor del atributo del eje y que determina la posición en el eje vertical. En el lado izquierdo del *widget* se pueden ajustar varias propiedades del gráfico, como el color, el tamaño y la forma de los puntos, los títulos de los ejes, el tamaño máximo de los puntos y el temblor. A continuación, se muestra una instantánea del diagrama de dispersión del conjunto de datos Iris con el color correspondiente al atributo de clase.

Seguidamente, se presenta un ejemplo respecto de las distintas variables desde la distribución en el Grupo 1 y en el Grupo 2. (ver Figura 125 y Figura 126).

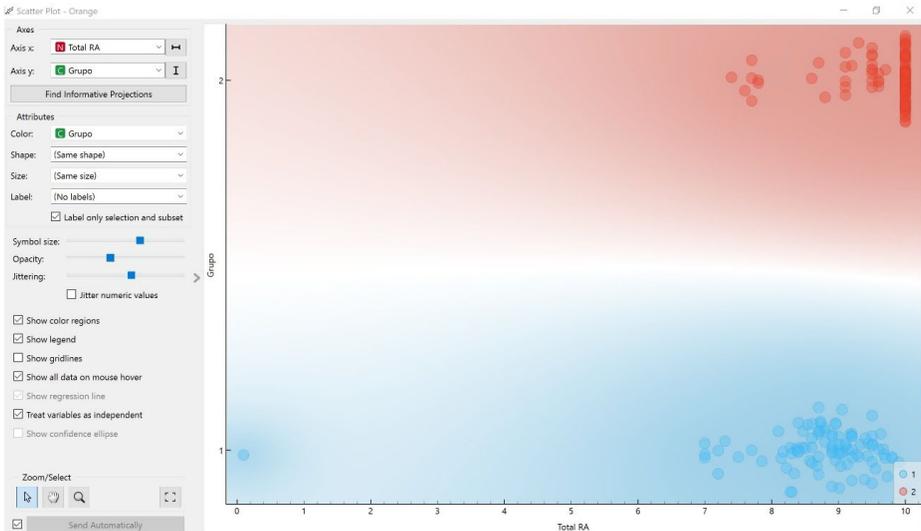
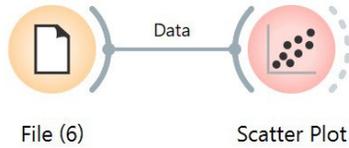


Figura 125. Ejemplo Scatter Plot.

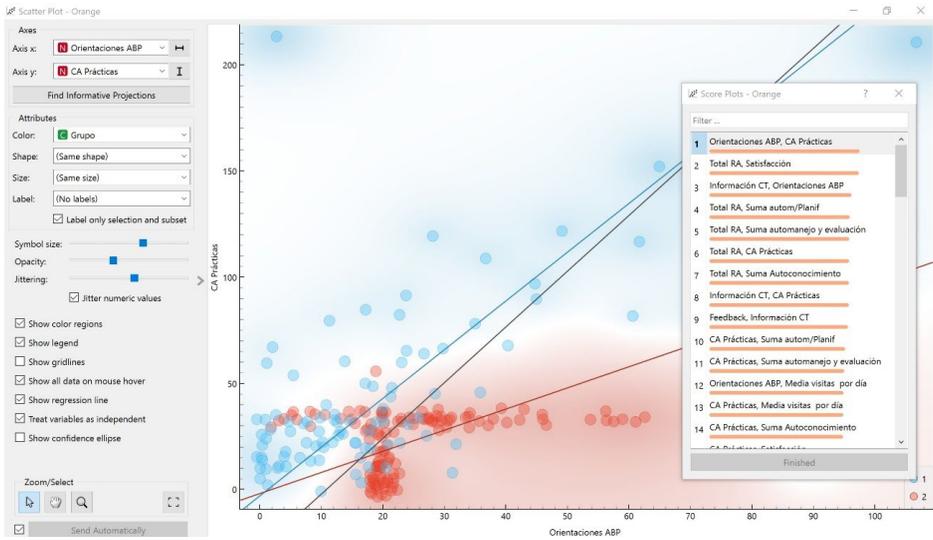
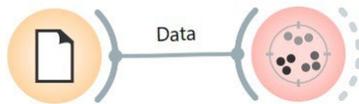


Figura 126. Ejemplo de Scatter Plot aplicando regresión.

Asimismo, se pueden visualizar el *widget* de *Radviz* (Hoffman et al. 1997). Este es una técnica de visualización multidimensional no lineal que puede mostrar datos definidos por tres o más variables en una proyección bidimensional. Las variables visualizadas se presentan como puntos de anclaje espaciados equidistantemente alrededor del perímetro de un círculo unitario. Los casos de datos se muestran como puntos dentro del círculo, con sus posiciones determinadas por una metáfora de la física: cada punto se mantiene en su lugar con resortes que están unidos en el otro extremo a los anclajes variables. La rigidez de cada resorte es proporcional al valor de la variable correspondiente y el punto termina en la posición donde las fuerzas del resorte están en equilibrio. Antes de la visualización, los valores de las variables se escalan para que estén entre 0 y 1. Las instancias de datos que están cerca de un conjunto de anclajes variables tienen valores más altos para estas variables que para las demás. Seguidamente, se presenta un ejemplo respecto de las distintas variables desde la distribución en el Grupo 1 y en el Grupo 2 (ver Figura 127).



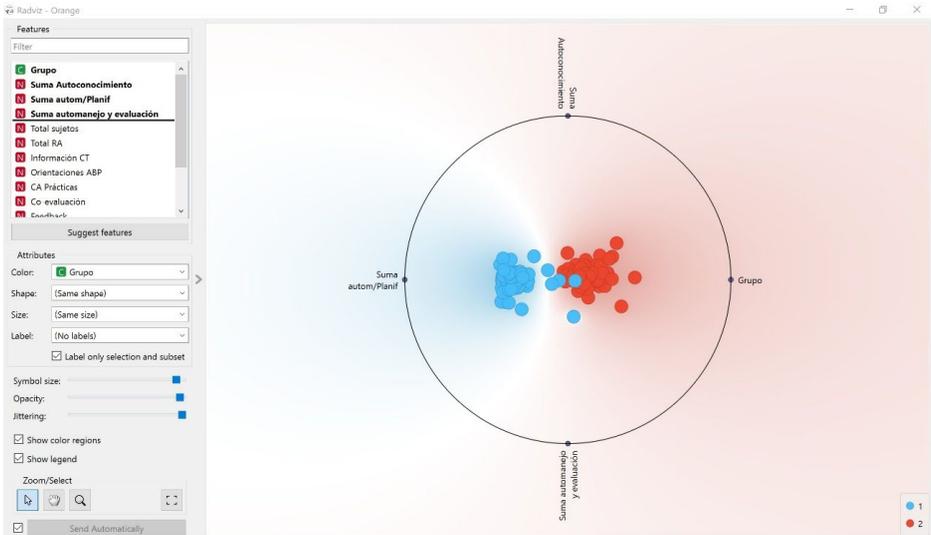


Figura 127. Ejemplo Radviz.

Asimismo, se pueden visualizar el *widget* de *Heat Map*. Este es un método gráfico para visualizar valores de atributos en una matriz bidireccional. Solo funciona en conjuntos de datos que contengan variables numéricas. Los valores se representan por colores según la paleta de colores seleccionada. Al combinar la variable de clase y los atributos en los ejes x e y, se visualiza dónde son más fuertes y dónde más débiles los valores de los atributos, lo que nos permite encontrar características típicas para cada clase. El *widget* permite seleccionar filas con un clic y arrastrando. Se puede ampliar con Ctrl++ (Cmd++) y reducir con Ctrl+- (Cmd+-). Ctrl+0 (Cmd+0) restablece el zoom a la versión ampliada, mientras que Ctrl+9 (Cmd+9) lo restablece al valor predeterminado (ver Figura 128 y Figura 129).

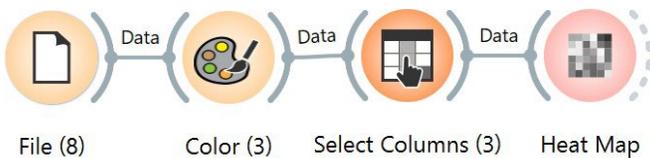


Figura 128. Pasos para hacer un Heat Map en Orange.

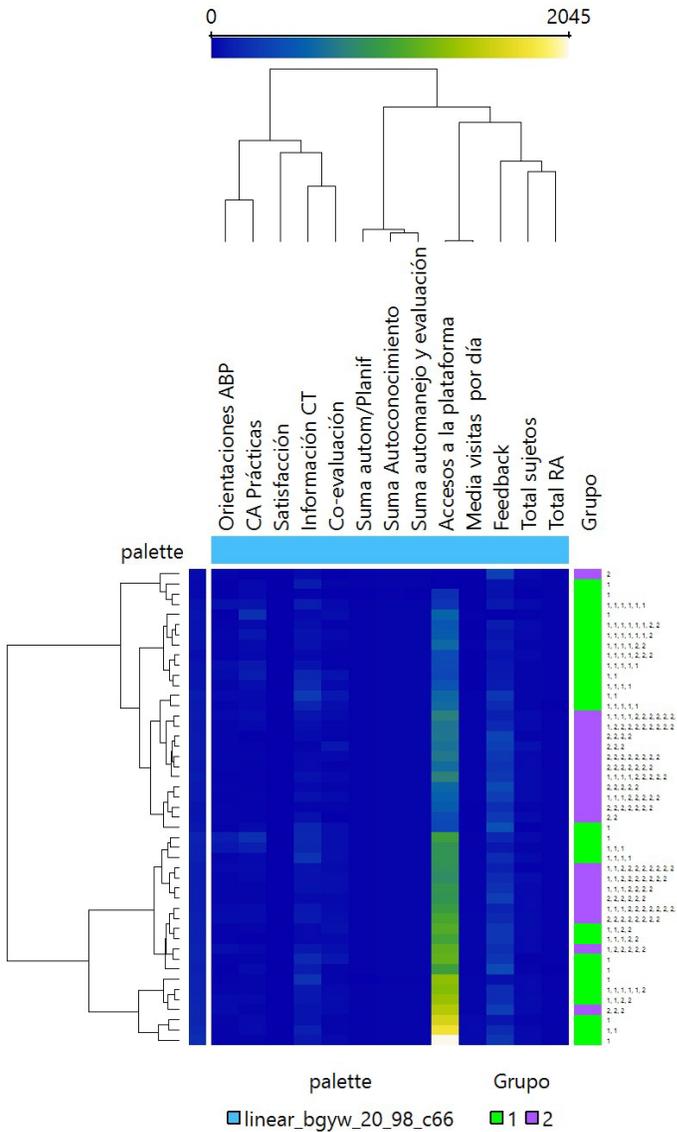


Figura 129. Ejemplo de Heat Map.

Análisis de *Machine Learning* Supervisado

Se ha utilizado el *widget* de árbol (*Tree*). Este es un algoritmo simple que divide los datos en nodos por pureza de clase (ganancia de información para la variable objetivo categórica y MSE para la numérica). Es un precursor de *Random Forest*. *Tree* in Orange está diseñado internamente y puede manejar conjuntos de datos categóricos y numéricos. También se puede utilizar tanto para tareas de clasificación como de regresión. Para visualizar el árbol se debe añadir el *widget* de *Tree Viewer* (ver Figura 130).

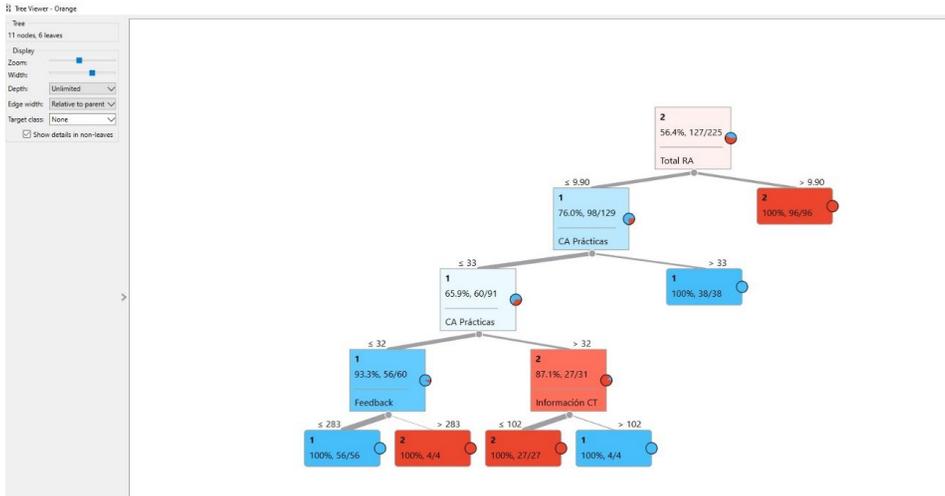


Figura 130. Ejemplo de un árbol de decisión con Orange.

Análisis de *Machine Learning* No Supervisado (ver Figura 131).

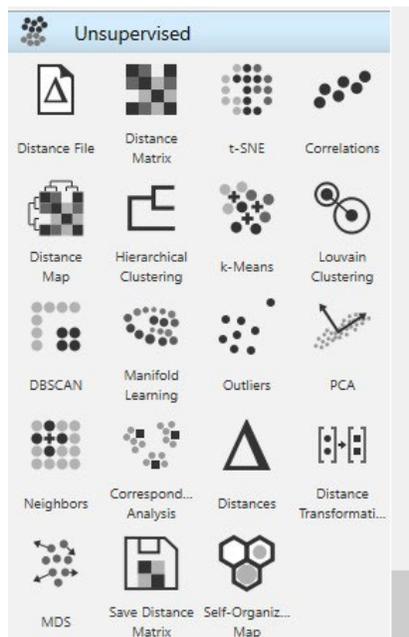


Figura 131. Algoritmos de clustering en Orange.

Se puede incluir el *widget* de *Principal Component Analysis* (PCA) calcula la transformación lineal PCA de los datos de entrada. Genera un conjunto de datos transformado con pesos de instancias individuales o pesos de componentes principales (ver Figura 132).



Figura 132. Pasos para hacer un PCA con Orange.

Seguidamente, se presenta un ejemplo de PCA sobre la Base de Datos de aprendizaje (ver Figura 133).

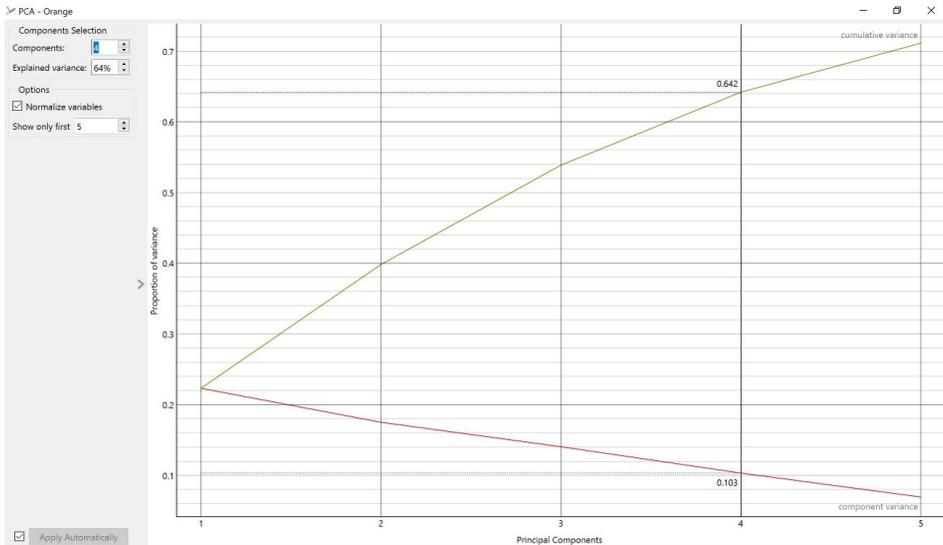


Figura 133. Ejemplo de PCA.

Asimismo, se pueden visualizar el *widget* de *Multidimensional scaling* (MDS). MDS es una técnica que encuentra una proyección de puntos de baja dimensión (en nuestro caso, bidimensional), donde intenta ajustar las distancias entre puntos lo mejor posible. El ajuste perfecto suele ser imposible de obtener, ya que los datos son de alta dimensión o las distancias no son euclidianas (ver Figura 134). En la entrada, el *widget* necesita un conjunto de datos o una matriz de distancias. Al visualizar las distancias entre filas, también puede ajustar el color de los puntos, cambiar su forma, marcarlos y mostrarlos al seleccionarlos. El algoritmo mueve los puntos de forma iterativa en una especie de simulación de un modelo físico: si dos puntos están demasiado cerca el uno del otro (o demasiado lejos), hay una fuerza que los separa (o los acerca). El cambio de posición del punto en cada intervalo de tiempo corresponde a la suma de las fuerzas que actúan sobre él (ver Figura 135).

Seguidamente, se presenta un ejemplo respecto de las distintas variables desde la distribución en el Grupo 1 y en el Grupo 2.

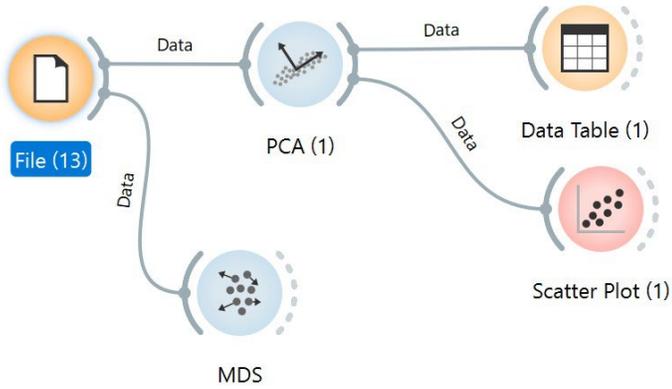


Figura 134. Pasos para hacer un MDS en Orange.

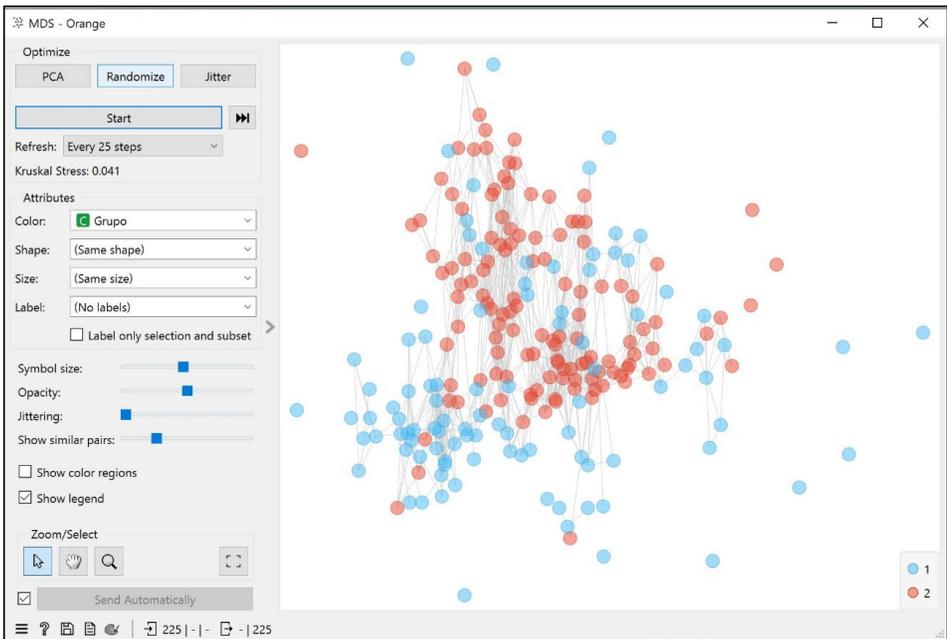


Figura 135. Ejemplo de MDS con Orange.

También, se puede estudiar el MDS aplicando un PCA (ver Figura 136).

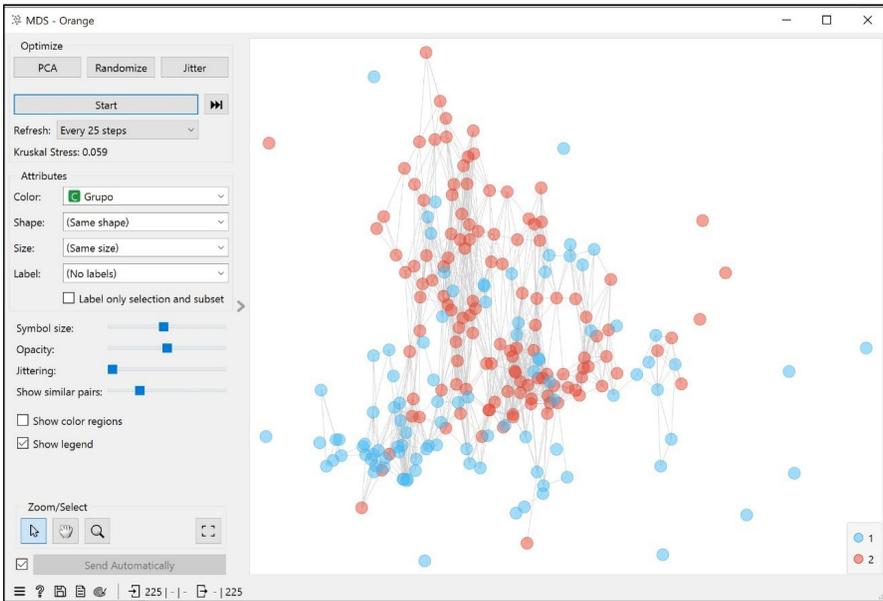


Figura 136. Ejemplo de MDS con PCA en Orange.

De igual modo, se puede analizar la disposición de los miembros de cada grupo en distintas variables. Por ejemplo, vamos a estudiar la disposición respecto de las subescalas de la Escala de Estrategias Metacognitivas de ACRA (autoconocimiento, planificación y auto-evaluación). (ver Figura 137, Figura 138 y Figura 139).

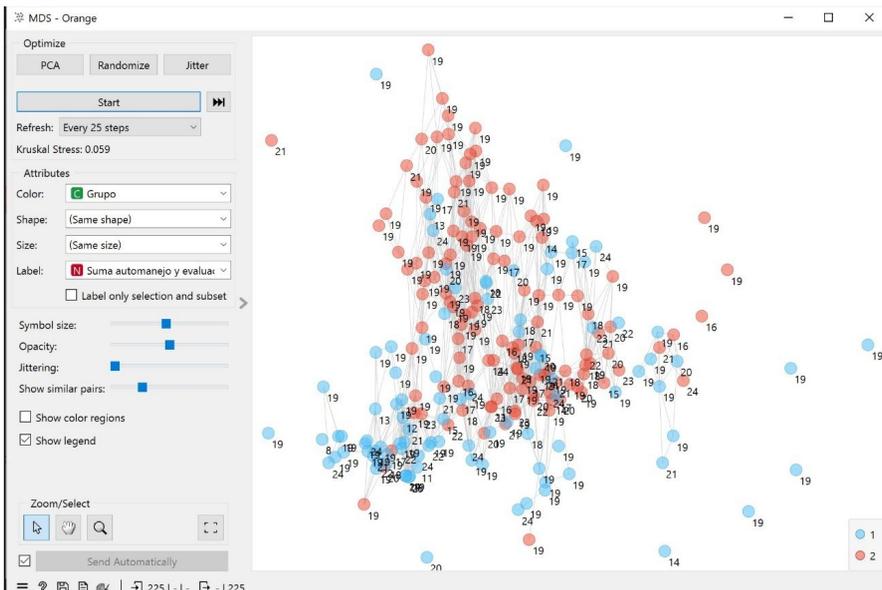


Figura 137. Ejemplo de MDS con un análisis de disposición en las subescalas de Estrategias Metacognitivas de ACRA.

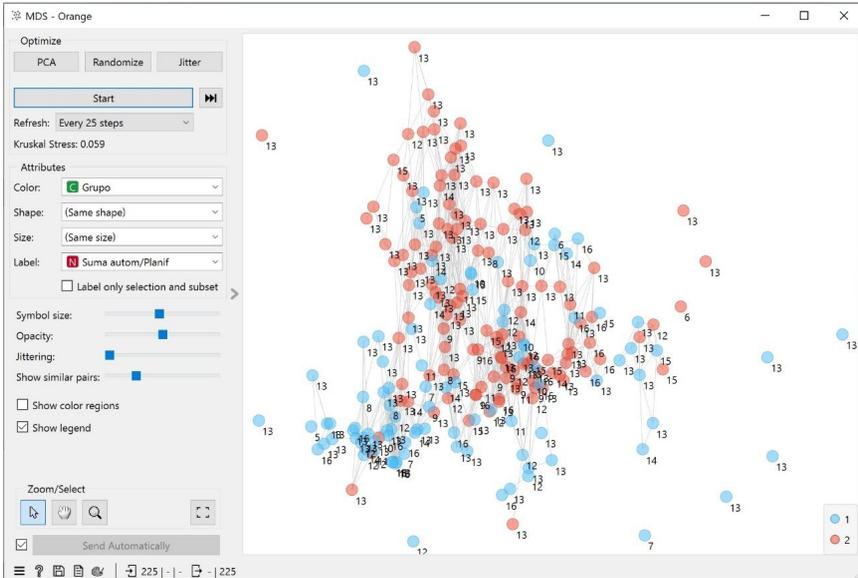


Figura 138. Ejemplo de MDS con un análisis de disposición en las subescalas de Estrategias Metacognitivas de ACRA.

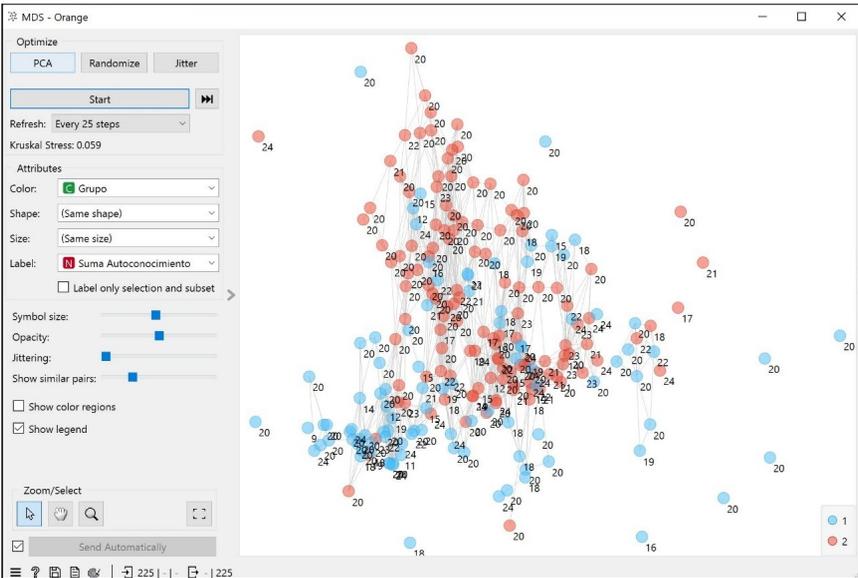


Figura 139. Ejemplo de MDS con un análisis de disposición en las subescalas de Estrategias Metacognitivas de ACRA.

Asimismo, se pueden visualizar el widget de *self organizing (SOM)*. SOM es un tipo de red neuronal artificial (RNA) que se entrena mediante aprendizaje no supervisado para producir una representación discreta bidimensional de los datos (ver Figura 140). Es un método para reducir la dimensionalidad. Los mapas autoorgani-

zados utilizan una función de vecindad para preservar las propiedades topológicas del espacio de entrada. Los puntos de la cuadrícula representan instancias de datos. Por defecto, el tamaño del punto corresponde al número de instancias representadas por el punto. Los puntos se colorean según la clase mayoritaria (si está disponible), mientras que la intensidad del color interior muestra la proporción de la clase mayoritaria. Para ver la distribución de clases, seleccione la opción *Mostrar gráficos circulares*. Al igual que otros *widgets* de visualización, los mapas autoorganizados también admiten la selección interactiva de grupos. Se puede utilizar la tecla *Mayús* para seleccionar un nuevo grupo y *Ctrl+Mayús* para añadirlo al grupo existente.

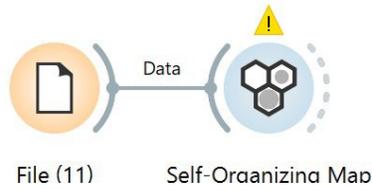


Figura 140. Pasos para hallar *organizing (SOM)* en Orange.

Un ejemplo, de procesamiento con la BBDD de ejemplo se puede consultar seguidamente. (ver Figura 141, Figura 142 y Figura 143).

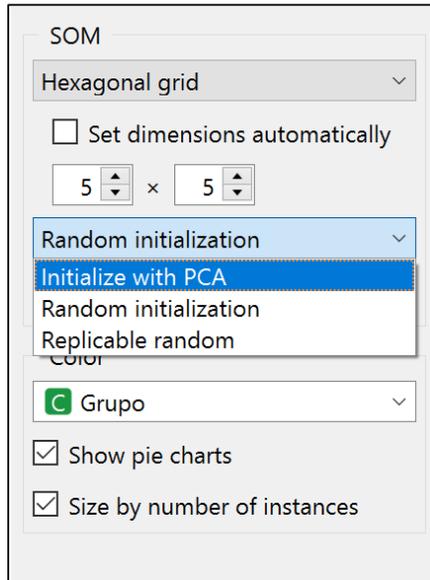


Figura 141. Ejemplo de SOM.

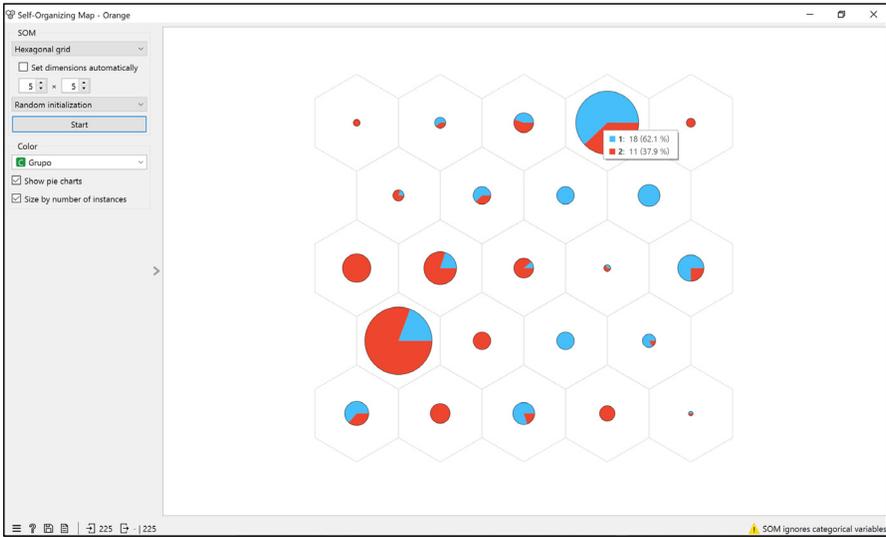


Figura 142. Ejemplo de SOM.

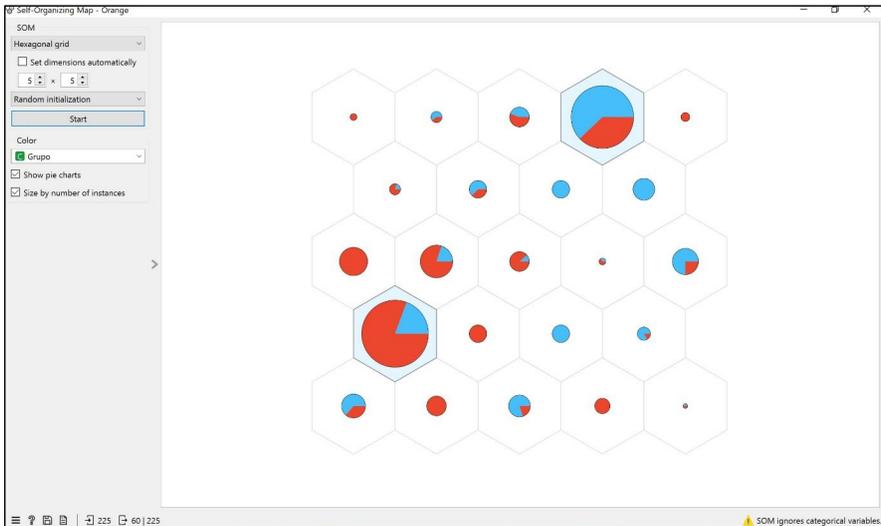


Figura 143. Ejemplo de SOM.

Asimismo, se puede aplicar el *widget Manifold Learning*. Este reduce la dimensionalidad de los datos de alta dimensión y, por lo tanto, es muy útil en combinación con *widgets* de visualización (ver Figura 144). Es una técnica que encuentra una variedad no lineal dentro del espacio de dimensiones superiores. El *widget* genera entonces nuevas coordenadas que corresponden a un espacio bidimensional. Estos datos pueden visualizarse posteriormente con un diagrama de dispersión u otros *widgets* de visualización. Produce diferentes incrustaciones para datos de alta dimensión. Todas las proyecciones utilizan el preprocesamiento predeterminado si es ne-

cesario. Se ejecuta en el siguiente orden: continuación de variables categóricas (con una característica por valor), imputación de valores faltantes con valores medios. Para anular el preprocesamiento predeterminado, preprocesar los datos de antemano con el *widget Preprocess*. El *widget* de aprendizaje múltiple transforma datos de alta dimensión en una aproximación de menor dimensión. Esto lo hace ideal para visualizar conjuntos de datos con muchas características. Utilizamos *voting.tab* para mapear datos de 16 dimensiones en un gráfico 2D. Luego se utiliza *Scatter Plot* para trazar las incrustaciones (ver Figura 145).

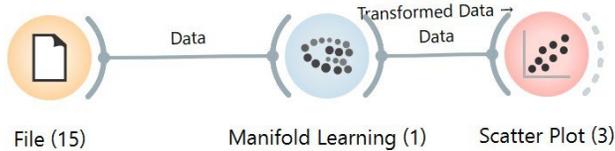


Figura 144. Pasos para hallar Manifold Learning.

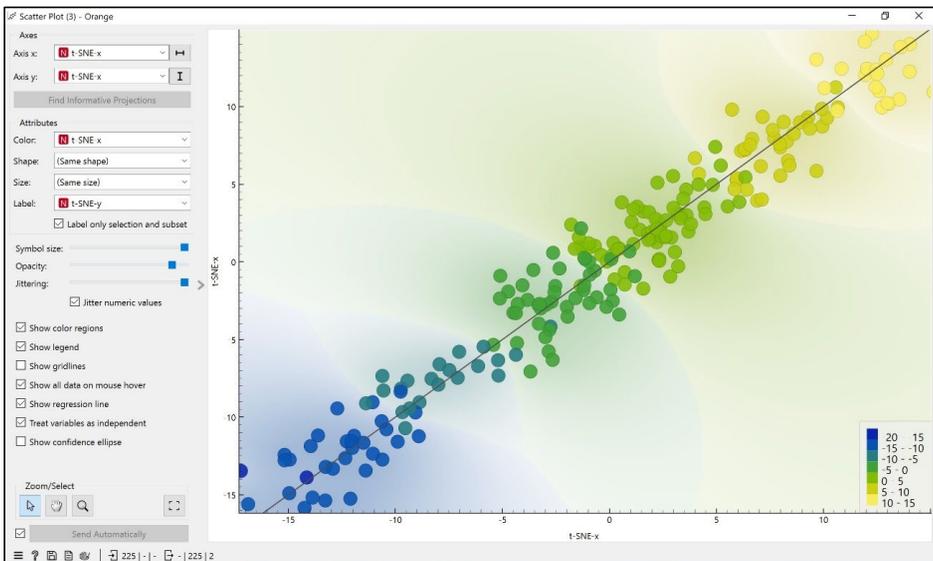


Figura 145. Ejemplo de Manifold Learning.

4.8. Preguntas de autoevaluación Tema 4.

1. ¿Qué se debe hacer antes de extraer los datos en un proceso de análisis en investigación?
 - a) Aplicar directamente técnicas de Machine Learning.
 - b) Preprocesar los datos para eliminar ruido.
 - c) Formular preguntas de investigación relacionadas con el problema.**
 - d) Evaluar el rendimiento de los algoritmos utilizados.

2. ¿En qué consiste la fase de integración de los datos dentro del proceso de minería de datos?
 - a) En aplicar algoritmos para clasificar los datos según su origen.
 - b) En fusionar datos de múltiples bases, evitando redundancias e inconsistencias.**
 - c) En eliminar los datos que no tienen una fuente clara.
 - d) En transformar los datos a gráficos para visualizarlos fácilmente.

3. ¿Cuándo se utiliza el aprendizaje supervisado en minería de datos?
 - a) Cuando se trabaja con datos no estructurados y sin contexto.
 - b) Cuando los datos están etiquetados con una clase o valor objetivo**
 - c) Cuando se desconoce la variable dependiente y no hay etiquetas.
 - d) Cuando se quieren generar datos sintéticos sin supervisión.

4. ¿Cuál es el objetivo principal del aprendizaje no supervisado?
 - a) Predecir una etiqueta o valor objetivo a partir de datos etiquetados.
 - b) Generar un modelo predictivo para nuevas instancias.
 - c) Encontrar patrones, relaciones o agrupaciones en datos sin etiquetar.**
 - d) Transformar datos numéricos en datos categóricos para el análisis.

5. ¿Cuál es una diferencia clave entre el *Educational Data Mining* (EDM) y el *Educational Process Mining*?
 - a) El EDM solo analiza datos de encuestas, mientras que el *Process Mining* analiza exámenes.
 - b) El EDM se centra en el resultado y variables asociadas, mientras que el *Process Mining* se enfoca en el proceso en sí.**
 - c) El *Process Mining* solo aplica algoritmos de *clustering*, mientras que el EDM usa Machine Learning.
 - d) El EDM se usa en contextos empresariales, y el *Process Mining* únicamente en centros educativos.

4.9. Práctica Tema 4.

Dada una base de datos en la que se definen distintas variables dependientes e independientes aplicar técnicas de *Machine Learning* supervisadas y no supervisadas justificando previamente las hipótesis de partida y plasmando el análisis de datos desde el uso de algoritmos supervisados y no supervisados. Para ello, se puede utilizar el software libre de *data mining Orange* <https://orangedatamining.com/>, *software* libre de *data mining Knime* <https://www.knime.com/knime-analytics-platform> o bien el *software* de análisis estadístico de datos SPSS, que puede utilizarse desde

UBULabs. Relativo a las bases de datos se pueden utilizar las bases de datos del proyecto financiado por la Agencia Nacional de Investigación *SmartLearnUni* que están publicadas en acceso abierto en el Repositorio de la Universidad de Burgos <http://hdl.handle.net/10259/10197>.



REFERENCIAS

- Agor, X. (2018). Trabajo propio, CC BY-SA 3.0. Recuperado de Wikipedia 31 de julio de 2018 [Enlace](#)
- American Psychiatric Association, DSM-5 Task Force. (2013). *Diagnostic and statistical manual of mental disorders: DSM-5™* (5th ed.). American Psychiatric Publishing, Inc.. <https://doi.org/10.1176/appi.books.9780890425596>
- Anderson, J.R., y Bower, G. H. (2014). *Human Associative Memory*. New York: Psychology Press. <https://doi.org/10.4324/9781315802886>
- Arnaiz-González, Á., Díez-Pastor, J. F., Rodríguez, J. J., y García-Osorio, C. (2016a). Instance selection for regression: *Adapting DROP*. *Neurocomputing*, 201(12), 66-81. <https://doi.org/10.1016/j.neucom.2016.04.003>
- Arnaiz-González, Á., Díez-Pastor, J. F., García-Osorio, C., y Rodríguez, J. J. (2016b). Random feature weights for regression trees. *Progress in Artificial Intelligence*, 5(2), 91–103. <https://doi.org/10.1007/s13748-016-0081-5>
- Arnaiz-González, A. (2024). Módulo VII.1 intervención temprana y aplicación de recursos inteligentes: internet of things e inteligencia artificial. En M.C. Sáiz-Manzanares, M.C., y M. Santamaría Vazquez (Eds.), *Formación y especialización en atención temprana: uso de recursos tecnológicos y de inteligencia artificial* (pp. 227-233). Burgos: Servicio de Publicaciones de la Universidad de Burgos. <https://doi.org/10.36443/9788418465802>
- Arnaiz González, Á., Díez Pastor, J.F., y Rodríguez Arribas, S. (2024). Módulo IV.13. Técnicas de observación y evaluación a partir de recursos inteligentes: introducción a la minería de datos. En M.C. Sáiz-Manzanares y M. Santamaría Vázquez (Eds.), *Formación y Especialización en Atención Temprana: uso de Recursos Tecnológicos y de Inteligencia Artificial* (145-155). Burgos: Servicio de Publicaciones de la Universidad de Burgos. <https://doi.org/10.36443/9788418465802>
- Artino, A. R. (2008). Cognitive Load Theory and the Role of Learner Experience: An Abbreviated Review for Educational Practitioners. Association for the

- Advancement of Computing. *Education Journal, AACE Journal*, 16(4), 425-439.
- Baddeley A. (2000). The episodic buffer: a new component of working memory? *Trends Cogn Sci.*, 4(11), 417-423. [https://doi.org/10.1016/s1364-6613\(00\)01538-2](https://doi.org/10.1016/s1364-6613(00)01538-2)
- Bash, M.A.S., y Camp, B.W. (1985). *Think Aloud: Increasing Social and Cognitive Skills-A Problem Solving Program for Children*. Illinois: Research Press.
- Breiman, L., Friedman, J., Olshen, R., y Stone, C. (2017). *Classification and Regression Trees*. Boca Raton: Routledge. <https://doi.org/10.1201/9781315139470>
- Bogarín, A., Romero, C., y Cerezo, R. (2016). Aplicando minería de datos para descubrir rutas de aprendizaje frecuentes en Moodle. *edmetic*, 5(1), 73-92. <https://doi.org/10.21071/edmetic.v5i1.4017>
- Bourdeaud'hui, H., Aesaert, K., y van Braak, J. (2021). Exploring the relationship between metacognitive awareness, motivation, and L1 students' critical listening skills. *Journal of Educational Research*, 114(1), 40-51. <https://doi.org/10.1080/00220671.2021.1872474>
- Broadbent, J., y Poon, W. L. (2015). Self-regulated learning strategies and academic achievement in online higher education learning environments: A systematic review. *The Internet and Higher Education*, 27, 1-13. <https://doi.org/10.1016/j.iheduc.2015.04.007>
- Brown, A., y DeLoache, J. S. (1978). Skills, Plans and self-regulation. En R. S. Siegel (Ed.), *Children's thinking: What develops?* (pp. 3-35). Hillsdale, N.J.: Erlbaum
- Camp, B.W., Blom, G.E., Herbert, F., y Van Doornick, W.J. (1985). Think Aloud: A program for developing self-control in young aggressive boys. *Journal of Abnormal Psychology*, 5, 157-169. <https://doi.org/10.1007/BF00913091>
- Carretero. M., y Asensio, M. (2008). *Psicología del Pensamiento*. Madrid: Alianza Editorial.
- Caton, R. (1887). Description of a new form of recording apparatus for the use of practical physiology classes. *J. Anat. Physiol.*, 22, 103-106.
- Cerezo, E., Fernández, E., Amieiro, N., Valle, A., Rosário, P., y Núñez, J. C. (2019). El papel mediador de la autoeficacia y la utilidad entre el conocimiento y el uso de estrategias de autorregulación del aprendizaje. *Revista de Psicodidáctica*, 24(1), 1-8. <https://doi.org/10.1016/j.psicod.2018.08.001>
- Cerezo, R., Sánchez-Santillán, M., Paule-Ruiz, M. P., y Núñez, J. C. (2016). Students' LMS interaction patterns and their relationship with achievement: A case study in higher education. *Computers & Education*, 96, 42-54. <https://doi.org/10.1016/j.compedu.2016.02.006>

- Chen, O., Castro-Alonso, J.C., Paas, F. et al. (2018). Extending Cognitive Load Theory to Incorporate Working Memory Resource Depletion: Evidence from the Spacing Effect. *Educ Psychol Rev*, 30, 483–501. <https://doi.org/10.1007/s10648-017-9426-2>
- Chen, O., y Kalyuga, S. (2020). Exploring factors influencing the effectiveness of explicit instruction first and problem-solving first approaches. *European Journal of Psychology of Education*, 35(3), 607–624. <https://doi.org/10.1007/s10212-019-00445-5>
- Chen, O., Paas, F. y Sweller, J. (2023). A Cognitive Load Theory Approach to Defining and Measuring Task Complexity Through Element Interactivity. *Educ Psychol Rev*, 35, 63. <https://doi.org/10.1007/s10648-023-09782-w>
- Chire, Y. (2018). Trabajo propio, Dominio público. Recuperado de Wikipedia 31 de julio de 2018 [Enlace](#).
- Colby, K.M. (1975). *Artificial Paranoia: A Computer Simulation of Paranoid Processes*. New York: Pergamon Press INC. <https://doi.org/10.1016/C2013-0-02631-X>
- Copeland, J. (2003). The Turing Test, en Moor, J. H. Moor (Ed.), *The Turing Test: The Elusive Standard of Artificial Intelligence* (pp. 1-21). Springer. <https://doi.org/10.1007/978-94-010-0105-2>
- de Bruin, A. B. H., Biwer, F., Hui, L., Onan, E., David, L., y Wiradhany, W. (2023). Worth the effort: The start and stick to desirable difficulties (S2D2) framework. *Educational Psychology Review*, 35(2), Article 41. <https://doi.org/10.1007/s10648-023-09766-w>
- Delgado García, A.E., Mira, J., González Boticario, J., Diez Vegas, F.J. (1995). *Aspectos básicos de la inteligencia artificial*. Madrid: Sanz-Torres.
- Díaz, A., Pérez, M. V., González-Pienda, J. A., y Núñez, J. C. (2017). Impacto de un entrenamiento en aprendizaje autorregulado en estudiantes universitarios. *Perfiles Educativos*, 39(157), 87-104. Recuperado de <http://www.iisue.unam.mx/perfiles/numeros/2017/157> acceso 25/09/2024
- Dillon, S.J., Kleinmann, W., Fomina, Y., Werner, B., Schultz, S., Klucsarits, S., Moreno, W., Butsko, A., McIntire, D.D., Nelson, D.B. (2021). Does simulation improve clinical performance in management of postpartum hemorrhage? *Am J Obstet Gynecol*. 225(4), 435-435. <https://doi.org/10.1016/j.ajog.2021.05.025>
- Doise, W., y Mugny, G. (1979). Individual collective conflicts of centrations in cognitive development. *European Journal of Social Psychology*, 9, 105-108. <https://doi.org/10.1002/ejsp.2420090110>

- Došilović, F. K., Brčić, M., y Hlupić, N. (2018). Explainable artificial intelligence: A survey. 2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), Opatija, Croatia, 2018, pp. 0210-0215, <https://doi.org/10.23919/MIPRO.2018.8400040>
- Efklides, A. (2012). Commentary: How readily can findings from basic cognitive psychology research be applied in the classroom? *Learning and Instruction*, 22(4), 290–295. <https://doi.org/10.1016/j.learninstruc.2012.01.001>
- Efklides, A. (2008). Metacognition: Defining its facets and levels of functioning in relation to self-regulation and co-regulation. *European Psychologist*, 13(4), 277–287. <https://doi.org/10.1027/1016-9040.13.4.277>
- 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
- Ericsson, K. A., y Kintsch, W. (1995). Long-term working memory. *Psychological Review*, 102(2), 211–245. <https://doi.org/10.1037/0033-295X.102.2.211>
- Feuerstein, R. (1980). *Instrumental enrichment*. Baltimore: University Park Press.
- Flavell, J. H. (1979). Metacognition and cognitive monitoring. *American Psychologist*, 34, 906-911. <https://doi.org/10.1037/0003-066X.34.10.906>
- Flavell, J.H. (1993). *El desarrollo cognitivo: nueva edición revisada*. Madrid: Visor.
- Fodor, J.A. (1986). *La modularidad de la mente*. Madrid: Morata.
- Frawley, W. (1999). *Vygotsky y la Ciencia Cognitiva*. Barcelona: Paidós.
- García, S., Luengo, J., y Herrera, F. (2015). *Data Preprocessing in Data Mining. Intelligent Systems Reference Library (ISRL, volume 72)*. Switzerland: Springer. <https://doi.org/10.1007/978-3-319-10247-4>
- Gil-Chaves, I.D., Guevara-López, J.R., García-Zapata, J.L., Leguizamón Robayo, A., y Rodríguez Niño, G. (2016). *Process Analysis and Simulation in Chemical Engineering*. Switzerland: Springer. <https://doi.org/10.1007/978-3-319-14812-0>
- Hart, S. G., y Staveland, L. E. (1988). Development of NASA-TLX (Task Load Index): Results of empirical and theoretical research. En P. A. Hancock y N. Meshkati (Eds.), *Human mental workload* (pp. 139–183). North-Holland. [https://doi.org/10.1016/S0166-4115\(08\)62386-9](https://doi.org/10.1016/S0166-4115(08)62386-9)
- Hartmann, S., Weiss, M., Newman, A. and Hoegl, M. (2020), Resilience in the Workplace: A Multilevel Review and Synthesis. *Applied Psychology*, 69: 913-959. <https://doi.org/10.1111/apps.12191>

- Hofmann, T., Schölkopf, B., y Smola, A. J. (2008). Kernel methods in machine learning. *The annals of statistics*, 36(3), 1171-1220. <https://doi.org/10.1214/009053607000000677>
- Holmes, S., Moorhead, A., Bond, R., Zheng, H., Coates, V., y Mctear, M. (2019). Usability testing of a healthcare chatbot: Can we use conventional methods to assess conversational user interfaces?. In Proceedings of the 31st European Conference on Cognitive Ergonomics (ECCE 2019), Maurice Mulvenna and Raymond Bond (Eds.). ACM, New York, NY, USA, 207-214. Recuperado de <https://www.ulster.ac.uk/research/topic/computer-science/artificial-intelligence/projects/cuq> (Acceso 15/10/2024).
- Hanckok, P.A., y Meshkati, N. (1988). *Human mental workload*. Amsterdam: North Holland.
- Järvelä, S., Malmberg, J., y Koivuniemi, M. (2016). Recognizing socially shared regulation by using the temporal sequences of online chat and logs in CSCL. *Learning and Instruction*, 42, 1-11. <https://doi.org/10.1016/j.learninstruc.2015.10.006>
- Koller, D., y Friedman, N. (2009). *Probabilistic Graphical Models: Principles and Techniques*. MIT Press
- Kalyuga, S., Rikers, R., y Paas, F. (2012). Educational implications of expertise reversal effects in learning and performance of complex cognitive and sensorimotor skills. *Educational Psychology Review*, 24(2), 313–337. <https://doi.org/10.1007/s10648-012-9195-x>
- Kelly, J. T., Campbell, K. L., Gong, E., y Scuffham, P. (2020). The Internet of Things: Impact and implications for health care delivery. *Journal of medical Internet Research*, 22(11), e20135. <https://doi.org/10.2196/20135>
- Kitchener, K. S. (1983). Cognition, metacognition, and epistemic cognition: A three-level model of cognitive processing. *Human Development*, 26(4), 222–232. <https://doi.org/10.1159/000272885>
- Klepsch, M., y Seufert, T. (2020). Understanding instructional design effects by differentiated measurement of intrinsic, extraneous, and germane cognitive load. *Instr Sci*, 48, 45–77. <https://doi.org/10.1007/s11251-020-09502-9>
- Libenson, y Mark H. (2024). *Practical Approach to Electroencephalography*. Second edition., Philadelphia: Elsevier. <https://doi.org/10.1016/C2014-0-02633-0>.
- Likourezos, V., y Kalyuga, S. (2017). Instruction-first and problem-solving-first approaches: Alternative pathways to learning complex tasks. *Instructional Science*, 45(2), 195–219. <https://doi.org/10.1007/s11251-016-9399-4>
- Longoni, M.G., Porcel, E.A., López, M.V., y Dapozo, G.N. (2010, Octubre). Modelos de Redes Neuronales Perceptrón Multicapa y de Base Radial para

la predicción del rendimiento académico de alumnos universitarios. CACIC 2010 - XVI Congreso Argentino de Ciencias de la Computación, Universidad de Morón, Argentina, 692-701.

- Maddox, B.B., Crabbe, S.R., Fishman, J.M. et al. (2019). Factors Influencing the Use of Cognitive–Behavioral Therapy with Autistic Adults: A Survey of Community Mental Health Clinicians. *J Autism Dev Disord*, 49, 4421–4428. <https://doi.org/10.1007/s10803-019-04156-0>
- Marticorena Sánchez, R., y Sáiz Manzanares, M.C (2024). *Protocolo para la integración de un chatbot en una plataforma virtual de aprendizaje tipo Moodle*. Repositorio Institucional de la Universidad de Burgos. <http://hdl.handle.net/10259/8926>
- Marticorena Sánchez, R. (2024). Intervención temprana y aplicación de recursos inteligentes: Intelligent Personal Assistants. En M.C. Sáiz-Manzanares y M. Santamaría Vázquez (Eds.), *Formación y Especialización en Atención Temprana: uso de Recursos Tecnológicos y de Inteligencia Artificial* (235-357). Burgos: Servicio de Publicaciones de la Universidad de Burgos. <https://doi.org/10.36443/9788418465802>
- Marulis, L. M., y Nelson, L. J. (2021). Metacognitive processes and associations to executive function and motivation during a problem-solving task in 3–5 year olds. *Metacognition and Learning*, 16(1), 207–231. <https://doi.org/10.1007/s11409-020-09244-6>
- Markus, A., Kors, J.A., y Rijnbeek, P.R. (2021). The role of explainability in creating trustworthy artificial intelligence for health care: A comprehensive survey of the terminology, design choices, and evaluation strategies. *Journal of Biomedical Informatics*, 113, 103655. <https://doi.org/10.1016/j.jbi.2020.103655>
- Martínez-Sarmiento, L. F., y Gaeta, M. L. (2019). Utilización de la plataforma virtual Moodle para el desarrollo del aprendizaje autorregulado en estudiantes universitarios. *Educar*, 55(2), 479-498. <https://doi.org/10.5565/rev/educar.883>
- Maudes, J., Rodríguez, J. J., García-Osorio, C., y García-Pedrajas, N. (2012). Random feature weights for decision tree ensemble construction. *Information Fusion*, 13(1), 20–30. <https://doi.org/10.1016/j.amc.2013.03.139>
- Mayer, R.E. (2010). Applying the Science of Learning to Medical Education. *Technology and Control*, 39, 169-175. <http://dx.doi.org/10.1111/j.1365-2923.2010.03624.x>
- Meichenbaum (1977). *Cognitive-Behavior Modification: An integrative approach*. New York: Plenum Press.
- Meichenbaum y Goodman (1969). The developmental control of operant motor responding by verbal operant. *Journal of experimental Child Psychology*, 7, 553-565. [https://doi.org/10.1016/0022-0965\(69\)90016-2](https://doi.org/10.1016/0022-0965(69)90016-2)

- Meichenbaum y Goodman (1971). Training impulsive children to talk to themselves: A means of developing self-control. *Journal of Abnormal Psychology*, 77, 115-126. <https://doi.org/10.1037/h0030773>
- Meijer, J., Veenman, M. V. J., y Van Hout-Wolters, B. H. A. M. (2006). Metacognitive Activities in Text-Studying and Problem-Solving: Development of a taxonomy. *Educational Research and Evaluation*, 12(3), 209-237. <https://doi.org/10.1080/13803610500479991>
- Newell, A., y Simon, H. A. (1972). *Human Problem Solving*. Englewood Cliffs: Prentice Hall. <http://garfield.library.upenn.edu/classics1980/A1980KD04600001.pdf>
- Ministerio de Trabajo y Asuntos Sociales del Gobierno de España. Mental workload assessment: the NASA TLX method Estimation de la charge de travail mental: la méthode NASA-TLX. Recuperado de https://www.insst.es/documents/94886/327064/ntp_544.pdf/0da348cc-7006-4a8a-9cee-25ed6f59efdd (acceso 14/10/2024).
- NASA Task Load Index. Recuperado de <https://digital.ahrq.gov/health-it-tools-and-resources/evaluation-resources/workflow-assessment-health-it-toolkit/all-workflow-tools/nasa-task-load-index> (acceso 14/10/2024).
- Nelson, K. (1996). *Language in cognitive development: Emergence of the mediated mind*. Cambridge University Press. <https://doi.org/10.1017/CBO9781139174619>
- Nelson, T. O., y Narens, L. (1990). Metamemory: A theoretical framework and new findings En G. H. Bower (Eds.), *The psychology of learning and motivation* (Vol. 26, pp. 125-141). New York, NY: Academic Press.
- Nelson, T. O., y Narens, L. (1994). Why investigate metacognition? En J. Metcalfe y A. P. Shimamura (Eds.), *Metacognition: Knowing about knowing* (pp. 1-25). Cambridge, MA: MIT Press.
- Norman, E., y Furnes, B. (2016). The relationship between metacognitive experiences and learning: Is there a difference between digital and non-digital study media?. *Computers in Human Behavior*, 54, 301-309. <https://doi.org/10.1016/j.chb.2015.07.043>
- Park, B., Korbach, A., y Brünken, R. (2020). Does thinking-aloud affect learning, visual information processing and cognitive load when learning with seductive details as expected from self-regulation perspective? *Computers in Human Behavior*, 111, 106411. <https://doi.org/10.1016/j.chb.2020.106411>
- Pardo, C., Diez-Pastor, J. F., García-Osorio, C., Rodríguez, J. J. (2013). Rotation forests for regression. *Applied Mathematics and Computation*, 219(19), 9914-9924. <https://doi.org/10.1016/j.amc.2013.03.139>

- 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>
- Puga, Krzywinski, y Altman, (2015). Bayesian statistics: Today's predictions are tomorrow's priors. *Nat Methods*, 12, 377–378. <https://doi.org/10.1038/nmeth.3368>
- Quinlan, J.R. (2014). *C4. 5: Programs for Machine Learning*. Elsevier.
- Rivière, Á. (2003). Los conceptos de sujeto en las psicologías del conocimiento. En Ruiz- J.M. Vargas, , y M. Belinchón (Eds.), *Ángel Rivière Obras escogidas. Volumen I. Diálogos sobre Psicología: De los cómputos mentales al significado de la conciencia* (pp. 13-22). Madrid: Panamericana.
- Robillos, R. J., y Bustos, I. G. (2022). Learners' listening skill and metacognitive awareness through metacognitive strategy instruction with pedagogical cycle. *International Journal of Instruction*, 15(3), 393-412. <https://doi.org/10.29333/iji.2022.15322a>
- Sáiz-Manzanares, M.C. (1994). *Adaptación y validación de un programa de desarrollo sociocognitivo en niños con privación socio-ambiental*. Tesis Doctoral. Valladolid: Servicio de Publicaciones de la Universidad de Valladolid. <http://hdl.handle.net/10259/139> acceso 25/09/2024
- 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., Payo-Hernanz, R., Zaparaín-Yáñez, M.J., Andres-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*, e62103. <https://doi.org/10.3791/62103>
- Sáiz-Manzanares, M.C., Queiruga, M.Á., García-Osorio, C.I., Montero, E., y Rodríguez-Medina, J. (2019). Observation of Metacognitive Skills in Natural Environments: A Longitudinal Study With Mixed Methods. *Front. Psychol.*, 10, 1-13. <https://doi.org/10.3389/fpsyg.2019.02398>
- Sáiz-Manzanares, M.C., Ramos Pérez, I., Arnaiz-Rodríguez, Á., Rodríguez-Arribas, S., Almeida, L., y 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>

- 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., Rodríguez-Díez, J.J., Marticorena, R., Zaparaín, M.J., y 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. y Valdivieso-León, L. (2020). Relación entre rendimiento académico y desarrollo de Estrategias de autorregulación en estudiantes universitarios. *Revista Electrónica Interuniversitaria de Formación del Profesorado*, 23(3), 49-65. <https://doi.org/10.6018/reifop.385491>
- Sethi, P., y Sarangi, S.R. (2017). *Internet of Things: Architectures, Protocols and Applications*. *Journal of Electrical and Computer Engineering*, 9324035(25). <https://doi.org/10.1155/2017/9324035>
- Schraw, G., y Dennison, R. S. (1994). Assessing metacognitive awareness. *Contemporary Educational Psychology*, 19(4), 460-475. <https://doi.org/10.1006/ceps.1994.1033>
- 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>
- Shimamura, A. P. (2000). The role of the prefrontal cortex in dynamic filtering. *Psychobiology*, 28(2), 207-218. <https://doi.org/10.3758/BF03331979>
- Stephanou, G., y Mpiontini, M. (2017). Metacognitive knowledge and metacognitive regulation in self-regulatory learning style, and in its effects on performance expectation and subsequent performance across diverse school subjects. *Psychology*, 8, 1941-1975. <https://doi.org/10.12691/rpbs-8-1-1>
- Stephanou, G., y Karamountzos, D. (2020). Enhancing Students' Metacognitive Knowledge, Metacognitive Regulation and Performance in Physical Education via TGFU. *Research in Psychology and Behavioral Sciences*, 8(1), 1-10. <https://doi.org/10.12691/rpbs-8-1-1>
- Sterman, M. B., y Chartier, D.R. (2023). Chapter 7 - Origins of electroencephalogram rhythms and implications for neurofeedback En D.R. Chartier., et al. *Introduction to Quantitative EEG and Neurofeedback*. Third Edition (pp. 103-120). <https://doi.org/10.1016/B978-0-323-89827-0.00030-9>
- Sternberg, R. (1986). *Las capacidades humanas: Un enfoque desde el procesamiento de la información*. Barcelona: Labor Universitaria.

- Sternberg, R. (1987). *Inteligencia Humana II*. Barcelona: Paidós.
- Sternberg, R. (1990). *Más allá del cociente intelectual*. Bilbao: DDB.
- Sweller, J. (2010). Cognitive load theory: Recent theoretical advances. En J. L. Plass, R. Moreno, y R. Brünken (Eds.), *Cognitive load theory* (pp. 29–47). Cambridge University Press. <https://doi.org/10.1017/CBO9780511844744.004>
- Sweller, J. (2023). The Development of Cognitive Load Theory: Replication Crises and Incorporation of Other Theories Can Lead to Theory Expansion. *Educ Psychol Rev*, 35, 95. <https://doi.org/10.1007/s10648-023-09817-2>
- Sweller, J., van Merriënboer, J.J.G. y Paas, F. (2019). Cognitive Architecture and Instructional Design: 20 Years Later. *Educ Psychol Rev*, 31, 261–292. <https://doi.org/10.1007/s10648-019-09465-5>
- Vapnik, V. (2013). *The nature of statistical learning theory*. New York: Springer science & business media.
- van Gog, T., y Sweller, J. (2015). Not new, but nearly forgotten: The testing effect decreases or even disappears as the complexity of learning materials increases. *Educational Psychology Review*, 27(2), 247–264. <https://doi.org/10.1007/s10648-015-9310-x>
- van der Stel, M., y Veenman, M. V. J. (2014). Metacognitive Skills and Intellectual Ability of Young Adolescents: A Longitudinal Study from a Developmental Perspective. *European Journal of Psychology of Education*, 29, 117-137. <https://doi.org/10.1007/s10212-013-0190-5>
- Veenman, M. V. J. (2007). The assessment and instruction of self-regulation in computerbased environments: A discussion. *Metacognition and Learning*, 2, 177-183. <https://doi.org/10.1007/s11409-007-9017-6>
- Veenman, M. V. J. (2011a). Alternative assessment of strategy use with self-report instruments: a discussion. *Metacognition and Learning*, 6, 205-211. <https://doi.org/10.1007/s11409-011-9080-x>
- Veenman, M. V. J. (2011b). Learning and Self-Monitor and Self-Regulate. En R. Mayer y P. Alexander. (Eds.), *Handbook of Research on Learning and Instruction* (pp .197-218). New York: Routledge.
- Veenman, M. V. J. (2015). Thinking about metacognition improves thinking. En R. Wegerif y J. C. Kaufman (Eds.), *The Routledge International Handbook of Research on Teaching Thinking* (pp. 280-288). University of Exeter: Taylor and Francis Inc. <https://doi.org/10.4324/9781315797021>
- Veenman, M. V. J., y van Cleef, D. (2019). Measuring metacognitive skills for mathematics: students' self-reports versus on-line assessment methods.

- ZDM – Mathematics Education*, 51(4), 691-701. <https://doi.org/10.1007/s11858-018-1006-5>
- Veenman, M. V. J., Prins, F. J., y Verheij, J. (2003). Learning styles: Self-report versus thinkingaloud measures. *British Journal of Educational Psychology*, 73(3), 357-372. <https://doi.org/10.1348/000709903322275885>
- Veenman, M.V.J., Van Hout-Wolters, B.H.A.M., y Afflerbach, P. (2006). Metacognition and learning: conceptual and methodological considerations. *Metacognition Learning*, 1, 3–14. <https://doi.org/10.1007/s11409-006-6893-0>
- Ventura, A. C., Cattoni, M. S., y Borgobello, A. (2017). Aprendizaje autorregulado en el nivel universitario: Un estudio situado con estudiantes de psicopedagogía de diferentes ciclos académicos. *Revista electronica educare*, 21(2), 1-20. <https://doi.org/10.15359/ree.21-2.1>
- Weizenbaum, J. (1976). *Computer power and human reason: From judgment to calculation*. W. H. Freeman & Co.
- Witten, I-H., y Eibe, F. (2005). *Data mining: practical machine learning tools and techniques* (2nd Edition). Amsterdam: Elsevier.
- Woll, B., (2019). *Cognitive Benefits of Language Learning: Broadening our*. British Academy. United Kingdom.
- Vygotsky, L.S. (1962). *Thought and language*. Cambridge: Mass., MIT Press.
- Winston, Patrick Henry. (1992). *Artificial Intelligence*. Addison-Wesley.
- Zimmerman, B. J. (2008). Investigating self-regulation and motivation: historical background, methodological developments, and future prospects. *American Educational Research Journal*, 45, 166–183. <https://doi.org/10.3102/0002831207312909>
- Zimmerman, B. J., y Schunk, D. (2008). Motivation. An essential dimension of self-regulated learning. En D. Schunk y B. J. Zimmerman (Eds.), *Motivation and Self-regulated learning. Theory, research and applications* (pp. 1-31). New York: Lawrence Erlbaum.



RELACIÓN DE TABLAS.

Tabla 1. <i>Relación entre los conceptos de conocimiento de la cognición, regulación de la cognición y conocimiento metacognitivo (adaptación de Sáiz-Manzanares, 2019 p. 16).</i>	27
Tabla 2. <i>Factores de carga cognitiva.</i>	34
Tabla 3. <i>Plantilla de carga cognitiva.</i>	35
Tabla 4. <i>Análisis de percepción del continuo de carga cognitiva en distintas dimensiones.</i>	35
Tabla 5. <i>Tabla de Evaluación del Método NASA-TLX.</i>	36
Tabla 6. <i>Tabla de puntuaciones.</i>	36
Tabla 7. <i>Dimensiones de NASA y relación con la percepción de la carga intrínseca y extrínseca.</i>	37
Tabla 8. <i>Métricas posibles extraídas de eye tracking Tobii Pro Lab v.24.21 formato Interval-based TSV file.</i>	62
Tabla 9. <i>Métricas posibles extraídas de eye tracking Tobii Pro Lab v.24.21 formato AOI-based TSV file.</i>	66
Tabla 10. <i>Parámetros más representativos que pueden obtenerse con la técnica de seguimiento ocular y su importancia en el tratamiento de la información (información traducida y adaptada de Sáiz-Manzanares et al. (2021) p. 3-4.</i>	75
Tabla 11. <i>Indicadores de registro multimodal en el tratamiento de la información. (información traducida y adaptada de Sáiz-Manzanares et al. (2024) p. 3.</i>	79



RELACIÓN DE FIGURAS.

Figura 1.	<i>Modelo de Nelson y Narens (1990) (imagen elaboración propia desde el modelo de Nelson y Narens).....</i>	<i>26</i>
Figura 2.	<i>Clasificación de las estrategias Metacognitivas adaptación de van der Stel y Veenman (2014).....</i>	<i>28</i>
Figura 3.	<i>Proceso de enseñanza-aprendizaje (imagen fuente propia).....</i>	<i>29</i>
Figura 4.	<i>Relación interconceptual en el ámbito metacognitivo (imagen fuente propia).</i>	<i>29</i>
Figura 5.	<i>Marco teórico de NASA TLX adaptado a la aplicación en el contexto del proceso de enseñanza-aprendizaje.</i>	<i>34</i>
Figura 6.	<i>Ejemplo de diálogo de flujo con Chatfuel.</i>	<i>44</i>
Figura 7.	<i>Ejemplo de diálogo de flujo con IBM WatsonX.....</i>	<i>45</i>
Figura 8.	<i>Ejemplos de diálogos en aplicaciones tipo bot con asistentes con imagen.</i>	<i>45</i>
Figura 9.	<i>Tomado del Manual Tobii Pro Lab v. 1.194 p. 155.</i>	<i>52</i>
Figura 10.	<i>Tomado del Manual Tobii Pro Lab v. 1.194 p. 158.</i>	<i>52</i>
Figura 11.	<i>Imagen tomada de Tobii información en web enlace</i>	<i>53</i>
Figura 12.	<i>Imagen tomada de Tobii información en web enlace</i>	<i>53</i>
Figura 13.	<i>Imagen tomada de Tobii TD Snap enlace</i>	<i>54</i>
Figura 14.	<i>Tomado de TD Snap Motor Plan enlace</i>	<i>55</i>

Figura 15.	<i>Imagen tomada de Tobii TD Snap Express enlace</i>	55
Figura 16.	<i>Imagen tomada de Tobii TD Snap Express enlace</i>	56
Figura 17.	<i>Imagen tomada de Tobii TD Snap Express enlace</i>	56
Figura 18.	<i>Tomado del Manual Tobii Pro Lab v. 1.194 p. 159.</i>	57
Figura 19.	<i>Parámetros para la medición del ajuste en calibración tomado del Tobii dynavox enlace</i>	57
Figura 20.	<i>Indicadores de calibración en un equipo Tobii Pro Lab (fuente propia).</i>	58
Figura 21.	<i>Ejemplos de visualización de los puntos de calibración (fuente propia).</i>	58
Figura 22.	<i>Posibilidades de inclusión de tareas en un dispositivo Tobii Pro Lab v.24.21 (fuente propia).</i>	59
Figura 23.	<i>Definición de las variables y de los parámetros en el estudio.</i>	59
Figura 24.	<i>Proceso de anonimización de los datos de los participantes (fuente propia).</i>	60
Figura 25.	<i>Integración de señales de eye tracker, facial, sonido y de GSR (fuente propia).</i>	61
Figura 26.	<i>Integración de señales con EEG imagen de acceso abierto tomada de Bitbrain enlace</i>	61
Figura 27.	<i>Registro en vídeo del posicionamiento dinámico de la frecuencia dentro del estímulo (fuente propia).</i>	70
Figura 28.	<i>Heat Map obtenido durante la ejecución de una actividad (fuente propia).</i>	70
Figura 29.	<i>Scan Path de la ejecución de un usuario durante una actividad (fuente propia).</i>	71
Figura 30.	<i>Modelos de análisis de distancia métodos string edit (imágenes tomadas de Sáiz Manzanares et al., 2020) p. 12-13.</i>	72

Figura 31.	<i>Modelos de análisis de distancia métodos string edit (imágenes tomadas de Sáiz Manzanares et al., 2020) p. 14-15.....</i>	<i>72</i>
Figura 32.	<i>Dispositivo GSR, posición de los dedos para el registro, ejemplo de registro tomado de Bitbrain.....</i>	<i>82</i>
Figura 33.	<i>Imagen del registro en EEG con 16 canales tomado de Bitbrain enlace</i>	<i>82</i>
Figura 34.	<i>Dispositivo tipo diadema con electrodos secos tecnología de Bitbrain y registro de señales.....</i>	<i>83</i>
Figura 35.	<i>Análisis de registro multicanal tomado de Bitbrain web.</i>	<i>84</i>
Figura 36.	<i>Hans Berger en estudios de neuropsiquiatría (imágenes tomadas de acceso libre).....</i>	<i>85</i>
Figura 37.	<i>Áreas de Brodmann (esta foto de Autor desconocido está bajo licencia CC BY-SA).</i>	<i>86</i>
Figura 38.	<i>Lóbulos frontal y prefrontal, canales de registro en EEG formulación internacional y resumen de las funciones cognitivas (imagen de acceso libre tomada de Bitbrain, destacado propio).....</i>	<i>87</i>
Figura 39.	<i>Lóbulos parietal y parietooccipital, canales de registro en EEG formulación internacional y resumen de las funciones cognitivas (imagen de acceso libre tomada de Bitbrain estacado propio).....</i>	<i>88</i>
Figura 40.	<i>Lóbulos parietooccipital y occipital, canales de registro en EEG formulación internacional y resumen de las funciones cognitivas (imagen de acceso libre tomada de Bitbrain estacado propio).....</i>	<i>89</i>
Figura 41.	<i>Representación gráfica de las ondas gamma tomada de Bitbrain.....</i>	<i>90</i>
Figura 42.	<i>Representación gráfica de las ondas beta tomada de Bitbrain.....</i>	<i>90</i>
Figura 43.	<i>Representación gráfica de las ondas alpha tomada de Bitbrain.....</i>	<i>91</i>
Figura 44.	<i>Representación gráfica de las ondas Theta tomada de Bitbrain.....</i>	<i>92</i>
Figura 45.	<i>Representación gráfica de las ondas Delta tomada de Bitbrain.....</i>	<i>92</i>

Figura 46.	<i>Procesamiento de datos en el análisis de señales multicanal integradas.</i>	93
Figura 47.	<i>Representación de emociones imágenes fuente propia Sáiz-Manzanares (2025). propia http://hdl.handle.net/10259/10225</i>	93
Figura 48.	<i>Representación del análisis del impacto en la percepción de distintas emociones (imagen fuente propia)</i>	94
Figura 49.	<i>Representación del análisis del engagement en la percepción de distintas emociones (imagen fuente propia)</i>	94
Figura 50.	<i>Representación del análisis de la memorización en la percepción de distintas emociones (imagen fuente propia)</i>	95
Figura 51.	<i>Representación del análisis de la valencia en la percepción de distintas emociones (imagen fuente propia)</i>	95
Figura 52.	<i>Representación del análisis de la carga de trabajo en la percepción de distintas emociones (imagen fuente propia)</i>	96
Figura 53.	<i>Análisis de las áreas de interés en la emoción 1 (imagen fuente propia)</i>	96
Figura 54.	<i>Análisis de las áreas de interés en la emoción 2 (imagen fuente propia)</i>	97
Figura 55.	<i>Análisis de las áreas de interés en la emoción 3 (imagen fuente propia)</i>	97
Figura 56.	<i>Análisis de las áreas de interés en la emoción 4 (imagen fuente propia)</i>	98
Figura 57.	<i>Análisis de las áreas de interés en la emoción 5 (imagen fuente propia)</i>	98
Figura 58.	<i>Mapa de calor en el área de interés de triángulo facial (imagen fuente propia)</i>	99
Figura 59.	<i>Mapa de focalización en el área de interés de triángulo facial (imagen fuente propia)</i>	99

Figura 60.	<i>Mapa de trayectoria en el área de interés de triángulo facial (imagen fuente propia).</i>	100
Figura 61.	<i>Mapa de biométricas en el área de interés de triángulo facial (imagen fuente propia).</i>	100
Figura 62.	<i>Mapa de tiempo en el área de interés de triángulo facial (imagen fuente propia).</i>	101
Figura 63.	<i>Imagen adaptada del original de García, Luengo, y Herrera (2015) p. 3 sobre Knowledge Discovery in Databases (KDD).</i>	119
Figura 64.	<i>Imagen adaptada del original de García, Luengo, y Herrera (2015) preparación de los datos p. 12.</i>	121
Figura 65.	<i>Clasificación de las Técnicas de Machine Learning.</i>	124
Figura 66.	<i>Tomada de Antti Ajanki AnA.</i>	125
Figura 67.	<i>Aplicación de la técnica del vecino más cercano con el paquete estadístico SPSS (fuente propia).</i>	126
Figura 68.	<i>Gráfico de regresión de residuo estandarizado realizado con el paquete estadístico SPSS (fuente propia).</i>	128
Figura 69.	<i>Gráficos de regresión parcial realizado con el paquete estadístico SPSS (fuente propia).</i>	128
Figura 70.	<i>Modelo de Regresión lineal Múltiple realizado con el paquete estadístico SPSS (fuente propia).</i>	129
Figura 71.	<i>Árbol de decisión realizado con el paquete estadístico SPSS (fuente propia).</i>	131
Figura 72.	<i>Resultados del Árbol de decisión realizado con el paquete estadístico SPSS (fuente propia).</i>	131
Figura 73.	<i>Centroides iniciales en este caso $k = 3$ se generan de forma aleatoria dentro de un conjunto de datos. Tomado de Weston.1 (2018).</i>	133

Figura 74.	<i>Los k grupos son generados asociando el punto con la media más cercana. Se realiza a través del diagrama de Voronoi generado por los centroides Weston.2 (2018).</i>	133
Figura 75.	<i>El centroide de cada uno de los k grupos se recalcula Weston.3 (2018).</i>	133
Figura 76.	<i>Los pasos 2 y 3 se repiten hasta que se logra la convergencia. Weston.4 (2018).</i>	133
Figura 77.	<i>Ejemplo de convergencia del algoritmo k-means tomado de Agor (2018).</i>	133
Figura 78.	<i>Comparación de agrupamiento entre un modelo de clustering k-mean y uno EM, tomado de Chire (2018).</i>	134
Figura 79.	<i>Esquema de análisis de datos con un procedimiento tradicional y con uno de Process Mining. Tomado de Bogarín, Romero, y Cerezo (2016) p. 77. Reproducido con permiso de los autores.</i>	137
Figura 80.	<i>Inteligencia Artificial, Minería de Datos y Deep Learning.</i>	139
Figura 81.	<i>Ejemplo de clases, instancias y atributos.</i>	139
Figura 82.	<i>Software de Data Mining Orange.</i>	140
Figura 83.	<i>Widgets que ofrece Orange.</i>	140
Figura 84.	<i>Carga de datos en Orange.</i>	141
Figura 85.	<i>Base de datos en formato Excel.</i>	142
Figura 86.	<i>Datos en formato CSV.</i>	142
Figura 87.	<i>Base de datos en formato CVS.</i>	143
Figura 88.	<i>Cambio de puntos a comas.</i>	143
Figura 89.	<i>Cambio de los separadores de tabulación de comas a punto y coma.</i>	144
Figura 90.	<i>Importación de la base de datos en el software Orange.</i>	144

Figura 91.	<i>Visualización de los datos en un formato tabular.....</i>	<i>145</i>
Figura 92.	<i>Visualización del «Scatter Plot» y el de «Distribution» en el software Orange.</i>	<i>145</i>
Figura 93.	<i>Tipos de tareas que se pueden realizar con Orange.</i>	<i>146</i>
Figura 94.	<i>Aplicación de algoritmos de aprendizaje supervisado conociendo la clase.....</i>	<i>146</i>
Figura 95.	<i>Aprendizaje supervisado. Regresión.</i>	<i>147</i>
Figura 96.	<i>Utilización del algoritmo k-NN con Orange.</i>	<i>147</i>
Figura 97.	<i>Utilización del algoritmo de regresión con Orange.....</i>	<i>148</i>
Figura 98.	<i>Modelo de Linear Regression con Orange.....</i>	<i>148</i>
Figura 99.	<i>División del conjunto de datos.</i>	<i>149</i>
Figura 100.	<i>Evaluar errores en Orange.....</i>	<i>149</i>
Figura 101.	<i>Validación cruzada.</i>	<i>149</i>
Figura 102.	<i>Test and Score en Orange.....</i>	<i>150</i>
Figura 103.	<i>Representación del vecino más cercano (k-NN).....</i>	<i>150</i>
Figura 104.	<i>Representación de un árbol de decisión.....</i>	<i>151</i>
Figura 105.	<i>Visualización de las bifurcaciones en Orange.</i>	<i>151</i>
Figura 106.	<i>Validación cruzada con Orange.....</i>	<i>152</i>
Figura 107.	<i>Representación de Clustering.....</i>	<i>153</i>
Figura 108.	<i>«Select Columns» en Orange.</i>	<i>153</i>
Figura 109.	<i>k-Means en Orange.</i>	<i>154</i>
Figura 110.	<i>Selección archivo csv.....</i>	<i>154</i>
Figura 111.	<i>Feature Statistics.....</i>	<i>155</i>

Figura 112. <i>Estadísticos descriptivos de las variables seleccionadas.</i>	155
Figura 113. <i>Normalización de datos.</i>	156
Figura 114. <i>Resultado de la normalización.</i>	157
Figura 115. <i>Selección Tabla pivote.</i>	158
Figura 116. <i>Tabla pivote subescala de autoconocimiento</i>	159
Figura 117. <i>Tabla pivote subescala de planificación.</i>	160
Figura 118. <i>Tabla pivote subescala de automanejo.</i>	161
Figura 119. <i>Box Plot.</i>	162
Figura 120. <i>Box Plot.</i>	162
Figura 121. <i>Box Plot comparación de medias.</i>	163
Figura 122. <i>Selección Line Plot.</i>	163
Figura 123. <i>Ejemplo de Line Plot.</i>	164
Figura 124. <i>Ejemplo Violin Plot.</i>	164
Figura 125. <i>Ejemplo Scatter Plot.</i>	165
Figura 126. <i>Ejemplo de Scatter Plot aplicando regresión.</i>	166
Figura 127. <i>Ejemplo Radviz.</i>	167
Figura 128. <i>Pasos para hacer un Heat Map en Orange.</i>	167
Figura 129. <i>Ejemplo de Heat Map.</i>	168
Figura 130. <i>Ejemplo de un árbol de decisión con Orange.</i>	169
Figura 131. <i>Algoritmos de clustering en Orange.</i>	169
Figura 132. <i>Pasos para hacer un PCA con Orange.</i>	170
Figura 133. <i>Ejemplo de PCA.</i>	170

Figura 134. <i>Pasos para hacer un MDS en Orange.</i>	171
Figura 135. <i>Ejemplo de MDS con Orange.</i>	171
Figura 136. <i>Ejemplo de MDS con PCA en Orange.</i>	172
Figura 137. <i>Ejemplo de MDS con un análisis de disposición en las subescalas de Estrategias Metacognitivas de ACRA.</i>	172
Figura 138. <i>Ejemplo de MDS con un análisis de disposición en las subescalas de Estrategias Metacognitivas de ACRA.</i>	173
Figura 139. <i>Ejemplo de MDS con un análisis de disposición en las subescalas de Estrategias Metacognitivas de ACRA.</i>	173
Figura 140. <i>Pasos para hallar organizing (SOM) en Orange.</i>	174
Figura 141. <i>Ejemplo de SOM.</i>	174
Figura 142. <i>Ejemplo de SOM.</i>	175
Figura 143. <i>Ejemplo de SOM.</i>	175
Figura 144. <i>Pasos para hallar Manifold Learning.</i>	176
Figura 145. <i>Ejemplo de Manifold Learning.</i>	176



RELACIÓN DE ACRÓNIMOS.

A

activación fisiológica 81
Ajusted Rang Index 74
algoritmo iterativo 134
almacenamiento 24, 83
AOI click metrics 69
AOI fixation metrics 62, 69
AOI Visit metrics 63, 69
aprendizaje activo 122
aprendizaje eficaz 33
aprendizaje no supervisado 74, 123, 124, 131, 141, 145, 152, 173, 177
aprendizaje semisupervisado 145
aprendizaje supervisado 74, 122, 123, 124, 125, 137, 145, 146, 150, 152, 177
árbol de decisión 101, 129, 151, 152
áreas cerebrales 86
áreas de Brodmann 87
Áreas de Interés 62, 75
Autoconocimiento 157
Automanejo 157

B

base de datos 73, 122, 137, 141, 144, 177
Base Radial 185
biomarcadores conductuales 51
Blended Learning 126
Blink Count 77
Blink Duration Average 77
Blink Duration Maximum 77
Blink Duration Minimum 77
Blink Duration Total 77
Blink Frequency count 77

bots 11, 12, 43, 47
Brodmann 85, 87, 88

C

calibración 57, 58, 69, 81, 82, 83
carga cognitiva 30, 31, 32, 33, 34, 35, 36, 39, 40, 79, 195
carga cognitiva germana 30, 32
clasificación 28, 73, 115, 122, 124, 125, 126, 134, 135, 137, 141, 150, 152, 155, 156, 168
clasificador 122, 152
clústeres 73, 131, 132, 134, 153
clustering 71, 74, 115, 124, 131, 134, 136, 137, 152, 153, 177
codificación 83
conductancia 79, 81
conocimiento metacognitivo 24, 26, 27, 29, 195
cross Validation 150
CSV File Import 154

D

data cleaning 120
data integration 120
data mining 73, 177
data normalization 120
data squashing 122
data transformation 120
Deep Learning 139
Dispersión 155
Distribution 145

E

Electrodermal activity 79
electroencefalograma 51, 61, 85, 90, 91
Electroencephalographic recording 80
EMD 137
engagement 83, 95
Ensembles 150, 152
escotadura preoccipital 88
Esfuerzo 35
Evaluación 25, 27, 36, 195
Event 62, 66, 69, 70, 106, 110
Event metrics 62, 66, 69

Exigencia física 34, 35
Exigencias mentales 37
Exigencia temporal 34, 35
Eye movement 70
eye tracker 61
eyetracker timestamp 69
eye tracking 12, 49, 51, 52, 54, 57, 60, 61, 62, 66, 71, 72, 73, 75, 78, 81, 98,
101, 102, 104, 105, 111, 112, 113, 118, 188, 195

F

Feature Statistics 155
feedback 25, 104
fijación 62, 63, 64, 65, 66, 67, 68, 69, 73, 75, 76, 79, 120
Fixation Count 75
Fixation Dispersion Average 76
Fixation Duration 75
Fixation Frequency count 75
frontal 80, 82, 86, 87, 91, 106
funciones cognitivas 23, 29, 87, 88, 89
Fuzzy miner 138

G

galvanic skin response 61, 64, 78
Gaze direction 69
gaze point 69, 72
Gaze point 2D 69
Genetic algorithm 138
glance 62, 70
Goodness-of-fit indices 137

H

habilidades de comunicación 55
Heat Map 70, 71, 167

I

impacto emocional 81
indicadores de exactitud 58
inteligencia artificial 11, 12, 24, 43, 44, 47, 154, 181, 183, 188
Inteligencia Artificial Generativa 21
interpolación lineal 121
Interval-based Tabulator Separated Valu 62

Interval metrics 62, 69

K

k-means 73, 131, 132, 133, 134, 153

L

lazy learning 125, 126

learning outcomes 107, 109, 110, 155

lenguaje 22, 23, 24, 43, 44, 47, 51, 54, 55, 73, 86

Linear Regression 148, 150

lóbulo frontal 86, 87

lóbulo prefrontal 86

lóbulos frontales 87

lóbulos parietales 87

lóbulos parietooccipitales 87

M

Machine Learning 12, 17, 71, 73, 74, 101, 117, 118, 119, 120, 121, 122, 123,
124, 134, 136, 139, 168, 169, 176, 177, 188

Maximum Likelihood 134

Media 64, 121, 155

Mediana 155

medidas biométricas 101, 113

memoria 23, 26, 29, 31, 32, 33, 39, 83, 91

Memorización 83

metaconciencia 29, 30, 31

metanivel 30

Minería de datos 138, 139

missing data 120

monitorización 30, 82

N

Naive Bayes 101

NASA TLX 33, 34, 36, 40, 187

noise identification 121

O

occipital 82, 87, 88, 89, 91

occipitales 87

occipitalidad 89

Orientación 25, 27, 38

P

parietooccipitales 87
Pattern Mining 138
pictogramas 54, 56
Planificación 25, 27, 38, 157, 164
precentral 86
Predictions 148
prefrontal 80, 82, 86, 87, 189
prefrontales 87
prefrontalidad 89
proceso de percepción consciente 90
ProM 137, 138
pupil diameter 63, 69

R

Random Forest 101, 168
Random sampling 149
reducción de datos 122
registro encefalográfico 51, 85
regresión 69, 101, 123, 124, 125, 126, 127, 128, 129, 130, 134, 135, 137, 141, 147, 148, 151, 152, 155, 156, 168
regresión lineal 147, 155, 156
regresión logística 155, 156
regulación metacognitiva 29, 30
Rendimiento 35
rendimiento académico 25, 186, 189
respuesta emocional 81
respuesta encefalográfica 61
respuesta psicogalvánica 51, 79, 82
resultados de aprendizaje 25, 27, 39, 72, 73, 78, 126, 155
retención 33, 83

S

sacada 62, 65, 66, 68, 76, 77, 79
Saccade Amplitude Maximum 76
Saccade Amplitude Minimum 76
Saccade Amplitude Total 76
Saccade Duration Maximum 76
Saccade Duration Minimum 76

Saccade Duration Total 76
Saccade Frequency count 76
Saccade Latency Average 77
Saccades Duration 76
Saccade Velocity Maximum 76
Saccade Velocity Minimum 76
Saccade Velocity Total 76
scan path 62, 70
Scan Path Length 77
Scatter Plot 145, 153, 165, 176
Select Columns 153
sensibilidad somática 88
Sistema Nervioso Autónomo 81
sistemas conversacionales inteligentes 43
Skin Conductance Response 70
Social Network Analysis Technique 138
sueño nulo 90
sueño profundo 93

T

Target 157
tecnología multicanal integrada 51
timestamp 69
Train-Test 149, 152
Transformada de Fourier 89
Tree Viewer 151, 168

V

Valencia 83, 113
validación cruzada 136, 149, 152
validity of eye data 69
valores perdidos 120, 121, 155
visualización 58, 59, 71, 78, 119, 138, 145, 151, 153, 165, 166, 174, 175
Visualización de procesos 138

W

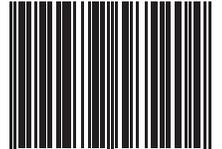
widget 144, 147, 148, 149, 151, 153, 155, 156, 157, 162, 163, 164, 165, 166,
167, 168, 170, 173, 175, 176
workload 83, 184, 185, 187



**UNIVERSIDAD
DE BURGOS**

**Servicio de Publicaciones e
Imagen Institucional**

ISBN 979-13-87585-20-4



9 791387 585204