



CENTRO DE CIENCIAS BÁSICAS
DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN

**MODELO DE EVALUACIÓN DE EXPERIENCIA DE APRENDIZAJE
BASADO EN *EYE TRACKING*, SEÑALES
ELECTROENCEFALOGRÁFICAS (*EEG*) Y CIENCIA DE DATOS.**

Tesis que presenta
EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ
para optar por el grado de

DOCTORADO EN CIENCIAS APLICADAS Y TECNOLOGÍA
TECNOLOGÍAS DE INGENIERÍA DE SOFTWARE Y OBJETOS DE APRENDIZAJE

TUTOR:

Dr. Francisco Javier Álvarez Rodríguez

COMITÉ TUTORAL:

Dr. Alfredo Ramírez García
Dr. Julio Cesar Ponce Gallegos

Aguascalientes, Aguascalientes, 23 de enero de 2025.

JORGE MARTÍN ALFÉREZ CHÁVEZ
DECANO DEL CENTRO DE CIENCIAS BÁSICAS

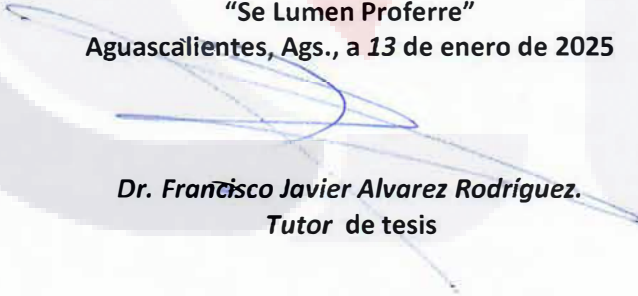
PRESENTE

Por medio del presente como **TUTOR** designado del estudiante **EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ** con ID 179552 quien realizó la tesis titulada: **MODELO DE EVALUACIÓN DE EXPERIENCIA DE APRENDIZAJE BASADO EN EYE TRACKING, SEÑALES ELECTROENCEFALOGRÁFICAS (EEG) Y CIENCIA DE DATOS**, un trabajo propio, innovador, relevante e inédito y con fundamento en el Artículo 175, Apartado II del Reglamento General de Docencia doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que él pueda proceder a imprimirla así como continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"

Aguascalientes, Ags., a 13 de enero de 2025


Dr. Francisco Javier Alvarez Rodríguez.
Tutor de tesis

c.c.p.- Interesado
c.c.p.- Secretaría Técnica del Programa de Posgrado

JORGE MARTÍN ALFÉREZ CHÁVEZ
DECANO DEL CENTRO DE CIENCIAS BÁSICAS

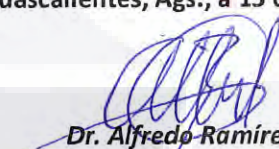
PRESENTE

Por medio del presente como **ASESOR** designado del estudiante **EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ** con ID 179552 quien realizó la tesis titulada: **MODELO DE EVALUACIÓN DE EXPERIENCIA DE APRENDIZAJE BASADO EN EYE TRACKING, SEÑALES ELECTROENCEFALOGRÁFICAS (EEG) Y CIENCIA DE DATOS**, un trabajo propio, innovador, relevante e inédito y con fundamento en el Artículo 175, Apartado II del Reglamento General de Docencia doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que él pueda proceder a imprimirla así como continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"

Aguascalientes, Ags., a 15 de enero de 2025



Dr. Alfredo Ramírez García
Asesor de tesis

c.c.p.- Interesado
c.c.p.- Secretaría Técnica del Programa de Posgrado

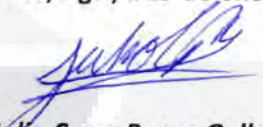
JORGE MARTÍN ALFÉREZ CHÁVEZ
DECANO DEL CENTRO DE CIENCIAS BÁSICAS

PRESENTE

Por medio del presente como **ASESOR** designado del estudiante **EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ** con ID 179552 quien realizó la tesis titulada: **MODELO DE EVALUACIÓN DE EXPERIENCIA DE APRENDIZAJE BASADO EN EYE TRACKING, SEÑALES ELECTROENCEFALOGRÁFICAS (EEG) Y CIENCIA DE DATOS**, un trabajo propio, innovador, relevante e inédito y con fundamento en el Artículo 175, Apartado II del Reglamento General de Docencia doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que él pueda proceder a imprimirla así como continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"
Aguascalientes, Ags., a 15 de enero de 2025



Dr. Julio Cesar Ponce Gallegos
Asesor de tesis

c.c.p.- Interesado
c.c.p.- Secretaría Técnica del Programa de Posgrado



UNIVERSIDAD AUTÓNOMA DE AGUASCALIENTES

DICTAMEN DE LIBERACIÓN ACADÉMICA PARA INICIAR LOS TRÁMITES DEL EXAMEN DE GRADO



Fecha de dictaminación dd/mm/aaaa: 20/01/2025

NOMBRE: Eduardo Emmanuel Rodríguez López **ID** 179552

PROGRAMA: Doctorado en Ciencias Aplicadas y Tecnología **LGAC (del posgrado):** Tecnologías de Ingeniería de Software y Objetos de Aprendizaje

TIPO DE TRABAJO: () Tesis () Trabajo Práctico

TÍTULO: Modelo de Evaluación de Experiencia de Aprendizaje basado en Eye Tracking, Señales Electroencefalográficas (EEG) y Ciencia de Datos

IMPACTO SOCIAL (señalar el impacto logrado): En la educación, para mejorar los aprendizajes desde la experiencia y su medición con el uso de herramientas objetivas de software y análisis de datos.

INDICAR SI NO N.A. (NO APLICA) SEGÚN CORRESPONDA:

INDICAR	SI	NO	N.A. (NO APLICA)	SEGÚN CORRESPONDA:
Elementos para la revisión académica del trabajo de tesis o trabajo práctico:				
SI				El trabajo es congruente con las LGAC del programa de posgrado
SI				La problemática fue abordada desde un enfoque multidisciplinario
SI				Existe coherencia, continuidad y orden lógico del tema central con cada apartado
SI				Los resultados del trabajo dan respuesta a las preguntas de investigación o a la problemática que aborda
SI				Los resultados presentados en el trabajo son de gran relevancia científica, tecnológica o profesional según el área
SI				El trabajo demuestra más de una aportación original al conocimiento de su área
SI				Las aportaciones responden a los problemas prioritarios del país
SI				Generó transferencia del conocimiento o tecnológica
SI				Cumple con la ética para la investigación (reporte de la herramienta antiplagio)
El egresado cumple con lo siguiente:				
SI				Cumple con lo señalado por el Reglamento General de Docencia
SI				Cumple con los requisitos señalados en el plan de estudios (créditos curriculares, optativos, actividades complementarias, estancia, predoctoral, etc)
SI				Cuenta con los votos aprobatorios del comité tutorial, en caso de los posgrados profesionales si tiene solo tutor podrá liberar solo el tutor
N.A.				Cuenta con la carta de satisfacción del Usuario
SI				Coincide con el título y objetivo registrado
SI				Tiene congruencia con cuerpos académicos
SI				Tiene el CVU del Conacyt actualizado
SI				Tiene el artículo aceptado o publicado y cumple con los requisitos institucionales (en caso que proceda)
En caso de Tesis por artículos científicos publicados				
N.A.				Aceptación o Publicación de los artículos según el nivel del programa
N.A.				El estudiante es el primer autor
N.A.				El autor de correspondencia es el Tutor del Núcleo Académico Básico
N.A.				En los artículos se ven reflejados los objetivos de la tesis, ya que son producto de este trabajo de investigación.
N.A.				Los artículos integran los capítulos de la tesis y se presentan en el idioma en que fueron publicados
N.A.				La aceptación o publicación de los artículos en revistas indexadas de alto impacto

Con base a estos criterios, se autoriza se continúen con los trámites de titulación y programación del examen de grado: Sí No

FIRMAS

Elaboró:
* NOMBRE Y FIRMA DEL CONSEJERO SEGÚN LA LGAC DE ADSCRIPCIÓN: César Eduardo Velázquez Amador

NOMBRE Y FIRMA DEL SECRETARIO TÉCNICO: Fco Alvarez

* En caso de conflicto de intereses, firmará un revisor miembro del NAB de la LGAC correspondiente distinto al tutor o miembro del comité tutorial, asignado por el Decano
Revisó:
NOMBRE Y FIRMA DEL SECRETARIO DE INVESTIGACIÓN Y POSGRADO: Alejandro Padilla Díaz

Autorizó:
NOMBRE Y FIRMA DEL DECANO: Martin Alferez

Nota: procede el trámite para el Depto. de Apoyo al Posgrado
En cumplimiento con el Art. 105C del Reglamento General de Docencia que a la letra señala entre las funciones del Consejo Académico: Cuidar la eficiencia terminal del programa de posgrado y el Art. 105F las funciones del Secretario Técnico, llevar el seguimiento de los alumnos.

Evidencia de artículos publicados y/o enviados a revistas indexadas

Artículo 1: Exploratory study of EEG signal patterns of blind and normal-sight people in a learning environment.

Publicado en International Journal on Interactive Design and Manufacturing, 2022.

Enlace a artículo: <https://link.springer.com/article/10.1007/s12008-022-00847-8>



International Journal on Interactive Design and Manufacturing (IJD&M)
<https://doi.org/10.1007/s12008-022-00847-8>

ORIGINAL PAPER

Check for updates

Exploratory study of EEG signal patterns of blind and normal-sight people in a learning environment

Eduardo Emmanuel Rodríguez Lopez¹ · Francisco Javier Álvarez Rodríguez¹ · Karla Yuritz Amador Rodríguez²

Received: 22 January 2021 / Accepted: 27 January 2022
© The Author(s), under exclusive licence to Springer-Verlag France SAS, part of Springer Nature 2022

Abstract
The EEG has allowed a great advance in development of neurosciences and clinical field, but it has also had a great impact in other areas such as technology or education. There are several studies focused on detecting attention, but few of them are aimed at people with blindness. Thus, in the present research, an exploratory method is proposed for detection of similarities and differences of EEG signals of 5 blind and 10 normal-sight people in a learning environment based on interaction (watching or listening) with popular science videos. Regarding analysis, Information Gain was applied, this technique for decision trees can be defined as the amount of information enhanced in the nodes before splitting them for making subsequent decisions. Therefore, although there was not performed the construction of a decision tree, the incidence of the main EEG signals (Delta, Theta, Alpha, Beta and Gamma) in the attention levels of the participants for this specific environment can be identified. Finally, the results show that the average levels of attention for both groups are around 50%, and the most influential waves were Delta, Theta and Alpha. It should be noted that this study is an initial analysis and is not intended to be conclusive, as a larger number of participants is needed, as well as the application of more in-depth processing methods.

Keywords EEG · Learning · Attention · Blind people · Normal-sight people

1 Introduction

Currently there are several ways to study the human brain, one of the most used is the electroencephalogram (EEG). Broadly speaking, this study consists of recording the brain's electrical activity (variations in electrical potential) using electrodes on the scalp [1–3]. Although the EEG is commonly used in medicine to diagnose sleep or brain disorders [4], it has also applications on psychology and neuroscience, and in recent years it has reached other areas, such as education, for example to detect mental stress or memory load in students [5–7]. One of the reasons of this development is the fact that the EEG is an affordable and very efficient tool to study the brain [8], for which it has been very well integrated in different disciplines. Thus, as far as education is concerned and thanks to the application of other computer tools such as Machine Learning, Data Mining or Artificial Intelligence, different ways of examining how people learn have been developed, especially focused on the analysis of user attention [9–11].

Artículo 2: Comorbidities and risk factors impact of COVID-19 in Mexico: a feature utility metrics approach.

Publicado en International Journal of Data Mining and Bioinformatics, 2022

Enlace al artículo: <https://www.inderscienceonline.com/doi/abs/10.1504/IJDMB.2021.124109>

Int. J. Data Mining and Bioinformatics, Vol. 26, Nos. 1/2, 2021 59

Comorbidities and risk factors impact of COVID-19 in Mexico: a feature utility metrics approach

Eduardo Emmanuel Rodríguez López*,
Daniel Hernández González,
Francisco Javier Álvarez Rodríguez
and Julio Cesar Ponce Gallegos

Universidad Autónoma de Aguascalientes,
Aguascalientes, Mexico
Email: emlopez@correo.uaa.mx
Email: dhgonzalez_21@hotmail.com
Email: fjalvar@correo.uaa.mx
Email: jcponce@correo.uaa.mx
*Corresponding author

Abstract: By applying Machine Learning, it is possible to determine the impact of the main comorbidities and risk factors associated with COVID-19 based on an analysis of official Mexican Secretary of Health data. This analysis was performed using Feature Utility Metrics: Mutual Information (MI), Permutation Importance (PI) and Partial Dependence Plot (PDP) with two different learning models (RandomForest and XGBoost), finding similarities between these metrics. According to these models, the main comorbidities and risk factors associated with COVID-19 are Age, Gender, Obesity, Diabetes and Hypertension. Regarding MI and PI (RandomForest), the main risk factor is Age, while for PI (XGBoost) is Obesity. Finally, the PDP graph for Age, shows that the associated probability of risk of COVID-19 infection increases considerably after 60-years-old. Therefore, it was confirmed that the main comorbidities and risk factors associated with COVID-19 in Mexico are coherent with the diseases and conditions most present in the population.

Keywords: comorbidities; COVID-19 risk factors; mutual information; permutation importance; feature utility metrics.

Artículo 3: UXEEGET: A framework for evaluating learning experience with EEG and Eye Tracking.

Enviado a Universal Access in the Information Society, 2024.

Evidencia de envío:

The screenshot shows a submission tracking interface for Springer Nature SNAPP. At the top, the Springer Nature SNAPP logo and the journal title 'Universal Access in the Information Society' are visible, along with an 'Account' link. The article title 'UXEEGET: A framework for evaluating learning experience with EEG and Eye Tracking' is prominently displayed in a dark blue header. The main content area is divided into two columns. The left column, titled 'CURRENT STATUS', features a green dot and the heading 'Your submission is in peer review'. Below this, an information icon (i) is followed by the section 'News about your peer review process', which includes a bullet point: 'The editor has invited 6 reviewer(s)'. A paragraph explains that after the editor collates and reviews reports, the author will be notified. A second paragraph states that the editor has decided the submission is suitable for peer review and is now inviting reviewers, a process that may take a few weeks. A final line promises to notify the author if revisions are needed. The right column, titled 'Progress so far', includes a 'Show history' link and a vertical progress indicator with five steps: 'Submission received', 'Technical check', 'Editorial assignment', 'With editor', and 'Peer review'. The 'Peer review' step is currently active, indicated by a white circle with a blue border. Below the progress indicator, the 'Your submission' section lists the title: 'UXEEGET: A framework for evaluating learning experience with EEG and Eye Tracking'.

AUTORIZACIONES

NOTA: Aquí van las cartas de votos aprobatorios de los Dres. Álvarez, Alfredo y Julio por separado.



AGRADECIMIENTOS

Sin duda alguna, mi tesis ha sido el trabajo más grande que he realizado en mi vida profesional y desde luego es mi deber agradecer a todos aquellos que estuvieron ahí para apoyarme en estos cuatro años del doctorado.

Quiero comenzar por agradecer a la Universidad Autónoma de Aguascalientes, por ser mi casa de estudios, no solo en el doctorado, sino en la ingeniería y en la maestría, guardo un gran cariño por la UAA.

Agradezco también al CONAHCyT, el máximo representante de la ciencia en nuestro país. Cuando cursaba la carrera tuve el sueño de llegar a estudiar un posgrado en investigación y gracias al CONAHCyT pude realizarlo durante la maestría y ahora en el doctorado.

Continúo agradeciendo a mi tutor y comité tutorial. Comenzando por mis asesores, el Dr. Alfredo Ramírez y el Dr. Julio Ponce, por toda su guía y comentarios de mejora a mi trabajo, siempre han estado ahí para enseñarme como hacer los ajustes necesarios en mi investigación. Continúo con mi tutor, el Dr. Francisco Álvarez, quien ha sido mi más grande referente en este mundo académico y profesional, me ha tendido la mano para ayudarme no solo en lo que respecta a mi trabajo, sino también en lo personal, agradezco mucho su calidad humana y su rigor profesional y de investigación para hacer de este, un trabajo de calidad.

En lo que respecta a la parte experimental de mi trabajo, no pude haber alcanzado este punto sin el valioso apoyo de mis estudiantes de pregrado de Ingeniería en Computación Inteligente: Manuel González, Joaquín Pedroza, Sandra López, Airam Merla e Hiram Díaz; así como de mi estudiante de maestría Ángel Villegas, de la MCCMA. A todos ellos les tengo gran gratitud y aprecio pues fueron parte fundamental en todo el proceso. Además, a todos mis estudiantes que me permitieron dirigir sus tesinas durante estos cuatro años, les agradezco también su confianza en mi persona.

Finalmente, agradezco a mi Dios por permitirme cumplir esta etapa, y a mi familia, sin su apoyo no habría podido concretarse todo este trabajo. Especial gratitud hacia mi esposa Silvia, quien ha sido mi compañera de vida desde adolescentes y ya entonces sabía mi sueño y siempre ha estado a mi lado apoyándome y creyendo en mí, mi gratitud absoluta.

DEDICATORIAS

Todo este esfuerzo, todo este trabajo y toda mi vida están dedicadas a mi Dios y mi familia, pues son el centro de mi existir. Para mi Dios, todo mi trabajo sea para alabarte, para mi familia, siempre seré incansable para ustedes.

Ustedes son mis mayores razones para hacer lo que hago, mis mayores motores y todo lo que me hace feliz. No hay mayor satisfacción para mí, que verlos felices.

Para mi pequeñito, Eduardo, el mayor de mis hijos, que por escucharme hablar de lo que siempre hablo ya dices que tienes doctorado también, y que no querías que me fuera a trabajar o me esperabas todos los días en la puerta al regresar de la universidad para poder jugar juntos, este trabajo es para ti mi amor.

Para mi pequeñito más pequeño, mi bebé, Lucas, que me saludabas al verme llegar en cuanto aprendiste a mover tu manita, y me regalabas tu hermosa sonrisa, este trabajo es para ti mi amor.

Para mi amada y hermosa esposa, Silvia, siempre has estado conmigo de la mano, en las buenas y en las malas, arriba y abajo, en la salud y en la enfermedad. Siempre has creído en mí, siempre has confiado en mí y siempre me has apoyado sin dudar. Este trabajo es para ti hermosa, Te amo con todo mi ser.

Y finalmente, para el Eduardo de hace más de 10 años que soñó con conseguir esto, aquí está el fruto de nuestro trabajo. ¡Lo logramos!

ÍNDICE

INTRODUCCIÓN 12

CAPÍTULO I. PLANTEAMIENTO DEL PROBLEMA 16

- 1. DESCRIPCIÓN DEL PROBLEMA16
- 2. JUSTIFICACIÓN.....18
- 3. DELIMITACIÓN DEL PROBLEMA.....19
- 4. PREGUNTAS DE INVESTIGACIÓN.....19
 - 4.1 *Pregunta de Investigación general*20
 - 4.2 *Preguntas de Investigación específicas*.....20
- 5. OBJETIVOS DE INVESTIGACIÓN20
 - 5.1 *Objetivo de Investigación general*.....20
 - 5.2 *Objetivos de Investigación específicos*.....20
- 6. HIPÓTESIS21
- 7. IMPORTANCIA TEÓRICA Y PRÁCTICA.....21

CAPÍTULO II. REFERENTES TEÓRICOS..... 23

- 1. REVISIÓN SISTEMÁTICA DE LA LITERATURA (RSL)23
 - 1.1 *Planificación*.....24
 - 1.2 *Búsqueda*25
 - 1.3 *Selección*.....26
 - 1.4 *Evaluación de calidad*.....28
 - 1.5 *Extracción*.....29
 - 1.6 *Resultados de la RSL*.....31
- 2. FUNDAMENTOS TEÓRICOS33
 - 2.1 *Aprendizaje*.....34
 - 2.2 *Experiencia de Usuario (UX)*.....37
 - 2.3 *Eye Tracking*.....47
 - 2.4 *EEG*.....52
 - 2.5 *Ciencia de datos*.....58

CAPÍTULO III. METODOLOGÍA DE INVESTIGACIÓN..... 63

- 1. DISEÑO EXPERIMENTAL Y CASOS DE ESTUDIO64
 - 1.1 *Experimento A: “Eye Tracking para el estudio de la carga cognitiva y su relación con el desempeño académico enfocado al área de matemáticas”*68
 - 1.2 *Experimento B: “Eye Tracking para la detección de patrones de TDAH en niños de entre 6 y 8 años”*70
 - 1.3 *Experimento C: “Eye Tracking para la detección de vista cansada y disminución del Síndrome Visual Informático”*.....73
 - 1.4 *Experimento D: “Algoritmos de Machine Learning en Neuromarketing”*.....75
 - 1.5 *Experimento E: Aplicación de técnicas de Eye Tracking y EEG en la generación de un modelo de predicción de orientación vocacional*.....78
 - 1.6 *Experimento F: Procesamiento de Ondas cerebrales para la identificación de emociones*.....81

1.7 Experimento G: Propuesta inicial de un modelo predictivo para la detección temprana de tendencias depresivas.....	83
2. EXPERIMENTO PRINCIPAL: MARCO CONCEPTUAL Y OBJETIVOS.....	87
2.1 Relevancia Y Hallazgos de las experimentaciones iniciales.....	87
2.2 Objetivos en el experimento principal.....	88
2.3 Relación con la hipótesis.....	89
2.4 Framework inicial.....	90
3. PROCEDIMIENTOS ESPECÍFICOS.....	92
3.1 Población y muestra.....	95
3.2 Tecnología.....	95
3.3 Recopilación de datos.....	97
3.4 Medidas de control.....	98
4. INSTRUMENTOS Y MEDIDAS.....	99
4.1 Instrumentos de recolección de datos.....	99
4.2 Variables de ET.....	100
4.3 Variables de EEG.....	100
4.4 Formulario.....	101
5. CONSIDERACIONES ÉTICAS.....	101
6. ANÁLISIS DE DATOS.....	102
6.1 Preprocesamiento de los datos.....	102
6.2 Aplicación de algoritmos de Aprendizaje Automático.....	106
6.3 Validación de modelos y métricas.....	110
6.4 Interpretación de los resultados de Aprendizaje Automático.....	112
CAPÍTULO IV. RESULTADOS.....	117
1. EVALUACIÓN DE LA HIPÓTESIS.....	117
1.1 Funcionamiento de la prueba de wilcoxon.....	117
1.2 Valor alpha.....	118
1.3 Valor p.....	118
1.4 Estadístico de Wilcoxon.....	119
2. INTERPRETACIÓN DE LOS RESULTADOS DE LA PRUEBA DE WILCOXON.....	119
3. VALIDACIÓN DE LOS RESULTADOS.....	120
DISCUSIONES DE RESULTADOS.....	122
INTERPRETACIÓN DE LOS RESULTADOS.....	122
RECAPITULACIÓN DE LA LITERATURA BASE.....	123
PATRONES Y TENDENCIAS.....	124
<i>Mutual Information</i>	125
<i>Permutation Importance</i>	126
CONSIDERACIÓN DE LIMITACIONES Y SEGGOS.....	128
IMPLICACIONES PRÁCTICAS Y TEÓRICAS.....	129
PROPUESTA DE FRAMEWORK FINAL.....	130
CONCLUSIONES.....	134
RESUMEN DE HALLAZGOS.....	134
CONTRIBUCIONES AL CONOCIMIENTO.....	135
REAFIRMACIÓN DE LOS OBJETIVOS.....	136
<i>Objetivo de Investigación general</i>	136

Objetivos de Investigación específicos.....137
IMPORTANCIA DEL FRAMEWORK137
SUGERENCIAS PARA FUTURAS INVESTIGACIONES138
REFLEXIONES FINALES139

REFERENCIAS..... 141

ANEXOS..... 159



Índice de Tablas

Tabla 1 Definiciones de Aprendizaje (Elaboración propia, 2023). 34

Tabla 2 Categorías de la UX, con base en (Roto et al., 2023)..... 39

Tabla 3 Tecnologías biométricas más comunes aplicadas en UX (Elaboración propia, 2023).
..... 44

Tabla 4 Clasificación de métricas en función del esfuerzo visual, con base en (Sharafi et al., 2015)..... 49

Tabla 5 Características principales de las ondas cerebrales (Elaboración del autor). 53

Tabla 6 Breve descripción de los casos de estudio (Elaboración propia, 2023). 67

Tabla 7 Software y Hardware utilizado en los experimentos iniciales / casos de estudio (Elaboración propia, 2023)..... 87

Tabla 8 Puntajes de cada modelo para F1-Score, Índice de Jaccard y Exactitud, dataframe con biométricos (Elaboración propia, 2024) 116

Tabla 9 Puntajes de cada modelo para F1-Score, Índice de Jaccard y Exactitud, dataframe sin biométricos (Elaboración propia, 2024) 116

Índice de Figuras

Fig. 1 Esquema metodológico empleado para realizar la RSL. Basado en (Kitchenham & Charters, 2007)	23
Fig. 2 Gráfica de pastel que muestra la contribución porcentual de cada base de datos/repositorio después de la Selección Preliminar. Total: 415 artículos (Elaboración propia, 2022).	27
Fig. 3 Gráfica de pastel que muestra la contribución porcentual de cada base de datos/repositorio después de la Selección detallada. Total: 66 artículos (Elaboración propia, 2022).....	29
Fig. 4 Framework para el reconocimiento de emociones basado en EEG y Eye Tracking propuesto por (Shi et al., 2017)	30
Fig. 5 Modelo ExodUX mencionado en (Kremer et al., 2016).....	31
Fig. 6 Gráfica de contribución de cada base de datos/repositorio (Elaboración propia, 2022).	31
Fig. 7 Panal de la experiencia de usuario. Título original: User Experience Honeycomb (Morville, 2004).	38
Fig. 8 Fases de la Experiencia de Usuario (Roto, 2011).....	38
Fig. 9 HCI y sus áreas relacionadas (Chakraborty et al., 2018).....	40
Fig. 10 Tobii Pro Glasses 3 (iMotions, 2021).....	51
Fig. 11 Captura de "Webcam eye tracker implementation video" (E. Dalmaijer, 2015b)...	51
Fig. 12 Tobii Pro Nano (Tobii LatAm, 2021a).	51
Fig. 13 Registro EEG real de las ondas separadas por ritmos (Elaboración propia, 2023).	54
Fig. 14 Sistema de colocación de electrodos 10 – 20 (Hu & Zhang, 2019).....	55
Fig. 15 Mindwave Mobile 2 Headset de NeuroSky (NeuroSky, 2021).	56
Fig. 16 EMOTIV EPOC X (EMOTIV, 2021).....	56
Fig. 17 Diagrama de Venn de la Ciencia de Datos (Conway, 2015)	59
Fig. 18 Diagrama de Venn de la Ciencia de Datos, basado en (L. Aggarwal, 2022).	59
Fig. 19 Metodología de investigación representada como diagrama de flujo (Elaboración propia, 2024).	64
Fig. 20 Metodología general de investigación de los casos de estudio / experimentos iniciales representada como diagrama de flujo (Elaboración propia, 2023).	66

Fig. 21 Mapas de calor del conjunto de disposiciones (Ortíz et al., 2022). 69

Fig. 22 Comparación de ambos clústers con respecto al número de participante y el número de desvíos en X (Algoritmo EM). (Elaboración de la alumna, tesina 2022). 72

Fig. 23 Síntomas más frecuentes del SVI (Campos et al., 2022). 74

Fig. 24 Comparación del comportamiento entre SVM, KNN y target de imagen de la categoría alimentos. (Elaboración de la alumna, tesina 2022). 77

Fig. 25 Comparación de métricas (Accuracy, Precision, Recall, F1-Score) de los modelos de Deep Learning con diferentes arquitecturas (Elaboración de los alumnos participantes en Verano de Investigación, 2022). 80

Fig. 26 Comparación de modelos de aprendizaje (KNN y SVM) con diferentes configuraciones: Default, con modificación en hiperparámetros y con validación cruzada estratificada (Elaboración del alumno, tesina 2023). 83

Fig. 27 Resultados finales de Accuracy: 0.82 y F1-Score: 0.823 para clasificación de tendencias depresivas utilizando KNN (Elaboración del alumno, tesina 2023). 85

Fig. 28 Cuadro Sinóptico sobre las áreas que comprenden el modelo de evaluación de Experiencia de Aprendizaje (Elaboración propia, 2022). 91

Fig. 29 Modelo inicial de evaluación de Experiencia de Aprendizaje (Elaboración propia, 2022). 92

Fig. 30 Diagrama de la experimentación principal con usuarios (Elaboración propia, 2023). 94

Fig. 31 Capturas del formulario sobre Experiencia de Aprendizaje en Google Forms (Elaboración del equipo de trabajo, 2023). 94

Fig. 32 Fragmento del video (OA) mostrando la implementación de la clase "Taco" (Elaboración del equipo de trabajo, 2023). 96

Fig. 33 Fragmento del video (OA) mostrando al narrador (generado con IA) dando el cierre del tema (Elaboración del equipo de trabajo, 2023). 97

Fig. 34 Evidencia de las pruebas experimentales (Elaboración del equipo de trabajo, 2023). 99

Fig. 35 Captura de pantalla de las primeras 8 instancias del dataframe estandarizado (Elaboración propia, 2024). 103

Fig. 36 Captura de pantalla del dataframe sin biométricos (Elaboración propia, 2024). 105

Fig. 37 Captura de pantalla sobre el código relativo a la optimización de hiperparámetros del KNN en el dataframe con biométricos (Elaboración propia, 2024)..... 108

Fig. 38 Captura de pantalla sobre el código relativo a la optimización de hiperparámetros del KNN en el dataframe sin biométricos (Elaboración propia, 2024)..... 109

Fig. 39 Parámetros de cada modelo en el dataframe con biométricos (Elaboración propia, 2024)..... 109

Fig. 40 Parámetros de cada modelo en el dataframe sin biométricos (Elaboración propia, 2024)..... 110

Fig. 41 Comparación de F1-Score de cada modelo, dataframe con biométricos (Elaboración propia, 2024). 112

Fig. 42 Comparación de Índice de Jaccard de cada modelo, dataframe con biométricos (Elaboración propia, 2024)..... 112

Fig. 43 Comparación de Exactitud de cada modelo, dataframe con biométricos (Elaboración propia, 2024). 113

Fig. 44 Comparación de F1-Score de cada modelo, dataframe sin biométricos (Elaboración propia, 2024). 114

Fig. 45 Comparación de Índice de Jaccard de cada modelo, dataframe sin biométricos (Elaboración propia, 2024)..... 114

Fig. 46 Comparación de Exactitud de cada modelo, dataframe sin biométricos (Elaboración propia, 2024). 115

Fig. 47 Implementación de la prueba de Wilcoxon en Python (Elaboración propia, 2024). 119

Fig. 48 Mutual Information aplicado dataset con biométricos (Elaboración propia, 2024). 125

Fig. 49 Cálculo de Permutation Importance para cada modelo (Regresión Logística, KNN y SVM) basado en Exactitud (Elaboración propia, 2024)..... 127

Fig. 50 Framework UXEEGET. Modelo para evaluación de experiencia de aprendizaje (Elaboración propia, 2024)..... 131

Fig. 51 Relación del framework UXEEGET con un Objeto de Aprendizaje (Elaboración propia, 2024). 132

Acrónimos

ADRF: *Average Duration of Relevant Fixations* (Duración Promedio de Fijaciones Relevantes)

AFD: *Average Fixation Duration* (Duración promedio de la Fijación)

AOI: *Areas of Interest* (Áreas de Interés)

API: *Application Programming Interface* (Interfaz de Programación de Aplicación)

BCI: *Brain Computer Interface* (Interfaz Cerebro - Computadora)

BVP: *Blood Volume Pressure* (Presión de Volúmen Sanguíneo)

EEG: Electroencefalografía

EMG: Electromiografía

ET: *Eye Tracking*

FC: *Fixation Count* (Conteo de Fijaciones)

FR: *Fixation Rate* (Tasa de Fijaciones)

FT: *Fixation Time* (Tiempo de Fijación)

GSR: *Galvanic Skin Response* (Respuesta Galvánica de la Piel)

HCI: *Human Computer Interaction* (Interacción Humano – Computadora)

ICI: Ingeniería en Computación Inteligente

ISC: Ingeniería en Sistemas Computacionales

IDE: *Integrated development Environment* (Entorno de Desarrollo Integrado)

KNN: *K – Nearest neighbors* (K – Vecinos más cercanos)

MAX: *Method for the Assessment of eXperience* (Método para la evaluación del usuario)

ML: *Machine Learning* (Aprendizaje Automático)

MOOCs: *Massive Open Online Courses* (Cursos masivos abiertos en línea)

NRRF: *Normalised Rate of Relevant Fixations* (Tasa Normalizada de Fijaciones Relevantes)

OA: Objeto de Aprendizaje

PVD: Pantalla de Visualización de Datos

POO: Programación Orientada a Objetos

RSL: Revisión Sistemática de la Literatura

SAPE: Sistema de Apoyo para Pruebas Experimentales

SD: *Spatial Density* (Densidad Espacial)

SPAM: *Secuential Pattern Mining* (Minería de Patrones Secuenciales)

SVI: Síndrome Visual Informático

SVM: *Support Vector Machine* (Máquinas de Soporte Vectorial)

STEM: Science, Technology, Engineering and Mathematics (Ciencia, Ingeniería, Tecnología y Matemáticas)

SW: Software

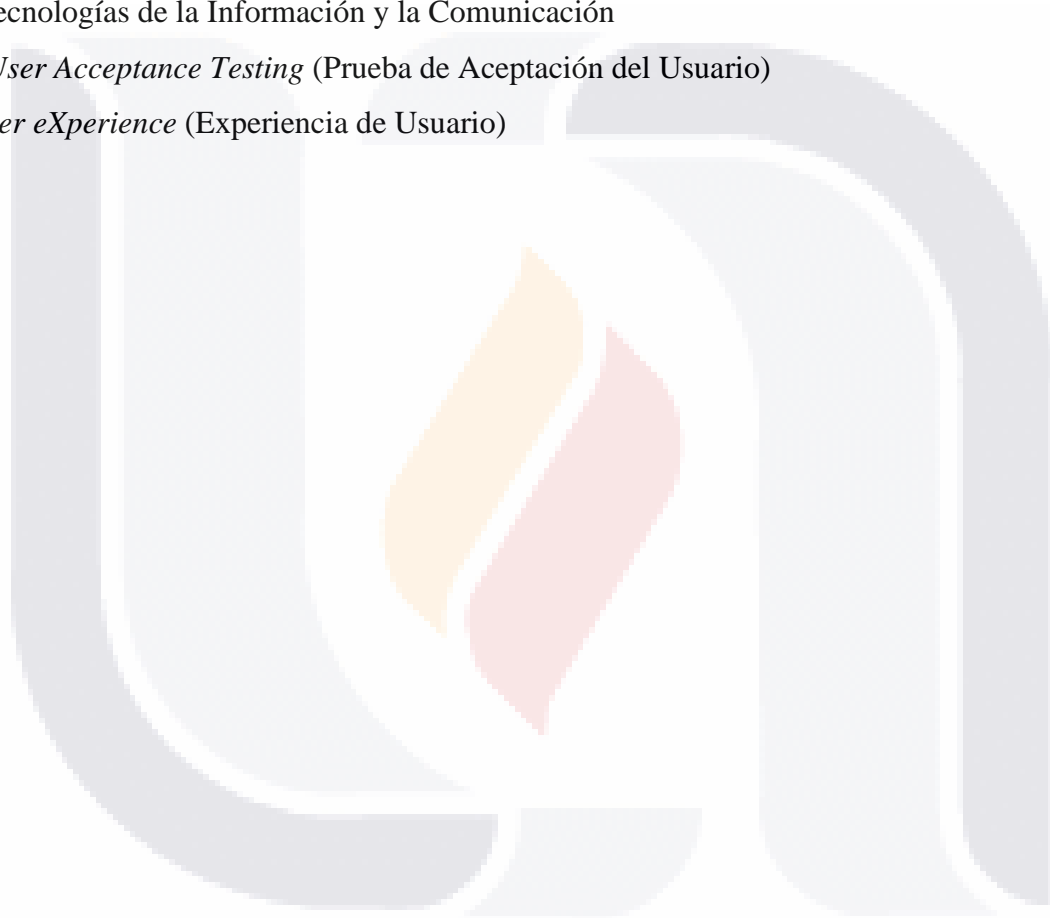
TDAH: Trastorno de Déficit de Atención e Hiperactividad

TOI: Time of Interest

TIC: Tecnologías de la Información y la Comunicación

UAT: *User Acceptance Testing* (Prueba de Aceptación del Usuario)

UX: *User eXperience* (Experiencia de Usuario)



Resumen

La evaluación de *UX* es primordial para conocer la aceptación e interacción que un usuario tiene con un sistema, si las técnicas tradicionales de *UX* se trasladan al campo de la enseñanza – aprendizaje, su aplicación puede tener aún más impacto, pues puede incidir en la calidad de los Objetos de Aprendizaje con los que un estudiante interactúa. Sin embargo, con métodos tradicionales no puede más que obtenerse información subjetiva del usuario, por lo que luego de una Revisión Sistemática de la Literatura y aplicando tecnologías ya bien adaptadas a este campo como el EEG, y otras emergentes como el *Eye Tracking*, en este trabajo se desarrolla un modelo (o *framework*), llamado UXEEGET, que incorpora también la Ciencia de Datos para obtener una mejor comprensión de la Experiencia de Aprendizaje, es decir, la experiencia derivada a partir de la interacción con un Objeto de Aprendizaje. Para lograr este objetivo, se recabaron datos de EEG, *Eye Tracking* y respuestas de un formulario sobre *UX* relativas a un video sobre Programación Orientada a Objetos (POO), de un grupo de 35 estudiantes de Ingeniería en Computación de semestre iniciales. Con los datos obtenidos se entrenaron varios modelos de Aprendizaje Automático (Regresión Logística, KNN y SVM) en un *dataset* con y sin biométricos (es decir, con y sin datos de EEG y *Eye Tracking*) para predecir la experiencia de aprendizaje, comparándola con la respuesta subjetiva dada por el usuario en el formulario de *UX*. Los resultados sugieren, a partir de una prueba de Wilcoxon en el contexto específico de la investigación, que la incorporación de EEG y *Eye Tracking* sí permite conocer de más precisa la experiencia de aprendizaje, comparado con el sólo uso de un instrumento simple y tradicional de *UX* (como lo es el formulario).

Abstract

UX evaluation is essential to know the acceptance and interaction that a user has with a system, if traditional UX techniques are transferred to the field of teaching - learning, its application can have even more impact, because it can affect the quality of the Learning Objects a student interacts with. However, traditional methods can only obtain subjective information from the user, so after a systematic review of the literature and applying technologies already well adapted to this field such as EEG, and other emerging technologies such as Eye Tracking, this paper develops a model (or framework), called UXEEGET, which also incorporates Data Science to obtain a better understanding of the Learning Experience, that is, the experience derived from the interaction with a Learning Object. To achieve this objective, EEG data, Eye Tracking and answers to a UX form related to a video on Object Oriented Programming (OOP) were collected from a group of 35 first semester Computer Engineering students. With the gathered data, several Machine Learning models (Logistic Regression, KNN and SVM) were trained on a dataset with and without biometrics (i.e. with and without EEG and Eye Tracking data) to predict the learning experience, comparing it with the subjective response given by the user on the UX form. The results suggest, based on a Wilcoxon test in the specific context of the research, that the incorporation of EEG and Eye Tracking does allow us to know more accurately the learning experience, compared to the use of a simple and traditional UX instrument (such as the form).

INTRODUCCIÓN

Con los nuevos avances tecnológicos, particularmente los relativos a la Computación, diversos sectores se han transformado por completo. Uno de los que mayor impacto ha tenido es sin lugar a duda la educación, y por ende la enseñanza y el aprendizaje.

Cada día se crean muchísimos recursos nuevos (gratuitos y de paga) que buscan acercar el conocimiento a millones de estudiantes a nivel mundial, de todos los niveles educativos edades, culturas e intereses. Esto por sí solo ya es un gran avance, pues se abren las oportunidades para muchas más personas que en décadas anteriores, pero en el mundo de hoy en día, es necesario que contenido de esta importancia se presente de la mejor manera posible a su público objetivo, pues el usuario promedio se encuentra bombardeado de información, por lo que retener su atención suele ser una tarea muchas veces complicada.

Un ejemplo práctico que ilustra a idea anterior es lo que sucede con los MOOCs (cursos masivos en línea), como los ofrecidos por plataformas como Coursera o edX. Constantemente durante el curso, y sobre todo al final de este, se solicita la retroalimentación del estudiante en varios rubros, por ejemplo, la estética de la *app* o página web que se está utilizando, el contenido del curso, la estructura u organización del material, la duración de los videos, las opiniones de los foros, etc. Si alguno de estos elementos no satisface la expectativa del estudiante (*usuario*) es poco probable que el curso se complete y, por ende, se pierda interés en el tema, o bien en el mejor de los casos, se busquen otras herramientas de aprendizaje.

El principal problema con la situación anterior (además de las consecuencias económicas que evidentemente tiene el organizador del curso), es que, desde un punto de vista más objetivo, puede que para ese estudiante, que en principio estuvo muy interesado en el tema central del curso (por ejemplo, la programación), pierda la motivación, interés o las ganas de continuar aprendiendo, no necesariamente porque el tema sea complicado (que la programación sea difícil), sino porque no se le presentó de la mejor manera.

Una situación muy similar pasa con las matemáticas. Muchas veces se estigmatiza a las matemáticas como un área “imposible” de aprender para muchas personas, sobre todo en edades tempranas, cuando en general, lo más probable es que no se hayan enseñado bien. Y no necesariamente la culpa recae completamente en el profesor, sino también en los recursos

didácticos que utiliza para enseñar las matemáticas. En el peor de los escenarios, un joven que tuvo una mala experiencia con las matemáticas decidirá (lamentablemente) enfocar su futura vida profesional o su elección de carrera universitaria hacia un campo que no tenga mucho que ver con las matemáticas. No porque sea un apasionado de la carrera o nueva área que eligió, sino por el mero hecho de no volver a encontrarse con matemáticas.

Ahora bien, la solución no radica completamente en el profesor, sino también en los recursos que utiliza, y, por otro lado, y más importante, en el estudiante. No sólo con respecto a su desempeño en el aula (que claramente es muy importante), sino también considerándolo como *usuario de un sistema*.

En este sentido, la Ingeniería de Software tiene mucho que aportar, más hoy en día que el Software está inmerso en los recursos educativos. Si se ve al estudiante no sólo como tal, sino también como un *usuario*, la información que imparte el profesor o los recursos que utiliza no son unidireccionales, sino que involucran activamente al estudiante para mejorar estos mismos y que el proceso de aprendizaje sea más completo. Si se involucra al estudiante y se comprende de mejor manera su experiencia e interacción en aula de clases, o de manera más sencilla, con un Objeto de Aprendizaje, pueden crearse a la postre mejores recursos para que el proceso de enseñanza – aprendizaje sea más personalizado o diseñado con un mejor enfoque.

Habiendo introducido *la experiencia* en los párrafos anteriores y desde un punto de vista más técnico, es importante destacar el concepto de la experiencia de usuario (*UX* por sus siglas en inglés). Esta se ha vuelto una de las áreas más relevantes en diversos campos debido a su capacidad de medir cómo un usuario se desenvuelve e interactúa con un producto, así como las emociones, ideas y sensaciones asociadas a este (Rajanen et al., 2017). Según (Hassan Montero, 2015) hay varios factores fundamentales que definen en su conjunto la *UX*, entre los que destacan Usabilidad, Accesibilidad, Interacción o Relación Esfuerzo-Beneficio.

Para evaluar la *UX* o alguno de sus factores antes mencionados, existe una gran variedad de técnicas y métodos; los hay más tradicionales como encuestas, o algunos otros que van más allá de las preguntas comunes (Vermeeren et al., 2010). De toda la variedad de técnicas utilizadas, han cobrado fuerza las que se basan en mediciones biométricas, como el *Eye Tracking* (traducido comúnmente como Seguimiento de mirada), las señales electroencefalográficas (EEG), la respuesta galvánica de la piel (*GSR*, por sus siglas en

inglés), el análisis de reconocimiento facial o la frecuencia cardíaca, pues ofrecen información fisiológica objetiva que no sería posible obtener ni analizar únicamente con métodos tradicionales y que interpretada correctamente, permite conocer las emociones reales de los usuarios (Schall, 2015a).

Si bien, la *UX* suele asociarse con la evaluación de productos tecnológicos, como páginas web, aplicaciones móviles o programas de escritorio, esta puede ser aplicada a cualquier tipo de productos o servicios (Norman & Nielsen, 2020) bajo ciertas adecuaciones. De esta manera, existen conceptos relacionados como “*Experiencia de Consumo*”, “*Experiencia de Compra*” y “*Experiencia de Uso*”, todas ellas asociadas al “*Marketing Experiencial*” (Piedragil, 2015). Así pues, bajo la premisa anterior y utilizando conceptos que constituyen a la *UX*, puede derivarse un concepto propio aplicado al aprendizaje: *La experiencia de Aprendizaje*.

Desde la pedagogía, se puede definir la experiencia de aprendizaje como “*la serie de actividades que van a lograr fijar el conocimiento de manera significativa y para toda la vida...*” (Ontiveros, 2007).

Sin embargo, el enfoque en el presente trabajo de investigación está orientado hacia la construcción de un modelo validado por Ciencia de Datos para el reconocimiento de patrones asociados al aprendizaje (utilizando las tecnologías mencionadas anteriormente, principalmente *Eye Tracking* y EEG) partiendo desde el campo de la *UX*. Es decir, no se pretende evaluar el aprendizaje o qué tan bien se aprende o no, sino la experiencia derivada de un ambiente u objeto de aprendizaje, para que a la postre, el modelo pueda aplicarse en situaciones pedagógicas reales y permita recabar datos de peso para el análisis de los expertos.

Así pues, el modelo (nombrado como UXEEGET) constituye un híbrido con campos como la *UX*, el Análisis de Datos y la Ciencia de Datos con un enfoque sustentado en las neurociencias para evaluar la experiencia de aprendizaje.

Con respecto a la organización del documento, a continuación, en el Capítulo I. Planteamiento del Problema, se presentan: la descripción del problema, la justificación, la delimitación, las preguntas y objetivos de investigación, así como la hipótesis y la importancia teórica y práctica de este trabajo.

En el Capítulo II. Referentes Teóricos, se exponen la Revisión Sistemática de la Literatura (RSL), y los Fundamentos Teóricos, donde se abordan las bases de la *UX*, el *Eye tracking*, EEG, otras tecnologías biométricas de evaluación y la Ciencia de Datos.

El Capítulo III. Metodología de Investigación, es el más robusto de toda la tesis. Abarca la descripción del Diseño Experimental y los Casos de Estudio; el Experimento Principal con el Marco Conceptual y los Objetivos de este; los Procedimientos Específicos (población y muestra, tecnología, recopilación de datos, etc.), la subsección sobre Instrumentos y Medidas, Consideraciones Éticas y por último el Análisis de Datos.

Le sigue el Capítulo VI. Resultados, donde se verifica la Prueba de Hipótesis, se da su interpretación y se validan los resultados obtenidos.

Ya no como capítulos, pero siendo secciones de mucha importancia, siguen las Discusiones de Resultados (se analizan los patrones y tendencias y se muestra el modelo o *framework* final UXEEGET, por mencionar algunas de las subsecciones); y las Conclusiones donde, por ejemplo, se destaca la importancia del *framework* y se cierra con las reflexiones finales.

Por último, en la sección Referencias se enlistan las fuentes bibliográficas utilizadas para este avance de tesis y como sección adicional, se presentan los Anexos A - G. En ellos se pueden encontrar los recursos que sirvieron de apoyo en algunos capítulos de la tesis, la productividad científica o un recuento de las actividades realizadas durante el doctorado.

TESIS TESIS TESIS TESIS TESIS

CAPÍTULO I. Planteamiento del problema

El objetivo primordial de esta investigación es la generación de un modelo de evaluación de experiencia de aprendizaje que ayude en la comprensión de este complejo proceso con miras a futuras mejoras. Se puede referir a este modelo como un marco de trabajo, o “*framework*”, sin embargo, antes de la construcción del modelo per se, es necesario conocer cuál es problema que se busca resolver con dicho *framework*. Dicho de otro modo, para abordar cualquier solución a un problema de investigación con rigor, es necesario primero conocer a detalle el problema que quiere atender. Así pues, en este primer capítulo se exponen todos los temas concernientes al planteamiento del problema. Más específicamente, su descripción, la justificación, los alcances o límites de la investigación con respecto al problema, las preguntas y objetivos de investigación, la hipótesis y por último, la importancia teórica y práctica de atender a este problema.

1. DESCRIPCIÓN DEL PROBLEMA

Ya se ha señalado que la intención de esta investigación no es proponer un modelo para mejorar el aprendizaje, pues es un proceso complejo que involucra varias áreas del conocimiento (psicología, fisiología, bioquímica, pedagogía, etc.). Realmente, se busca proponer un modelo de evaluación de experiencia de aprendizaje, apoyado con tecnologías biométricas. Es decir, se busca construir un modelo para estudiar si las experiencias que derivan de un encuentro con un objeto de aprendizaje son óptimas (lo cual sí podría generar una mejor consolidación del aprendizaje, pero dicho aspecto esta fuera del alcance de esta investigación), a partir de los datos recabados con EEG y *Eye Tracking*, así como respuestas de cada usuario.

El modelo está fuertemente basado en conceptos y técnicas de *UX* y áreas afines. La medición de *UX* se emplea para conocer la calidad de experiencia que tiene un usuario con respecto a su interacción con un sistema o producto (Law et al., 2009), principalmente conocer si fue positiva, negativa y el trasfondo de ello. Es decir, Si la *UX* fue positiva, la probabilidad de reencuentro con el sistema / producto, es mucho mayor, lo que a su vez puede generar compromiso y apego. Trasladando esta premisa al área del aprendizaje y la educación, si un estudiante se encuentra con un objeto de aprendizaje (consúltese el **Capítulo III, sección 3.2**

Tecnología, Objeto de Aprendizaje) que le genera experiencias positivas, es más probable que opte por usar esos recursos para estudiar, repasar, prepararse para un examen, etc.

Un ejemplo simple puede tomarse con el hecho de aprender programación (o conceptos relacionados). Hoy en día existe una basta cantidad de recursos para formarse en esta área, ya sean gratis o de paga, para distintos niveles educativos, enfocados en ciertos lenguajes, tecnologías o industrias. En el caso específico de la programación, un estudiante de nivel universitario podría optar por estudiar un tema en concreto con libros (impresos o digitales), *MOOCs*, tutoriales de páginas web, academias online, *bootcamps*, o vídeos (por ejemplo, de YouTube), además claro de las clases (presenciales, online o híbridas) que recibe en su universidad.

La importante elección de con cuál de todas las alternativas escoge para aprender (o estudiar, repasar, consultar referencias) está fuertemente basada en con cuál de ellas se siente más cómodo. Es cierto que, en este sentido, cada estudiante (usuario), tiene características únicas y estilos de aprendizaje muy diferentes al resto, sin embargo, también es cierto que hay características fundamentales que todo sistema que aspira a generar una *UX* positiva, debe tener (consúltese el **Capítulo II, sección 2.2 Experiencia de Usuario (UX)**).

Importante señalar una vez más que el hecho de que se trabaje con un objeto de aprendizaje que genera una *UX* positiva, no garantiza el aprendizaje, pero sí puede influir positivamente en él.

Ejemplos interesantes de cómo la *UX* influye en el proceso de aprendizaje pueden encontrarse en la creciente industria de las plataformas web educativas, por ejemplo, Coursera, edX, Udemy. En general, sus cursos, programas, certificaciones, etc. tienen el respaldo de universidades, empresas o profesionales de renombre, y suelen estar diseñados para generar una *UX* positiva que atrape a los usuarios y genere preferencia por su plataforma (Liapis et al., 2023).

También, en el campo de las aplicaciones móviles educativas, destaca Duolingo, pues para lograr una *UX* positiva, emplean técnicas de gamificación para atraer a sus usuarios y fomentar la práctica diaria de idiomas (Von Ahn, 2023). Así pues, con la práctica diaria, también se fomenta el aprendizaje.

En resumen, si un objeto de aprendizaje genera en el estudiante una *UX* positiva, será más probable que el aprendizaje sea mejor y más fluido. Para corroborar lo anterior, además se

propone trabajar con un par de tecnologías biométricas que han tenido mucho auge en los últimos años, el EEG y ET.

Aunque se profundizará sobre ellos en secciones más adelante de la investigación, es importante de momento resaltar que son dos tecnologías que permiten conocer información objetiva de un usuario, que probablemente de otra manera no se conocería. Por ejemplo, ambas tecnologías permiten medir distantes variantes de la atención, por ende, se puede determinar exactamente el nivel de atención prestado en una lección de clase, y compararlo con el nivel de atención (subjetivo) que el estudiante dice haber prestado. Es decir, son tecnologías complementarias a los estudios de *UX*.

2. JUSTIFICACIÓN

Como ya se ha señalado, a partir de la *UX* se comprenden otros conceptos, tales como la *Experiencia de Consumo*, *Experiencia de Compra* o *Experiencia de Uso*, además de otros como la *Experiencia del Cliente*, que se centra en medir cómo es la experiencia e interacción de un cliente con una empresa o servicio, “¿qué cosas valora realmente un cliente?” (Brunetta, 2019). El propósito de cada una de las “Experiencias” antes mencionadas no es medir su objeto ligado, sino los elementos, emociones o sentimientos relativos a ello. Es decir, la *Experiencia de Consumo* no mide qué consume el cliente, sino cómo fue su consumo, la *Experiencia de Compra* no mide cuánto gasta el cliente o qué compró, sino cómo fue su compra, qué tan fácil fue conseguir el bien adquirido o la comodidad que llevo este proceso. De igual manera, la *Experiencia de Uso* no mide el uso que se le dé a los productos, sino los sentimientos, emociones o la interacción que evoca usar determinado bien.

Así pues, el modelo propuesto para la evaluación de experiencia de Aprendizaje no pretende medir si los sujetos aprenden bien o no, o la calidad del aprendizaje, sino la experiencia e interacción durante el encuentro con un objeto de aprendizaje.

Es decir, el modelo utiliza los elementos pertenecientes a la *UX* para conformar, con la ayuda de otros campos como la Ciencia de Datos, las bases para medir la Experiencia de Aprendizaje mediante variables biométricas (objetivas) acompañadas de opiniones o información procedente de métodos de *UX* tradicionales (subjetivas).

Así pues, se pretende dejar un precedente que lleve la utilización de las herramientas de *UX* al campo del aprendizaje, pues realmente son pocas las investigaciones relativas a ello, o

bien, las existentes están dirigidas desde una perspectiva distinta (consúltese **Capítulo II, sección 1. Revisión Sistemática de la Literatura (RSL)**)).

3. DELIMITACIÓN DEL PROBLEMA

Toda investigación académica conlleva como punto importante la definición de su alcance o las limitaciones antes las que puede encontrarse. En el caso específico de esta investigación, se señalan a continuación las siguientes:

- **Limitaciones geográficas:** La investigación, y en específico la experimentación, se lleva a cabo únicamente en el estado de Aguascalientes, y más concretamente, sólo con usuarios de la comunidad de la UAA.
- **Limitaciones temporales:** El comienzo de este proyecto de investigación se dio a partir de enero de 2021, coincidiendo lamentablemente con la pandemia mundial de COVID-19, por lo que durante algunos semestres, la universidad limitó el acceso a la institución por razones de seguridad. Afortunadamente, conforme las condiciones mejoraron, las actividades se reactivaron con normalidad y la experimentación principal se llevó a cabo durante algunas semanas del semestre agosto – diciembre 2023.
- **Limitaciones teóricas:** Si bien existen una gran cantidad de artículos relacionados al EEG y el *Eye Tracking* en su conjunto, realmente un estudio de esta naturaleza en cuanto a su aporte a la experiencia de aprendizaje es novedoso, por lo que no se cuenta de momento con suficientes referencias teóricas al respecto. Lo anterior por otro lado es una ventaja, pues se crea la oportunidad de ser un estudio pionero en el campo.
- **Limitaciones metodológicas:** Similar al caso anterior, no existe demasiada información al respecto, sin embargo, mediante la Revisión Sistemática de la Literatura (RSL) se encontraron estudios con propuestas interesantes que sirven de guía para esta investigación.

4. PREGUNTAS DE INVESTIGACIÓN

Dado que ya se han revisado las primeras secciones que conforman al planteamiento del problema, es momento de definir las preguntas de investigación, general y específica, que a su vez están ligadas directamente con los objetivos de investigación (general y específico,

respectivamente), y que dictan las directrices para llevar a buen puerto el desarrollo del proyecto.

4.1 PREGUNTA DE INVESTIGACIÓN GENERAL

¿Cómo puede generarse un modelo de evaluación de Experiencia de Aprendizaje a partir de la *UX*, el *Eye Tracking* y el EEG gestionada con Ciencia de Datos?

4.2 PREGUNTAS DE INVESTIGACIÓN ESPECÍFICAS

- ¿Qué elementos, técnicas, herramientas y metodologías de la *UX* pueden ser tomados y adaptados para la creación del modelo de evaluación Experiencia de Aprendizaje, gestionado con Ciencia de Datos?
- ¿Qué métodos y herramientas de procesamiento y análisis pueden utilizarse para la evaluación de Experiencia de Aprendizaje con *Eye Tracking*, EEG y gestionado con Ciencia de Datos?
- ¿Qué métodos tradicionales de *UX* pueden adaptarse fácilmente al modelo de evaluación Experiencia de Aprendizaje gestionado con Ciencia de Datos?

5. OBJETIVOS DE INVESTIGACIÓN

A continuación, se presentan los objetivos de investigación, general y específicos, con los cuales se trata de dar respuesta a las preguntas de investigación.

5.1 OBJETIVO DE INVESTIGACIÓN GENERAL

- Definir las adaptaciones y elementos que compongan al modelo de Experiencia de Aprendizaje a partir de la *UX* resaltando principalmente las técnicas biométricas de *Eye Tracking* y EEG y su gestión mediante Ciencia de Datos.

5.2 OBJETIVOS DE INVESTIGACIÓN ESPECÍFICOS

- Realizar una búsqueda exhaustiva de los métodos, herramientas y técnicas de la *UX* que puedan ser aplicadas y adaptadas al modelo de evaluación Experiencia de Aprendizaje gestionado con Ciencia de Datos.

- Revisar y analizar el estado del arte de las herramientas y procesamientos basados en *Eye Tracking* y EEG aplicados a *UX* y gestionado con Ciencia de Datos.
- Indagar en distintos métodos tradicionales de *UX* que puedan ser adaptables al modelo de evaluación Experiencia de Aprendizaje gestionado con Ciencia de Datos.

6. HIPÓTESIS

Así cómo la *UX* aplicada en la Ingeniería de Software sirve para comprender las opiniones, interacción y sensaciones de un determinado producto de software, a partir de ella se puede generar un modelo aplicado al aprendizaje. A este concepto se le puede denominar *Experiencia de Aprendizaje* y puede ser evaluado mediante una combinación de herramientas biométricas (*Eye Tracking* y EEG) y métodos tradicionales de *UX* con validación con Ciencia de Datos. La idea central por tanto de este modelo es que a partir de la integración de las tecnologías de EEG y *Eye Tracking*, puede conocerse mejor la experiencia de aprendizaje de un usuario con respecto a un objeto de aprendizaje.

En términos de hipótesis nula y alternativa:

Hipótesis nula (H0): No hay diferencia significativa en los resultados del modelo de evaluación de experiencia de aprendizaje con la utilización de EEG y *Eye Tracking* con respecto a un modelo de *UX* tradicional, gestionado con Ciencia de Datos.

Hipótesis alternativa (H1): Existe una diferencia significativa en los resultados del modelo de evaluación de experiencia de aprendizaje con la utilización de EEG y *Eye Tracking* con respecto a un modelo de *UX* tradicional, gestionado con Ciencia de Datos.

Nota: La validación de la hipótesis se dio a partir del análisis de los resultados procedentes de la experimentación y con la prueba de signos de Wilcoxon.

7. IMPORTANCIA TEÓRICA Y PRÁCTICA

En años recientes se han llevado a cabo muchas investigaciones que combinan el EEG o el *Eye Tracking* en estudios de *UX*, incluso en ocasiones involucran ambas tecnologías a la par. Sin embargo, muy pocas son las que están orientadas al aprendizaje. Es cierto que muchas de estas investigaciones evalúan herramientas tecnológicas de aprendizaje (por ejemplo,

plataformas de aprendizaje, *MOOCs*, o *apps*), pero esto no quiere decir que evalúen la experiencia de aprendizaje en sí.

Por esta carencia de trabajos relacionados, es que se considera que el modelo de evaluación de experiencia de aprendizaje basado en EEG y *Eye Tracking* (y validado con Ciencia de Datos), es un estudio pionero en el campo. Claramente no será el único, pues cada día existe mucha investigación de gran calidad en el área experiencial, y tarde o temprano llegará una gran ola de investigaciones que abarquen también al aprendizaje. Pero sí se pretende que este modelo genere un precedente y que con el paso del tiempo pueda adaptarse y mejorarse según sea necesario.

En cuanto a la importancia práctica del modelo, es evidente que mejoras en todas las áreas de enseñanza, educación o aprendizaje a todos los niveles siempre serán en beneficio de la sociedad. No solo de la mexicana, sino del mundo entero en general, pues con la incorporación de nuevas tecnologías (por ejemplo, la Inteligencia Artificial o las Realidades Virtual y Aumentada), se busca diseñar y aplicar mejores contenidos educativos, y en este caso, crear mejores experiencias de aprendizaje.

CAPÍTULO II. Referentes teóricos

Ahora que ya se ha descrito el planteamiento del problema, en este “Capítulo II Referentes Teóricos”, se presenta la Revisión Sistemática de la Literatura (RSL), una metodología estructurada y rigurosa para evaluar y analizar los trabajos relacionados que pueden servir como base para esta investigación; y los Fundamentos Teóricos, una sección dedicada a abordar en profundidad cada uno de los temas más importantes sobre el modelo de evaluación de experiencia de aprendizaje.

1. REVISIÓN SISTEMÁTICA DE LA LITERATURA (RSL)

Para cualquier investigación es esencial realizar una búsqueda exhaustiva de los trabajos relacionados. Por ello, en esta sección se presenta una Revisión Sistemática de la Literatura (RSL), una metodología formal y estricta, compuesta de varias fases que permite analizar a detalle la evidencia científica disponible sobre un tema en particular.

Para dicho fin, se trabajó con una metodología basada en la guía propuesta por (Kitchenham & Charters, 2007), quienes estipulan los pasos a seguir para realizar una RSL en Ingeniería de Software.

En la Fig. 1 se muestra el esquema metodológico seguido para la RSL:



Fig. 1 Esquema metodológico empleado para realizar la RSL. Basado en (Kitchenham & Charters, 2007)

1.1 PLANIFICACIÓN

Esta fase, al igual que las consiguientes, fue dividida en diferentes actividades (las cuáles se describirán en cada subsección). Para este caso, consistió en:

- Generación de Protocolo.
- Definición de Preguntas de Investigación.
- Definición de criterios de inclusión y exclusión.

1.1.1 Generación de Protocolo.

De acuerdo con la guía para RSL en Ingeniería de Software, propuesta por (Kitchenham & Charters, 2007), se definió un protocolo de investigación definiendo el plan de acción. A partir de este, se generaron las preguntas de investigación para efectuar la RSL y otros elementos de los pasos siguientes. Consúltese el Anexo B para conocer a detalle el Protocolo de la RSL.

1.1.2 Definición de Preguntas de Investigación

Se plantearon las siguientes preguntas de investigación para realizar la RSL:

1. ¿Existen modelos de *UX* relacionados con el aprendizaje/enseñanza?
2. ¿Cómo son los modelos de *UX* que implementan EEG y *Eye Tracking* a la vez?
3. ¿Qué metodologías de *Data Science* se pueden utilizar para procesar datos provenientes de EEG y *Eye Tracking*?
4. ¿Qué metodologías de investigación se pueden aportar desde el *marketing*?

Cabe señalar que, aunque la investigación (y por consiguiente la RSL) está centrada en *UX* y áreas afines, desde el *Marketing* se pueden ofrecer investigaciones semejantes, sobre todo en lo que se refiere a la aplicación de ambas técnicas biométricas (EEG y *Eye Tracking*); por ello se considera la cuarta pregunta.

1.1.3 Definición de criterios de inclusión y exclusión

Cada artículo consultado durante la RSL puede tener o no relación con el tema de investigación. Se consideró que esta existía si se presentaba alguno de los siguientes:

- Modelo o *framework* de *UX* orientado al aprendizaje.

- TESIS TESIS TESIS TESIS TESIS
- Modelo o *framework* de procesamiento de datos conjunto de EEG o *Eye Tracking*, sea o no con relación a la *UX*.
 - Investigaciones de EEG o *Eye Tracking* con relación al aprendizaje o áreas afines.

Es importante aclarar que estos criterios de inclusión y exclusión se emplean para realizar el filtrado de artículos (sobre todo en las fases iniciales de la búsqueda). La determinación final de relevancia directa con el tema de investigación se da a través de la lectura completa de cada artículo y del cumplimiento de criterios de calidad (Véase sección **1.4 Evaluación de Calidad**).

1.2 BÚSQUEDA

Esta fase consistió en la exploración de artículos empleando distintos recursos bibliográficos. Para este caso, se dividió en dos actividades:

- Definición de cadenas de búsqueda.
- Consultas de repositorios y bases de datos.

1.2.1 Definición de cadenas de búsqueda

Cada repositorio o base de datos cuenta con opciones para realizar búsquedas avanzadas, por ello se determinaron cadenas con palabras clave y operadores binarios a partir de las preguntas de investigación. Las cadenas de búsqueda fueron:

- *User Experience AND Learning*
- *User Experience AND (EEG OR Eye Tracking)*
- *EEG AND Eye Tracking*
- *Marketing AND (EEG OR Eye Tracking)*

Nota: Para la Búsqueda en Springer Link se utilizó el operador NEAR para más precisión:

1.2.2 Consultas de repositorios y bases de datos

Para una RSL más completa, se consultaron repositorios de referencias bibliográficas y/o bases de datos de artículos de artículos científicos importantes en el campo de la

Ingeniería de Software o de la investigación científica en general, además de que se contara con convenio vigente con la UAA o que fueran *Open Access*. Estas fueron:

- IEEE Xplore
- Science Direct Elsevier
- Springer Link
- ACM Digital Library
- PubMed
- ArXiv
- Academic Search Ultimate EBSCO
- Directory of Open Access Journals (DOAJ)
- Web of Science (WOS)

Cabe indicar que el periodo de búsqueda fue delimitado de 2010 – 2021.

1.3 SELECCIÓN.

Luego de haber realizado la búsqueda en las bases de datos y repositorios de referencias bibliográficas, se procedió a seleccionar aquellos resultados más afines al tema de investigación. Para este caso, esta fase fue dividida en:

- Selección Preliminar: Resultados de búsqueda.
- Selección detallada: Por relación de título de artículo y *abstract*.

1.3.1 Selección preliminar: Resultados de búsqueda

En la mayoría de los repositorios o bases de datos antes mencionadas, es posible descargar archivos .txt o .csv con los metadatos de cada artículo (autor, año, tipo de documento, foro/revista, etc.) obtenido en la búsqueda. A partir de ello, en el punto anterior se obtuvieron un total de 415 trabajos de investigación, pudiendo ser artículos de revista, artículos en memorias de congreso, capítulos de libro, etc. Para un rápido vistazo estadístico de la proporción de artículos encontrados en cada base de datos, se muestra la gráfica de la Fig. 2.

1.3.2 Selección detallada: Por relación de título de artículo y *abstract*

Esta actividad fue dividida en dos tareas, por un lado, a partir de los archivos con los metadatos de los artículos, se identificaron más fácilmente sus títulos y se comprobó de manera manual la relación con el tema de investigación. Luego de este análisis, se obtuvieron 147 artículos.

Por otro lado, la segunda tarea consistió en realizar la lectura de los *abstracts* de los artículos que pasaron la tarea anterior e identificar una posible relación con el tema de investigación. Se obtuvieron un total de 72 artículos, aunque existieron 6 de distintas bases de datos a los que no se tuvo acceso o resultaron duplicados, por lo que al final se obtuvieron 66 artículos, lo que supone una reducción aproximadamente del 83% con respecto a los resultados de la selección preliminar. Para revisar la contribución de cada base de datos o repositorio, puede consultarse la gráfica de la Fig. 3.




Fig. 2 Gráfica de pastel que muestra la contribución porcentual de cada base de datos/repositorio después de la Selección Preliminar. Total: 415 artículos (Elaboración propia, 2022).

1.4. EVALUACIÓN DE CALIDAD.

Esta fase consistió en la aplicación de criterios de calidad y lectura completa de cada artículo resultante de la fase anterior. Fue dividida en dos actividades:

- Definición de criterios de calidad.
- Lectura completa de artículos filtrados.

1.4.1 Definición de criterios de calidad

Previo a la lectura completa de cada artículo, se fijaron criterios de calidad para garantizar la relación directa con el tema de investigación. estos fueron:

1. Objetivo de investigación próximo al interés de búsqueda.
2. Metodología de investigación aplicada con rigor científico y apegada al uso de EEG y/o *Eye Tracking*.
3. Resultados con rigor y conclusiones pertinentes.

Debe señalarse que los criterios de calidad no son iguales o equivalentes a los criterios de inclusión/exclusión, puesto que los primeros sirven como guía para realizar la fase de Selección, mientras que los segundos garantizan el rigor y la relevancia que los artículos que pasaron las fases previas deben cumplir para considerar que se tiene relación directa con el tema de investigación.

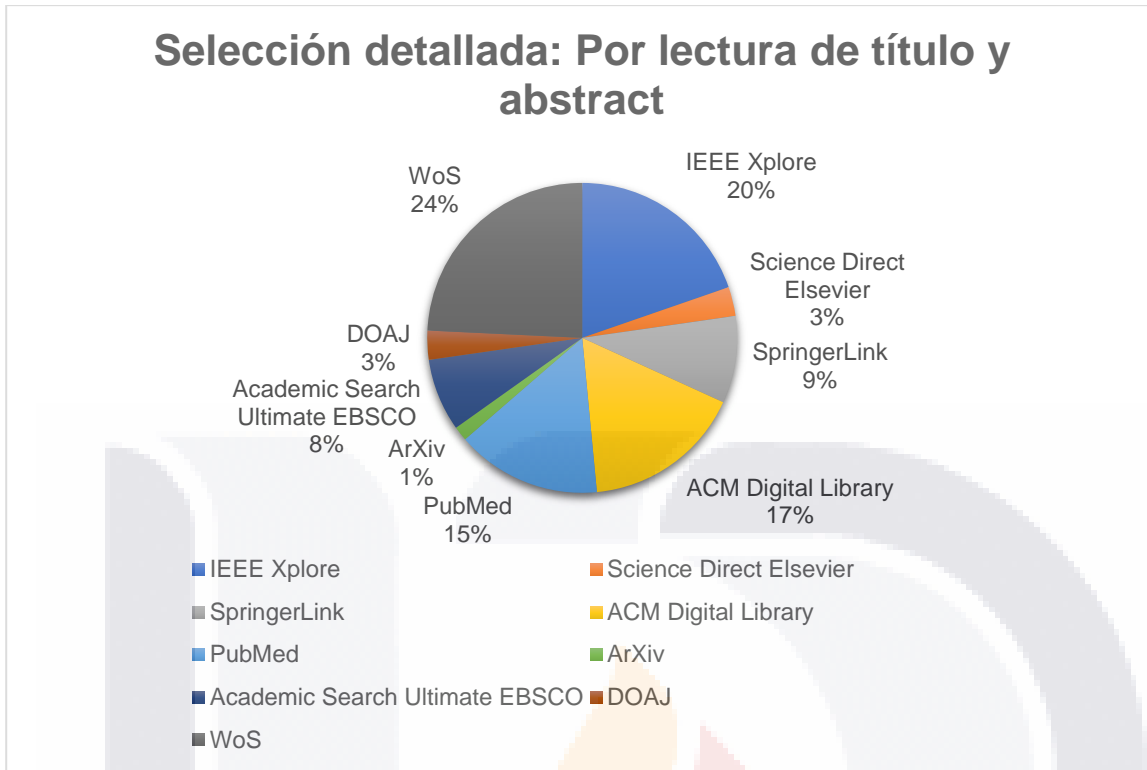


Fig. 3 Gráfica de pastel que muestra la contribución porcentual de cada base de datos/repositorio después de la Selección detallada. Total: 66 artículos (Elaboración propia, 2022).

1.4.2 Lectura completa de artículos filtrados

Al leer el *abstract*, se obtiene una idea general del contexto, metodología, objetivos, avances y resultados de un artículo, sin embargo, en este punto es necesario profundizar en aquellos que pasaron la selección detallada. Para ello, se leyó cada artículo que pasó la fase anterior y se le aplicaron los criterios de calidad. Cabe resaltar que se definió que un artículo tuvo relación directa con el tema de investigación si satisfizo uno o más criterios de calidad.

1.5. EXTRACCIÓN.

Habiendo terminado las fases anteriores, esta última consistió la condensación de los datos y fue dividida en:

- Descripción breve de artículos finales.
- Generación de decisión de relación final.

1.5.1 Descripción breve de artículos finales

Dada la gran diversidad de artículos finales, se generó la Tabla 8 (Anexo C). En ella, se concentran los resultados junto a una breve descripción de cada uno de ellos y se resalta si tuvieron relación directa y cuáles criterios de calidad cumplieron (en caso de haber sido así).

1.5.2 Generación de decisión de relación final

Como ya se mencionó, luego de la lectura completa y la aplicación de criterios de calidad, se determinó si cada uno de los artículos finales contaba con relación directa o no con el tema de investigación (Anexo C, Tabla 8). En los Resultados de la RSL puede consultarse la contribución de cada base de datos.

De todos los trabajos expuestos en la Tabla 8 (Anexo C), vale la pena destacar las contribuciones de dos de ellos. El primero (Fig. 4) de (Shi et al., 2017), presenta un *framework* sobre el reconocimiento de emociones basado en EEG y *Eye tracking*, por lo que es un buen ejemplo para la combinación de ambas técnicas biométricas. Por otro lado, el segundo (Fig. 5) de (Kremer et al., 2016) expone un modelo de características para tomar en cuenta cuando se evalúa *UX* fuera del ámbito computacional. Así pues, combinando ideas de los puntos anteriores, se pueden tener bases para el modelo de evaluación de experiencia de aprendizaje.

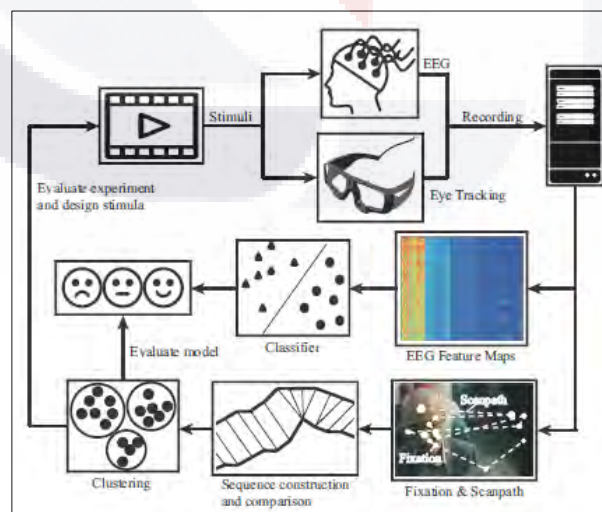


Fig. 4 Framework para el reconocimiento de emociones basado en EEG y *Eye Tracking* propuesto por (Shi et al., 2017)

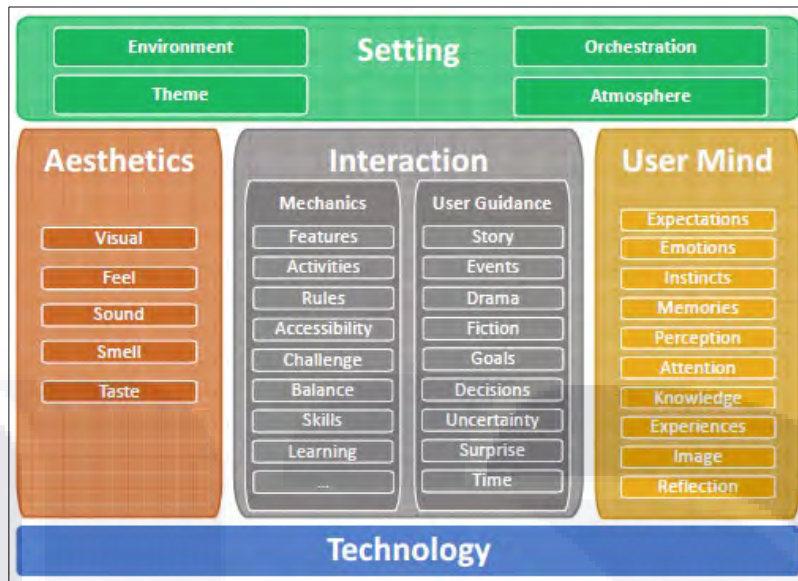


Fig. 5 Modelo ExodUX mencionado en (Kremer et al., 2016).

Este modelo sirve como una base interesante para el modelo de evaluación de Experiencia de Aprendizaje de esta investigación.

1.6. RESULTADOS DE LA RSL.

Como se describió durante las fases anteriores, del total de artículos iniciales (415), al finalizar se obtuvieron 66. Luego de la aplicación de los criterios de calidad, se obtuvieron 28 artículos con relación directa al tema de investigación. La aportación de cada base de datos/repositorio puede consultarse en la gráfica de la Fig. 6:




Fig. 6 Gráfica de contribución de cada base de datos/repositorio (Elaboración propia, 2022).

Además, a partir de los resultados finales, se identificaron las principales líneas de investigación los mismos, los cuáles fueron divididos en las siguientes categorías:

- Modelo o *framework* de *UX* orientado al aprendizaje.
- Modelo o *framework* de procesamiento de datos conjunto de EEG o *Eye Tracking*, sea o no con relación al *UX*.
- Investigaciones de EEG o *Eye Tracking* con relación al aprendizaje o alguna de sus áreas.

1.6.1 Bases de datos y/o repositorios con mayor contribución

Las bases de datos/repositorios que tuvieron más relación directa fueron:

1. Web of Science (7 artículos).
2. Pubmed (5 artículos)
3. Springer Link (4 artículos)

Mientras que IEEE Xplore, ASU EBSCO y ACM Digital Library cuentan con tres cada uno.

1.6.2 Respuesta a las preguntas base para la búsqueda

Luego de haber concluido la RSL, a continuación, se da respuesta a las preguntas base para la búsqueda de la fase de Planificación.

- ¿Existen modelos de *UX* relacionados con el aprendizaje/enseñanza?

Entre los trabajos que más destacan por la aplicación de *UX* en el aprendizaje, se encuentran, el de (Kremer et al., 2016), quienes proponen un modelo de aprendizaje interactivo que destaca las principales categorías de experiencia: estética, interacción, mente del usuario, configuración o tecnología; el de (Mendoza-Franco et al., 2021) con su metodología de herramientas de aprendizaje digital; (Mavengere & Ruohonen, 2019) quienes proponen la adaptación y mejora de ambientes virtuales; o el *framework* para medición de *UX* en ambientes e-learning de (Wiklund-Engblom, 2010).

- TESIS TESIS TESIS TESIS TESIS
- *¿Cómo son los modelos que implementan EEG y Eye Tracking a la vez?*
Suelen aplicarse en conjunto para reconocimiento de emociones (López-Gil et al., 2016; Shi et al., 2017; Zheng et al., 2014) o para evaluación de atención (Putze et al., 2013; Rodrigue et al., 2015). Además, destacan otros enfocados en estudio de procesamiento mental (Scharinger et al., 2020), carga cognitiva (Brouwer et al., 2017), retención de información (Maguire et al., 2014) o usabilidad (Falkowska et al., 2016).
 - *¿Qué metodologías y técnicas se utilizan para procesar datos de EEG y Eye Tracking?*
En varios trabajos se aplican y comparan distintos algoritmos de Machine Learning, Deep Learning o campos afines. Destaca que algunos aplican Support Vector Machine (Shi et al., 2017; Zheng et al., 2014) o KNN (López-Gil et al., 2016), mientras que (Dimigen & Ehinger, 2021) propone un análisis basado en regresión multivariada.
 - *¿Qué metodologías y técnicas se pueden aportar desde el marketing?*
Aunque se revisaron estudios de marketing (Bazzani et al., 2020; Dobias et al., 2013; Jain et al., 2018; Pei & Li, 2021) que aplicaron EEG y *Eye Tracking*, así como algunas otras técnicas biométricas, no se encontraron propuestas relevantes para el tema de investigación, pues no cumplieron alguno de los criterios de calidad propuestos.

Por último, como cierre de capítulo, cabe destacar que la RSL sirvió para sentar las bases del desarrollo de la tesis, puesto que se descubrieron enfoques y propuestas que pueden adaptarse para este trabajo de investigación.

2. FUNDAMENTOS TEÓRICOS

En esta sección se presentan los principales fundamentos teóricos de los temas y conceptos relacionados con el proyecto de investigación, comenzando por el concepto de Aprendizaje, seguido por Experiencia de Usuario (UX), pues ambos son las bases de Experiencia de Aprendizaje. Después se aborda brevemente una introducción a las técnicas de medición biométricas, para de ahí profundizar en el *Eye Tracking* (Seguimiento ocular) y Electroencefalografía (EEG), que se emplean como herramientas principales de medición. Finalmente, se da una breve descripción de la Ciencia de Datos, disciplina con la cual se procesan y analizan los datos provenientes de las técnicas biométricas para validar el modelo.

2.1 APRENDIZAJE

Este concepto puede abordarse desde diferentes perspectivas y áreas. Para el caso de esta investigación se resaltan principalmente tres, la psicología, pedagogía y la fisiología, pues son las áreas que se considera dan definiciones más precisas y objetivas. Por lo anterior, en la Tabla 1 se muestra un conjunto de definiciones de estos campos de estudio con sus respectivas referencias.

Tabla 1 Definiciones de Aprendizaje (Elaboración propia, 2023).

Definición	Área/ciencia	Referencia
<i>“Un mejoramiento que acompaña a la práctica” o un proceso para “sacar provecho de la experiencia”.</i>	Pedagogía	(Rivera et al., 2021)
<i>“Se entiende por aprendizaje al proceso, en virtud del cual una actividad se origina o se cambia a través de la reacción a una situación encontrada con tal que las características del cambio registrado en la actividad puedan explicarse con fundamentos en las tendencias innatas de respuesta, la maduración o estados transitorios del organismo”.</i>	Psicología	(Bower & Hilgard, 2004)
Cambio en la conducta debido a la experiencia.	Psicología	(Chance, 2001)

<i>“Adquisición por la práctica de una conducta duradera”.</i>	Psicología	(Real Academia Española, 2023)
La habilidad de modificar el comportamiento (propio) con base en la experiencia.	Fisiología	(Barrett, 2013)
<i>“Proceso de cambio relativamente permanente en el tiempo en el comportamiento de un individuo, producto de una experiencia”</i>	Fisiología	(Glejzer, 2017)

Sin entrar en las diversas teorías del aprendizaje (pues están fuera de los límites de la investigación), se puede observar que en varias de las definiciones se encuentra una palabra clave a tomar en cuenta, “experiencia”. El aprendizaje se da o parte de una experiencia, es por ello por lo que, en la presente investigación, se aborda este tema desde la perspectiva de la UX, que si bien, como ya se mencionó está generalmente más relacionada al mundo de la ingeniería de software, puede también adaptarse según las necesidades a un entorno distinto.

2.1.1 Estilos de aprendizaje.

Además de las distintas definiciones, es importante resaltar que existen diferentes estilos de aprendizaje. Según (Hudson, 2017) se engloban en tres:

- Visual: Mirando y observando.
- Auditivo: Escuchando y hablando.
- Kinestésico: Experiencia física.

Si bien no se profundizará más en estos estilos, es importante tenerlos en cuenta, pues a partir de ellos es más fácil abordar qué tipo de recurso puede implementarse con respecto al estudiante al que va dirigido (aunque es difícil suponer las características personales que mejor se adecúan a cada individuo).

2.1.2 Objeto de aprendizaje.

Otro concepto de suma relevancia que vale la pena revisar y que sirve como un puente entre aprendizaje y UX a través de la tecnología, es Objeto de Aprendizaje (OA). Se trata de un término relativamente nuevo (alrededor de tres décadas atrás), que han tratado diversos

TESIS TESIS TESIS TESIS TESIS

autores en el contexto de la aplicación de las Tecnologías de la Información y Comunicación (TIC) en la educación. De acuerdo con diversos autores como (Callejas Cuervo et al., 2011; Maldonado et al., 2020; Villarreal et al., 2016) el término OA fue por primera vez propuesto en 1992 por Wayne Hodgins y se acuñó como *“cualquier recurso digital que puede ser utilizado como soporte para el aprendizaje”*.

Por otro lado, de acuerdo con el *Standard for Learning Object Metadata* de (IEEE, 2020):

“... un objeto de aprendizaje es definido como cualquier entidad, digital o no digital que es usada para el aprendizaje, educación o entrenamiento”.

Es importante destacar la definición anterior, dado que para la construcción del modelo de evaluación de experiencia de aprendizaje es necesario la utilización de un OA con el cual el usuario interactúe. En el caso particular de la presente investigación, se tomará el OA solo desde la perspectiva como un recurso digital, puesto que para el análisis se emplean tecnologías biométricas, que serán abordadas más adelante en este capítulo.

Para justificar la elección del OA que se puede implementar, es importante tomar en cuenta la calidad de este. De acuerdo con (Velázquez et al., 2006), la calidad del OA se define mediante cuatro aspectos:

- Elementos tecnológicos
- Elementos pedagógicos
- Elementos de contenido
- Elementos estéticos

Al llegar a la sección sobre la implementación del OA durante la construcción del modelo de evaluación de experiencia de aprendizaje, se retomarán brevemente estos puntos.

Ahora que ya se ha abordado el primer concepto de relevancia en la investigación, aportando definiciones desde distintas disciplinas y conceptos generales sobre los OA, se puede continuar con otro de los términos fundamentales, la Experiencia de Usuario, presentada a continuación.

2.2 EXPERIENCIA DE USUARIO (UX).

Como se mencionó brevemente en la introducción, la experiencia de Usuario (en adelante, *UX*, del inglés *User eXperience*) es el campo que se encarga de medir cómo un usuario se desenvuelve e interactúa con un producto y las emociones, ideas y sensaciones asociadas al mismo (Rajanen et al., 2017). Otra definición similar dicta que “*la UX trata del estudio, diseño y evaluación de las experiencias que las personas tienen con el uso (o el encuentro) con un sistema*” (Roto, 2011). Además, de acuerdo con (Del Giorgio Solfa et al., 2018), con la *UX* “*se busca resolver de manera sistemática los problemas de utilidad del producto, psicología del placer y satisfacción de uso*”.

De acuerdo con (U.S. Department of Health & Human Services, 2023a), la *UX* busca asegurar que los usuarios encuentren valor en aquello que se les provee (sistema, página web, aplicación móvil, etc.). Por ende, con base en las ideas de (Morville, 2004), para conseguir evocar una *UX* de valor y significativa, la información presente en el elemento (y el elemento en sí) con que se interactúa debe cumplir cada uno de los factores enlistados a continuación (pueden observarse también en la Fig. 7).

- **Útil:** El producto (o sistema) debe ser útil y brindar soluciones innovadoras.
- **Usable:** Debe ser de fácil uso.
- **Deseable:** Elementos como la imagen, identidad, etc. deben evocar emociones y apreciación.
- **Localizable:** Debe ser navegable, es decir, que los usuarios puedan encontrar lo que necesitan con facilidad.
- **Accesible:** Debe tener contenido accesible para personas con discapacidad (físicas o mentales, por ejemplo, existen adaptaciones de algunas aplicaciones o bien herramientas alternativas que permiten el uso a personas con ciertas discapacidades, como ceguera, sordera, autismo, etc.).
- **Fiabile:** Se debe evocar en el usuario confianza y credibilidad.
- **Valiosa:** La información debe cumplir con un propósito.



Fig. 7 Panal de la experiencia de usuario. Título original: *User Experience Honeycomb* (Morville, 2004).

La *UX* es un concepto dinámico que involucra varias fases (véase la Fig, 8): anticipada, momentánea, episódica y acumulativa (Roto, 2011), por lo que su relevancia es duradera y puede ser registrada de manera precisa.

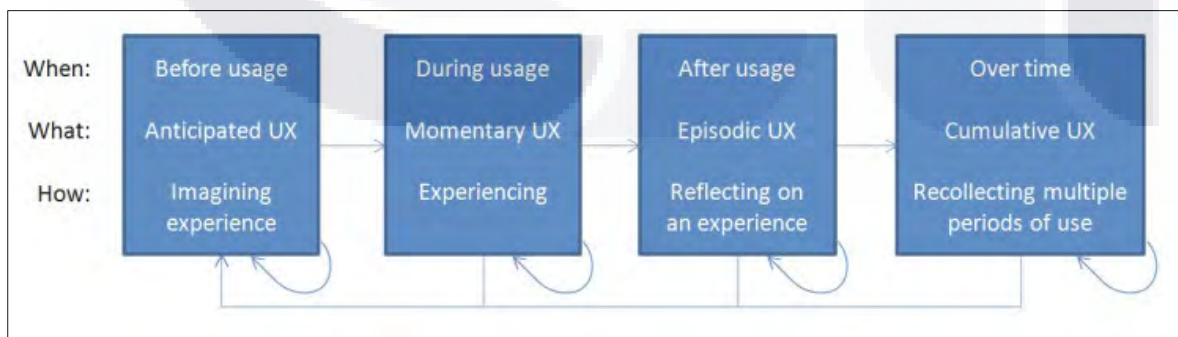


Fig. 8 Fases de la Experiencia de Usuario (Roto, 2011)

Con respecto a las categorías de la *UX*, según (Roto et al., 2023), los estudios de *UX* pueden agruparse en las categorías descritas en la Tabla 2:

Tabla 2 Categorías de la UX, con base en (Roto et al., 2023)

Categoría	Grupos
Por tipo de estudio	Estudios de campo Estudios de laboratorio Estudios en línea Cuestionarios
Por periodo (Fig. 8)	Antes de uso Instantánea Episódica A largo plazo
Por evaluador	Experto en UX Usuario a la vez Grupos de usuarios Parejas de usuarios
Por tipo de datos	Cualitativos Cuantitativos
Por aplicación	Servicios Web Software móvil Software de PC Diseño de Hardware

Cuando se aborda el tema de *UX*, deben tomarse en cuenta una multitud de conceptos relacionados o derivados de la misma, es por ello por lo que en los siguientes subpuntos se describirán algunos de los más comúnmente relacionados con la *UX* y que además tienen relevancia directa con el modelo de evaluación de experiencia de aprendizaje.

2.2.1 Interacción Humano – Computadora (HCI)

Si bien, puede parecer en primera instancia que la *UX* es un término meramente asociado a productos (físicos o digitales), realmente su aplicación está sumamente ligada a la Interacción Humano – Computadora (*HCI*, por sus siglas en inglés) (Hornbæk & Hertzum, 2017). De acuerdo con (Sinha et al., 2010) la *HCI* “es una disciplina relativa al diseño, evaluación e

implementación de sistemas computacionales interactivos para uso humano y del estudio de los principales fenómenos que los rodean". Otro enfoque interesante de (Brejcha, 2015) dicta que la *HCI* está ligada a la estructura de un sistema (computacional), mientras que la *UX* se encarga de las actividades relativas a los procesos de diseño de *HCI*. Por último, cabe resaltar una definición más amplia y pionera propuesta por (Myers et al., 1996), quienes afirman que la *HCI* se encarga del estudio de cómo las personas usan, implementan y diseñan sistemas computacionales interactivos, y cómo las computadoras influyen en los individuos, organizaciones y la sociedad en general. Dada la diversidad de definiciones, y considerando que el concepto en sí mismo es complejo, la *HCI* se ve influenciada por una gran variedad de ciencias y áreas del conocimiento (Fig. 9). Aunque un estudio a profundidad sobre *HCI* está fuera del alcance de esta investigación, es importante abordar brevemente este concepto, puesto que el modelo de evaluación de experiencia de aprendizaje surge de la interacción de un usuario con un objeto de aprendizaje digital.

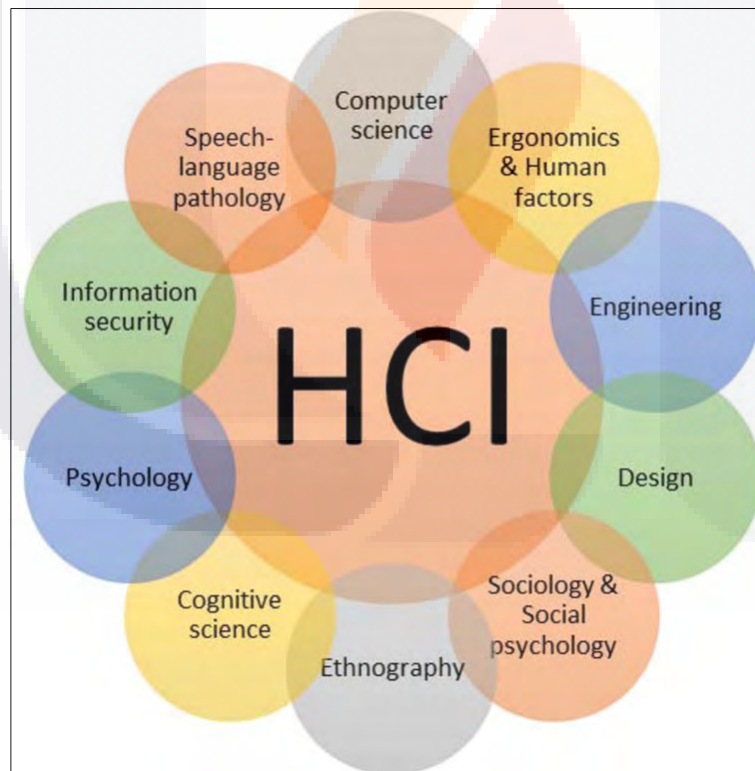


Fig. 9 HCI y sus áreas relacionadas (Chakraborty et al., 2018)

2.2.2 Usabilidad

Por otro lado, un término que también suele asociarse comúnmente a la *UX* (y en ocasiones suele confundirse) es la “Usabilidad”. Si bien, son términos relacionados, no son equivalentes, y esta puede definirse “*como un subconjunto de la calidad de uso compuesto por la eficacia, la eficiencia y la satisfacción...*” o bien como el “*grado en que un producto o sistema puede ser utilizado por usuarios específicos para lograr objetivos específicos con eficacia, eficiencia y satisfacción en un contexto de uso específico*” (ISO/IEC, 2011).

Existen pilares o características que resaltan de la Usabilidad y le dan la relevancia que tiene dentro del campo de la *UX*. Aunque dependen de cada autor, algunas de ellas son muy similares o directamente las mismas; por ejemplo (Karwowski et al., 2003) afirman que la Usabilidad se sustenta en cinco atributos principales:

1. Capacidad de aprendizaje
2. Eficiencia
3. Memorabilidad
4. Errores
5. Satisfacción

Mientras que, por otro lado, (U.S. Department of Health & Human Services, 2023b), señala que la Usabilidad es una combinación de los siguientes factores:

1. Diseño intuitivo
2. Facilidad de aprendizaje
3. Eficiencia de uso
4. Memorabilidad
5. Frecuencia y severidad de errores
6. Satisfacción subjetiva

De los elementos mencionados por ambas fuentes se destaca que: ambos consideran la capacidad y facilidad de aprendizaje (puntos 1 y 2 respectivamente); la eficiencia (de uso o interacción) con el sistema (puntos 2 y 3 respectivamente); los errores (puntos 4 y 5 respectivamente) que el usuario puede cometer; la memorabilidad, que se refiere a la capacidad del usuario de recordar efectivamente el sistema en una siguiente visita o encuentro

(U.S. Department of Health & Human Services, 2023b) (puntos 3 y 4 respectivamente); y por último, la satisfacción (puntos 5 y 6 respectivamente) entendiéndose como el agrado (subjetivo) del usuario por el sistema.

Si bien todos los puntos son relevantes, debe considerarse que algunos pueden tener mayor impacto en lo que al modelo de evaluación de experiencia de aprendizaje se refiere. Por ejemplo, el punto sobre Diseño Intuitivo es vital para la interacción con un objeto de aprendizaje, pues de este puede partir también la facilidad de aprendizaje y la memorabilidad.

De manera similar a los factores que influyen la *UX*, existen las 10 heurísticas de Usabilidad para diseño de interfaces de usuario de (Nielsen, 2020). Cabe señalar que, aunque se propusieron por primera vez en 1994, han sido refinadas y siguen vigentes hasta la actualidad. Estas son:

1. Visibilidad de estatus del sistema.
2. Relación entre el sistema y el mundo real.
3. Control y libertad del usuario.
4. Consistencia y estándares.
5. Prevención de errores.
6. Reconocimiento en lugar de memoria.
7. Flexibilidad y eficiencia de uso.
8. Diseño estético y minimalista.
9. Ayuda a los usuarios a reconocer, diagnosticar y recuperarse de errores.
10. Ayuda y documentación.

Aunque estas heurísticas son una guía muy popular dentro del diseño web, realmente pueden ser fácilmente aplicables para cualquier diseño de interfaces. Son un equivalente a una guía de buenas prácticas que garantizan una óptima usabilidad del sistema, y por ende pueden conducir también a una *UX* positiva.

Retomando la *UX*, la Usabilidad además resalta como un elemento clave dada su importancia en distintos modelos de desarrollo de software, sobre todo los iterativos (Goodman et al., 2012), como cascada o espiral. De hecho, la prueba de usabilidad es junto a la prueba de aceptación del usuario (*UAT*, del inglés *User Acceptance Testing*), las dos variantes de *testing*

de software más importantes relacionadas con el usuario. La primera se encarga de verificar la facilidad de uso, apariencia o sentir del usuario al interactuar con el software, mientras la segunda de verificar las expectativas y aceptación del usuario (O'Regan, 2017).

Otro aspecto clave de aplicación de la usabilidad es el muestreo estadístico necesario para conocer el sentir de los usuarios. Según (Nielsen & Landauer, 1993), en un estudio de usabilidad no se necesitan más de cinco usuarios para conocer la percepción general del público, sin embargo, la situación cambia si se desea conocer una percepción de *UX* más global, ya sea exploratoria o detallada, pues se debe considerar una muestra de 15 a 30 usuarios (Tobii LatAm, 2021c).

Ahora bien, cabe considerar que, aunque la *UX* es un término base y central en este trabajo de investigación, su contribución está más orientada a la cimentación de las metodologías propias de su campo que pueden aplicarse para desarrollar el modelo de evaluación de experiencia de aprendizaje. Es por lo anterior, que, en el siguiente subpunto, se muestra un breve repaso por los métodos de evaluación de *UX* que implican técnicas biométricas.

2.2.3 Métodos de evaluación de UX con tecnologías biométricas.

Hay una gran cantidad de métodos de evaluación de *UX* en las que se emplean distintas técnicas para recabar la información del usuario. Pueden ser desde las tradicionales (por ejemplo, las que obtienen información de *UX* en general como MAX de (Cavalcante et al., 2015), o HED/UT de (Voss et al., 2003) hasta las que emplean tecnologías biométricas, una tendencia que lleva relativamente pocos años aplicándose.

A diferencia de los métodos tradicionales, los que emplean tecnologías biométricas, permiten obtener información directa y objetiva, puesto que surgen del comportamiento psicofisiológico del usuario y revelan su estado emocional con mejor precisión (Ganglbauer et al., 2009; Maia & Furtado, 2016), por lo que cada vez más son más utilizados, incluso en conjunto con los métodos tradicionales (así se puede tener información objetiva a la vez que se tiene la percepción del usuario).

Para profundizar al respecto, debe entenderse primero que la biometría es el campo de la ciencia que se encarga de establecer la identidad de un individuo a partir de sus atributos personales físicos, químicos o de comportamiento (Jain et al., 2007). Otra definición similar,

dicta que la biometría “se refiere a los métodos automatizados de reconocimiento de una persona, basados en sus características fisiológicas o de comportamiento” (Li, 2009).

En la Tabla 3 puede consultarse un concentrado de las tecnologías biométricas más comúnmente aplicadas a estudios de UX.

Tabla 3 Tecnologías biométricas más comunes aplicadas en UX (Elaboración propia, 2023).

Tecnología biométrica	Referencia
Electroencefalografía (EEG)	(Campisi & Rocca, 2014; Carrillo et al., 2015),
Eye Tracking (Seguimiento de mirada)	(Borgianni et al., 2018)
Respuesta Galvánica de la Piel (GSR, del inglés: Galvanic Skin Response) o actividad electro-dérmica.	(Andreassi, 2010; Bruun, 2018)
Reconocimiento Facial (Facial Coding / Recognition)	(Den Uyl & Van Kuilenburg, 2005; Pantic, 2014)
Electromiografía (EMG)	(Mandryk et al., 2006)
Presión de volumen sanguíneo (BVP, del inglés: Blood Volume Pressure)	(Yao et al., 2014)
Ritmo cardíaco	(Ali et al., 2012)

Como se mencionó anteriormente, la tendencia en estudios de UX está enfocada cada vez más en aplicar alguna (o varias) de estas tecnologías en conjunto con métodos más tradicionales para entender de manera más completa la UX. Por ejemplo, en el mundo de los videojuegos, es de suma importancia conocer la UX con mayor precisión, no solo para conocer la satisfacción del jugador, sino también la inmersión o emociones al jugarlo (Zaki et al., 2021).

Aunque se ha realizado una breve descripción de la biometría aplicada a la UX, es importante señalar que, para esta investigación, únicamente se abordarán dos de las principales, *Eye Tracking* y EEG, dado que cuentan con mayor aplicación, métricas y antecedentes, que permiten entender la UX con mayor profundidad.

Sin embargo, antes de proceder a los fundamentos teóricos de estas dos tecnologías, vale la pena señalar que precisamente entre las métricas más comunes tanto de EEG como de *Eye Tracking*, se encuentra el nivel de atención (por ejemplo, en el *Eye Tracking* se trata de atención visual). Por lo anterior, a continuación, se aborda brevemente esta métrica de importancia para comprender mejor la *UX*.

2.2.4 Evaluación de atención.

A diferencia de las demás tecnologías biométricas, el EEG y el *Eye Tracking* destacan por la gran cantidad de variables que pueden obtenerse a través de ellas. Si bien, en los siguientes puntos se abordarán con mayor profundidad las métricas de cada una de estas tecnologías, vale la pena señalar una de las más favorables que comparten (aunque con un análisis muy particular en cada caso), la atención.

Cada una lo hace de una manera diferente y se centran en “atenciones distintas”. Por ejemplo, mediante el *Eye Tracking* se puede medir la atención visual; esta puede obtenerse o derivarse del análisis de mapas de calor en Áreas de Interés (AOI, del inglés *Areas of Interest*) por tiempo o por cantidad de fijaciones en un elemento gráfico, etc. Mientras que, con el EEG, se puede conocer el nivel de atención durante una actividad en concreto a través del análisis de los diferentes ritmos cerebrales (algunas están relacionadas directamente con la atención, así pues, al realizar análisis matemáticos y aplicar ciertos algoritmos a estos ritmos, puede conocerse su intensidad o nivel).

Un análisis más detallado al respecto puede consultarse en las siguientes secciones al abordar *Eye Tracking* y EEG, así como en la sección anterior, Revisión Sistemática de la Literatura; donde puede apreciarse que muchos de los trabajos que combinan estas tecnologías lo hacen desde un enfoque basado en medición de atención.

Para destacar la importancia que tiene la medición de atención en el modelo de evaluación de experiencia de aprendizaje, es conveniente replicar la afirmación de (Goleman, 2013):

“Nuestra capacidad de atención determina nuestro desempeño al realizar la tarea”.

Se puede así declarar entonces que, a mejor atención, mejor desempeño, y, por tanto, si esto se combina con otros factores como un buen objeto de aprendizaje y la procuración de una

UX favorable, el aprendizaje puede ser óptimo. Cabe aclarar también que no necesariamente atención significa consolidación de aprendizaje, pero sí influye de manera significativa en él, por lo que se debe acotar que esta investigación se enfoca en la experiencia de aprendizaje y no en el aprendizaje per se.

En cuanto a las definiciones formales, la palabra “atención” proviene del latín *attendere*, que significa “ir hacia”, lo que de acuerdo con (Goleman, 2013), permite conectarse al mundo y delinear y definir nuestra experiencia. Nuevamente es interesante señalar que al igual que con las definiciones de aprendizaje, en esta sobre atención también se encuentra el término “experiencia”.

Otra definición, un tanto más informal dicta que la atención es “*la repentina toma de posesión por parte de la mente, en una forma clara y vívida, de uno de los aparentes objetos simultáneos del pensamiento*” (Schooler et al., 2011).

Con respecto a las categorías de atención, (Goleman, 2013) distingue dos:

- Atención selectiva: Permite dar un enfoque en un objeto e ignorar todo lo demás.
- Atención abierta: Permite incorporar información de alrededor, del interior y percatarse de señales sutiles.

Aunque evidentemente existen muchas otras dependiendo del autor o del campo de conocimiento, ambos tipos de atención tienen relación directa con el aprendizaje y existen muchas investigaciones de las ciencias cognitivas centradas en ello, pero están fuera del alcance de esta.

Retomando la asociación entre atención y aprendizaje, existe una relación positiva, es decir, cuando se tiene una atención enfocada, se aprende más; cuando se concentra en lo que se está aprendiendo, se forman nuevas conexiones neuronales que a la vez pueden permitir almacenar en memoria lo aprendido (Goleman, 2013). Por otro lado, mantener una atención enfocada es complicado, pues constantemente se experimentan distracciones. Cuanto más se perturba la atención, más ineficaz puede ser la respuesta, por ejemplo, en un examen (existe una correlación directa entre el desempeño de atletas universitarios y tendencia a desenfocar la atención debido a la ansiedad (Smith et al., 1990).

Comúnmente las distracciones se presentan también al leer, pues según (Smallwood et al., 2007), un lector suele distraerse entre un 20 - 40% del tiempo que recorre un texto, por ende, un estudiante distraído suele aprender poco. Para evitar lo anterior, al leer se requiere concentración sostenida e inmersión, lo que (Carr, 2011) denomina “*lectura profunda*”.

La atención es por tanto un indicador clave en lo que respecta a la medición de *UX*. Si bien no está relacionada en las definiciones tradicionales, es inherente a ella. Así pues, con un objeto de aprendizaje de óptima calidad, en un ambiente favorable y con las herramientas adecuadas, un buen nivel de atención del estudiante puede significar generar una experiencia de aprendizaje positiva.

Después de un breve recorrido por la importancia de la evaluación de atención para el modelo de experiencia de aprendizaje, en las siguientes secciones se abordarán las tecnologías biométricas empleadas en el modelo, comenzando por *Eye Tracking*.

2.3 EYE TRACKING.

El *Eye Tracking* (también conocido en menor medida como *Gaze Monitoring*) es aplicado en muchas ciencias y áreas del conocimiento como la psicología, la medicina, el marketing o las ciencias de la computación. Su traducción directa al español es “Seguimiento ocular” aunque también suele emplearse “Seguimiento de mirada” (aunque para este caso, es más correcto señalar “*Gaze tracking*”). De acuerdo con (Duchowski, 2017), la importancia del *Eye Tracking* radica en que a través de dicha técnica se puede seguir la atención visual de una persona. Esto por sí solo implica conocer más variables asociadas a ello, como la “ruta” o “camino” visual para llegar a un determinado punto, la fijación o la cantidad de veces que se observa dicho punto, y más importante aún, por qué en específico ese punto. Es por ello por lo que el *Eye tracking* es una herramienta sumamente utilizada en campos como la investigación en *UX*, pues permite conocer información objetiva del comportamiento visual de un usuario.

Sin entrar en detalles fisiológicos más profundos sobre el sistema de visión humano o las propiedades biológicas de la visión y el ojo, el *Eye Tracking* se fundamenta principalmente en el análisis de dos tipos de movimientos oculares a partir de los cuales se deriva todo el potencial de esta herramienta, los movimientos sacádicos (o sacadas) y las fijaciones.

2.3.1 Movimientos sacádicos.

De acuerdo con (Duchowski, 2017), los movimientos sacádicos (o sacadas), son movimientos oculares (voluntarios y/o reflexivos) rápidos (entre 10 - 100 ms) que se efectúan para reposicionar la fovea en un nuevo lugar del entorno visual. La fovea es una depresión en el centro de la mácula, la cual a su vez es una pequeña zona central de la retina que permite ver los objetos con claridad (American Academy of Ophthalmology, 2023).

2.3.2 Fijaciones.

Se trata de movimientos oculares para estabilizar la retina sobre un objeto estacionario de interés. Están caracterizados a su vez de muy pequeños movimientos oculares para mantener la fijación, tremor, deriva y microsacadas (Duchowski, 2017).

2.3.3 Otros movimientos oculares.

Existen también otros movimientos oculares, que, aunque no tienen probablemente la misma relevancia en cuanto a *Eye Tracking* se refiere, es importante conocerlos. Se trata de los movimientos de persecución o búsqueda (en inglés, *pursuit movements*), los cuales se dan cuando se sigue visualmente un objeto en movimiento (Duchowski, 2017); y los nistagmos, movimientos oculares rápidos e incontrolados (Boyd & DeAngelis, 2022).

La importancia de revisar los tipos de movimientos oculares radica en que a partir de ellos pueden obtenerse las diferentes métricas y variables que distinguen a las aplicaciones del *Eye Tracking*. Es por ello por lo que, a continuación, se presentan algunas de las métricas más importantes reportadas en la literatura.

2.3.4 Métricas de Eye Tracking.

El *Eye Tracking* suele aplicarse en experimentos muy diversos y, por ende, dependiendo del tipo de estudio, se pueden analizar ciertas variables de interés por encima de otras. Debido a lo anterior, varios autores han revisado y conjuntado una serie de métricas propuestas en la literatura científica (algunas de ellas relacionadas con la atención), que pueden explorarse con *Eye Tracking*. (Poole & Ball, 2006) destacan las que a continuación se enlistan:

- **Número total de fijaciones:** Un mayor número de fijaciones indica una menor eficiencia de la búsqueda, lo que puede indicar un problema en el *layout* (esquema organizativo) de la interfaz.
- **Número de fijaciones sobre un área de interés:** Mayor número de fijaciones indica mayor importancia para el usuario.
- **Duración de la mirada fija sobre un área de interés:** Mayor duración indica mayor dificultad para interpretar el contenido del área.
- **Densidad espacial de las fijaciones:** Cuando las fijaciones se concentran en una zona más pequeña indica mayor eficiencia en la búsqueda visual, mientras que si son más dispersas sugieren que la búsqueda está resultando menos eficiente.
- **Tiempo transcurrido hasta la primera fijación:** Cuanto menos tiempo transcurra hasta que el usuario se fije por primera vez en un área de interés, mayor será la capacidad de las propiedades gráficas del área para atraer la atención visual.

Por otro lado, un enfoque muy interesante basado en las métricas de *Eye Tracking* en Ingeniería de Software sugiere que estas pueden clasificarse en función del esfuerzo visual (Sharafi et al., 2015), las cuales se muestran en la Tabla 4:

Tabla 4 Clasificación de métricas en función del esfuerzo visual, con base en (Sharafi et al., 2015)

Tipo de métrica	Métricas
Basadas en número de fijaciones	Conteo de fijaciones (FC, del inglés, <i>Fixation Count</i>)
	Tasa de fijaciones (FR, del inglés, <i>Fixation Rate</i>)
	Densidad de Fijación Espacial (SD, del inglés, <i>Spatial Density</i>)
	Casco convexo (del inglés <i>Convex Hull</i>)
Basadas en la duración de las fijaciones	Duración promedio de la fijación (AFD, del inglés, <i>Average Fixation Duration</i>)
	Relación entre el tiempo de fijación en el objetivo y en todos los objetivos (ROAFT, del inglés <i>Ratio of ON-target:All-target Fixation Time</i>)
	Tiempo de fijación (FT, del inglés, <i>Fixation Time</i>)

	Duración Promedio de Fijaciones Relevantes (ADRF, del inglés, <i>Average Duration of Relevant Fixations</i>)
	Tasa Normalizada de Fijaciones Relevantes (NRRF, del inglés, <i>Normalised Rate of Relevant Fixations</i>)
Basadas en sacadas	Número de sacadas
	Duración de sacada
	Tasa de regresión
Basadas en rutas de exploración visual (<i>scanpaths</i>)	Frecuencia de cambio de atención
	Matriz transicional
	Edición de distancia
	Minería de patrones secuenciales (SPAM, del inglés, <i>Sequential Pattern Mining</i>)
	<i>Scanmatch</i>
	Linearidad
Basadas en Tamaño de pupila y tasa de parpadeo	Tamaño de pupila
	Tasa de parpadeo

Cabe aclarar que las métricas de la Tabla 4 están enfocadas en un análisis de elementos de Ingeniería de Software (por ejemplo, segmentos de código, diagramas UML, etc.). Sin embargo, muchas de ellas pueden adaptarse o bien tomarse directamente para aplicarlas en otro contexto (por ejemplo, para el análisis visual de un objeto de aprendizaje). En lo que respecta a variables y métricas fuera de la atención visual, con el *Eye Tracking* se pueden identificar (Tobii LatAm, 2021b):

- Compromiso o Empeño
- Visibilidad (De un producto o elemento)
- Encontrabilidad (de un producto o elemento)
- Impulsividad de compra (aplicada en *marketing*).

2.4.5 Sistemas de adquisición para *Eye Tracking*

Ahora bien, en lo que respecta a los sistemas de adquisición, existen tres maneras convencionales de realizar el seguimiento ocular, estas son utilizando:

- Lentes (Fig. 10)
- Cámara Web (Fig 11)
- *Eye tracker* fijo profesional. (Fig 12)



Fig. 10 Tobii Pro Glasses 3 (iMotions, 2021)



Fig. 11 Captura de "*Webcam eye tracker implementation video*" (E. Dalmaijer, 2015b).



Fig. 12 Tobii Pro Nano (Tobii LatAm, 2021a).

Este *eye tracker* fijo se adhiere a la pantalla de una computadora de escritorio o laptop.

De las tres opciones antes mencionadas, los lentes y el *eye tracker* fijo son las que cuentan con una mejor precisión y definición en cuanto a imagen y desempeño, sin embargo, la opción del *eye tracker* con cámara web puede implementarse con costos muy bajos o incluso de manera gratuita con software *open-source*.

2.4.6 Software para *Eye Tracking*

En cuanto al software se refiere, existen alternativas de todo tipo, desde herramientas con una gran capacidad de análisis y soporte (las cuales suelen tener precios relativamente altos) y opciones gratuitas y *open-source* que utilizan la cámara web como *eye tracker*; entre las que destacan *PyGaze*, *toolbox* que permite implementar experimentos de *Eye Tracking* basados en Python (E. S. Dalmaijer et al., 2014), y *WebGazer.js* para implementaciones con JavaScript (Brown HCI Group, 2016).

Por lo anterior, y gracias a las facilidades de manejo, implementación y su relevancia como una técnica biométrica, el *Eye Tracking* es una de las herramientas principales en las que se basa el modelo de evaluación de experiencia de aprendizaje.

2.4 EEG

La electroencefalografía (EEG) es una técnica de exploración del comportamiento del cerebro mediante el registro de las ondas cerebrales. A un nivel fisiológico más profundo, se trata del “registro de las corrientes eléctricas derivadas de los cuerpos celulares y las dendritas de la corteza cerebral mediante electrodos colocados en el cuero cabelludo” (Fox, 2011). El primer EEG fue realizado por primera vez por el psiquiatra alemán Hans Berger el 6 de julio de 1924 en un joven de 17 años que estaba siendo sometido a una neurocirugía (Ínce et al., 2021). Si bien, en una primera instancia se trató de un método de exploración enfocado a la medicina y la psicología, en realidad desde hace años se puede aplicar también para estudios de *marketing* o evaluación de *UX* (véase sección **1. Revisión Sistemática de la Literatura (RSL)**).

2.4.1 Ritmos cerebrales

Las ondas cerebrales pueden clasificarse por sus bandas de frecuencia (también llamados ritmos) y tienen características en particular, como se muestra en la Tabla 5.

Tabla 5 Características principales de las ondas cerebrales (Elaboración del autor).

Ritmo cerebral	Rango de Frecuencia	Características
Delta (δ)	1 – 5 Hz (Fox, 2011)	Comunes al dormir (Fox, 2011).
Theta (θ)	5 – 8 Hz (Fox, 2011)	Comunes al dormir. Cuando se está despierto pueden relacionarse con estrés emocional intenso (Fox, 2011)
Alpha (α)	8 – 13 Hz (Barrett, 2013; Jain et al., 2018)	Ritmo en reposo, despierto, pero con los ojos cerrados, relacionado con niveles bajos de atención. (Barrett, 2013), relajación, atención abierta (Goleman, 2013). Nota: Estos ritmos también son conocidos como ondas de Berger (en honor al inventor del EEG) (Ínce et al., 2021).
Beta (β)	13 – 30 Hz (Barrett, 2013; Jain et al., 2018)	Relacionado con concentración mental (Barrett, 2013)
Gamma (γ)	30 – 80 Hz (Barrett, 2013)	Relacionado con el estado de alerta y el enfoque de atención (Barrett, 2013), procesos creativos (Goleman, 2013).

Cabe señalar que todos los ritmos están presentes en todo momento y en cualquier parte del cuero cabelludo (con mayor concentración en algunas zonas), la diferencia radica en la sincronización de estas ondas (o bien el aumento pronunciado y dominante) al realizar ciertas tareas o encontrarse en estados específicos, por ejemplo, al dormir, estar alerta, resolver algún ejercicio matemático, etc.

Una representación de las ondas cerebrales separadas por ritmos se puede observar en la Fig. 13. En ella se incluyen de izquierda a derecha y de arriba abajo: Señal Cruda (o *Raw*, es decir

la que se obtiene directamente al realizar un registro sin dividir la señal por frecuencias, ni realizar ningún procesamiento), ritmo Gamma, ritmo Delta, ritmo Theta, ritmo Beta y ritmo Alpha. Las ondas presentadas en esta figura corresponden a un registro EEG real de las señales del autor, realizado con OpenViBE y un *headset* MindWave Mobile.




Fig. 13 Registro EEG real de las ondas separadas por ritmos (Elaboración propia, 2023).

2.4.2 Sistemas de adquisición para EEG

Dado que el EEG puede aplicarse en diversas áreas, el sistema de adquisición varía en función del enfoque. Por ejemplo, para un registro clínico, se utiliza un electroencefalógrafo clínico, para el cual existen gran cantidad de marcas comerciales. Por otro lado, para realizar un registro de investigación fisiológica, suele utilizarse un sistema de adquisición Biopac (que también se emplea para otra gran diversidad de estudios de fisiología, no solo EEG). Sin embargo, en lo que compete a la investigación en *UX* (y también en marketing) se puede hacer uso de *headsets* o diademas más sencillos y económicos que permiten también una buena adquisición, tratamiento y análisis de las señales EEG.

Independientemente del sistema que se esté utilizando, todos siguen un estándar en cuanto a los puntos de registro, es decir, el lugar del cuero cabelludo en donde se colocan los electrodos de adquisición. Este estándar es conocido como sistema 10 – 20 y fue diseñado en

1958 por la *International Federation in Electroencephalography and Clinical Neurophysiology* (Federación Internacional en Electroencefalografía y Neurofisiología Clínica) bajo la continua revisión de la *American Electroencephalographic Society* (Sociedad Americana de Electroencefalografía).

El sistema consta de 75 puntos de colocación para los electrodos, y aunque evidentemente se pueden realizar registros sin la necesidad de cubrir todos los puntos de colocación, todos los sistemas de adquisición siguen este estándar, es decir, aunque se tengan menos electrodos, estos corresponden con alguno de los puntos del sistema 10 – 20. El sistema 10 – 20 puede observarse en la Fig. 14.

Entre los sistemas comerciales (y populares) de adquisición de señales de EEG comerciales se encuentran la Mindwave Mobile 2 (Fig. 15, mismo modelo que el utilizado en esta investigación), que cuenta con un electrodo en la posición FP1 del sistema 10 – 20, este sistema permite adquirir “en seco” las señales EEG (NeuroSky, 2021); o la EMOTIV EPOC X (Fig. 16), que cuenta con 14 canales de adquisición, basada también en el sistema 10 – 20 y sí necesita de gel conductor para la adquisición de las señales EEG (EMOTIV, 2021).

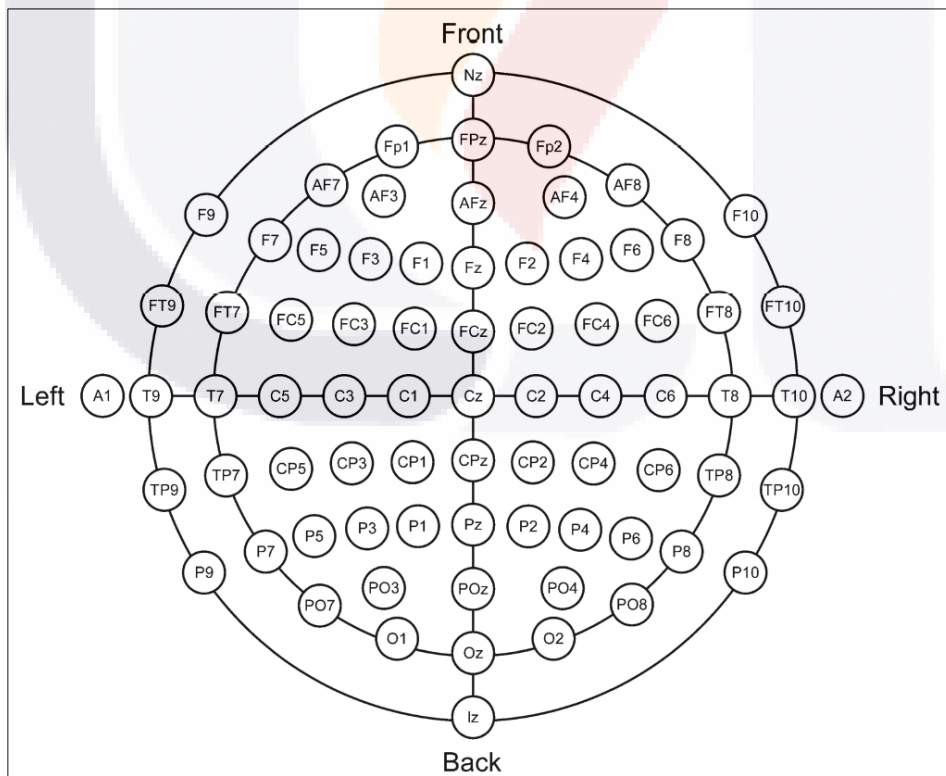


Fig. 14 Sistema de colocación de electrodos 10 – 20 (Hu & Zhang, 2019)



Fig. 15 Mindwave Mobile 2 Headset de NeuroSky (NeuroSky, 2021).




Fig. 16 EMOTIV EPOC X (EMOTIV, 2021).

2.4.3 Métricas de EEG

Ahora bien, en cuanto a métricas, varían dependiendo del sistema de adquisición y sobre todo del procesamiento que pueda darse a las señales. De acuerdo con (Tobii LatAm, 2021b), mediante el EEG se puede medir:

- Atención
- Compromiso emocional
- Valencia afectiva o memorización

Estas mediciones se obtienen en función del análisis de los ritmos antes mencionados, pues como se señaló, estos se relacionan con actividades o estados concretos. Es común que varios de los *headsets* entreguen niveles de atención o meditación directamente sin procesamiento o programación por parte del experimentador, pues se obtienen a través de algoritmos preprogramados. Este es el caso por ejemplo de los *headsets* mostrados en las Figuras 15 y 16. Por otra parte, algunos estudios calculan estos niveles a través de la relación distintas bandas de frecuencia, como es el caso de (N.-H. Liu et al., 2013) quienes calculan la atención como la relación de las energías de las señales Alpha entre Beta.

2.4.5 Software para EEG

Si bien se requiere software especializado para la adquisición, ya sea de fabricante u *open source*, la gran ventaja de trabajar con EEG es que se trabaja básicamente con señales, aunque en este caso son señales electrofisiológicas. Por ende, para el procesamiento puede utilizarse software científico más general (como Matlab) o incluso lenguajes de programación de propósito general con librerías especializadas en EEG, como es el caso de eeglib para Python (Cabañero, 2021).

Un ejemplo de software *open source* que cuenta con soporte para varios sistemas de adquisición comerciales es OpenViBE, enfocado en diseño, procesamiento y pruebas sobre sistemas de Interacción Cerebro – Computadora (BCI, del inglés, *Brain Computer Interfaces*) (OpenViBE, 2015). Por otro lado, para realizar análisis más profundos a través de Matlab, existe EEGLab, un *toolbox* diseñado para procesamientos más robustos con EEG (SCCN, 2021).

Una vez que se han revisado los puntos más relevantes sobre esta tecnología, así como de *Eye Tracking*, es importante pasar al último apartado de los Fundamentos Teóricos. Se trata de la Ciencia de Datos (conocida también popularmente por su nombre en inglés, *Data Science*), el elemento clave que permite validar el modelo de evaluación de experiencia de aprendizaje.

2.5 CIENCIA DE DATOS

En esta subsección, se aborda brevemente la relevancia y algunos conceptos clave de la Ciencia de Datos y su relación con algunas otras áreas de las que se apoya o bien forman parte de ella.

La Ciencia de Datos puede definirse de varias maneras más o menos estrictas o cerradas y depende de la perspectiva desde la cual se aborde. Para (Igual & Seguí, 2017), La ciencia de Datos se puede definir como:

“Una metodología por la cual se pueden definir ideas prácticas a partir de los datos”.

Así pues, al tomar la definición anterior, se puede entender que la Ciencia de Datos es un híbrido que combina grandes campos científicos para obtener información útil a través del procesamiento de datos (que pueden provenir de una o varias fuentes).

2.5.1 Disciplinas que conforman a la Ciencia de Datos

Con diagramas de Venn (Conway, 2015) explica que la Ciencia de Datos es la intersección de los conjuntos que se muestran en la Fig. 17 (aunque la definición es un tanto informal). Se resalta que entiende la Ciencia de Datos como la composición de varias áreas, en este caso específico, conocimiento de matemáticas y estadística, conocimiento (o experiencia) especializado, y habilidades de *hacking* (entiéndase en este contexto como habilidades informáticas o de programación).

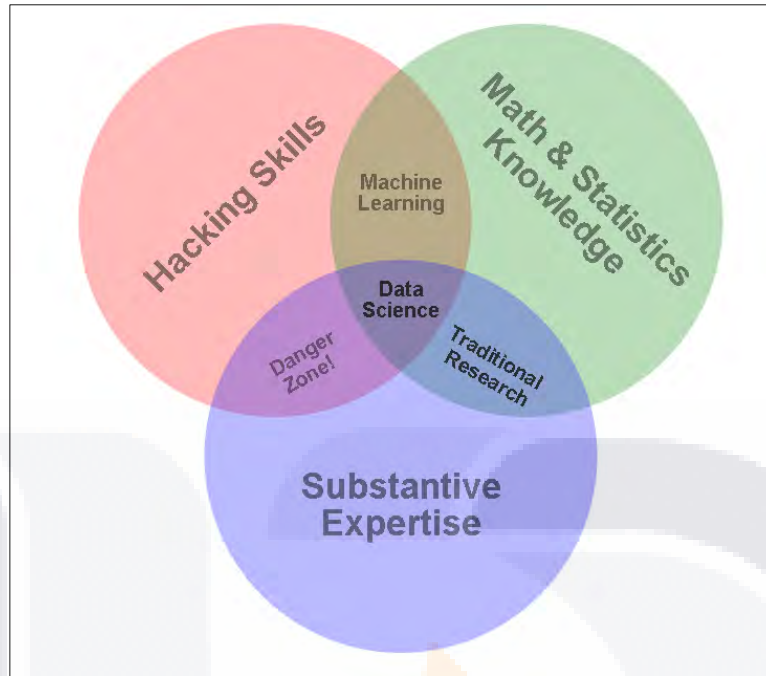


Fig. 17 Diagrama de Venn de la Ciencia de Datos (Conway, 2015)

Otra definición más completa de (L. Aggarwal, 2022), dicta que la Ciencia de Datos es el campo de estudio sobre la extracción de conocimiento e información a partir de datos imprecisos (o irregulares); y que convierte esa información en acciones que pueden ser llevadas a cabo por un negocio u organización. Además, también entiende a la Ciencia de Datos como la intersección de tres áreas primordiales: Ciencias de la Computación, Matemáticas y Experiencia Empresarial (Fig. 18).



Fig. 18 Diagrama de Venn de la Ciencia de Datos, basado en (L. Aggarwal, 2022).

Ambos diagramas, el de (Conway, 2015) y el de (L. Aggarwal, 2022) guardan muchas similitudes, aunque el segundo es más formal.

2.5.2 Perspectivas y tipos de Ciencia de Datos

Profundizando un poco más sobre sus aplicaciones, de acuerdo con (Igual & Seguí, 2017), la Ciencia de Datos permite explorar el mundo (a partir de los datos) desde cuatro estrategias distintas:

- Probar la realidad
- Descubrir patrones
- Predecir eventos futuros
- Entender a las personas y el mundo

Así pues, no es de sorprender que la Ciencia de Datos tenga miles de aplicaciones, las cuales varían según el tipo de análisis de datos que se requiera. Para (L. Aggarwal, 2022), existen cuatro tipos de análisis distintos, los cuales dependen de su complejidad y valor, y en orden ascendente son:

- Descriptivo (¿Qué pasa en el negocio/organización?)
- Diagnóstico (¿Por qué pasa?)
- Predictivo (¿Qué podría pasar después?)
- Prescriptivo (¿Qué se puede hacer para mejorar?)

A primera vista podría parecer que la Ciencia de Datos está únicamente enfocada al ámbito empresarial o de los negocios, pero realmente puede aplicarse en cualquier organización o área, independientemente de la rama que sea.

2.5.3 Áreas relacionadas

Como ya se corroboró en ambos diagramas de Venn, la Ciencia de Datos es la combinación de varias disciplinas. Además de las ya mencionadas como matemáticas o ciencias de la computación, existen otras áreas que, o bien derivan de la Ciencia de Datos (como una especialización), o tienen una relación muy estrecha. Ejemplos de lo anterior son:

- *Machine Learning* (Aprendizaje Automático)
- *Deep Learning* (Aprendizaje Profundo)

- Ingeniería de Datos
- Análisis de datos
- Minería de Datos
- *Bussines Intelligence* (Inteligencia de Negocios)
- *Big Data*

La definición exacta de si estas áreas son parte de la Ciencia de Datos o áreas aparte es debatible, pues existen muchos autores que discrepan al respecto. Por ejemplo, para (L. Aggarwal, 2022), la Minería de Datos y el *Machine Learning* son parte del ciclo de vida de la Ciencia de Datos; mientras que para (Skiena, 2017) el *Machine Learning* deriva de las Ciencias de la Computación, y para (C. Aggarwal, 2015), la Minería de Datos es una campo aparte. Lo mismo sucede con las demás áreas relacionadas de acuerdo con el autor al que se consulte.

2.5.4 Software y aplicaciones para Ciencia de Datos.

Existen una gran cantidad de opciones para realizar tareas relacionadas con Ciencia de Datos. R y Python destacan como los lenguajes de programación con mayor cantidad de recursos, librerías, módulos, APIs, y herramientas etc. para implementar técnicas estadísticas, de *Machine Learning* o de procesamiento en general.

En cuanto a R, es un lenguaje de programación de cómputo estadístico (The R Foundation, 2023), mientras que Python es un lenguaje de programación de alto nivel de propósito general con aplicaciones muy variadas (Hunt, 2019) con librerías enfocadas en manipulación de datos y *Machine Learning* muy eficientes y de fácil uso.

Ambos son gratuitos, *open source* y cuentan con IDEs muy buenos para realizar Ciencia de Datos. En el caso de R, destaca R Studio, mientras que para Python se tienen diversas opciones como Spyder (IDE especializado en *Machine Learning*) u opciones web como Google Colab, Kaggle Notebooks o Jupyter.

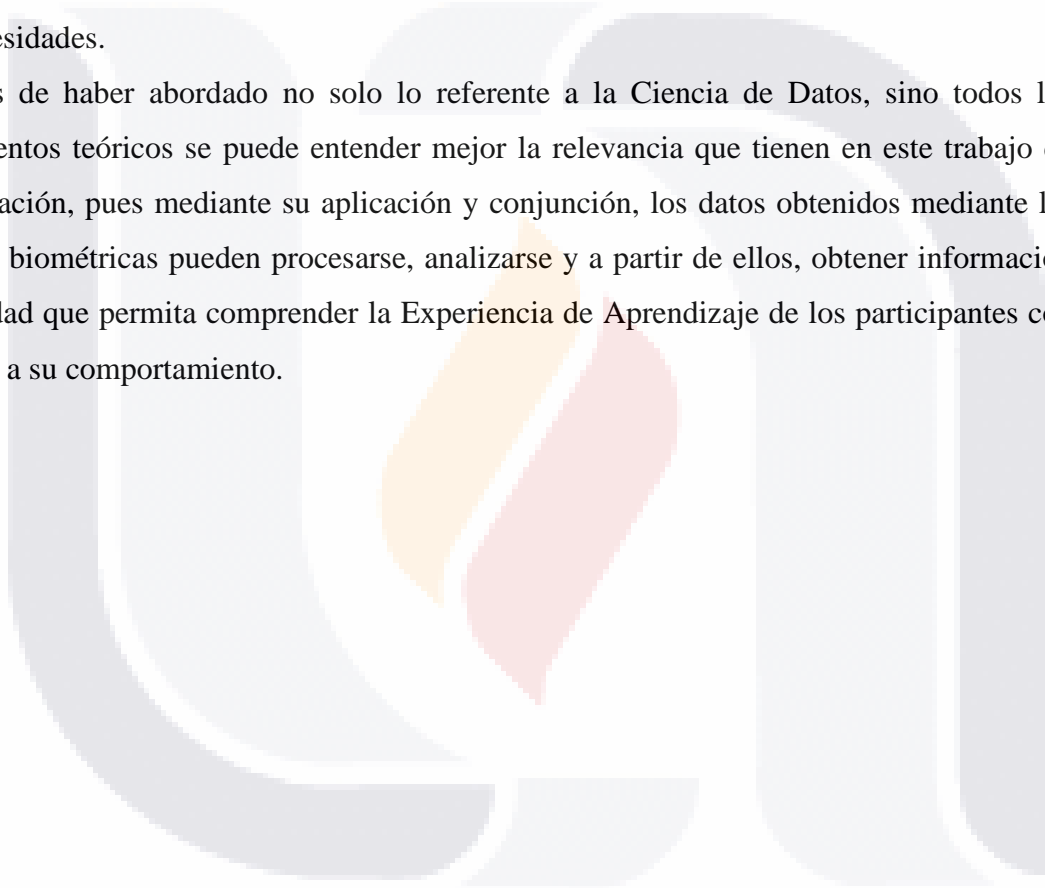
Además, existen también aplicaciones en las que no es necesario programar (en algunas es opcional) para realizar análisis de datos o entrenar modelos de *Machine Learning*. Entre los más populares se encuentran:

- Microsoft Power BI (permite programación en DAX)

- Microsoft Excel (tiene herramientas de análisis de datos básicos)
- Matlab (Aunque se programa, también cuenta con varios *toolboxes*)
- Tableau
- Weka
- Orange

Entre muchos otros que surgen continuamente, ya sean de pago o de uso gratuito, por lo que puede utilizarse la herramienta o recurso de preferencia del científico de datos o bien, según sus necesidades.

Después de haber abordado no solo lo referente a la Ciencia de Datos, sino todos los fundamentos teóricos se puede entender mejor la relevancia que tienen en este trabajo de investigación, pues mediante su aplicación y conjunción, los datos obtenidos mediante las técnicas biométricas pueden procesarse, analizarse y a partir de ellos, obtener información de utilidad que permita comprender la Experiencia de Aprendizaje de los participantes con relación a su comportamiento.



CAPÍTULO III. Metodología de Investigación

El desarrollo de una investigación consta de varias fases. En este caso en particular en el que se busca crear un modelo a partir de la combinación de distintas tecnologías, es necesario que cada elemento del modelo este constituido y estructurado con bases sólidas. Gracias a los resultados obtenidos en la RSL se han consultado los principales trabajos relacionados con la UX en conjunto con *Eye Tracking* y EEG aplicados en el aprendizaje que pueden servir como guía para la creación del modelo. Además, después de un recorrido por los Fundamentos Teóricos, se conoce la relevancia de cada uno de los temas involucrados.

Por tanto, ahora se puede desarrollar y profundizar en la metodología de investigación, la cual puede considerarse la columna vertebral del presente proyecto, y cuyas fases se encuentran representada en la Fig. 19 a manera de diagrama de flujo.

Aunque cada una de las fases representadas en el diagrama de flujo será abordada a fondo en cada subsección dentro de este capítulo, a continuación, se explicará brevemente en qué consistió cada una de ellas.

La sección sobre diseño experimental y casos de estudio explica por qué la estrategia empleada es la indicada para realizar la experimentación principal y cómo los casos de estudios sirvieron para conocer poco a poco las herramientas y técnicas que se utilizaron a lo largo de la investigación. Con respecto a la generación del marco conceptual del experimento principal, en esta sección se presentan los hallazgos de los casos de estudio, la propuesta inicial de modelo de evaluación de experiencia de aprendizaje (en adelante también se referirá a este como *framework*), y su relación con la hipótesis.

En seguida se presenta la sección sobre los procedimientos específicos donde se expone la definición de la población y muestra, se describe la tecnología utilizada, la recopilación de datos y las medidas de control. Después, se presentará la sección sobre instrumentos y medidas, donde se describirán, por ejemplo, las variables provenientes de EEG y *Eye Tracking*. Posteriormente, se describirá la sección sobre consideraciones éticas, relativa a la confidencialidad de los datos y la carta de consentimiento informado.

Las últimas secciones corresponden a todo el trabajo correspondientes a Ciencia de Datos, partiendo del Análisis de Datos, (incluyendo en este punto el preprocesamiento de datos y la aplicación de algoritmos de *Machine Learning*), seguido de la sección sobre validación de

modelos y métricas (en ella se analiza el F1-Score, por ejemplo) y finalmente la interpretación de los resultados de *Machine Learning*.

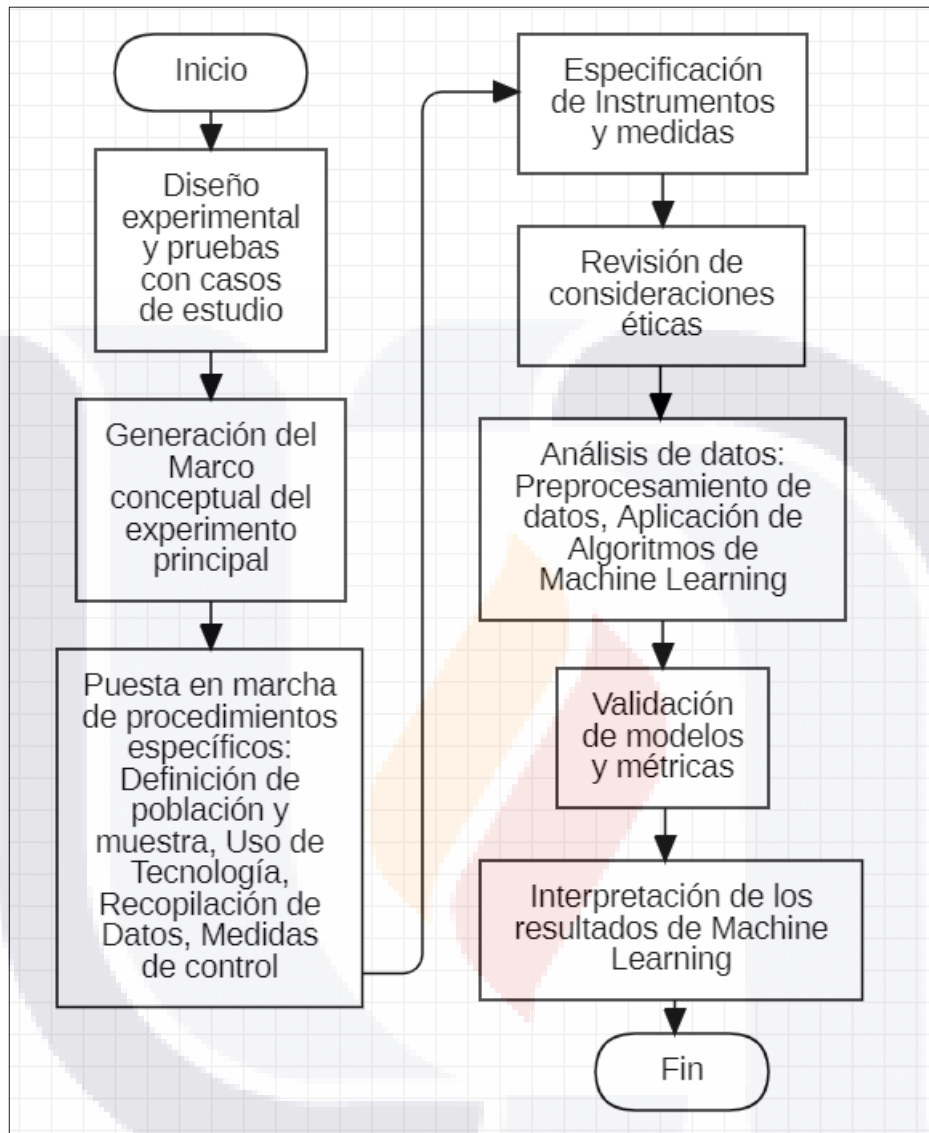


Fig. 19 Metodología de investigación representada como diagrama de flujo (Elaboración propia, 2024).

1. DISEÑO EXPERIMENTAL Y CASOS DE ESTUDIO

Llevar a cabo una investigación científica conlleva pasos rigurosos que hay que seguir para tratar de responder a las preguntas de investigación, y por ende alcanzar los objetivos planteados. En el caso de la presente investigación, el diseño experimental puede considerarse dividido en dos bloques principales. El primero corresponde a todos los casos de estudio en

las que se participó como supervisor de investigaciones de estudiantes de pregrado; mientras que el segundo corresponde a la experimentación principal, la cual se describirá con mayor detalle en las secciones subsecuentes.

Dado que se desarrolla un *framework* basado en diversos elementos, es bueno generar n número de experimentaciones previas para poder probar las tecnologías, herramientas, metodologías y enfoques para que a la postre, faciliten la implementación de la experimentación principal. Así pues, los casos de estudio corresponden a investigaciones más cortas derivadas del asesoramiento y / o dirección de trabajos de tesina o programas de investigación de alumnos de pregrado. Estas sirvieron para probar tecnología en contextos específicos, por ejemplo, ciertos algoritmos de *Machine Learning*, o bien para tener un primer contacto con software especializado de EEG o *Eye Tracking*.

Cada uno de los trabajos desarrollados en conjunto con los alumnos de pregrado está orientado a una situación, contexto y objetivos diferentes y particulares, no necesariamente orientados a la aplicación de las tecnologías biométricas en *UX*, sino en diversas áreas, como se verá a continuación. Es importante pues, señalar que el objetivo primordial de estos trabajos es considerar diferentes escenarios de experimentación, herramientas y además aportar a la formación de capital humano como uno de los requisitos deseables en el Doctorado en Ciencias Aplicadas y Tecnologías.

Así pues, en las siguientes subsecciones se describirán de manera general cada uno de los trabajos de investigación orientados a estas tecnologías biométricas. Cabe aclarar por supuesto que el crédito del desarrollo general de cada uno de estos proyectos es de los alumnos de pregrado, mientras que el trabajo propio se orientó a la asesoría, supervisión y dirección de estos trabajos de investigación desde el inicio hasta su culminación y presentación final (varios de ellos sirvieron como trabajo de titulación y/o para mención honorífica).

A manera de breve descripción, se presenta el diagrama de la Fig. 20, en el cual se engloba la estructura general que siguió cada uno de estos experimentos (independientemente de su objetivo principal).

Como puede observarse, todos los casos de estudio comenzaron con la revisión de marco teórico concerniente a cada tema. En general se compartían conceptos sobre EEG, *Eye Tracking* y *Machine Learning*, pero se diferenciaban en su aplicación, por ejemplo, orientado

a SVI, TDAH, Carga Cognitiva, perfiles STEM, clasificación de emociones, etc. (consúltese cada experimento para mayor detalle). Posteriormente, se realizaba la revisión de antecedentes y estado del arte para conocer estudios similares que sirvieran de guía, y se revisaban aspectos técnicos sobre la tecnología a trabajar (por ejemplo, revisión de software en específico, hardware necesario, etc.). En adelante, en cada caso de estudio se planteó un protocolo de experimentación (puede consultarse la Tabla 6 para una síntesis de los datos generales al respecto ¹); se realizaron pruebas piloto y n número de pruebas experimentales (con base en la muestra estadística establecida en cada caso); y los resultados fueron analizados en su mayoría empleando técnicas de Ciencia de Datos. Finalmente, se generaron discusiones, conclusiones y se publicaron los hallazgos obtenidos en artículos científicos (para la mayoría de los casos).

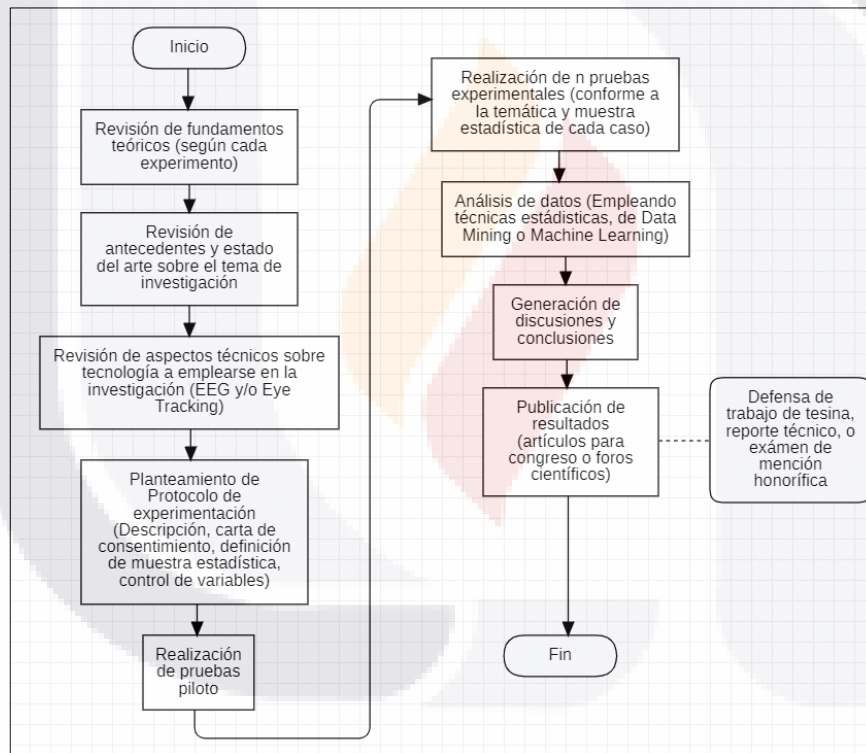


Fig. 20 Metodología general de investigación de los casos de estudio / experimentos iniciales representada como diagrama de flujo (Elaboración propia, 2023).

¹ Todos los experimentos de cada caso de estudio se desarrollaron en el Laboratorio de Industria de Software del Edificio 204 del Centro de Ciencias Básicas de la Universidad Autónoma de Aguascalientes.

Tabla 6 Breve descripción de los casos de estudio (Elaboración propia, 2023).

Experimento	Desarrollado por	Duración promedio del experimento	Muestra estadística	Resultados publicados
Eye Tracking para el estudio de la carga cognitiva y su relación con el desempeño académico enfocado al área de matemáticas.	Ing. Ángel Eduardo Villegas Ortíz. (ISC).	10 minutos.	10 participantes.	Sí, en Conf-IRM 2022.
Eye tracking para la detección de patrones de TDAH en niños de entre 6 y 8 años.	Ing. María Isabel Cordero Zúñiga (ICI).	7 – 9 minutos.	15 participantes.	Sí, en CONTIE 2022.
Eye tracking para la detección de vista cansada y disminución del Síndrome Visual Informático.	Ing. Sergio Adal Ruíz Campos (ICI).	10 minutos.	20 participantes.	Sí, en CONTIE 2022.
Algoritmos de Machine Learning en Neuromarketing.	Ing. Jessica de Luna García.	3 minutos.	13 participantes.	Sí, en CNCIIC 2022.
Aplicación de técnicas de Eye tracking y EEG en la generación de un modelo de predicción de orientación vocacional.	Alumnos de “Verano Delfín” de Investigación Científica, provenientes de: UdG, IPN, TecNM y Universidad de Pamplona (Colombia)	17 minutos.	34 participantes.	No. Pero una extensión de la investigación fue aceptada en EDULEARN 2024.
Procesamiento de Ondas cerebrales para la identificación de emociones.	Ing. Giancarlo Ramírez Díaz de León	4 minutos	36 participantes	No, solo para titulación.
Propuesta inicial de un modelo predictivo para la detección temprana de tendencias depresivas.	Ing. Cristian Pinto Méndez	10 minutos	20 participantes	No, solo para titulación.

1.1 EXPERIMENTO A: “*EYE TRACKING* PARA EL ESTUDIO DE LA CARGA COGNITIVA Y SU RELACIÓN CON EL DESEMPEÑO ACADÉMICO ENFOCADO AL ÁREA DE MATEMÁTICAS”

Descripción.

Este trabajo fue derivado del proyecto de investigación del Ing. Ángel Eduardo Villegas Ortíz, egresado de Ing. En Sistemas Computacionales de la Universidad Autónoma de Aguascalientes. Está orientado a la implementación de un sistema de escritorio desarrollado en Java para medir la carga cognitiva en un problema de matemáticas básicas de alumnos de ingenierías en la UAA, mediante la aplicación de *Eye Tracking*. Además, en cuanto al sistema se refiere, está fuertemente orientado al desarrollo siguiendo la metodología en espiral y con un enfoque completo desde la Ingeniería de Software.

Con el sistema (apoyado por *Eye Tracking*) se exploraron los diferentes efectos que tiene la disposición en la que es planteado un problema matemático en la atención visual y carga cognitiva de un usuario y cómo estos pueden afectar sus resultados al resolver el problema. Lo anterior con la finalidad de encontrar un modelo óptimo que permita al estudiante responder de mejor manera.

Método.

La investigación consistió en las siguientes fases:

1. Búsqueda de antecedentes y descripción del estado del arte del área en cuestión (carga cognitiva y atención visual en ejercicios académicos de matemáticas).
2. Implementación de un modelo en espiral para el desarrollo de las diferentes versiones del sistema, llamado SAPE (Sistema de Apoyo para Pruebas Experimentales) por el estudiante. Consistió en la definición de requerimientos, planteamiento de los distintos diagramas (de flujo, de clases, de navegación, etc.), pruebas de usabilidad y desarrollo de nuevas iteraciones del sistema. El lenguaje utilizado fue Java.
3. Pruebas piloto de *Eye Tracking*, utilizando un Tobii Pro Nano como dispositivo de adquisición de precisión y el software Tobii Pro Lab para la implementación de las pruebas y generación de datos.

4. Pruebas reales de experimentación conjuntando el Tobii Pro Nano, Tobii Pro Lab y SAPE para la medición de carga cognitiva y atención visual con la aplicación del ejercicio de matemáticas.
5. Análisis de los datos generados a partir de los mapas de calor y otras métricas de *Eye Tracking* para determinar la mejor distribución de elementos en el ejercicio de matemáticas y garantizar una mejor atención visual y una menor carga cognitiva.
6. Análisis de los resultados finales y generación de conclusiones.

Resultados.

A partir del análisis de las distintas métricas de *Eye Tracking* (sobre todo mapas de calor), con respecto a las pruebas realizadas en el SAPE, fue posible encontrar la mejor disposición de elementos gráficos en el ejercicio de matemáticas propuesto. Dado que el proceso siguió una metodología en espiral, se efectuaron varias iteraciones para mejorar el sistema a partir de las evaluaciones y comentarios de los usuarios, además claro de los datos obtenidos con *Eye Tracking*. Un concentrado de los mapas de calor de las fijaciones en las diferentes disposiciones gráficas puede observarse en la Fig. 21.

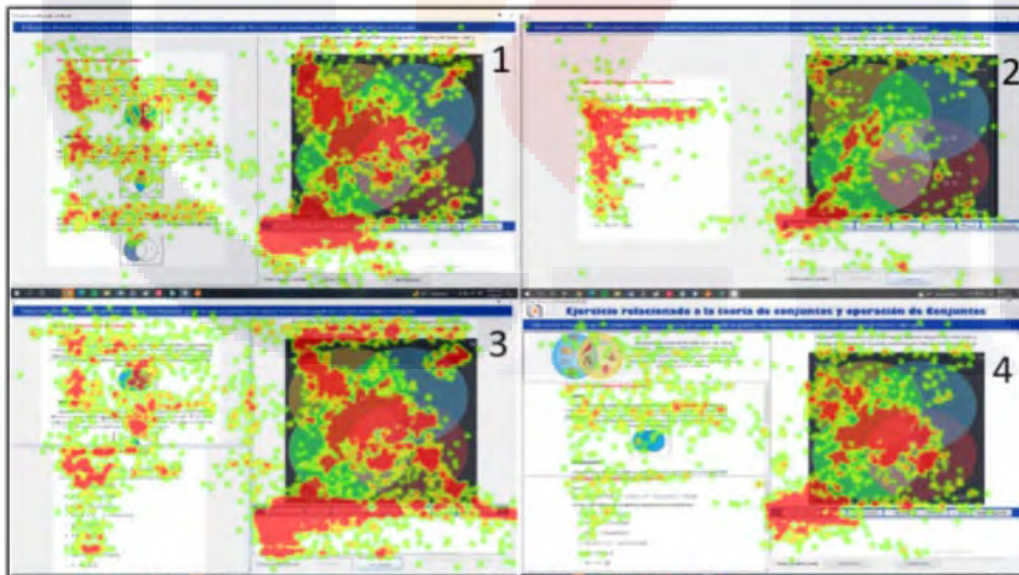


Fig. 21 Mapas de calor del conjunto de disposiciones (Ortíz et al., 2022).

Aportación.

Gracias a este trabajo, se pudieron explorar herramientas de *Eye Tracking*, como lo son el Tobii Pro Lab y el Tobii Pro Nano, además de poder tener un primer acercamiento a la multitud de variables de *Eye Tracking* con las que se puede trabajar en un experimento de este estilo (Tobii Pro Lab permite exportar alrededor de 80 variables distintas, que van desde cantidad de fijaciones en un área de interés, tiempos de fijación, microsacadas, etc.). En este experimento en específico se trabajó con mapas de calor de fijaciones, niveles de atención visual, número de visitas a elementos, patrones de recorrido y análisis de Áreas de Interés (AOI). Todas estas variables de estudio permiten una primera aproximación a las variables y métricas de *Eye Tracking* que pueden evaluarse en el modelo de evaluación de experiencia de aprendizaje.

Alcance.

A partir de este trabajo de investigación se generó un artículo que fue presentado por el Ing. Ángel Villegas en el Conf-IRM 2022 de Ontario Tech, Canadá, de manera virtual.

Referencia: (Ortíz et al., 2022).

1.2 EXPERIMENTO B: “EYE TRACKING PARA LA DETECCIÓN DE PATRONES DE TDAH EN NIÑOS DE ENTRE 6 Y 8 AÑOS”

Descripción.

Esta investigación deriva del proyecto de los Seminarios de Investigación I y II de la Ing. María Isabel Cordero Zúñiga, egresada de Ingeniería en Computación Inteligente de la Universidad Autónoma de Aguascalientes. El trabajo está orientado al desarrollo de una plataforma web sencilla con contenido adaptado para niños de entre 6 y 8 años, en combinación de *Eye Tracking* mediante cámara web para la detección de patrones del Trastorno de Déficit de Atención e Hiperactividad (TDAH).

El contenido de la plataforma está enfocado en actividades didácticas sencillas para niños en el rango de edad antes mencionado, diseñadas con la intención de encontrar patrones asociados al TDAH, lo anterior validado por una especialista en psicología.

Método.

La investigación consistió en diferentes fases:

1. Búsqueda de antecedentes y descripción del estado del arte del área en cuestión (patrones visuales de niños con TDAH y aplicaciones de *Eye Tracking* enfocadas a la psicología).
2. Desarrollo de plataforma web con contenidos didácticos para niños de entre 6 y 8 años. Las actividades se centraron en ejercicios de asociación, lectura y relación.
3. Investigación e implementación de *Eye Tracking* vía cámara web para su combinación con la plataforma web didáctica mencionada en el punto anterior.
4. Pruebas piloto de la plataforma web en conjunto con el *Eye Tracking* vía cámara web.
5. Pruebas reales con el permiso por escrito de padres de familia de niños con y sin tendencia a TDAH utilizando la plataforma web y el *Eye Tracking* vía cámara web. La muestra estadística fue de 15 niños, quienes realizaron los ejercicios didácticos en la plataforma a la vez que sus datos de *Eye Tracking* fueron adquiridos. Es importante señalar que los padres de familia realizaron una encuesta previa sobre información relacionada a sus hijos, desde datos generales hasta cuestiones médicas como posibles tendencias a TDAH o uso de medicamentos. Los datos de dicha encuesta también fueron incorporados a los datos generados a partir del *Eye Tracking* para construir un *dataset* más grande y completo para su posterior análisis.
6. Análisis de datos mediante la aplicación de diferentes algoritmos en Weka (software de *Data Mining* y *Machine Learning*).
7. Análisis de resultados finales y generación de conclusiones.

Resultados.

Luego de probar diferentes algoritmos de *clustering* en Weka, Canopy y EM registraron los mejores desempeños. Canopy generó un primer clúster con 11 muestras de individuos con patrones de TDAH, de los cuales, 8 efectivamente presentaron este patrón, mientras que los tres restantes pertenecían al grupo control. El segundo clúster consistía en individuos sin patrones de TDAH.

Por otro lado, EM agrupó de mejor manera ambas poblaciones, pues situó a los 8 individuos con patrones de TDAH correctamente, al igual que los 7 restantes en otro clúster (Figura 22).

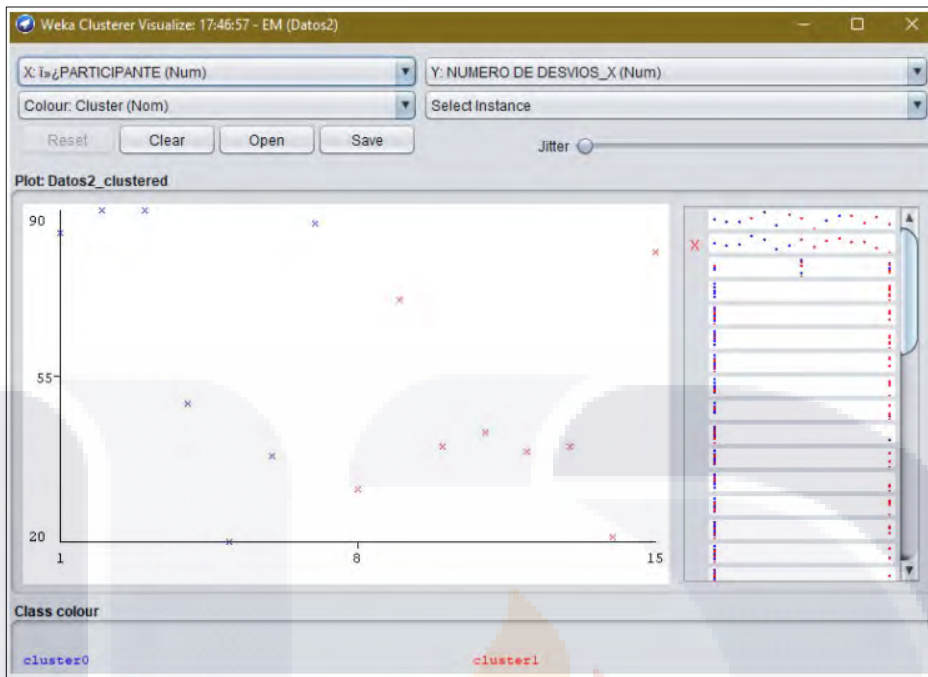


Fig. 22 Comparación de ambos clústers con respecto al número de participante y el número de desvíos en X (Algoritmo EM). (Elaboración de la alumna, tesina 2022).

Aportación.

De manera similar al experimento anterior, en este trabajo también se pudieron probar técnicas de *Eye Tracking*, aunque con un enfoque realizado vía cámara web. Aunado a lo anterior, se pudieron probar algoritmos de *clustering*, como Canopy y EM. Por otro lado, este caso de estudio aportó mucha información sobre la interacción usuario – objeto de aprendizaje, pues se desarrolló un sistema web sencillo para niños enfocado en actividades didácticas relacionadas con la lectura y el razonamiento. Si bien, vale la pena acotar que, para el modelo de evaluación de experiencia de aprendizaje se desarrolló un objeto de aprendizaje para estudiantes de nivel superior y mayores de edad.

Alcance.

A partir de este trabajo de investigación se generó un artículo que se presentó en CONTIE 2022, San José Costa Rica, de manera virtual. Además, sirvió como base para el examen de Mención Honorífica de la Ing. María Isabel Cordero Zúñiga. **Referencia:** (Zúñiga et al., 2022)

1.3 EXPERIMENTO C: “*EYE TRACKING* PARA LA DETECCIÓN DE VISTA CANSADA Y DISMINUCIÓN DEL SÍNDROME VISUAL INFORMÁTICO”

Descripción.

Esta investigación, al igual que la anterior, proviene del proyecto de los de Seminarios de Investigación I y II. En este caso del Ing. Sergio Adal Ruíz Campos, egresado de Ingeniería en Computación Inteligente de la Universidad Autónoma de Aguascalientes. El proyecto está enfocado en la detección de vista cansada para la disminución del Síndrome Visual Informático (SVI) mediante el análisis de datos provenientes de *Eye Tracking* y complementarios, a través de la implementación de una red neuronal sencilla desarrollada en Python con TensorFlow y Keras.

Método.

La investigación consistió en diferentes fases:

1. Búsqueda de antecedentes y descripción del estado del arte del área en cuestión (patrones visuales del SVI y su análisis con técnicas de *Deep Learning*).
2. Investigación de arquitecturas y topologías sobre redes neuronales que pudieran aplicarse en la investigación.
3. Creación de un formulario (en Google Forms) concerniente a datos generales y de hábitos de uso de Pantallas de Visualización de Datos (PVD) contestado por cada participante previo a la experimentación con *Eye Tracking*.
4. Creación de diseño experimental, basado en lectura, en el software Tobii Pro Lab como actividad enfocada a la detección de vista cansada.
5. Realización de pruebas piloto con el Tobii Pro Nano y el Tobii Pro Lab.
6. Experimentación con usuarios, partiendo primero con la aplicación del formulario mencionado en el punto 3, y posteriormente la actividad de lectura. Se tuvo una muestra estadística de 20 usuarios y el proceso llevó aproximadamente 10 minutos con cada uno.
7. Diseño, programación e implementación de red neuronal para analizar los datos provenientes del *eye tracker* y formulario (previamente procesados y limpios) para predecir tendencias al Síndrome Visual Informático. La red fue desarrollada en Python con TensorFlow y Keras a través de Google Colab.

8. Análisis de los resultados obtenidos de las predicciones y generación de conclusiones.

Resultados.

Como se mencionó en el punto anterior, se construyó una red neuronal sencilla para clasificar a los participantes con tendencia a SVI. La arquitectura de la red, que se definió luego de probar varias configuraciones de manera empírica, consistió en 11 elementos de entrada (atributos o variables del *dataset*), con tres capas ocultas de 60, 30 y 15 neuronas en cada una respectivamente (utilizando la función ReLu como activación) y una capa final de salida con la función sigmoide. También se aplicaron validación cruzada (10 *folds*, para mejorar el entrenamiento del *dataset*) y capas de *dropout* para ayudar en el desempeño de la red. Finalmente se logró una precisión del 97.5% en la clasificación de individuos con tendencia a SVI. Una pequeña gráfica sobre los síntomas más frecuentes del SVI (datos que formaron parte de uno de los atributos de entrada en la red neuronal) puede observarse en la Fig. 23.




Fig. 23 Síntomas más frecuentes del SVI (Campos et al., 2022).

Aportación.

Este trabajo guarda similitud con respecto a las técnicas que también se exploraron en el Experimento 1. Se utilizaron los mismos recursos de Hardware y Software (Tobii Pro Nano y Tobii Pro Lab), aunque se utilizaron variables distintas. Resalta la métrica sobre parpadeos (necesaria dada la naturaleza del estudio), que propiamente no se encuentra dentro de las

variables de estudio disponibles en el Software, pero que puede ser derivada de un análisis de tiempos a partir de los datos de fijación. Para poder llegar a tal determinación, se consultó con un representante oficial de la empresa fabricante a nivel Latinoamérica, Tobii Latam. Otra diferencia importante con respecto al Experimento 1, fue la aplicación de *Deep Learning* con una red neuronal sencilla para clasificación binaria. El modelo permitió tener un primer acercamiento a la implementación a esta rama del *Machine Learning* con datos de *Eye Tracking* que pueden ser de ayuda para la evaluación del modelo de experiencia de aprendizaje.

Alcance.

A partir de este trabajo de investigación se generó un artículo que se presentó en CONTIE 2022, San José Costa Rica, de manera virtual. Además, sirvió como base para el examen de Mención Honorífica del Ing. Sergio Adal Ruíz Campos. **Referencia:** (Campos et al., 2022).

1.4 EXPERIMENTO D: “ALGORITMOS DE MACHINE LEARNING EN NEUROMARKETING”

Descripción.

Esta investigación, al igual que las dos anteriores, también deriva de los Seminarios de Investigación I y II. En este caso, de la Ing. Jessica de Luna García, egresada de Ingeniería en Computación Inteligente de la Universidad Autónoma de Aguascalientes. El trabajo está centrado en la aplicación de algoritmos de *Machine Learning* (SVM y KNN) en *neuromarketing*. Esta vez, a diferencia de los casos anteriores, la tecnología biométrica utilizada es la Electroencefalografía (EEG), aplicada mediante el uso de un *headset* MindWave Mobile y técnicas de análisis estadístico de las señales.

Método.

La investigación consistió en varias fases:

1. Búsqueda de antecedentes y descripción del estado del arte del área en cuestión (Algoritmos de *Machine Learning* que se suelen aplicar en estudios de *NeuroMarketing* y *Marketing* en general).

2. Investigación sobre software de adquisición y preprocesamiento de señales EEG. En este caso, se utilizó la plataforma OpenViBE, cliente de adquisición para entablar la conexión del *headset* MindWave Mobile y la Computadora; y cliente de diseño para crear la arquitectura de adquisición y filtrado de las señales en sus diferentes bandas de frecuencia (Delta, Theta, Alpha, Beta y Gamma). Todas las señales se guardaron en distintos archivos .csv a partir de un pequeño script desarrollado en Python para a la postre generar un *dataset* general más grande.
3. Desarrollo de entorno de experimentación de *neuromarketing*. Consistió en la selección de imágenes de distintas categorías, como comida, videojuegos, turismo, entre otras; en espectros positivos y negativos (o no placenteros). En total, se generaron 24 imágenes.
4. Realización de formulario (en Google Forms) de preferencias de consumidor con respecto a las imágenes de las categorías descritas en el punto anterior. Cada participante, previo a la experimentación, debió contestar este instrumento.
5. Realización de pruebas piloto con el *headset* MindWave Mobile y el entorno de neuromarketing.
6. Experimentación con usuarios. Se realizaron 13 pruebas en las que se mostraban las imágenes antes mencionadas a los usuarios, a la par que se registraban sus señales EEG mediante el *headset* y OpenViBE.
7. Limpieza de datos y generación de estadísticos. Luego de haber tratado los datos de las señales EEG, se obtuvieron diversos estadísticos sobre las señales que a la postre sirvieron como atributos para un *dataset* mayor al cual se le aplicaron los algoritmos de *Machine Learning*.
8. Aplicación de algoritmos de *Machine Learning* (SVM y KNN) utilizando Python con la librería y herramientas de scikit-learn y el IDE PyCharm sobre el *dataset* de estadísticos mencionado en el punto anterior.
9. Análisis de resultados y generación de conclusiones.

Resultados.

Luego de aplicar SVM y KNN al *dataset* de estadísticos de señales EEG comentado en el punto anterior, se logró comparar el desempeño de ambos algoritmos con respecto a la

respuesta esperada (definida en el formulario de preferencias de cada participante) de cada imagen, de cada categoría (alimentos, turismo, etc.). A manera de ejemplo, en la Fig. 24, se muestra un gráfico comparativo de ambos algoritmos y la respuesta esperada (*target*) de una de las imágenes de la categoría alimentos.

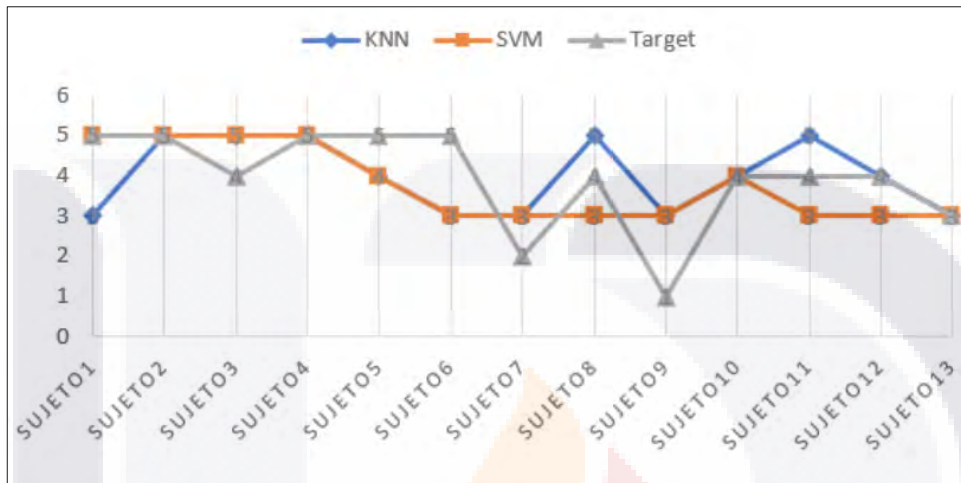


Fig. 24 Comparación del comportamiento entre SVM, KNN y *target* de imagen de la categoría alimentos. (Elaboración de la alumna, tesina 2022).

Aportación.

A diferencia de los experimentos anteriores, este fue el primero en el que se probó tecnología de EEG. En particular, sirvió para probar Hardware y Software como el *headset* Mindwave Mobile y el sistema de adquisición y diseño OpenViBE para señales EEG. Además de lo anterior, también pudieron probarse algoritmos de *Machine Learning* enfocados en clasificación múltiple, en específico SVM y KNN. Lo anterior dejó un precedente interesante para la aplicación y comparación de algoritmos que para validar el modelo de experiencia de aprendizaje (como en el caso del Experimento 3 con las Redes Neuronales).

Alcance.

A partir de este trabajo de investigación se generó un artículo que se presentó en el CNCIIC de ANIEI 2022, Puerto Vallarta, México, de manera virtual. **Referencia:** (De Luna et al., 2022).

1.5 EXPERIMENTO E: APLICACIÓN DE TÉCNICAS DE *EYE TRACKING* Y EEG EN LA GENERACIÓN DE UN MODELO DE PREDICCIÓN DE ORIENTACIÓN VOCACIONAL.

Descripción.

Esta investigación surge a partir de la participación de varios alumnos procedentes de distintas universidades nacionales y extranjeras en el Verano de Investigación Científica “Delfín” 2022. Estuvieron participando bajo mi supervisión, alumnos de la Universidad de Guadalajara (UdG), Tecnológico Nacional de México (TecNM), Instituto Politécnico Nacional (IPN) y la Universidad de Pamplona (Colombia), en una estancia breve de siete semanas con el objetivo principal de fomentar la ciencia entre alumnos próximos a egresar. En este caso en particular, se desarrolló una investigación basada en la predicción de tendencia de orientación vocacional a carreras STEM (Science, Technology, Engineering and Mathematics) de jóvenes próximos a ingresar a la universidad, mediante la obtención de datos de EEG y *Eye tracking*; y la aplicación de técnicas de *Machine Learning*. A diferencia de las investigaciones anteriores, esta pudo ser llevada a cabo más rápido (por la cantidad de participantes) y además sirvió como un buen preámbulo para probar ambas técnicas biométricas por primera vez en conjunto.

Método.

La investigación consistió en varias fases:

1. Búsqueda de antecedentes y descripción del estado del arte del área en cuestión (Investigaciones sobre la aplicación de Inteligencia Artificial o el *Machine Learning* en la predicción de orientación vocacional; y el uso de técnicas biométricas en Ciencia de Datos).
2. Investigación sobre software de adquisición y preprocesamiento de señales EEG y *Eye Tracking*. Para el caso del EEG, se utilizó la plataforma OpenViBE como software de adquisición y Matlab para el procesamiento. Se trabajó principalmente con los niveles de atención promedio. Para el caso de *Eye tracking*, se trabajó con Tobii Pro Lab y se tomaron métricas de AOI, tiempo total de fijación o número total de fijaciones.

3. Realización de formulario (en Google Forms) basado en preguntas clásicas de pruebas de orientación vocacionales. Este fue diseñado con preguntas específicas de área STEM y adecuado para obtener información de EEG y *Eye Tracking* al momento de realizarlo. Cada participante, previo a la experimentación, debió contestar este instrumento.
4. Realización de pruebas piloto con el *headset* MindWave Mobile y el Tobii Pro Nano en laboratorio.
5. Experimentación con usuarios. Se realizaron 44 pruebas en las que los usuarios respondieron a la prueba de orientación vocacional a la par que se registraban sus datos biométricos (EEG y *Eye Tracking*).
6. Limpieza de datos y generación de atributos para creación del *dataset*. Luego de obtener los provenientes de la prueba (formulario), así como de EEG y *Eye Tracking* se procedió a limpiarlos y adecuarlos para ser utilizados con algoritmos de *Machine Learning*.
7. Aplicación de algoritmos de *Machine Learning* utilizando Python con las librerías scikit-learn y TensorFlow sobre el *dataset* antes señalado. La aplicación de los algoritmos se codificó en VS Code.
8. Análisis de resultados y generación de conclusiones.

Resultados.

Se probaron diferentes modelos de *Machine Learning* en general (Aprendizaje Supervisado) y modelos más específicos con Redes Neuronales (Fig. 25) para comparar los diferentes resultados en las métricas de desempeño (*Accuracy, Precision, Recall* y *F1-Score*) al realizar las predicciones. En general, los modelos de *Deep Learning* se comportaron de mejor manera y se obtuvieron puntajes *F1-Score* cercanos al 90%. Más allá de los resultados obtenidos, lo más relevante de la investigación fue la conjunción de ambas técnicas biométricas y la aplicación de los algoritmos de *Machine Learning* para la predicción. Fue, por tanto, el primer ejercicio más cercano al modelo de evaluación de Experiencia de Aprendizaje.




Fig. 25 Comparación de métricas (*Accuracy*, *Precision*, *Recall*, *F1-Score*) de los modelos de *Deep Learning* con diferentes arquitecturas (Elaboración de los alumnos participantes en Verano de Investigación, 2022).

Aportación.

Como se mencionó anteriormente, en este trabajo pudieron explorarse distintos algoritmos de *Machine Learning* en general, así como distintas arquitecturas y configuraciones de modelos con redes neuronales, y métricas de clasificación que no se habían aplicado en experimentos previos. Además de la ventaja que supone la comparación de distintos modelos, también fue el primer acercamiento en el que se sincronizaron EEG y *Eye Tracking*. Para el caso de EEG se utilizó el *headset* Mindwave Mobile, OpenViBe y Matlab (para el procesamiento y adecuación de las señales), mientras que para *Eye Tracking* se utilizó Tobii Pro Nano y Tobii Pro Lab. En cuanto a la combinación de tecnologías biométricas se refiere, en este caso de estudio pudieron probarse ambas por primera ocasión, lo que supone un precedente de importancia a tomar en cuenta, sobre todo en la parte experimental y de análisis de datos para el modelo de evaluación de experiencia de aprendizaje.

Alcance y Extensión.

A partir del *dataset* generado durante la estancia de Verano de Investigación Científica “Delfín”, se realizaron pruebas con otro modelo de *Machine Learning*, XGBoost Classifier. Con esta nueva investigación se buscó realizar nuevas predicciones y mejorar la capacidad de predicción de tendencia a carreras tipo STEM, como parte del trabajo de reporte técnico del Ing. biomédico del Instituto Politécnico Nacional (IPN), Axell Gutiérrez Albano, del cual

se participó como Co-tutor. Los resultados fueron publicados en EDULEARN 2024.

Referencia: (Ramírez et al., 2024).

1.6 EXPERIMENTO F: PROCESAMIENTO DE ONDAS CEREBRALES PARA LA IDENTIFICACIÓN DE EMOCIONES.

Descripción.

Este experimento (y el siguiente), al igual que los experimentos 2 - 4, deriva de la investigación de los Seminarios I y II del Ing. Giancarlo Ramírez Díaz de León, egresado de la carrera de Ingeniería en Computación Inteligente de la Universidad Autónoma de Aguascalientes.

El trabajo está centrado en la clasificación de emociones a través del análisis de señales EEG con algoritmos de *Machine Learning* (en específico, SVM y KNN), cuando se les muestra a los participantes imágenes positivas y negativas sobre animales (apelando a la reacción a través del posible vínculo afectivo humano – animal). En términos metodológicos, fue muy similar al Experimento 4.

Método.

La investigación consistió en varias fases:

1. Búsqueda de antecedentes y descripción del estado del arte del área en cuestión (Algoritmos de *Machine Learning* que se suelen aplicar en estudios de clasificación de emociones).
2. Investigación sobre software de adquisición y preprocesamiento de señales EEG. La metodología fue muy similar a la realizada en el Experimento 4, utilizando OpenViBE y el *headset* MindWave Mobile, aplicando filtros Butterworth para la separación en frecuencia de los distintos ritmos cerebrales (Delta, Theta, Alpha, Beta y Gamma). Todas las señales se guardaron en distintos archivos .csv y a partir de ellos se generó un *dataset* final más grande.
3. Desarrollo de entorno de experimentación para clasificación de emociones. Consistió en la selección de 10 imágenes positivas y negativas sobre animales, apelando a los vínculos y relación Humano – Animal, (conocidos en inglés como HARs, HAIs y HABs).

4. Realización de formulario (en Google Forms) para conocer la opinión de los participantes con respecto a las imágenes descritas en el punto anterior. Cada participante, posterior a la experimentación, debió contestar este instrumento.
5. Realización de pruebas piloto con el *headset* MindWave Mobile.
6. Experimentación con participantes. Se realizaron 36 pruebas en las que se mostraban las imágenes antes mencionadas a los participantes, a la par que se registraban sus señales EEG mediante el *headset* y OpenViBE.
7. Limpieza de datos y generación de estadísticos. Luego de haber tratado los datos de las señales EEG, se obtuvieron diversos estadísticos sobre las señales que a la postre sirvieron como atributos para un *dataset* mayor al cual se le aplicaron los algoritmos de *Machine Learning*. Cabe destacar que también se agregaron al *dataset*, las características de Hjorth, un tipo de características propias de las señales EEG que no se habían explorado en experimentos anteriores.
8. Aplicación de algoritmos de *Machine Learning* (SVM y KNN) utilizando Python con las librerías y herramientas de scikit-learn y pyeeg y Jupyter Notebooks sobre el *dataset* de estadísticos mencionado en el punto anterior.
9. Análisis de resultados y generación de conclusiones.

Resultados.

Como se mencionó anteriormente, se probaron diferentes algoritmos, en concreto, distintas versiones de SVM y KNN. Las variaciones principales entre algoritmos se realizaron en función de la mejora con respecto a diferentes hiperparámetros, resultando KNN el mejor de ambos, aclarando que también se utilizó validación cruzada estratificada para mejorar la distribución de las muestras durante el entrenamiento. Al final se obtuvo un F1 – score de 0.92, (Fig. 26) lo que corrobora una muy buena clasificación de emociones.

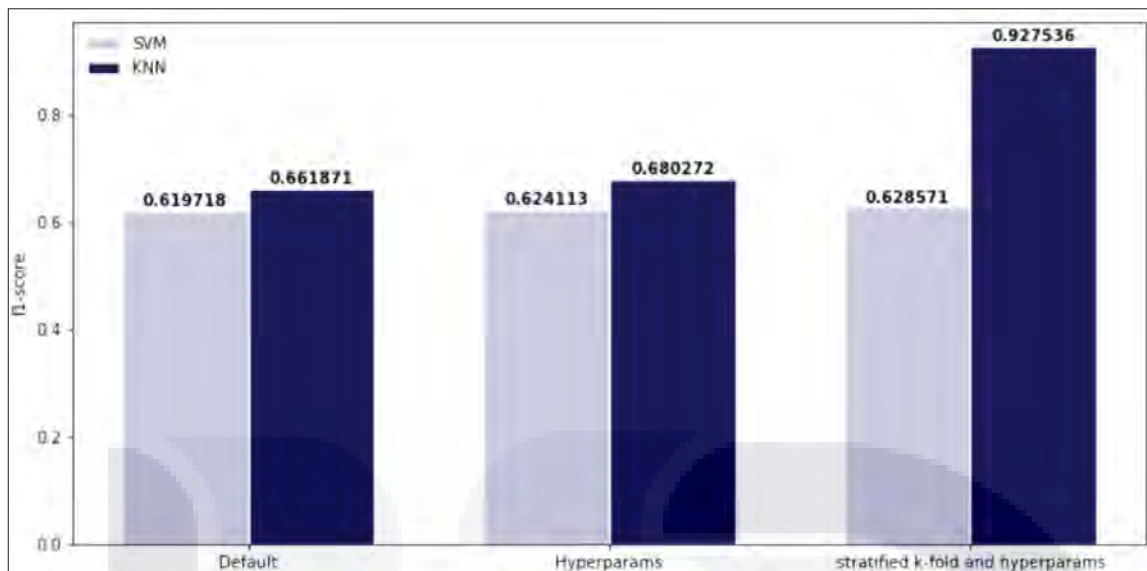


Fig. 26 Comparación de modelos de aprendizaje (KNN y SVM) con diferentes configuraciones: Default, con modificación en hiperparámetros y con validación cruzada estratificada (Elaboración del alumno, tesina 2023).

Aportación.

A pesar de que se comentó que metodológicamente este experimento fue muy similar al Experimento 4, en este experimento también se probaron las características de Hjorth (calculadas mediante funciones de la librería pyeeg) lo que aportó mayor cantidad de información al *dataset* con el que se entrenaron los algoritmos. Esto, por consiguiente, ayuda en la exploración de las variables o atributos a tomarse en cuenta para el análisis de datos en el modelo de evaluación de experiencia de aprendizaje.

Alcance.

El trabajo de investigación sirvió para proyecto de titulación del Ing. Giancarlo Ramírez Díaz de León, de la carrera de Ingeniería en Computación Inteligente.

1.7 EXPERIMENTO G: PROPUESTA INICIAL DE UN MODELO PREDICTIVO PARA LA DETECCIÓN TEMPRANA DE TENDENCIAS DEPRESIVAS.

Descripción.

Como ya se señaló, este experimento deriva del proyecto de investigación de las materias de Seminarios de Investigación I y II del Ing. Cristian Pinto Méndez, egresado de Ingeniería en Computación Inteligente de la Universidad Autónoma de Aguascalientes.

Consistió en la participación de un grupo de 20 personas para clasificación de tendencias depresivas mediante la aplicación de KNN. El estudio contó con el apoyo del Departamento de Psicología de la UAA, y en términos metodológicos, guarda similitud a los experimentos 4 y 6, aunque utilizando únicamente el ritmo Alpha para el análisis.

Método.

La investigación consistió en varias fases:

1. Búsqueda de antecedentes y descripción del estado del arte del área en cuestión (Algoritmos de *Machine Learning* que se suelen aplicar en estudios de clasificación de depresión o enfermedades afines).
2. Investigación sobre software de adquisición y preprocesamiento de señales EEG. La metodología fue muy similar a la realizada en los experimentos 4 y 6, utilizando OpenViBE y el *headset* MindWave Mobile. En este caso únicamente se trabajó con el ritmo Alpha de acuerdo con lo señalado en la literatura para estudios de clasificación de tendencias depresivas mediante EEG.
3. Desarrollo de entorno de experimentación para clasificación de tendencias depresivas. Consistió en un experimento en el que se pedía al participante que contestase una serie de preguntas personales (opiniones, gustos, preferencias) a la par que se realizaba su registro EEG. Cabe señalar que el estudio estuvo dividido en dos fases. En la primera, la respuesta a las preguntas antes señaladas se hacía en completo silencio, mientras que la segunda se realizaba escuchando la música favorita del participante. Lo anterior tenía la finalidad de verificar si existía un cambio en el ritmo Alpha, sobre todo al estar el participante concentrado en responder a las preguntas, y luego al comenzar la música de su preferencia. El diseño de este experimento tuvo el respaldo de profesores del departamento de psicología, a quienes el estudiante contactó directamente para asesorías y consulta. Es importante señalar también que previo al experimento se conocía si el participante tenía tendencias depresivas o no (diagnosticadas por un especialista).
4. Realización de pruebas piloto con el *headset* MindWave Mobile.
5. Experimentación con participantes. Se realizaron 20 pruebas, 10 con participantes con tendencias depresivas (identificados como CTD) y 10 con participantes sin tendencias depresivas (STD) utilizando el *headset* MindWave Mobile y OpenViBE.

6. Limpieza de datos y generación de estadísticos. Al igual que el experimento 4, luego de haber tratado los datos de las señales EEG, se obtuvieron diversos estadísticos sobre las señales que a la postre sirvieron como atributos para un *dataset* mayor al cual se le aplicaron los algoritmos de *Machine Learning*.
7. Aplicación de algoritmos de *Machine Learning* utilizando Python con las librerías y herramientas de scikit-learn y Jupyter Notebooks sobre el *dataset* de estadísticos mencionado en el punto anterior. Aunque el algoritmo que mejor desempeño tuvo fue el KNN, también se probaron SVM y Redes Neuronales (con TensorFlow).
8. Análisis de resultados y generación de conclusiones.

Resultados.

Al igual que en el experimento anterior, se probaron diferentes algoritmos, en específico se trabajó con SVM, KNN y diversos modelos de Redes Neuronales. Entre todos, el que mejor destacó fue el KNN, con un F1 – score de 0.82 (Fig. 29), alcanzando un muy buen puntaje para la clasificación de tendencias depresivas. Cabe aclarar, además, que, si bien los resultados son óptimos y prometedores, para realizar un diagnóstico formal de la depresión siempre será necesario de un profesional de la salud mental, por lo que los resultados alcanzados en esta investigación, como todo el trabajo en sí, deben tomarse desde una perspectiva de apoyo y no conclusiva.

```
Epoch 1/15  
Epoch 2/15  
Epoch 3/15  
Epoch 4/15  
Epoch 5/15  
Epoch 6/15  
Epoch 7/15  
Epoch 8/15  
Epoch 9/15  
Epoch 10/15  
Epoch 11/15  
Epoch 12/15  
Epoch 13/15  
Epoch 14/15  
Epoch 15/15  
Accuracy: 0.82  
F1-Score: 0.8235294117647058
```

Fig. 27 Resultados finales de *Accuracy*: 0.82 y *F1-Score*: 0.823 para clasificación de tendencias depresivas utilizando KNN (Elaboración del alumno, tesina 2023).

Aportación.

Al guardar similitudes con los experimentos 4 y 6, se pudo corroborar la importancia de las variables estadísticas de las señales EEG en un proyecto de clasificación binaria. Si bien, los algoritmos que se utilizaron ya habían sido explorados, experimentalmente no se había trabajado sobre el análisis de una única señal, que en este caso fue el ritmo Alpha, por lo que también se estableció un buen precedente para el modelo de evaluación de experiencia de aprendizaje.

Alcance.

Este trabajo de investigación sirvió para la titulación del Ing. Cristian Pinto Méndez, egresado de la carrera de Ingeniería en Computación Inteligente de la UAA.

Como ya se mencionó, el modelo de evaluación de experiencia de aprendizaje aplica distintas herramientas biométricas (y otras más tradicionales) para recabar información sobre los usuarios, por ende, emprender distintas experimentaciones previas, fortalece el desarrollo del modelo. Aunado a lo anterior, es deseable que el alumno del DCAT participe en la formación y dirección de investigación de alumnos de pregrado, ya sea como director o asesor de tesis, por lo que realizar estas experimentaciones cumple con doble objetivo. Por un lado, poder recabar información importante sobre las tecnologías que se aplicarán en el modelo (herramientas, software, metodologías, contextos, etc.) y por otro, participar en la formación de capital humano. Así pues, con los experimentos descritos en los puntos anteriores, han podido cumplirse ambos objetivos, aunque bien, pueden seguirse ampliando para enriquecer al modelo desde otros puntos de vista.

Como aportación adicional a las actividades de Retribución Social, requisito dentro del DCAT, se dirigieron más tesis en el curso 2023 – 2024, con estudiantes de Seminario de Investigación I y II también de la carrera de ICI. Estos trabajos de investigación no están incluidos en esta sección como casos de estudio o experimentos previos, pues se realizaron a la par o después de ya realizada la experimentación principal (descrita a continuación). Cabe destacar que se contó con el apoyo de varios de los estudiantes dirigidos en esta etapa para dicha experimentación. El listado total de los trabajos dirigidos se encuentra en el Anexo E.

2. EXPERIMENTO PRINCIPAL: MARCO CONCEPTUAL Y OBJETIVOS

Los casos de estudio sirvieron como aproximaciones previas para planear y realizar el experimento principal, cuyo objetivo es la elaboración del modelo de evaluación de experiencia de aprendizaje. Así pues, en las siguientes subsecciones se aborda la influencia que estas tuvieron (por ejemplo, probar alguna tecnología específica), los objetivos de este experimento principal, su relación con la hipótesis, y un modelo o *framework* inicial que se diseñó como base para el modelo final.

2.1 RELEVANCIA Y HALLAZGOS DE LAS EXPERIMENTACIONES INICIALES.

Cada caso de estudio tuvo alguna aportación para la elaboración del modelo de evaluación de experiencia de aprendizaje. Aunque a primera vista pudiera parecer que existen algunos que no guardan una relación directa, siempre existió un punto al cual poderle sacar ventaja. Por ejemplo, en los primeros casos de estudio, se probaron herramientas relativas a alguna tecnología específica, ya fuese EEG o *Eye Tracking*. O bien, una vez que ya se tenía más experiencia al respecto, en algunos otros se experimentó con nuevos métodos de procesamiento o se implementaron otros algoritmos de *Machine Learning* con los que no se había trabajado.

En la Tabla 7 se muestra una relación de las herramientas (software y hardware) y tecnologías biométricas que se pudieron probar con los experimentos iniciales.

Tabla 7 Software y Hardware utilizado en los experimentos iniciales / casos de estudio (Elaboración propia, 2023).

Experimento	Hardware	Software	Tecnología biométrica	Algoritmos / Análisis
<i>Eye Tracking</i> para el estudio de la carga cognitiva y su relación con el desempeño académico enfocado al área de matemáticas.	Tobii Pro Nano	Tobii Pro Lab	<i>Eye Tracking</i>	Análisis estadísticos de los mapas de calor y cantidad de fijaciones.

<i>Eye Tracking</i> para la detección de patrones de TDAH en niños de entre 6 y 8 años.	Eye tracker vía cámara web	Webgaze; Weka para análisis de datos	<i>Eye Tracking</i>	Algoritmos de <i>clustering</i> , destacan EM y Canopy.
<i>Eye Tracking</i> para la detección de vista cansada y disminución del Síndrome Visual Informático.	Tobii Pro Nano	Tobii Pro Lab; Python	<i>Eye tracking</i>	Redes Neuronales simples desarrolladas con TensorFlow y Keras.
Algoritmos de <i>Machine Learning</i> en <i>Neuromarketing</i>	MindWave Mobile	OpenViBE; Python	EEG	Algoritmos de clasificación en Python, SVM y KNN.
Aplicación de técnicas de <i>Eye Tracking</i> y EEG en la generación de un modelo de predicción de orientación vocacional	Tobii Pro Nano y MindWave Mobile	OpenVibe; Tobii Pro Lab; Matlab	<i>Eye Tracking</i> y EEG	Varios algoritmos de clasificación en Python; destacan las redes neuronales con distintas arquitecturas y XGBoostClassifier.
Procesamiento de Ondas cerebrales para la identificación de emociones.	MindWave Mobile	OpenViBE; Python	EEG	Algoritmos de clasificación en Python, SVM y KNN además de exploración de características de Hjorth para señales EEG.
Propuesta inicial de un modelo predictivo para la detección temprana de tendencias depresivas.	MindWave Mobile	OpenViBE; Python	EEG	Algoritmos de clasificación en Python, SVM, KNN y Redes Neuronales, además del tratamiento de la señal Alpha.

2.2 OBJETIVOS EN EL EXPERIMENTO PRINCIPAL

De manera similar a cómo se fijaron los objetivos de investigación de la tesis completa, también en este caso fue necesario establecer objetivos particulares al experimento principal. Es decir, ¿qué se busca lograr con este? Si ya se tiene información relevante y conveniente de los casos de estudio, con el experimento principal se busca llegar a un punto de conexión para poner en práctica lo aprendido y dirigirlo exclusivamente a la elaboración del modelo de evaluación de experiencia de aprendizaje.

Por lo anterior, se definieron los siguientes objetivos:

- Generar un objeto de aprendizaje que produzca una experiencia de aprendizaje favorable (se tomó como ejemplo particular la enseñanza de la Programación Orientada a Objetos).
- Diseñar un experimento con al menos 30 usuarios para conocer su experiencia de aprendizaje con respecto a un Objeto de Aprendizaje.

- TESIS TESIS TESIS TESIS TESIS
- Recabar información de *UX* tradicional (proveniente de un formulario) e información a partir de EEG y *Eye Tracking*, por cada usuario, cuando interactúan con el Objeto de Aprendizaje.
 - Analizar los datos, generar *datasets* comparativos (con y sin biométricos) y aplicar algoritmos de *Machine Learning* para generar predicciones y métricas de desempeño.
 - Comparar las métricas de desempeño (*dataset* con biométricos vs *dataset* sin biométricos).
 - Generar modelo (*framework*) final sobre el modelo de evaluación de experiencia de aprendizaje.

Así pues, a manera de resumen, el experimento principal sirve para generar el modelo o *framework* final de experiencia de aprendizaje, y además para validarlo estadísticamente, pues la aportación principal que se busca con este modelo es mostrar las ventajas que tiene la incorporación de EEG y *Eye Tracking* para una comprensión más completa de la experiencia de aprendizaje.

2.3 RELACIÓN CON LA HIPÓTESIS

En el modelo de evaluación de experiencia de aprendizaje se propone como componente clave la incorporación de mediciones con tecnologías biométricas, en específico EEG y *Eye Tracking*, puesto que aportan información objetiva sobre el usuario que de otra manera no sería posible determinar. Si bien se cuenta con la opinión del usuario, esta puede ser subjetiva o tener algún sesgo. Dado lo anterior, se plantea comparar dos conjuntos de datos (*datasets*) a partir de las mediciones realizadas en la interacción del usuario con el Objeto de Aprendizaje:

1. *Dataset* con biométricos
2. *Dataset* sin biométricos.

A partir de un análisis estadístico, puede determinarse la diferencia entre ambos conjuntos (para más detalles consulte el **Capítulo IV. Resultados, Sección 1. Evaluación de la hipótesis**).

2.4 FRAMEWORK INICIAL

Antes de definir el modelo evaluación de experiencia de aprendizaje final, se trabajó con una idea inicial de la cual partir. Esta está fundamentada en todo el trabajo de investigación previo, y a partir de los resultados obtenidos en la RSL. En ella, se descubrió que existen diversas metodologías y técnicas aplicables para medir la *UX* basadas en herramientas biométricas. Para recapitular, entre ellas, se destacan:

- EEG, una de las dos técnicas principales que se plantea usar en el modelo, se basa en el análisis de las señales cerebrales obtenidas mediante electrodos colocados en el cuero cabelludo.
- *Eye Tracking*, otra de las herramientas principales para el modelo, se basa en el seguimiento de la mirada, mapas de calor o mapas de fijación de la mirada (E. Dalmaijer, 2015a). Ha cobrado gran importancia en los estudios de *UX*, incluso, (J. Wang et al., 2019) comparan la relación que existe entre estudios tradicionales de Usabilidad y los basados en esta técnica, concluyendo que permite mayor recopilación de ideas.
- Otras técnicas biométricas como la respuesta galvánica de la piel (GSR), la frecuencia cardiaca, la electrocardiografía, *Facial Coding* y la electromiografía. Por motivos de simplicidad y alcance de la investigación, no se consideran en el modelo de evaluación de Experiencia de Aprendizaje.

De acuerdo con (Schall, 2015a) siempre que se realice un estudio de *UX* debe llevarse a cabo con métodos tradicionales y biométricos, puesto que permiten recabar información tanto objetiva como subjetiva de la opinión de los usuarios y así puedan complementarse.

Para comprender de mejor manera, no solo la incorporación de las técnicas biométricas, sino de todas las demás áreas relacionadas, se propone el esquema de la Fig. 28 para la construcción del *framework* propuesto:

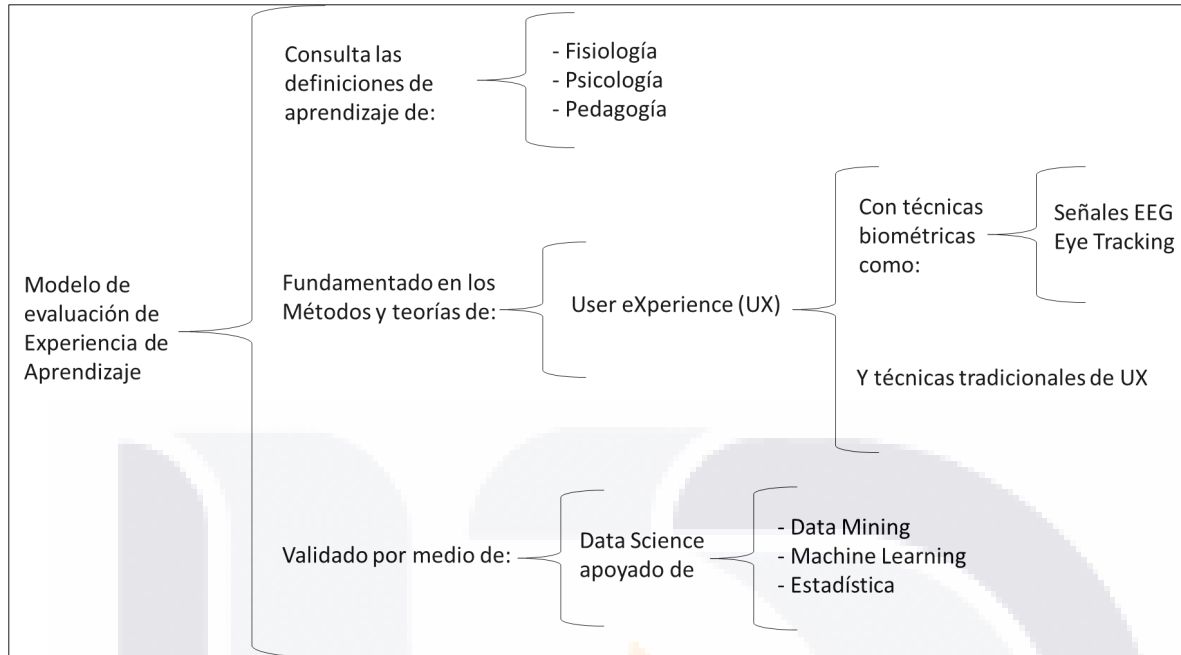


Fig. 28 Cuadro Sinóptico sobre las áreas que comprenden el modelo de evaluación de Experiencia de Aprendizaje (Elaboración propia, 2022).

Así pues, luego de la revisión del esquema anterior, se puede comprender mejor el *framework* inicial que se propone para crear el modelo de evaluación de la Experiencia de Aprendizaje, que consiste en los siguientes elementos (Fig. 29):

- Mediciones basadas en *Eye Tracking*.
- Mediciones basadas en electroencefalografía (EEG).
- Métodos tradicionales de *UX* (adaptadas a un entorno de aprendizaje).
- Registro de observaciones adicionales (como pueden ser comentarios, comportamientos o valoraciones (Schall, 2015a)).

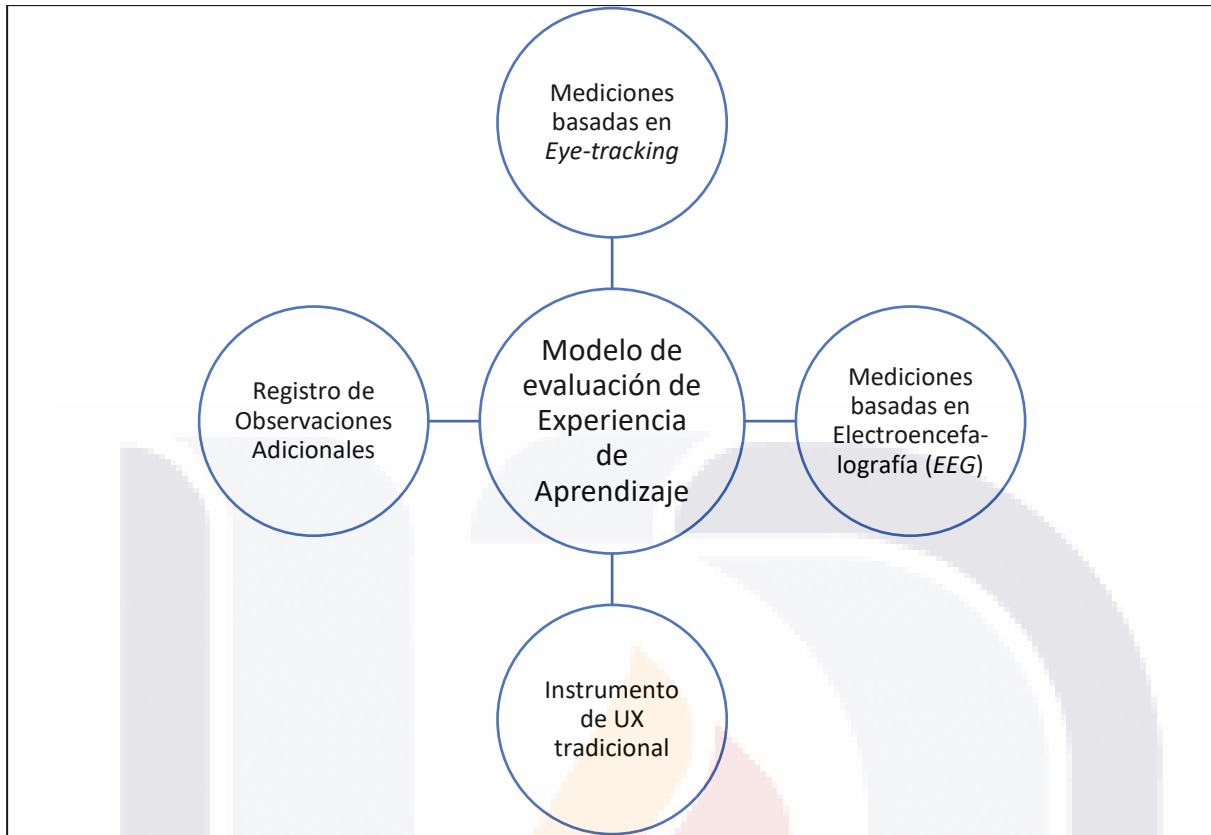


Fig. 29 Modelo inicial de evaluación de Experiencia de Aprendizaje (Elaboración propia, 2022).

Si bien, es un *framework* inicial, la experimentación principal sirve para refinarlo y crear la propuesta final. Así pues, a partir de este “boceto”, se realizaron y definieron los pasos que en las siguientes secciones se describen.

3. PROCEDIMIENTOS ESPECÍFICOS

Como ya se mencionó, todos los experimentos de los casos de estudio cumplieron con alguna función específica, ya fuese para probar algoritmos, software, herramientas, o enfoques de la investigación, sin embargo, a partir del experimento principal aquí descrito, es que todos ellos se conjugan para probar el modelo propuesto a partir de un objeto de Aprendizaje bien definido. Para el desarrollo de este experimento, fue de suma importancia el apoyo de los estudiantes de ICI de 9no semestre que conformaron mi equipo de trabajo (véanse sus nombres en la sección de agradecimientos).

Con respecto al experimento como tal, los pasos realizados se ilustran en el diagrama de la Fig. 30. A continuación, se muestra una breve descripción de cada punto del proceso experimental con usuarios:

- **Búsqueda de participantes con el perfil ideal:** Se definió una muestra estadística de por lo menos 30 participantes, esto para cumplir con los estudios sugeridos en la literatura para la realización de pruebas de *UX*. Se buscaron estudiantes de carreras afines a la programación, en sus primeros semestres, puesto que el objeto de aprendizaje era relativo a la Programación Orientada a Objetos.
- **Configuración del ambiente para el usuario:** Las pruebas fueron realizadas en los laboratorios de Industria de SW del Edificio 204 y el laboratorio de cómputo del edificio 54, ambos en el campus central de la UAA. Se generó un ambiente tranquilo y controlado, libre de distracciones para los usuarios.
Una vez que un usuario estaba por comenzar una prueba, se le mostraba de manera digital la carta de consentimiento informado para su lectura y firma, se le explicaba el proceso, se le colocaba la diadema Mindwave Mobile 2, y se realizaba la calibración del *Eye Tracker* Tobii Pro Nano 2. Finalizado dicho proceso, se procedía al registro.
- **Presentación del objeto de aprendizaje (video sobre POO):** El OA que se presentó fue diseñado en conjunto con los estudiantes de ICI que participaron en el proyecto. Fue realizado con IA y es relativo a la enseñanza de conceptos básicos sobre POO, como clase, objeto o los 4 Pilares.
- **Registro de datos (EEG; Eye Tracking y formulario):** A la par que el usuario observaba el OA, se realizó el registro de datos a través de la diadema Mindwave Mobile 2 y del Tobii Pro Nano. Al finalizar el video, el usuario contestaba un breve formulario relativo a su experiencia de aprendizaje (Fig. 31).
- **Generación de archivos .csv:** A partir de cada usuario, se generaba un archivo .csv con el registro de las señales EEG, mientras que para el *Eye Tracking*, dado que se trabajó con Tobii Pro Lab, se podía generar un *dataset* más grande con la información conjunta de todos los usuarios. Finalmente, mediante programación en Python, se unificaron todos los *datasets* (EEG, *Eye Tracking* y respuestas del formulario de cada usuario), para su posterior análisis con *Machine Learning*.

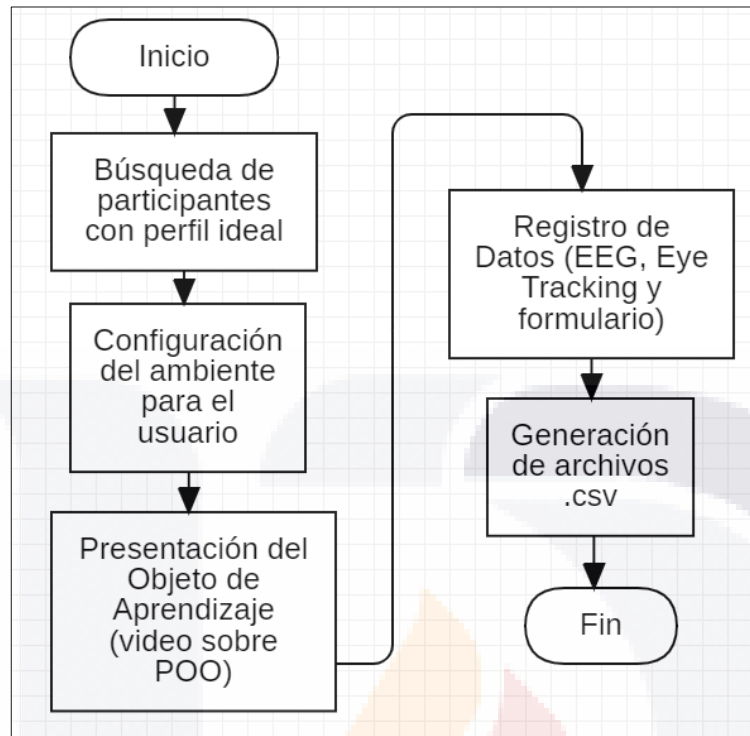


Fig. 30 Diagrama de la experimentación principal con usuarios (Elaboración propia, 2023).

Feedback Survey

Feedback Experiencia de Aprendizaje

Después de la experimentación llevada a cabo por el equipo Alpha, y bajo la supervisión del M.C.C. Eduardo Emmanuel Rodríguez López, usted deberá responder el siguiente cuestionario de retroalimentación, calificando según su experiencia.

Acceder a Google para guardar el progreso. Más información

* Indica que la pregunta es obligatoria

Entendí los temas tratados en el video *

Muy mal Mal Regular Bien Muy bien

Calificación

La claridad con que se explicó el tema fue: *

Muy malo Malo Regular Bueno Muy bueno

Calificación

El contenido audiovisual del video fue: *

Muy malo Malo Regular Bueno Muy bueno

Calificación

La capacidad del video para llamar mi atención fue: *

Muy mala Mala Regular Buena Muy buena

Calificación

Considero que mi experiencia de aprendizaje fue: *

Muy mala Mala Regular Buena Muy buena

Calificación

Enviar Borrar formulario

Fig. 31 Capturas del formulario sobre Experiencia de Aprendizaje en Google Forms (Elaboración del equipo de trabajo, 2023).

3.1 POBLACIÓN Y MUESTRA

Como ya se mencionó brevemente, se buscaron participantes que cumplieran con el perfil ideal, todos en la comunidad universitaria de la UAA. La gran mayoría fueron de Ingeniería en Computación Inteligente, con una ligera representación de alumnos de Ingeniería en Sistemas Computacionales, todos de 3er semestre. Lo anterior, debido a que se necesitaba que dichos usuarios contaran con las bases mínimas de programación para poder comprender de mejor manera los conceptos sobre Programación Orientada a Objetos, presentados en el Objeto de Aprendizaje. La muestra final fue de 35 usuarios.

3.2 TECNOLOGÍA

En cuestión de la tecnología empleada, se aborda esta sección desde los siguientes puntos:

- **Tecnologías de EEG:** Se utilizaron la diadema MindWave Mobile 2 como sistema de registro, el software Open ViBE Acquisiton Server para realizar la transmisión de datos y adquisición, y el OpenViBE Designer para el almacenamiento de las señales EEG en archivos .csv. El procesamiento de los datos fue realizado en Python. Para una descripción más detallada sobre las características técnicas (consúltese **sección 4. Instrumentos y Medidas**).

- **Tecnologías de Eye Tracking:** Se emplearon el *eye tracker* Tobii Pro Nano en conjunto con el software para adquisición, procesamiento y análisis propio del fabricante, Tobii Pro Lab. De igual manera que con los datos de EEG, el procesamiento de los datos recabados con *Eye Tracking* fue realizado en Python. Con respecto a una descripción más detallada sobre las características técnicas (consúltese **sección 4. Instrumentos y Medidas**).

- **Objeto de Aprendizaje:** El OA utilizado fue creación propia del equipo de trabajo. En un principio se planteó la posibilidad de utilizar algún recurso ya existente. Sin embargo, para evitar la necesidad de solicitar permiso por el uso de material con derechos de autor, y como un ejercicio de creatividad, se desarrolló un OA propio.

De común acuerdo con el tutor, se eligió que el OA fuera relativo a Programación, en atención a que la línea de investigación del doctorado es sobre Ingeniería de Software y Objetos de Aprendizaje. Este consiste en un vídeo realizado con ayuda de Inteligencia Artificial, enfocado en la enseñanza de los principios de la Programación Orientada a

Objetos, como los 4 pilares de la POO, los conceptos de clase u objeto, y breves ejemplos de su implementación en Java.

Su elaboración se llevó a cabo conforme a los principios de calidad de los OA, es decir, que contuviera elementos tecnológicos, pedagógicos, de contenido y estéticos, y además teniendo en cuenta el modelo ExodUX (Kremer et al., 2016) para diseño de experiencias de aprendizaje interactivo.

El OA estuvo basado en un guion realizado por todo el equipo de trabajo y fue producido en Canva, generando la voz artificial de un narrador y una persona virtual (generada con IA) a la que se le dotó de gesticulaciones faciales para simular el habla.

Para que el contenido del video fuera divertido y relacionable con elementos de la vida cotidiana de la sociedad mexicana, el personaje artificial (narrador) que explica los temas, emula a un taquero, que realiza analogías entre los tacos (comida popular mexicana) y los diferentes conceptos de la POO. En específico, se aprovecha de este folklor mexicano para la explicación de conceptos. Por ejemplo, una explicación sobre qué es una clase, hace una analogía a un taco, definiendo sus atributos y métodos. Para ello, se muestran animaciones acompañadas de código generado en Java (véase Fig. 32).

Un fragmento del video mostrando al narrador generado con IA puede verse en la Fig. 33.

Para ver el video completo, visite el siguiente enlace (Merla et al., 2024):

<https://youtu.be/RIKLphYtYBk?si=85HwXYEwMyiBqb5Y>

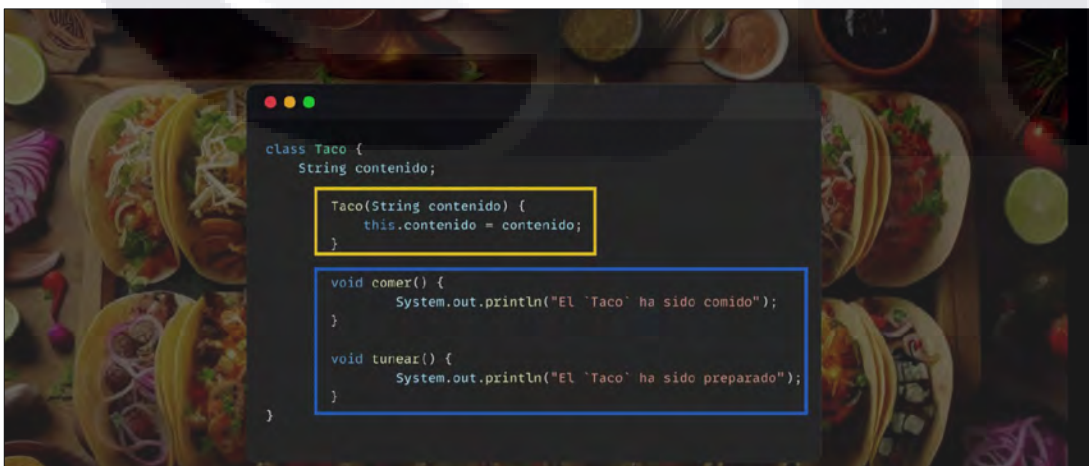


Fig. 32 Fragmento del video (OA) mostrando la implementación de la clase "Taco" (Elaboración del equipo de trabajo, 2023).



Fig. 33 Fragmento del video (OA) mostrando al narrador (generado con IA) dando el cierre del tema (Elaboración del equipo de trabajo, 2023).

Cabe recordar que los datos de EEG y *Eye Tracking* fueron adquiridos a la par que los usuarios observaban el video, mientras que el formulario sobre Experiencia de Aprendizaje se aplicaba inmediatamente después de terminar el video (únicamente se paraba el registro de datos de la MindWave Mobile 2 y del *eye tracker*).

3.3 RECOPIACIÓN DE DATOS

Como ya se señaló, en lo referente a la adquisición de datos se utilizaron dispositivos específicos para cada tecnología. Tanto la diadema MindWave Mobile 2, como el Tobii Pro Nano cuentan con características técnicas únicas en cuanto a frecuencia de muestro procesamiento de datos para capturar las variables que miden, sin embargo, estas características serán presentadas en la **sección 4. Instrumentos y Medidas**.

En lo referente al almacenamiento y gestión de estos datos, tanto el OpenViBe Designer, como el Tobii Pro Nano cuentan con herramientas para guardar los datos recopilados en archivos tsv, o .xlsx que después pueden ser tratados según le convenga al investigador. En este caso en particular, cada herramienta producía diferentes archivos que después eran procesados para juntarse en un solo *dataset*. Por ejemplo, mientras que en OpenViBE Designer genera archivos .csv por cada usuario, en el Tobii Pro Lab pueden exportarse todos los experimentos en un solo archivo .xlsx y de ahí obtener solo las métricas de interés.

Por otro lado, en cuanto a los datos provenientes del formulario, Google Forms tiene la opción de exportar las respuestas registradas también como archivo en formato .csv.

En resumen, luego de obtener los datos de las tres fuentes de interés (EEG, *Eye Tracking* y formulario), se combinaron las variables de interés en un solo *dataset* con 35 instancias (una instancia por usuario), para su posterior análisis con Ciencia de Datos. Para más detalle sobre las variables seleccionadas (consúltese **sección 4. Instrumentos y Medidas**).

3.4 MEDIDAS DE CONTROL

Durante cualquier experimentación es necesario controlar el ambiente y evitar cualquier tipo de distracción para el equipo de trabajo y en especial para el usuario. Para ello, y como ya se describió brevemente, todas las pruebas fueron llevadas a cabo en los laboratorios de Industria de SW del Edificio 204 y el laboratorio de cómputo del edificio 54, ambos en el campus central de la UAA.

Siempre se procuró un espacio tranquilo, con los equipos necesarios previamente calibrados y configurados antes de realizar alguna prueba con algún usuario. Además, antes de comenzar cada prueba, se le explicó al usuario el protocolo experimental y se le proporcionó una carta de consentimiento informado (la cual se detallará en la **sección 5. Consideraciones Éticas**). En la Fig. 34 se muestra evidencia de las pruebas experimentales llevadas a cabo en laboratorio de Industria de SW.

Ya que se realizó una descripción detallada del proceso experimental, es turno de abordar a profundidad los pasos siguientes a la experimentación. Para ello, a continuación, se muestra la sección Instrumentos y Medidas.




Fig. 34 Evidencia de las pruebas experimentales (Elaboración del equipo de trabajo, 2023).

4. INSTRUMENTOS Y MEDIDAS

Antes de pasar al análisis de datos, es importante mencionar cómo se obtuvieron los datos provenientes de la experimentación. Para ello, a continuación, se muestran las secciones relativas a los instrumentos de recolección de datos que se utilizaron, es decir, el *Eye Tracker*, la diadema Mindwave Mobile 2, las variables relacionadas con ambos dispositivos, y el formulario en Google Forms.

4.1 INSTRUMENTOS DE RECOLECCIÓN DE DATOS

Como ya se describió brevemente, para la recolección de datos se utilizaron tres fuentes principales:

- **Eye Tracking:** Tobii Pro Nano (revise Fig. 12), dispositivo de seguimiento de mirada basado en reflejo de córnea y pupila de alta precisión y exactitud Frecuencia de muestreo de 60Hz (Tobii AB, 2023). Se trabajó en conjunto con el *Eye Tracker Manager* para la instalación y calibración, y con el Tobii Pro Lab para la ejecución de los experimentos y la extracción de variables de seguimiento de mirada.
- **EEG:** MindWave Mobile 2 (revise Fig. 15), diadema para medición y extracción de las potenciales espectrales de cada banda de frecuencia del EEG. También mide atención y meditación. Frecuencia de muestreo de 512Hz (NeuroSky, 2021). Se trabajó en conjunto con el OpenViBE Acquisition Client para establecer la conexión Bluetooth con la computadora, y con el OpenViBE Designer para realizar la adquisición y registro de las señales EEG.

- TESIS TESIS TESIS TESIS TESIS
- **Cuestionario de UX:** Formulario en Google Forms (revise Fig. 31), diseñado para medir la experiencia de aprendizaje inspirado en un formulario de UX tradicional en escala de Likert (las opciones de respuesta van de “Muy mala” a “Muy buena”). Los enunciados que conformaron el cuestionario fueron:
 - “Entendí los temas tratados en el video:”
 - “La claridad con que se explicó el tema fue:”
 - “El contenido audiovisual fue:”
 - “La capacidad del video para llamar mi atención fue:”
 - “Considero que mi experiencia de aprendizaje fue:” (La respuesta a esta pregunta fue considerada como la clase en el *dataset* final).

4.2 VARIABLES DE ET

El Tobii Pro Lab (software oficial del fabricante), es una herramienta bastante completa que permite adquirir una gran cantidad de variables relacionadas con el experimento ejecutado con *Eye Tracking*. Hasta la fecha de realización del experimento (noviembre del 2023), se permitía exportar aproximadamente 80 variables distintas. Por cuestiones de simplicidad, se decidió trabajar con las siguientes variables, pues son las de mayor objetividad considerando todo el conjunto de variables disponibles en Tobii Pro Lab:

- Duración Total de Fijaciones Completas
- Duración Promedio de Fijaciones Completas
- Número Total de Fijaciones

Aunque en un inicio se definieron Tiempos de Interés (TOI, por sus siglas en inglés) por cada sección del video sobre POO, es decir, analizar la sección relativa a Clase, Objeto y los 4 pilares de la POO, al final se decidió utilizar las variables antes descritas por la duración completa del video, pues aportan una visión más general sobre la atención prestada al Objeto de Aprendizaje.

4.3 VARIABLES DE EEG

Con respecto a las variables de EEG, se trabajó con 10 señales provenientes directamente de la diadema. Estas fueron:

- Atención
- Meditación

Y las potencias espectrales de las siguientes ondas:

- Delta
- Theta
- Low Alpha
- High Alpha
- Low Beta
- High Beta
- Low Gamma
- Mid Gamma

A diferencia de las variables provenientes de *Eye Tracking* en Tobii Pro Lab, en OpenViBE se guardó registro por registro, para posteriormente obtener los valores promedios de cada señal durante todo el experimento (por participante) para finalmente juntarlos en el *dataset* que combinaba todas las variables.

4.4 FORMULARIO

Como ya se señaló, el cuestionario estuvo diseñado en Google Forms. Además de la facilidad de uso, también permite exportar las respuestas en un archivo .csv, que a la postre fue procesado para combinarlo con las variables procedentes de EEG y *Eye Tracking* y generar el *dataset* final. Este fue contestado por cada participante una vez terminada la experimentación. Contó con las preguntas descritas en la sección Cuestionario de UX, en Instrumentos de Recolección de Datos. Puede revisarse la Fig. 31 para ver una captura de pantalla de este.

5. CONSIDERACIONES ÉTICAS

Siempre es importante mantener transparencia hacia los participantes en un experimento, Por ello, antes de comenzar cada experimento, se les solicitó a los participantes que leyeran y firmaran una carta de consentimiento informado en la que se explicaba brevemente lo siguiente:

- Descripción de la actividad a realizar
- Tratamiento de los datos recabados
- Voluntariedad

- Contacto del líder de equipo de experimentadores (en este caso, fue uno de los alumnos de ICI).

En la carta se tenían que plasmar las firmas de tres involucrados:

- Participante / Usuario
- Experimentador
- Testigo (Comúnmente, el director del experimento)

Si bien en la carta se requerían datos personales de cada participante (nombre y firma), esto se realizó solo por motivos de control. En cuanto al tratamiento de datos personales recabados, siempre fueron tratados con estricta privacidad y únicamente con fines académicos. De hecho, en la construcción del *dataset* final, cualquier rastro de registro que pudiera identificar a algún participante, fue eliminado, pues no resulta de relevancia para el análisis de datos ni para el entrenamiento de los algoritmos de *Machine Learning*. Para ver a detalle el formato de la carta de consentimiento, consúltese el Anexo D.

6. ANÁLISIS DE DATOS

Ya se ha señalado que se obtuvieron datos de tres fuentes por cada participante, EEG, *Eye Tracking* y respuestas del Formulario. En esta sección, por tanto, se presentan los diferentes tratamientos y análisis que se le realizaron a estos conjuntos de datos para a la postre aplicar los algoritmos de *Machine Learning* con los cuáles generar las métricas necesarias y finalmente (en la sección de resultados), realizar las pruebas de hipótesis.

6.1 PREPROCESAMIENTO DE LOS DATOS

Mediante cada instrumento de recolección de datos se generaron archivos .csv o .xlsx que a la postre fueron combinados en un *dataset* final. En el caso del Tobii Pro Lab, se genera un archivo .xlsx que contiene la información de todos los participantes, por lo que la extracción de variables es muy directa y simple.

En el caso de los datos de EEG, como ya se explicó, se genera un archivo .csv por cada participante y la postre se juntan en uno solo obteniendo el promedio de cada variable; por otro lado, las respuestas provenientes del cuestionario se guardan en un solo archivo csv.

Estandarización de datos

La conjunción de todos los *datasets* en uno solo se realizó mediante un pequeño script de Python. Afortunadamente, y dado el tamaño de la muestra (35 participantes), no hubo datos nulos o errores en alguna variable (columna) o registro (instancia) del *dataset*. Por cuestiones de reducción en el coste computacional y mejor efectividad en los algoritmos de *Machine Learning* que se entrenaron, el *dataset* fue estandarizado con la función `StandardScaler` de `scikit learn` en Python. Esto ocasiona que todas las variables (salvo la clase) estén aproximadamente en un rango de -3 a 3, con media 0 y desviación estándar de 1. La estandarización se realiza con la siguiente ecuación (C. Aggarwal, 2015):

$$z_i^j = \frac{x_i^j - \mu_j}{\sigma_j}$$

Donde:

- z_i^j es el nuevo valor transformado o estandarizado.
- x_i^j es el valor original
- μ_j es la media de los valores en la columna (atributo)
- σ_j es la desviación estándar de los valores en la columna (atributo)

Una vez que el *dataset* fue estandarizado, se trabajó con él en un nuevo archivo de jupyter notebook de Python en Google Colab. En este ambiente, se cargó el *dataset* y se convirtió en un *dataframe* de Pandas (Fig. 35).

	Attention	Meditation	Delta	Theta	Low Alpha	High Alpha	Low Beta	High Beta	Low Gamma	Mid Gamma	Total duration of whole fixations	Average duration of whole fixations	Number of whole fixations	Forms: Understanding	Forms: Clarity	Forms: Audiovisual	Forms: Attraction	Forms: Experience
0	-0.033292	-0.027985	-0.782020	-0.080749	-0.084407	0.413818	-0.100883	-0.204204	-0.253486	0.047808	0.713200	-0.750714	0.758129	0.779813	0.677003	0.677003	-0.982467	2
1	0.900307	-1.325140	0.662957	1.264659	1.130588	0.920747	0.559767	-0.092586	0.233569	-0.327210	-1.248581	1.495029	-1.418698	-1.039750	-1.477098	-1.477098	0.827340	1
2	0.656454	-0.840028	-0.940576	-0.502993	-0.642788	-0.840518	-1.038499	-0.687612	-0.362571	-0.095525	0.633623	-0.940897	1.028454	0.779813	0.677003	0.677003	-0.827340	2
3	-1.954492	0.999160	0.829478	-0.316595	-0.584508	-0.642309	-0.572525	-0.608015	-0.467646	-0.865998	0.507377	-0.701015	0.829268	-1.039750	-1.477098	0.677003	-0.982467	1
4	-0.091054	1.051832	-0.612432	-0.535739	0.485906	2.079234	1.426766	0.561834	-0.249295	-0.294301	0.738449	-1.655903	3.646338	0.779813	0.677003	-1.477098	0.827340	2
5	-0.465721	-0.597186	-0.207906	0.339894	0.205778	0.014472	-0.396316	-0.422243	-0.403382	-0.358504	-1.516845	-1.080055	-0.223577	0.779813	-1.477098	0.677003	-0.982467	1
6	-1.906412	-0.518227	-0.803444	-1.013863	-1.334108	-1.470980	-1.724019	-1.175718	-0.969154	-1.123990	1.203854	1.241232	-0.536585	-1.039750	0.677003	-1.477098	-0.982467	2
7	1.000546	0.130596	0.694983	0.706089	0.553289	0.410236	0.588071	0.378222	0.550669	0.910441	0.602081	0.445381	-0.337356	-1.039750	-1.477098	-1.477098	-0.982467	1

Fig. 35 Captura de pantalla de las primeras 8 instancias del *dataframe* estandarizado (Elaboración propia, 2024).

Ajustes en la columna clase: Reducción de etiquetas y mapeo

La columna “Forms: Experience”, que correspondía a las respuestas de la última pregunta del cuestionario, fue la seleccionada como la clase, es decir, la variable a predecir. Sin

embargo, vale la pena volver a señalar que, aunque en el formulario había cinco opciones distintas para seleccionar, entre todos los participantes solo se escogieron las opciones “Muy Buena”, “Buena” y “Regular”, ajustando así la escala a 2, 1, 0 respectivamente. Es por ello por lo que en la Fig. 35 se observan dichos valores en esta columna.

Al revisar el balance de clases en la columna, las instancias correspondientes a cada una fueron:

- “Muy buena” → 16 instancias
- “Buena” → 17 instancias
- “Regular” → 2 instancias

La suma de las instancias de cada clase da un total de 35, correspondientes al total de participantes (y por ende sus registros) en el *dataframe*. Sin embargo, es muy notorio que la clase “Regular” está subrepresentada con respecto a las otras dos, por una amplia diferencia. Conocido este desbalance de clases, se optó por eliminar el par de registros pertenecientes a esta clase.

Esto implica varios puntos importantes:

- Por un lado, las respuestas de los participantes con respecto a cómo expresaron su experiencia de aprendizaje (con base en el formulario), fue positiva dada la amplia mayoría de respuestas “Buena” y “Muy Buena”.
- Y desde el punto de vista computacional, el problema pasa a ser uno de clasificación binaria, lo que provoca entonces un comportamiento distinto a si se abordara como un problema multiclase.

La principal razón de la eliminación de este par de registros radica justamente en lo ya mencionado, es decir, la clase está subrepresentada y no aporta información relevante con respecto a las otras dos clases. Por otro lado, al tratarse de un *dataframe* pequeño, habría que aplicar validación cruzada estratificada para tratar de garantizar la misma distribución de cada clase en cada pliegue, pero al solo existir dos registros, no podrían haberse generado más que dos pliegues, lo cual en términos prácticos no resulta en mucho beneficio.

Finalmente, y también por motivos de acondicionar el problema a un problema de clasificación binaria más tradicional, se realizó una recodificación de etiquetas con las clases que quedaron. Es decir, se realizó lo siguiente:

Mapeo de clases: {1: 0, 2:1}

Lo anterior simplemente significa que las etiquetas se ajustaron a la forma tradicional de un problema binario con representación con 1s y 0s, conservando siempre el mismo orden.

Generación de *dataframe* sin biométricos

Habiendo realizado los ajustes anteriores, y para realizar la comparación propuesta en la hipótesis de la investigación, a partir del *dataframe* completo (Fig. 35), se generó uno nuevo considerando únicamente las variables correspondientes a las respuestas del formulario. Estas fueron:

- *Forms: Understanding*
- *Forms: Clarity*
- *Forms: Audiovisual*
- *Forms: Attraction*
- *Forms: Experience* (La clase)

En la Fig. 36 puede observarse una captura de pantalla de los primeros 7 registros de este nuevo *dataframe*.

	Forms: Understanding	Forms: Clarity	Forms: Audiovisual	Forms: Attraction	Forms: Experience
0	0.779813	0.677003	0.677003	-0.982467	2
1	-1.039750	-1.477098	-1.477098	0.827340	1
2	0.779813	0.677003	0.677003	0.827340	2
3	-1.039750	-1.477098	0.677003	-0.982467	1
4	0.779813	0.677003	-1.477098	0.827340	2
5	0.779813	-1.477098	0.677003	-0.982467	1
6	-1.039750	0.677003	-1.477098	-0.982467	2

Fig. 36 Captura de pantalla del *dataframe* sin biométricos (Elaboración propia, 2024).

Considerando lo anterior, la idea central para probar la hipótesis es revisar si hay una diferencia real entre el desempeño de los algoritmos de *Machine Learning* (que se

abordarán en la sección siguiente) en el *dataframe* completo (con biométricos) y el *dataframe* sin biométricos (sólo con las variables del formulario). Dicho de otro modo, corroborar estadísticamente que los datos provenientes de *Eye Tracking* y EEG aportan más información para determinar la experiencia de aprendizaje de un sujeto que interactúa con un Objeto de Aprendizaje.

Cómo último paso previo a la aplicación de los Algoritmos de *Machine Learning*, cada *dataframe* se dividió en X e y , siendo X las variables predictoras e y la clase. En cada caso, X corresponde a:

- *Dataframe* completo: Variables de ET, EEG y cuatro primeras preguntas del formulario.
- *Dataframe* sin biométricos: Cuatro primeras preguntas del formulario.

Mientras que y es la columna “*Forms: Experience*” la cual ya se había abordado previamente.

6.2 APLICACIÓN DE ALGORITMOS DE APRENDIZAJE AUTOMÁTICO

Existen muchos algoritmos de *Machine Learning* que pueden aplicarse para abordar un problema de aprendizaje supervisado, y más específicamente uno de clasificación binaria, como en este caso. En esta sección, por tanto, se explica la selección de los modelos aplicados, así como su ajuste de hiperparámetros para maximizar su rendimiento.

Selección de modelos

Gracias a la experiencia con que se contaba luego de realizar los casos de estudio expuestos antes, se decidió realizar pruebas preliminares con distintas clases de algoritmos. Por ejemplo, se probaron algoritmos basados en árboles como Bosques Aleatorios (*Random Forest*) o XGBoost, sin embargo, luego de algunas pruebas iniciales se decidió descartar la implementación de esta clase de algoritmos, pues en general no tenían un desempeño tan sobresaliente (posiblemente por el número de instancias).

Además de los algoritmos antes mencionados, y dada la naturaleza del problema (clasificación binaria), se decidió probar también tres algoritmos más, muy populares también en este tipo de problemas y general con muy buen desempeño. Estos fueron la

Regresión Logística (*Logistic Regression*), KNN y Máquinas de Soporte Vectorial (SVM).

La Regresión Logística es uno de los más populares para problemas de clasificación binaria, mientras que KNN se basa en proximidad entre instancias (de ahí procede su nombre – vecinos más cercanos, en español), y, por último, las Máquinas de Soporte Vectorial se basan en la búsqueda del mejor hiperplano para maximizar la separación entre clases.

En pruebas preliminares, estos tres algoritmos fueron los que mejor desempeño tuvieron por lo que fueron los seleccionados para ser entrenados con ambos conjuntos de datos.

Ajuste de hiperparámetros

Cada modelo de *Machine Learning* tiene hiperparámetros que deben ajustarse para maximizar su rendimiento en el entramiento con un conjunto de datos. Si bien, podrían entrenarse sin ningún ajuste específico, esto no es lo adecuado, pues ocasionaría que los modelos realizaran predicciones sin aprovechar todo su potencial.

Si bien, los hiperparámetros pueden ajustarse “a mano”, o empíricamente, utilizando los valores típicos dentro de los rangos comúnmente utilizados para cada modelo, existen herramientas para encontrar la mejor combinación de estos en un rango especificado de manera automática. Tal es el caso de la función `GridSearchCV` de `scikit learn`, utilizada para realizar una búsqueda exhaustiva de la combinación de los mejores hiperparámetros para maximizar el rendimiento de un algoritmo de *Machine Learning* (Scikit Learn, 2024).

Aunque esta función es muy popular, existe una alternativa más completa para elegir los mejores hiperparámetros de un modelo. Se trata de un *framework* llamado Optuna, utilizado también con el mismo fin, pero que funciona con el uso de técnicas de optimización avanzada. Fue la técnica utilizada para encontrar la mejor optimización de los hiperparámetros de cada modelo y su funcionamiento en general es el siguiente (Akiba et al., 2019):

- **Definición de espacio de búsqueda:** Mediante funciones propias de Optuna, se define el espacio de búsqueda para los hiperparámetros.

- **Objetivo de Optimización:** Se define una función objetivo para optimizar El modelo se entrena en esta función y se devuelve una métrica de rendimiento (por ejemplo, Exactitud, F1-Score, Precisión, Recobro, etc.).
- **Ejecución del estudio:** Se crea un estudio de Optuna para ejecutar la optimización y hallar los mejores hiperparámetros.

Este procedimiento fue aplicado con los tres modelos antes descritos, Regresión Logística, KNN y SVM y en dos versiones distintas para cada modelo, pues debe recordarse que se generaron dos conjuntos de datos (con y sin biométricos). Es decir, cada modelo de *Machine Learning*, fue optimizado para encontrar la mejor combinación de hiperparámetros con cada *dataframe*.

Como ejemplo, en la Fig. 37 se muestra una captura de pantalla del segmento de código sobre la optimización del KNN en el *dataframe* con biométricos, y en la Fig. 38 se muestra una captura similar, pero referida al *dataframe* sin biométricos. A primera instancia ambos segmentos de código pueden parecer iguales, sin embargo, la diferencia radica en los conjuntos de datos que se utilizan para realizar la optimización. Para el *dataframe* con biométricos, se utilizan X e y, mientras que, para el otro conjunto, X_Sin e y_Sin.

```
from sklearn.neighbors import KNeighborsClassifier

# Definir la función de objetivo para Optuna
def objective(trial):
    params = {
        'n_neighbors': trial.suggest_int('n_neighbors', 3, 20),
        'weights': trial.suggest_categorical('weights', ['uniform', 'distance']),
        'p': trial.suggest_int('p', 1, 5),
    }

    model = KNeighborsClassifier(**params)

    # Realizar validación cruzada estándar
    cv_scores = cross_val_score(model, X, y, cv=5, scoring='f1')

    # Retornar la media de los puntajes de validación cruzada como el valor objetivo para Optuna
    return cv_scores.mean()

# Crear el estudio de Optuna y optimizar los hiperparámetros
study_knn = optuna.create_study(direction='maximize')
study_knn.optimize(objective, n_trials=100)

# Obtener los mejores hiperparámetros encontrados
best_params_knn = study_knn.best_params
print("Mejores hiperparámetros encontrados para KNN:", best_params_knn)
```

Fig. 37 Captura de pantalla sobre el código relativo a la optimización de hiperparámetros del KNN en el *dataframe* con biométricos (Elaboración propia, 2024).

```

# Definir la función de objetivo para Optuna
def objective(trial):
    params = {
        'n_neighbors': trial.suggest_int('n_neighbors', 3, 20),
        'weights': trial.suggest_categorical('weights', ['uniform', 'distance']),
        'p': trial.suggest_int('p', 1, 5),
    }

    model = KNeighborsClassifier(**params)

    # Realizar validación cruzada estándar
    cv_scores = cross_val_score(model, X_Sin, y_Sin, cv=5, scoring='f1')

    # Retornar la media de los puntajes de validación cruzada como el valor objetivo para Optuna
    return cv_scores.mean()

# Crear el estudio de Optuna y optimizar los hiperparámetros
study_knn = optuna.create_study(direction='maximize')
study_knn.optimize(objective, n_trials=100)

# Obtener los mejores hiperparámetros encontrados
best_params_knn = study_knn.best_params
print("Mejores hiperparámetros encontrados para KNN:", best_params_knn)

```

Fig. 38 Captura de pantalla sobre el código relativo a la optimización de hiperparámetros del KNN en el *dataframe* sin biométricos (Elaboración propia, 2024).

El mismo ejercicio representado en el par de figuras anteriores fue realizado también para la Regresión Logística y para el SVM. Una vez terminadas las optimizaciones, se definieron los hiperparámetros de cada modelos en distintas listas, para luego ser utilizadas en la definición de los modelos para cada conjunto de datos. En la Fig. 37 se muestran los hiperparámetros establecidos para cada modelo en el *dataframe* con biométricos y en la Fig. 38 para el *dataframe* sin biométricos.

```

paramsLogR = {
    'C': 777780.3514383844,
    'penalty': 'l2',
    'random_state' : RANDOM_STATE
}

paramsKNN = {
    'n_neighbors': 12,
    'weights': 'uniform',
    'p': 1,
}

paramsSVM = {
    'C': 1.6883478631677344,
    'kernel': 'linear',
    'gamma': 'auto',
    'random_state' : RANDOM_STATE
}

```

Fig. 39 Parámetros de cada modelo en el *dataframe* con biométricos (Elaboración propia, 2024).

```

paramsLogR_S = {
    'C': 549723.369496033,
    'penalty': 'l2',
    'random_state' : RANDOM_STATE
}

paramsKNN_S = {
    'n_neighbors': 8,
    'weights': 'uniform',
    'p': 2
}

paramsSVM_S = {
    'C': 0.7683792761133359,
    'kernel': 'sigmoid',
    'gamma': 'scale',
    'random_state' : RANDOM_STATE
}
    
```

Fig. 40 Parámetros de cada modelo en el *dataframe* sin biométricos (Elaboración propia, 2024).

Finalmente, ya con los hiperparámetros optimizados para cada modelo en cada conjunto de datos, se realizó el entrenamiento utilizando validación cruzada con cinco pliegues, pues proporciona una ventaja dado el tamaño reducido de los conjuntos de datos (33 instancias cada uno). Así pues, en la siguiente sección se muestran los resultados obtenidos de acuerdo con las métricas de clasificación para cada modelo de *Machine Learning*.

6.3 VALIDACIÓN DE MODELOS Y MÉTRICAS

Para verificar el rendimiento de los modelos en cada conjunto de datos, se decidió utilizar tres métricas diferentes, estas fueron:

- F1-Score
- Índice de Jaccard
- Exactitud

La razón principal de utilizar estas métricas por encima de otras es debido a su importancia y uso común en los problemas de clasificación cuando las clases están equilibradas (o prácticamente equilibradas, como en este caso, 16 instancias de una y 17 de otra). Además, son excluyentes entre sí, es decir, calcular una métrica no determina la otra. Y, por último, todas varían en un rango de 0 a 1, mientras más cercano a 1, mejor.

A pesar de que existen otras métricas populares como Precisión o Recobro (*Recall*, en inglés), estas ya están incluidas implícitamente en el F1-Score, pues se calcula como (Thakur, 2020):

$$F_1 = \frac{2(P * R)}{(P + R)}$$

Donde:

- F_1 es el F1-Score
- P es la Precisión
- R es el Recobro

Por otro lado, la exactitud se calcula como (Thakur, 2020):

$$Exactitud = \frac{\text{Número de predicciones correctas}}{\text{Número total de predicciones}}$$

Y el índice o coeficiente de Jaccard como (IBM, 2021):

$$J(y, \hat{y}) = \frac{|y \cap \hat{y}|}{|y \cup \hat{y}|}$$

Donde:

- $J(y, \hat{y})$ es el Índice de Jaccard
- y son las etiquetas verdaderas
- \hat{y} son las etiquetas predichas

Por ende, el cálculo de estas tres métricas para cada modelo de *Machine Learning* permite establecer un escenario de comparación robusto y así determinar el desempeño de los modelos en cada conjunto de datos. Lo anterior, por tanto, conlleva a verificar si la incorporación de biométricos da una mayor explicación sobre la experiencia de aprendizaje.

6.4 INTERPRETACIÓN DE LOS RESULTADOS DE APRENDIZAJE AUTOMÁTICO

Luego de haber explicado brevemente las razones de utilizar las métricas antes descritas, estas fueron calculadas para cada modelo mediante funciones de scikit-learn, y con su respectivo conjunto de datos (con y sin biométricos).

Los resultados de F1-Score, Índice de Jaccard y Exactitud para los tres modelos en el conjunto de datos con biométricos se muestran en las Fig. 41, 42 y 43 respectivamente.




Fig. 41 Comparación de F1-Score de cada modelo, *dataframe* con biométricos (Elaboración propia, 2024).




Fig. 42 Comparación de Índice de Jaccard de cada modelo, *dataframe* con biométricos (Elaboración propia, 2024).

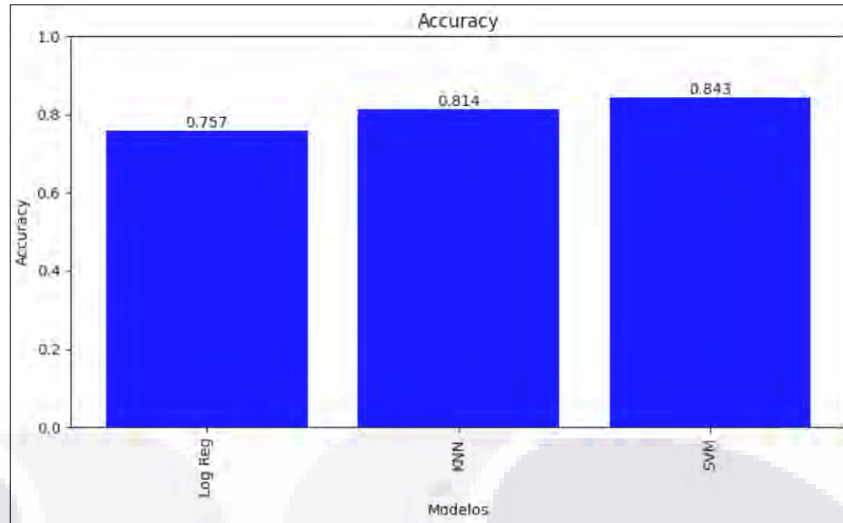


Fig. 43 Comparación de Exactitud de cada modelo, *dataframe* con biométricos (Elaboración propia, 2024).

Como ya se mencionó, las tres métricas varían en un rango entre 0 y 1, y mientras más cercanas se encuentren a 1, mejor, aunque valores mayores a 0.8, especialmente en F1-Score son considerados muy buenos.

Por lo anterior, puede apreciarse que el modelo que mejor puntaje tuvo en las tres métricas fue el SVM, demostrando por tanto el mejor desempeño en cuanto a clasificación se refiere. El segundo en orden fue el KNN, con valores ligeramente debajo de los obtenidos con SVM, mientras que la Regresión Logística fue el modelo con el desempeño más bajo, sobre todo en lo que se refiere al Índice de Jaccard.

Para el caso del F1-Score, Índice de Jaccard y Exactitud de los modelos en el *dataframe* sin biométricos, se muestran las Fig. 44, 45 y 46 respectivamente.




Fig. 44 Comparación de F1-Score de cada modelo, *dataframe* sin biométricos (Elaboración propia, 2024).




Fig. 45 Comparación de Índice de Jaccard de cada modelo, *dataframe* sin biométricos (Elaboración propia, 2024).




Fig. 46 Comparación de Exactitud de cada modelo, *dataframe* sin biométricos (Elaboración propia, 2024).

La primera gran diferencia que puede apreciarse con respecto a las gráficas de las figuras correspondientes al *dataframe* con biométricos, es que en este caso el SVM y el KNN tienen un igual comportamiento en las tres métricas. Es decir, ambos modelos empataron en puntaje al evaluar F1-Score, Índice de Jaccard y Exactitud. Mientras, la Regresión Logística demostró un desempeño muy similar al caso anterior, con valores muy similares, sin sobresalir en ninguna de las tres métricas.

Aritméticamente puede verse que, para la gran mayoría de los casos, los puntajes de las métricas de cada modelo fueron más altos en el *dataframe* con biométricos, que en el de sin biométricos. Esto se ilustra en las tablas 8 y 9, con una precisión de cuatro decimales, aunque en el código en Python fueron utilizados los valores completos. Además, para resaltar la diferencia, se muestran en verde los valores más altos, en rojo el caso contrario y en azul los valores empatados.

Tabla 8 Puntajes de cada modelo para F1-Score, Índice de Jaccard y Exactitud, *dataframe* con biométricos (Elaboración propia, 2024)

Modelo	F1-Score	Índice de Jaccard	Exactitud
Regresión Logística	0.7314	0.5900	0.7571
KNN	0.8314	0.7233	0.8142
SVM	0.8414	0.7366	0.8428

Tabla 9 Puntajes de cada modelo para F1-Score, Índice de Jaccard y Exactitud, *dataframe* sin biométricos (Elaboración propia, 2024)

Modelo	F1-Score	Índice de Jaccard	Exactitud
Regresión Logística	0.7380	0.5900	0.7238
KNN	0.8261	0.7200	0.7904
SVM	0.8261	0.7200	0.7904

Con la representación de las tablas es más claro lo antes afirmado, es decir que en general los modelos tuvieron un mejor desempeño cuando trabajaron con el *dataframe* con biométricos. Esto puede indicar que la incorporación de los datos de *Eye Tracking* y EEG aporta información de relevancia para comprender mejor la experiencia de aprendizaje. Sin embargo, de momento la comparación ha sido únicamente aritmética, por lo que no necesariamente es concluyente, además, si bien hay mejora, los valores son muy cercanos. Descrito en lo anterior, en el siguiente capítulo “Resultados”, se describe la prueba de hipótesis realizada mediante la prueba de signos de Wilcoxon, para tener un sustento de los resultados desde la inferencia estadística.

CAPÍTULO IV. Resultados

Como ya pudo observar en la sección anterior, los modelos se desempeñaron mejor con la incorporación de los datos de EEG y *Eye Tracking*, aunque la mejora no fue substancial (aparentemente) en términos puramente aritméticos. Es decir, la diferencia entre el desempeño de los modelos no parece ser de tanta relevancia. Es por lo anterior, que en esta sección se presenta la aplicación de la prueba de Wilcoxon, una prueba no paramétrica para realizar una validación estadística de los resultados. En este contexto, se utiliza para probar si realmente existe evidencia estadística de una mejora en los modelos cuando se trabaja con el *dataset* con biométricos, que sin él.

Esta prueba sirve directamente para validar la prueba de hipótesis (véase **Capítulo I: Planteamiento del Problema**), y según sus resultados, se rechaza o se acepta la hipótesis nula. Al igual que otras pruebas utilizadas en inferencia estadística, de fijarse el valor Alpha (nivel de significancia), el cual se comparará con el valor p obtenido en el cálculo de la prueba. Una descripción más a detalle sobre la prueba y sus resultados se muestra a continuación.

1. EVALUACIÓN DE LA HIPÓTESIS

El nombre completo de esta prueba es “Prueba de los rangos con signo de Wilcoxon”, y es utilizada para comparar si las medianas de dos muestras relacionadas son significativamente diferentes. Si bien existen pruebas más completas, por ejemplo, la prueba *t-student*, la prueba de Wilcoxon se acomoda mejor para poblaciones pequeñas (≤ 30), además, no se necesita verificar la distribución de los datos, como si se requiere en la prueba *t-student*. Es considerada una prueba no paramétrica. (Heckert et al., 2002).

1.1 FUNCIONAMIENTO DE LA PRUEBA DE WILCOXON

Esta prueba suele aplicarse cuando quiere medirse el efecto de algún procedimiento (o tratamiento, por ejemplo, en el caso de la medicina), comparando observaciones pareadas. Su funcionamiento es el siguiente (Heckert et al., 2002):

- 1) Calcular las diferencias entre observaciones pareadas, $d_i = X_i - Y_i$
- 2) Descartar las diferencias iguales a 0.

- 3) Ordenar las diferencias absolutas de forma ascendente.
- 4) Asignar rangos a las diferencias absolutas.
- 5) Asignar el signo de las diferencias calculadas en el punto 1) a los rangos.
- 6) Sumar los rangos positivos y negativos por separado, W_+ y W_- .
- 7) Tomar el estadístico de la prueba de Wilcoxon como el menor de las sumas W_+ y W_- .

En este caso, las observaciones pareadas corresponden a cada métrica de rendimiento calculada para cada modelo en cada conjunto de datos, es decir, F1-Score, Índice de Jaccard y Exactitud (Tablas 8 y 9).

1.2 VALOR ALPHA

Alpha (α) se refiere al valor de significancia (o significación) de la prueba (IBM, 2024) y representa la probabilidad de rechazar la hipótesis nula cuando en realidad es verdadera (error Tipo I). Comúnmente se establece en 0.05, es decir, existe un 5% de probabilidad de cometer un error Tipo I. El nivel de confianza de la prueba es el complemento de Alpha, es decir $1 - \alpha$.

Para el caso de la prueba planteada, se definió:

- $\alpha = 0.05$, y, por ende,
- Nivel de Confianza = 0.95.

1.3 VALOR P

Se refiere a la probabilidad de haber producido un resultado por casualidad. El valor p mide la evidencia contra la hipótesis nula. Si $p < \alpha$, se rechaza la hipótesis nula (y se acepta la hipótesis alternativa), lo que sugiere que hay evidencia suficiente para determinar que hay una diferencia significativa entre ambos conjuntos de datos (IBM, 2024) (para este caso, las métricas de las tablas 8 y 9).

1.4 ESTADÍSTICO DE WILCOXON.

Se refiere al resultado obtenido en el paso 7) del procedimiento descrito en el funcionamiento de la prueba de Wilcoxon. Al obtenerse, es comparado con una distribución conocida para obtener el valor p .

2. INTERPRETACIÓN DE LOS RESULTADOS DE LA PRUEBA DE WILCOXON

La prueba de Wilcoxon fue aplicada mediante una función contenida en el módulo *stats* de la librería *SciPy* en Python, por lo que su implementación es bastante directa y sencilla. En la Fig. 47 se observa el segmento de código en el que fue aplicada la prueba, así como sus resultados (Estadístico de Wilcoxon, valor p , y conclusión con base en la prueba).

```
[ ] # Wilcoxon

from scipy.stats import wilcoxon
# Aplicar la prueba de Wilcoxon
statistic, p_value = wilcoxon(metrics_full, metrics_Sin, alternative='greater')

# Imprimir el estadístico de la prueba y el valor p
print("Estadístico de la prueba de Wilcoxon:", statistic)
print("Valor p:", p_value)

# Interpretar los resultados
alpha = 0.05
if p_value < alpha:
    print("Hay una diferencia significativa entre los conjuntos de datos.")
else:
    print("No hay una diferencia significativa entre los conjuntos de datos.")
```

```
↔ Estadístico de la prueba de Wilcoxon: 40.0
Valor p: 0.01953125
Hay una diferencia significativa entre los conjuntos de datos.
```

Fig. 47 Implementación de la prueba de Wilcoxon en Python (Elaboración propia, 2024).

A continuación, se remarcan varios puntos importantes contenidos en la Fig. 47:

- Se aplica la función `wilcoxon` dándole como argumentos el listado de las métricas correspondientes al conjunto de datos con biométricos (`metrics_full`), el listado de las métricas del conjunto de datos sin biométricos (`metrics_Sin`), y fijando `alternative='greater'`, lo que sirve para comparar si el conjunto `metrics_full` es

mayor a *metrics_sin*. Lo anterior se debe fijar dado que la prueba de Wilcoxon permite conocer si los conjuntos son estadísticamente iguales, o diferentes (teniendo en cuenta cuál es más grande o pequeño).

- Esta prueba produce dos resultados, el estadístico de Wilcoxon (que dio como resultado 40.0) y el valor p , calculado a partir del estadístico de Wilcoxon y que dio como resultado 0.01953125.
- Dado que el valor p es menor al valor α ($0.01953125 < 0.05$), se rechaza la hipótesis nula (y por ende se acepta la hipótesis alternativa), concluyendo que:
 - o **Existe una diferencia significativa entre los conjuntos de datos.**
- Y dado que se fijó el parámetro *alternative= 'greater'*, en la función, también puede concluirse que:
 - o **El conjunto de datos con biométricos fue mayor que el conjunto sin biométricos.**

Esto implica entonces que, para los modelos de *Machine Learning* entrenados (Regresión Logística, KNN y SVM), en los dos conjuntos de datos (con y sin biométricos), con las métricas de rendimiento seleccionadas (F1-Score, Índice de Jaccard y Exactitud), existe una diferencia significativa en la información que aportan los datos provenientes de EEG y *Eye tracking*, con respecto al sólo uso de la información proveniente del cuestionario basado en *UX*.

3. VALIDACIÓN DE LOS RESULTADOS

Con los resultados obtenidos se puede rechazar la hipótesis nula, tomando entonces la hipótesis alternativa, de este modo:

Hipótesis alternativa (H1): Existe una diferencia significativa en los resultados del modelo de evaluación de experiencia de aprendizaje con la utilización de EEG y *Eye Tracking* con respecto a un modelo de *UX* tradicional, gestionado con Ciencia de Datos.

Aunque bien, es importante remarcar la especificación que se señaló en la última parte de la sección anterior. Es decir, esta conclusión fue válida con los modelos entrenados, utilizando

estos conjuntos de datos (con la muestra estadística asociada, referente a participantes), y con las métricas de *Machine Learning* que se aplicaron.

Para generalizar, será necesario experimentar en otros escenarios, por ejemplo, ampliando el número de participantes, explorando otras variables de EEG o *Eye Tracking*, probando otro Objeto de Aprendizaje, o realizando pruebas con otros modelos de *Machine Learning*. Existen pues, muchas variables o factores que pueden contribuir para el ajuste de un experimento a futuro que corrobore los resultados aquí obtenidos.

Finalmente, debe hacerse notar que este capítulo estuvo centrado en los resultados a partir de la prueba de hipótesis, sin embargo, si se desea conocer los resultados concernientes a cada caso de estudio, pueden consultarse en cada uno de los n experimentos. Por otro lado, los información sobre los procedimientos y resultados procedentes de la aplicación de los algoritmos de *Machine Learning* pueden consultarse en el **Capítulo III. Metodología de Investigación, sección 6.2 Aplicación de Algoritmos de Aprendizaje Automático.**

DISCUSIONES DE RESULTADOS

La sección aquí presentada es fundamental para este trabajo de investigación. Su principal objetivo es interpretar y analizar con mayor profundidad los resultados presentados en la sección anterior. Está compuesta de varias subsecciones, como son la interpretación de los resultados, en la que se revisa la implicación de los resultados con respecto a las preguntas y objetivos de investigación; una breve recapitulación de la literatura que sirvió como base; un análisis de los patrones y tendencias; una sección sobre la consideración de limitaciones y sesgos; implicaciones prácticas y teóricas, así como la propuesta del *framework* final y por último las sugerencias para futuras investigaciones.

INTERPRETACIÓN DE LOS RESULTADOS

En esta subsección se revisa de manera más profunda la implicación de los resultados en relación con la preguntas y objetivo de investigación generales (estos se presentan nuevamente para una mejor referencia; para revisar las preguntas y objetivos específicos, consúltese el **Capítulo I. Planteamiento del Problema, subsecciones 4 y 5** respectivamente).

Pregunta general de investigación.

¿Cómo puede generarse un modelo de evaluación de Experiencia de Aprendizaje a partir de la UX, el *Eye Tracking* y el EEG gestionada con Ciencia de Datos?

Objetivo general de investigación.

Definir las adaptaciones y elementos que compongan al modelo de Experiencia de Aprendizaje a partir de la UX resaltando principalmente las técnicas biométricas de *Eye Tracking* y EEG y su gestión mediante Ciencia de Datos.

Como ya es sabido, el objetivo está planteado para tratar de responder a la pregunta de investigación. Y a su vez, en cualquier investigación el objetivo debe cubrirse con los resultados. Para este caso, los resultados obtenidos de la prueba de hipótesis de Wilcoxon demostraron que sí existió una diferencia significativa en el desempeño de los modelos de

Machine Learning que fueron entrenados y validados con el conjunto de datos que contenía biométricos, con respecto a su similar sin biométricos.

Aunque el objetivo está definido con respecto a la definición de un modelo o *framework* (que se presenta más adelante en esta misma sección de Discusiones) de experiencia de aprendizaje, la prueba de hipótesis ayuda a validar la creación de este modelo.

Desglosando el objetivo, es claro que el modelo o *framework* debe estar compuesto de tres elementos esenciales:

- Basado en UX
- Involucrando técnicas biométricas de *Eye Tracking* y EEG.
- Gestionado con Ciencia de Datos.

Lo anterior se logró favorablemente dado que, se utilizó un cuestionario tradicional de UX, basado en escala de Likert, además de la implementación de las tecnologías biométricas de *Eye Tracking* con el Tobii Pro Nano, y EEG con la diadema MindWave Mobile 2, en la captura de datos; y que por último estos datos fueron procesados y analizados con algoritmos y técnicas de Ciencia de Datos (aplicando *Machine Learning* y áreas afines). Además, debe señalarse que, dado que está orientado al aprendizaje, el objeto de estudio con el que se planteó este modelo fue justamente un Objeto de Aprendizaje (El video sobre POO).

Más detalles con respecto al modelo se presentan en la sección *Framework* Final.

RECAPITULACIÓN DE LA LITERATURA BASE

En la RSL, del **Capítulo II. Referentes Teóricos**, se mostró un estudio muy detallado sobre los trabajos de investigación más relacionados con este proyecto. Se siguió un método riguroso basado en los lineamientos de (Kitchenham & Charters, 2007). Se desarrolló un protocolo (Anexo B) y como resultado final de la RSL se generó una tabla concentrando todos los trabajos de investigación finales que pasaron todos los filtros descritos en la sección RSL, Capítulo II, acompañados de una breve explicación de su relevancia con respecto a esta investigación de acuerdo con el cumplimiento de unos criterios de calidad definidos previamente. Debido a su extensión, esta tabla se presenta por separado en el Anexo C.

Puede observarse que al final de la RSL, de un total de 415 trabajos consultados, sólo 28 tuvieron relación directa con el tema de investigación de este proyecto, y sus temáticas o líneas de investigación se centraban en alguna de las siguientes categorías:

- Modelo o *framework* de *UX* orientado al aprendizaje.
- Modelo o *framework* de procesamiento de datos conjunto de EEG o *Eye Tracking*, sea o no con relación al *UX*.
- Investigaciones de EEG o *Eye Tracking* con relación al aprendizaje o alguna de sus áreas.

De estos 28 trabajos, ninguno tiene la misma finalidad que este proyecto de investigación, aunque sí existieron algunos que sirvieron como base para plantear elementos del *framework*, por ejemplo, y como ya se expuso en el capítulo II, el modelo ExodUX propone un modelo de aprendizaje interactivo que contempla la integración de varias categorías de experiencia: estética, interacción, mente del usuario, configuración o tecnología, las cuales sirvieron para construir el Objeto de Aprendizaje sobre POO (consúltese **Capítulo III. Metodología de Investigación, sección 3.2 Tecnología**).

En lo referente a la gestión mediante Ciencia de Datos, tal cual se explica en la sección 1.6 Resultados de la RSL en el Capítulo II, los algoritmos de *Machine Learning* más comúnmente utilizados fueron SVM (Shi et al., 2017; Zheng et al., 2014) o KNN (López-Gil et al., 2016), dos de los algoritmos (junto con la Regresión Logística), aplicados en este proyecto de investigación.

Para una revisión más específica sobre los procesos o resultados del RSL, consúltese el **Capítulo II, Sección 1. Revisión Sistemática de la Literatura (RSL)**.

PATRONES Y TENDENCIAS

Una parte importante de este capítulo es analizar los patrones y tendencias que pueden existir entre las variables y la clase. Esto es relevante ya que de esta manera puede tomarse en cuenta qué atributos en el *dataset* son más relevantes para el *framework*, es decir, cuáles aportan más información para determinar la experiencia de aprendizaje. Este análisis puede realizarse mediante distintas técnicas. Desde el punto de vista de la Ciencia de Datos, existen métricas que permiten identificar esta relevancia de atributos utilizando diferentes técnicas. En esta sección se presentan *Mutual Information* y *Permutation Importance*.

Estas métricas provienen de un campo del *Machine Learning* conocido como Ingeniería de Atributos (en inglés, *Feature Engineering*) y más específicamente de un campo conocido

como métricas de calidad de atributos (en inglés, *Feature Utility Metrics*) y son básicamente funciones para medir la asociación entre los atributos y las clases.

Antes de entrar de lleno en la aplicación de estas métricas, debe señalarse que este análisis sólo se realizó sobre el *dataset* con biométricos, pues como ya se observó, aporta más información para determinar la clase, y lógicamente, al tener más variables (17) que el *dataset* sin biométricos, puede realizarse un análisis más profundo.

MUTUAL INFORMATION

Mutual Information funciona muy parecido a una correlación. En términos simples, mide cómo el grado de conocimiento de una variable (atributo) reduce la incertidumbre sobre la otra (Holbrook, 2021). Su aplicación común en Ciencia de Datos es para conocer el grado de importancia que tienen las variables de un *dataset* con respecto a la clase. Además, a diferencia de *Permutation Importance*, *Mutual Information* es agnóstica de modelo, lo que quiere decir que no depende de un modelo de aprendizaje (sea Regresión Logística, Árboles de Decisión, KNN, etc.).

Al aplicar *Mutual Information* y ranquear los valores de más grande a más pequeño, se obtienen los resultados de la Fig. 48.




Fig. 48 *Mutual Information* aplicado *dataset* con biométricos (Elaboración propia, 2024).

Para esta métrica, la variable que más información aporta para conocer la clase es “*Forms: Clarity*” del formulario de *UX*, lo que guarda sentido, pues las preguntas estaban estrechamente relacionadas entre sí. Sin embargo, en lo concerniente a las variables biométricas, es interesante destacar que, con base en esta métrica, solo las variables de EEG tienen importancia, siendo la potencia espectral de *Delta* la de mayor aporte de información, mientras que le siguen *Low Beta*, *High Beta*, *Theta*, la señal de Meditación y otras más de menor valor.

Es interesante notar que las variables de *Eye Tracking*, así como la señal de atención de EEG no tienen siquiera información que aportar a la clase, claro, desde el punto de vista del *Mutual Information*. Esto no quiere decir que después de este análisis haya que desechar estos atributos sin problema alguno, pues deben analizarse también los resultados de *Permutation Importance*, aunque idealmente debería existir un cierto grado de coherencia entre las variables más importantes en ambas métricas.

PERMUTATION IMPORTANCE

Esta métrica, a diferencia de *Mutual Information*, es dependiente del modelo de aprendizaje con el que se trabaja en el sentido en que sólo puede aplicarse una vez que este ha sido ajustado. Por otro lado, tiene la ventaja de poder aplicarse con cualquier modelo.

De manera sencilla, su funcionamiento se basa en medir la importancia de las variables (atributos), al permutar de manera aleatoria sus valores (es decir los valores en la columna correspondiente a esa variable en el *dataset*) y evaluar cómo esto afecta al rendimiento del modelo. Luego de realizar este procedimiento con una variable en concreto, los valores son reordenados a su forma original y nuevamente se repite este proceso con la variable (columna) siguiente del *dataset* (Becker, 2021).

Se aplicó *Permutation Importance* a cada modelo con el que se trabajó, Regresión Logística, KNN y SVM obteniendo las gráficas de la Fig. 49. Un valor positivo más alto en esta métrica significa que tiene mayor impacto en la clasificación, mientras que un valor negativo o cercano a 0 significa que esa variable no afecta o no tiene demasiada importancia en términos del rendimiento del modelo (exactitud, F1-Score). En el caso de

la Fig. 49, se muestran los resultados con base en el rendimiento de exactitud para cada modelo.




Fig. 49 Cálculo de *Permutation Importance* para cada modelo (Regresión Logística, KNN y SVM) basado en Exactitud (Elaboración propia, 2024).

Puede observarse que a diferencia del *Mutual Information*, con *Permutation Importance* la influencia de cada variable es muy distinta según cada modelo de aprendizaje, aunque existen ciertas similitudes, por ejemplo, “*Forms Clarity*” sigue siendo la variable más relevante en los modelos de Regresión Logística y SVM. En el caso de KNN, aunque ocupa el 7mo lugar, sigue siendo muy importante, con una magnitud similar a las dos variables precedentes a ella (*Theta* y *Low Alpha*).

Con respecto a las variables de EEG, para cada modelo hay por lo menos presencia de tres ellas en el top 5 de cada modelo. Para el caso de la Regresión Logística son *Delta*, *Low Beta* y *Mid Gamma*; para KNN son *High Beta*, *Low Gamma* y *Mid Gamma*; y para SVM son *Mid Gamma*, *Low Beta* y *High Alpha*.

Para el caso de las variables de *Eye Tracking*, a diferencia de *Mutual Information*, donde prácticamente no son consideradas en el ranking, en este caso presentan comportamientos muy distintos. Es de destacarse que “*Average duration of whole fixations*” está en 3er puesto para Regresión Logística, mientras que “*Total duration of whole fixations*” está en segundo lugar (con una magnitud mucho más alta a sus variables sucesoras) en el caso del KNN.

Por otro lado, la variable que tuvo un desempeño más pobre para casi todos los casos fue “*Number of whole fixations*”, siendo solo relevante para KNN. Finalmente, para SVM, ninguna variable de *Eye Tracking* fue relevante.

Es interesante como en el caso de la Regresión Logística, el top 3 de variables con mayor importancia es casi el mismo que el obtenido según *Mutual Information*, salvo por la variable de *Eye Tracking* que sí está presente en esta ocasión, aunque inmediatamente atrás se encuentra *Low Beta*, que sí está en *Mutual Information*.

CONSIDERACIÓN DE LIMITACIONES Y SESGOS

Elaborar un marco de trabajo conlleva también su implementación para probar con un caso de estudio. Como pudo observarse en los resultados antes expuestos, aunque la hipótesis se corroboró, se delimitó al alcance y contexto específico en que fue probada. Como recapitulación, se trabajó a partir de un *dataset* con variables provenientes de un formulario de *UX* común, de *Eye tracking* y de EEG, conformado desde el trabajo con poco más de 30 usuarios y con un OA específico. Además, fueron entrenados tres modelos de *Machine Learning* (Regresión Logística, KNN y SVM), en un problema de clasificación binaria. Lo

anterior implica que el *framework* está definido bajo unas condiciones muy específicas, y por ende no puede asegurarse que se obtendrán los mismos resultados bajo otras circunstancias. Es relevante pues, denotar que existen limitaciones evidentes, pero esto no representa un problema per se, sino una oportunidad para probar el modelo en escenarios distintos, lo que puede ayudar para encontrar puntos débiles o reforzar algunos otros.

Por otro lado, aunque no concierne al *framework*, sino a los datos con los que se trabajó, se explicó que inicialmente únicamente se tenía presencia de 3 clases, siendo que las opciones totales en el formulario correspondían a 5 (basado en escala de Likert, de “Muy malo” a “Muy bueno”). Esto implicó que dos de las opciones no fueron tomadas en cuenta por los participantes del experimento. Y más aún, cuando se revisó el *dataset* resultante una vez acabadas las pruebas, se notó que la clase correspondiente a “Regular”, estaba subrepresentada, con solo 2 instancias, por lo que decidió descartarse. Lo anterior provocó que, aunque en un inicio se intentaba plantear un problema de clasificación multiclase, finalmente se adecuó a uno de clasificación binaria.

Esto puede entenderse como un sesgo en cuanto a las respuestas, derivado tal vez, del OA con que se trabajó. Así pues, utilizar otro OA, o incluso modificaciones en cuanto a cómo se plantearon las preguntas del formulario (en específico la relativa a la clase) puede provocar mayor presencia de clases en el *dataset* y por ende sí trabajarse como un problema multiclase.

IMPLICACIONES PRÁCTICAS Y TEÓRICAS

Con este proyecto de investigación se pretende dejar un precedente en la combinación de las áreas y tecnologías que lo componen aplicadas a la experiencia de aprendizaje. Mucho se habla hoy en día de tecnologías emergentes o de la aplicación de la Inteligencia Artificial en tantos ámbitos de la vida cotidiana. En este caso, aunque se trabaja con elementos muy puntuales de diversas áreas del conocimiento, se demuestra que un problema que podría considerarse tradicionalmente del área de la educación y abordarse sólo con métodos tradicionales, también puede ser impactado desde otras perspectivas si se trabaja con la ayuda de otras ciencias.

En la práctica, como ya se mencionó en la sección anterior, hay ciertas limitaciones y sesgos que fueron bien descritas, pero sientan también un antecedente para que se exploren nuevas

combinaciones de OAs, mayor número de participantes, pruebas con distintos algoritmos de *Machine Learning*, etc. para robustecer esta área de estudio.

En la teoría, una vez que se vayan generando nuevos proyectos similares, no necesariamente basados en este, pero sí con un enfoque parecido, podrán definirse los elementos que mejor refinen el modelo. Solo por tomar un ejemplo, cada día se realizan nuevos proyectos con *Eye Tracking*, lo que permitirá experimentar y teorizar sobre el impacto o beneficio de esta tecnología en este campo, tomando tal vez nuevas variables, métricas o índices.

En resumen, este proyecto de investigación buscó proponer una nueva perspectiva para investigar y abordar la experiencia de aprendizaje, sobre todo desde el campo de las ciencias de la computación, lo que conllevó grandes retos (combinar y probar tecnología), pero también grandes avances.

PROPUESTA DE FRAMEWORK FINAL

Ya en este punto, puede integrarse todo lo discutido anteriormente para la generación del modelo o *framework* final. Vale la pena referenciar la Fig. 29, pues fue el boceto inicial del modelo a partir del cual se realizó la experimentación principal.

Debido a la integración e implementación de las tres principales áreas o tecnologías que abarcó el proyecto de investigación, se decidió nombrar al modelo como UXEEGET (combinación de *UX*, *EEG* y *Eye Tracking*). Dándole así un nombre reconocible y simple de recordar.

De ahora en adelante entonces, se refiere al *framework* mediante este nombre. En la Fig. 50 se muestra UXEEGET con los elementos que lo componen y la descripción al respecto se presenta a continuación:

- **UX:**

Principal área de la Ingeniería de Software en la que se basa el modelo. Representada mediante un cuestionario tradicional en escala de Likert una vez terminada la interacción con el OA. Para futuras versiones pueden explorarse otros instrumentos de evaluación de *UX*.

- **EEG:**

Una de las dos tecnologías biométricas implementadas. Implementada para conocer información objetiva sobre la experiencia de aprendizaje. Se adquieren las potencias espectrales de las señales de Delta, Theta, Alpha, Beta y Gamma (necesario especificar

que la diadema MindWave Mobile 2 divide cada señal en dos rangos, consúltese Capítulo III Metodología de Investigación, Sección 4.3), además de las señales de Atención y Meditación. Para futuras implementaciones del modelo pueden probarse otros dispositivos de adquisición.

- **Eye Tracking:**

La segunda tecnología biométrica implementada. Utilizada también para obtener información objetiva, en este caso relativa al comportamiento visual. En el caso del *Eye Tracking*, se utilizaron las variables: Duración Total de Fijaciones Completas (DTFC), Duración Promedio de Fijaciones Completas (DPFC) y Número Total de Fijaciones (NTF). Para futuras modificaciones del modelo pueden explorarse distintas o más variables de *Eye Tracking*, dependiendo siempre del dispositivo y software de adquisición con el que se cuente.

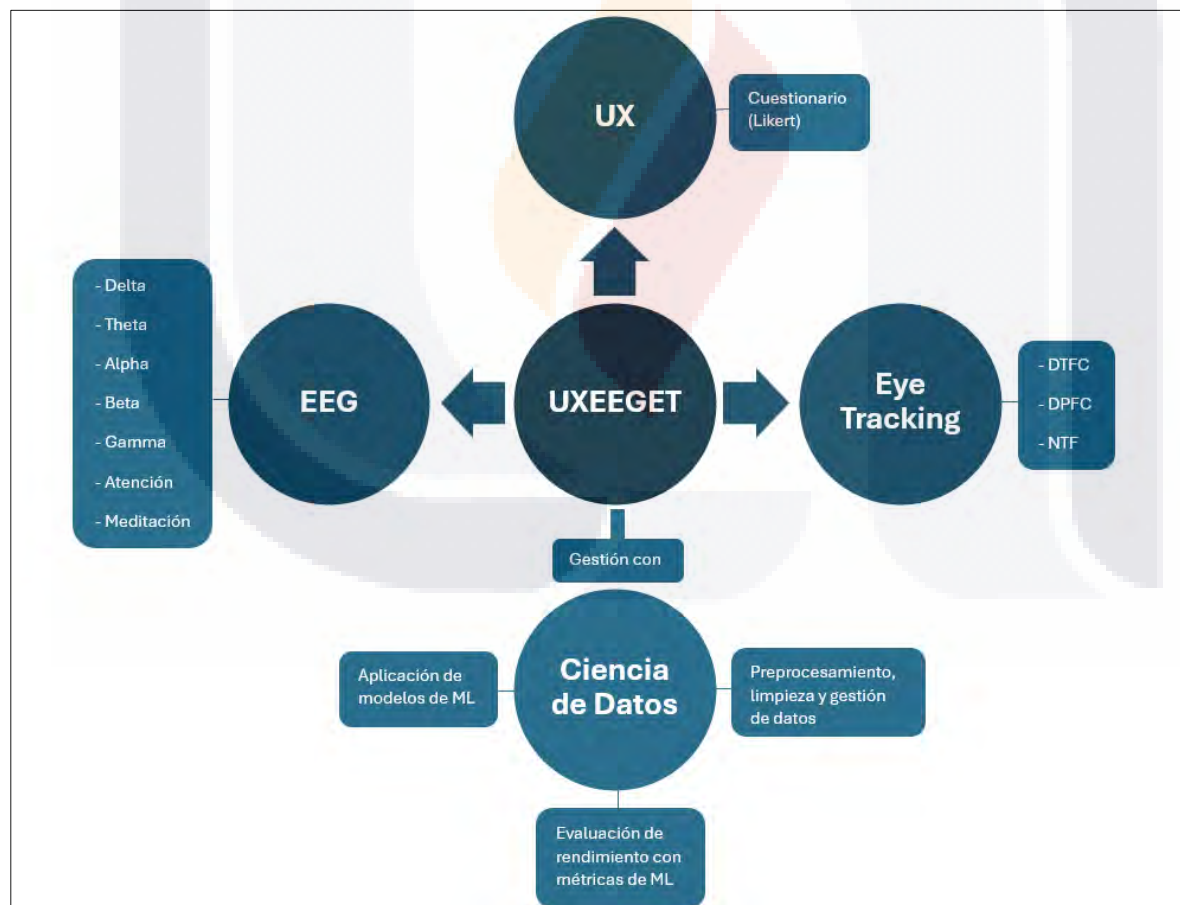


Fig. 50 Framework UXEEGET. Modelo para evaluación de experiencia de aprendizaje (Elaboración propia, 2024).

- **Ciencia de Datos:**

Es la parte del modelo que permite integrar los datos provenientes de cada una de las áreas antes mencionadas y darle sentido al *framework*. Tiene tres principales funciones:

- o Preprocesamiento, limpieza y gestión de datos.
- o Aplicación de modelos de *Machine Learning*.
- o Evaluación de rendimiento con métricas de *Machine Learning*.

El modelo por sí mismo no funciona sin su aplicación a un OA, por lo que el diagrama de la Fig. 51 muestra su relación.

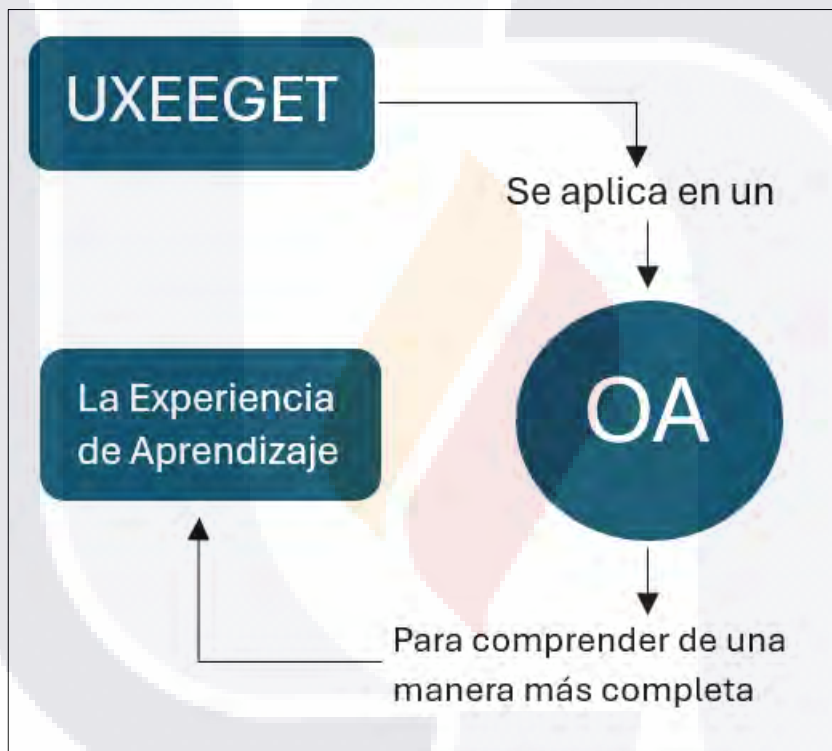


Fig. 51 Relación del *framework* UXEEGET con un Objeto de Aprendizaje (Elaboración propia, 2024).

Una vez, como se ha señalado anteriormente, el modelo no pretende medir qué tan bien se aprende o no, ese objetivo está fuera del alcance de esta investigación, sino conocer de una manera más completa cómo es la experiencia de aprendizaje, lo que puede afirmarse que se logró con esta investigación.

En resumen, aunque es un modelo producto de cuatro años de investigación, siempre existe capacidad de mejora, como algunas de las propuestas que se describen en la siguiente sección.

Estas son sólo algunas de las posibles mejoras que pueden considerarse para continuar el trabajo relativo al modelo, pero siempre pueden existir nuevas alternativas gracias a la participación de nuevos investigadores y perspectivas.



CONCLUSIONES

Como parte final del documento de tesis, esta sección sirve como clausura a la investigación resaltando los puntos más importantes. Así pues, a continuación, se muestran el resumen de hallazgos, la contribución al conocimiento, la reafirmación de los objetivos de investigación, la importancia del *framework* final y una sección sobre reflexiones finales.

RESUMEN DE HALLAZGOS

Ya en distintas secciones del documento se han mencionado puntos interesantes que se descubrieron con los casos de estudio y con el experimento principal. En esta breve sección se enlistarán los hallazgos de mayor importancia que se encontraron durante los cuatro años de la investigación, principalmente centrándose en lo relativo al experimento principal.

- Gracias a la incorporación de variables biométricas (*Eye Tracking* y EEG), la experiencia de aprendizaje puede comprenderse de mejor manera, comparado con sólo utilizar un cuestionario tradicional de *UX*.
- Dependiendo de los modelos de *Machine Learning* entrenados, las variables de EEG suelen aportar más información que las de *Eye Tracking* (al menos las variables seleccionadas) para comprender la experiencia de aprendizaje.
- Con respecto a las variables de EEG, en cada modelo de *Machine Learning* hay mayor aporte de información en las variantes de las señales Beta y Gamma, probablemente porque son las señales con mayor frecuencia en el EEG y suelen relacionarse con estados de concentración y/o atención más elevados (véase **Tabla 5**), por ejemplo, para tareas lógicas, como es el caso de un OA relativo a la POO.
- La muestra estadística de 30 usuarios fue suficiente para poder generar un *dataset* completo. Esto sin embargo no quiere decir que no se sugiera realizar experimentos con un mayor número de participantes, pues para el caso de proyectos relacionados con la Ciencia de Datos, regularmente una mayor cantidad de datos resulta benéfica.
- Gracias al cuestionario de *UX* fue evidente que el OA fue del agrado de la mayoría de los participantes. Esto se refleja en las respuestas que se seleccionaron (la clase del *dataset*) y en la corroboración mediante el análisis con Ciencia de Datos junto a las variables biométricas. Lo anterior puede explicarse principalmente a dos motivos. El

primero es la incorporación de IA, que aunque no es nuevo, es un área incipiente que puede explotarse mucho para generar mejores contenidos educativos; y el segundo tiene que ver con la buena edición y calidad del contenido, diseñado incluso desde una perspectiva divertida y específicamente para los usuarios participantes.

Habiendo revisado los principales hallazgos, la siguiente sección se centra en las principales contribuciones al conocimiento que generó este trabajo de investigación.

CONTRIBUCIONES AL CONOCIMIENTO

Todas las investigación científicas y tecnológicas buscan realizar aportaciones para las áreas del conocimiento en las que se ven involucradas. Este trabajo no es la excepción y es por ello por lo que, a continuación, se enlistan las principales contribuciones que este proyecto de tesis aporta.

- Desde el punto de vista del *UX*, e incluyendo el área del *HCI*, esta investigación exploró y logró exitosamente conjuntar un par de tecnologías que no suelen analizarse a la par. Si bien es cierto que ya existen muchos trabajos que las combinan con diferentes objetivos (véase **Capítulo II Fundamentos Teóricos, sección 1 Revisión Sistemática de la Literatura (RSL)**), es mucho mayor la proporción de estudios y artículos científicos que suelen utilizarlas por separado. Además, con respecto a aquellas que sí las emplean juntas, ninguno de los artículos consultados tenía como campo de estudio la experiencia de aprendizaje.
- Desde el punto de vista de la Ciencia de Datos, la conformación del *dataset* con las variables procedentes de EEG y *Eye Tracking*, y la aplicación de los algoritmos de *Machine Learning* que fueron utilizados, sientan también un precedente. Es cierto que se trata de un *dataset* pequeño y con únicamente tres modelos entrenados (Regresión Logística, KNN y SVM), pero la principal contribución está centrada en la metodología detrás para la conformación de este *dataset* (véase **Capítulo III Metodología de Investigación**, a partir de las sección **4 Instrumentos y Medidas**). Para pruebas futuras, algunos pasos siguientes pueden ser la aplicación de otras familias de algoritmos como Redes Neuronales o algoritmos basado en Árboles.

- TESIS TESIS TESIS TESIS TESIS
- Evidentemente, la principal y más grande contribución es el *framework* UXEEGET. Su creación fue el objetivo principal de este trabajo de investigación y puede concluirse que fue exitosa. Si bien es cierto que de momento solo ha sido probado con un solo experimento en concreto (el experimento principal), para llegar a él existieron n casos de estudio previos y un análisis de literatura exhaustivo. Los siguientes pasos para darle realce son ponerlo a prueba en escenarios distintos (distintas muestras estadísticas, complementar variables de EEG y *Eye Tracking*, probar otros OA) y entrenar modelos nuevos de *Machine Learning*, así como la incorporación de otras técnicas de Ciencia de Datos.

En resumen, existieron aportaciones valiosas, tanto metodológicas como prácticas en diversas áreas del conocimiento, como lo son la UX y la Ciencia de Datos, pues fueron áreas del saber fundamentales en este trabajo de investigación.

Habiendo cubierto los puntos anteriores, la siguiente sección repasa los objetivos para analizar su cumplimiento.

REAFIRMACIÓN DE LOS OBJETIVOS

La mejor manera de conocer el estado de un proyecto de investigación es analizarlo con respecto a cómo van cubriéndose sus objetivos. Por eso mismo, la mejor manera de saber si ya ha finalizado, es repasar cada objetivo y corroborar si estos ya han sido cumplidos o no. Por esta razón, a continuación, se vuelven a presentar los objetivos de investigación que se plantearon en el **Capítulo I Planteamiento del Problema, sección 5**, junto con una breve explicación de su cumplimiento.

OBJETIVO DE INVESTIGACIÓN GENERAL

- Definir las adaptaciones y elementos que compongan al modelo de Experiencia de Aprendizaje a partir de la UX resaltando principalmente las técnicas biométricas de *Eye Tracking* y EEG y su gestión mediante Ciencia de Datos.

CUMPLIDO. Mediante la creación del *framework* UXEEGET y (previamente) con el experimento principal.

OBJETIVOS DE INVESTIGACIÓN ESPECÍFICOS

- Realizar una búsqueda exhaustiva de los métodos, herramientas y técnicas de la *UX* que puedan ser aplicadas y adaptadas al modelo de evaluación Experiencia de Aprendizaje gestionado con Ciencia de Datos.

CUMPLIDO. En parte con la RSL y en parte con la experimentación con los casos de estudio.

- Revisar y analizar el estado del arte de las herramientas y procesamientos basados en *Eye Tracking* y EEG aplicados a *UX* y gestionado con Ciencia de Datos.
- **CUMPLIDO.** Mismo caso que el objetivo anterior, fue en parte cubierto con la RSL y en parte con la experimentación con los casos de estudio.

Indagar en distintos métodos tradicionales de *UX* que puedan ser adaptables al modelo de evaluación Experiencia de Aprendizaje gestionado con Ciencia de Datos.

CUMPLIDO. Cubierto también con la RSL, pero más específicamente con la construcción del marco teórico relativo a *UX* y tecnologías biométricas.

Puede aseverarse entonces que todos los objetivos de investigación fueron cubiertos satisfactoriamente. En resumen, todos se engloban con la propuesta del modelo final, el *framework UXEEGET*.

IMPORTANCIA DEL FRAMEWORK

Reforzando lo que se mencionó en la sección anterior, todos los objetivos llevaban implícita la tarea de la construcción del modelo final de evaluación de experiencia de aprendizaje, el *framework UXEEGET*. Esta es la principal aportación de este proyecto de investigación y como tal se espera que sirva de precedente para que, con mejoras o adaptaciones futuras, pueda usarse en nuevos contextos.

Como ya se ha sugerido, es importante que pueda probarse en otros escenarios, pues la principal finalidad del *framework* es servir como una herramienta para comprender mejor la

experiencia de aprendizaje. Probablemente puede objetarse que no es viable aplicar el *framework* dentro de un aula de clases tradicional porque no se tienen suficientes herramientas para analizar las señales EEG o datos de *Eye Tracking* de todos los estudiantes, ni siquiera en una única clase en un día cualquiera.

Tal objeción es coherente y de sentido común, pero el *framework* no está diseñado para ser implementado en un salón de clases tradicional. Incluso, considerar la idea de monitorear a todos los estudiantes en una clase completa resulta inviable, al menos con este tipo de tecnologías, pues los participantes pueden sentirse incómodos por el simple hecho de estar portando una diadema EEG o estar cerca de un *eye tracker* todo el tiempo.

Por ende, dado que lo anterior es utópico y poco práctico, el principal uso que se le puede dar al *framework* UXEEGET es para el diseño y validación de OAs. Es decir, puede aprovecharse el modelo para que se valide la calidad de los OAs que son presentados ante un grupo de referencia o que planean incorporarse a un MOOC por ejemplo.

Una idea simple es utilizar el *framework* mediante un proceso iterativo en el que, con las adaptaciones necesarias, un OA sea probado con un grupo de estudiantes para conocer su experiencia de aprendizaje. Si está fue tal cual como se esperaba, el modelo sirve para validar que el OA es de calidad y cumple con sus objetivos, pero en caso contrario, una vez que se tiene la retroalimentación, hacer los ajustes necesarios en el OA para nuevamente ser probado aplicando el *framework*.

Siempre hay espacio para mejora y como ya se ha propuesto antes, para tener una mayor confianza y datos más contundentes, es preferible usar tecnologías vanguardistas y con la mejor calidad posible. Idealmente pueden probarse las mejores diademas EEG y *eye trackers* del mercado, analizar un conjunto de variables más extenso y aplicar otras técnicas de *UX* que mejor le parezcan al investigador en turno. Si bien aquí se presentaron elementos concretos, el *framework* no es estático y está abierto a adaptaciones.

SUGERENCIAS PARA FUTURAS INVESTIGACIONES

En toda área de las ciencias y la tecnología siempre existe espacio para la mejora. Este trabajo, por supuesto no es la excepción, por ende, las principales sugerencias para trabajo futuro se enlistan a continuación (algunas de ellas ya fueron mencionadas brevemente en otras secciones):

- Probar con otros objetos de aprendizaje.
- Probar con algoritmos de *Machine Learning* distintos (por ejemplo, basados en árboles como Árboles de Decisión, *Random Forest*, XGBoost, u otros como Redes Neuronales).
- Considerar nuevas variables tanto de EEG como de *Eye Tracking* (esto es muy dependiente de los instrumentos que se utilizan, es decir, diademas de EEG o *Eye Trackers*).
- Considerar la implementación de otros métodos de *UX* (en este caso se utilizó un cuestionario tradicional basado en escala de Likert, pero pueden plantearse técnicas distintas).
- Considerar una muestra estadística de participantes más alta (en este caso fueron poco más de 30, pero puede extenderse para generar así *datasets* más grandes).
- En lo concerniente a la Ciencia de Datos, pueden explorarse la implementación de técnicas de reducción de dimensionalidad previo al entrenamiento de los modelos.
- También con respecto a la Ciencia de Datos, y sobre todo para conocer la influencia de cada variable, pueden emplearse otras técnicas de Ingeniería de Atributos.
- Con respecto al área técnica, este trabajo fue implementado y desarrollado en Python, pero pueden probarse otros lenguajes de Programación, por ejemplo R.

REFLEXIONES FINALES

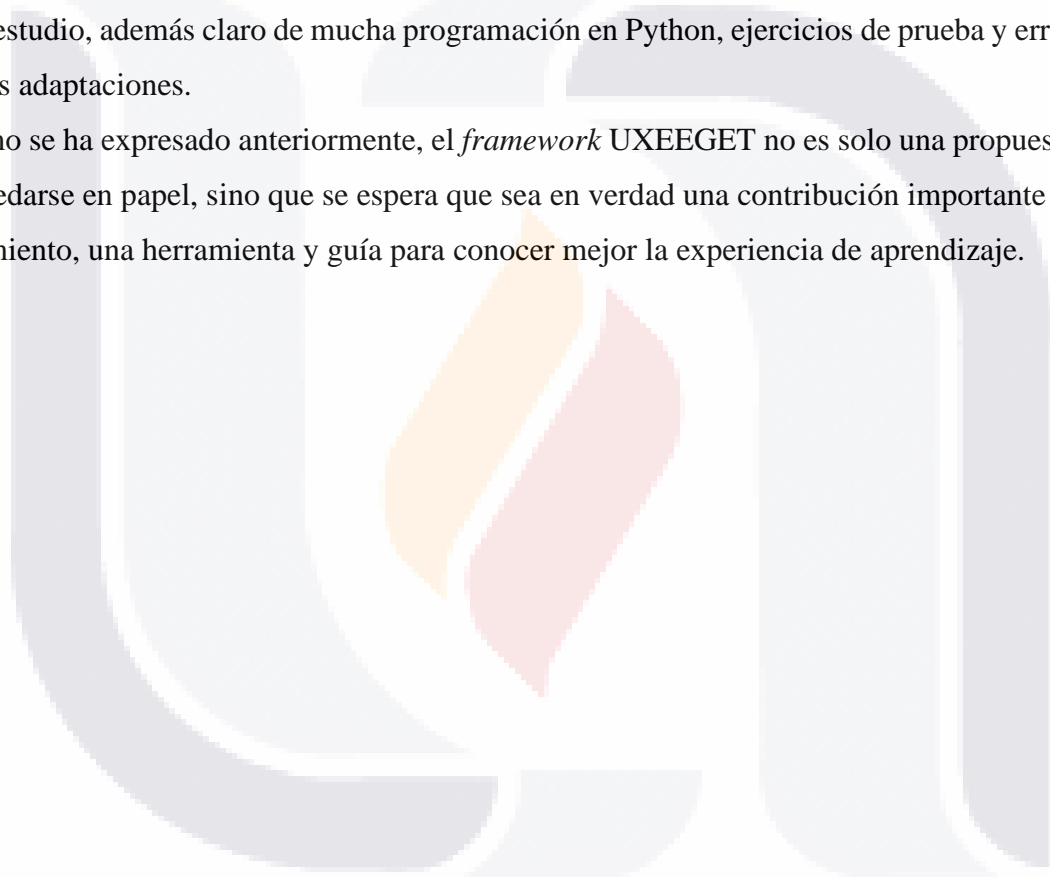
Un trabajo de investigación doctoral es uno de los procesos académicos más desafiantes y rigurosos. En este caso en específico, la construcción de un modelo de trabajo o *framework*, conlleva además realizar mucho trabajo previo para que sus bases sean sólidas. La elaboración del *framework* UXEEGET requirió del esfuerzo y colaboración de muchas personas, algunas de las cuáles menciono públicamente en los Agradecimientos al inicio de

este trabajo de tesis. Solo mediante una metodología rigurosa y el gran apoyo en dirección y asesoría de mi comité tutorial es que este objetivo pudo cumplirse cabalmente.

Desarrollar un modelo para comprender de mejor manera la experiencia de aprendizaje, conllevo paradójicamente de muchas experiencias que provocaron el producto final, como el trabajo con los casos de estudio, mucha interacción con usuarios, además de mucho aprendizaje teórico y práctico.

Para poder robustecer el modelo, fue necesario indagar lo más posible sobre Ciencia de Datos, un área en la cual incluso se consiguió una Certificación Profesional y que implicó mucho estudio, además claro de mucha programación en Python, ejercicios de prueba y error y nuevas adaptaciones.

Así como se ha expresado anteriormente, el *framework* UXEEGET no es solo una propuesta para quedarse en papel, sino que se espera que sea en verdad una contribución importante al conocimiento, una herramienta y guía para conocer mejor la experiencia de aprendizaje.



REFERENCIAS

- Aggarwal, C. (2015). *Data mining: the textbook*. Springer.
- Aggarwal, L. (2022). What is Data Science? In *IBM Technology*.
<https://youtu.be/RBSUwFGa6Fk>
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A next-generation hyperparameter optimization framework. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2623–2631.
<https://doi.org/10.1145/3292500.3330701>
- Alexiou, A., & Schippers, M. C. (2018). Digital game elements, user experience and learning: A conceptual framework. *Education and Information Technologies*, 23(6), 2545–2567.
<https://doi.org/10.1007/s10639-018-9730-6>
- Ali, N. M., Abdullah, S. Z., Salim, J., Sulaiman, R., Zaman, H. B., & Lee, H. (2012). Exploring user experience in game using heart rate device. *Asia-Pacific Journal of Information Technology and Multimedia*, 1(2), 28–36.
<https://doi.org/https://doi.org/10.17576/apjitm-2012-0102-03>
- American Academy of Ophthalmology. (2023, April 11). *La fóvea*. Salud Ocular.
<https://www.aaof.org/salud-ocular/anatomia/la-fovea>
- Andreassi, J. L. (2010). *Psychophysiology: Human behavior and physiological response*. Psychology press. <https://doi.org/10.4324/9780203880340>
- Barrett, K. E. (2013). *Ganong fisiología médica* (McGraw-Hill Interamericana, Ed.; 24th ed.). McGraw Hill Mexico. <https://books.google.com.mx/books?id=mDuEBgAAQBAJ>
- Bazzani, A., Ravaioli, S., Trieste, L., Faraguna, U., & Turchetti, G. (2020). Is EEG Suitable for Marketing Research? A Systematic Review. In *Frontiers in Neuroscience* (Vol. 14, p. 1343). <https://doi.org/10.3389/fnins.2020.594566>
- Becker, D. (2021). *Machine Learning Explainability - Permutation Importance*.
<https://www.kaggle.com/dansbecker/permutation-importance>
- Benyon, D. (2019). *Designing User Experience*. Pearson Educación.
<https://books.google.es/books?id=MXqFDwAAQBAJ>
- Bodala, I. P., Kukreja, S., Li, J., Thakor, N. V., & Al-Nashash, H. (2015). Eye tracking and EEG synchronization to analyze microsaccades during a workload task. *2015 37th*

- Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 7994–7997. <https://doi.org/10.1109/EMBC.2015.7320247>
- Bækgaard, P., Petersen, M. K., & Larsen, J. E. (2014). In the twinkling of an eye: Synchronization of EEG and eye tracking based on blink signatures. *2014 4th International Workshop on Cognitive Information Processing (CIP)*, 1–6. <https://doi.org/10.1109/CIP.2014.6844504>
- Borgianni, Y., Rauch, E., Maccioni, L., & Mark, B. G. (2018). User Experience Analysis in Industry 4.0 - The Use of Biometric Devices in Engineering Design and Manufacturing. *2018 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, 192–196. <https://doi.org/10.1109/IEEM.2018.8607367>
- Bower, G. H., & Hilgard, E. R. (2004). *Teorías del Aprendizaje*. México. MX. 2º.
- Boyd, K., & DeAngelis, K. (2022, December 2). *¿Qué es un nistagmo?* Salud Ocular. <https://www.aaoo.org/salud-ocular/enfermedades/nistagmo>
- Brejcha, J. (2015). *Cross-Cultural Human-Computer Interaction and User Experience Design: A Semiotic Perspective*. CRC Press. <https://books.google.com.mx/books?id=kle3BgAAQBAJ>
- Brouwer, A.-M., Hogervorst, M. A., Oudejans, B., Ries, A. J., & Touryan, J. (2017). EEG and eye tracking signatures of target encoding during structured visual search. *Frontiers in Human Neuroscience*, 11, 264. <https://doi.org/10.3389/fnhum.2017.00264>
- Brown HCI Group. (2016). *WebGazer.js*. WebGazer.js Democratizing Webcam Eye Tracking on the Browser. <https://webgazer.cs.brown.edu/#>
- Brunetta, H. (2019). *La experiencia del cliente*. Grupo Planeta - Argentina.
- Bruun, A. (2018). It's not complicated: A study of non-specialists analyzing GSR sensor data to detect UX related events. *Proceedings of the 10th Nordic Conference on Human-Computer Interaction*, 170–183. <https://doi.org/https://doi.org/10.1145/3240167.3240183>
- Cabañero, L. (2021, September 8). *Eeglib*. PyPi: Eeglib 0.4.1 A Library with Some Tools and Functions for EEG Signal Analysis. <https://pypi.org/project/eeglib/>
- Callejas Cuervo, M., Hernández Niño, E. J., & Pinzón Villamil, J. N. (2011). Objetos de aprendizaje, un estado del arte. *Entramado*, 7(1), 176–189.

- Campisi, P., & Rocca, D. La. (2014). EEG Biometrics. In S. Z. Li & A. K. Jain (Eds.), *Encyclopedia of Biometrics* (pp. 1–11). Springer US. https://doi.org/10.1007/978-3-642-27733-7_9145-2
- Campos, S. A. R., López, E. E. R., Rodríguez, F. J. Á., & Soto, A. T. (2022). Trend prediction technique for Computer Visual Syndrome (CVS) with eye tracking as support. *2022 International Conference on Inclusive Technologies and Education (CONTIE)*, 1–6. <https://doi.org/10.1109/CONTIE56301.2022.10004418>
- Carr, N. (2011). *Superficiales: ¿Qué está haciendo Internet con nuestras mentes?* Penguin Random House Grupo Editorial España. <https://books.google.com.mx/books?id=0bLKmaXgdxMC>
- Carrillo, I., Meza-Kubo, V., Morán, A. L., Galindo, G., & García-Canseco, E. (2015). Processing EEG signals towards the construction of a user experience assessment method. In *Ambient Intelligence for Health* (pp. 281–292). Springer. https://doi.org/10.1007/978-3-319-26508-7_28
- Cavalcante, E., Rivero, L., & Conte, T. (2015). Evaluating the Feasibility of MAX: A Method Using Cards and a Board for Assessing the Post-Use UX. *International Journal of Software Engineering and Knowledge Engineering*, 25(09n10), 1759–1764. <https://doi.org/10.1142/S0218194015710138>
- Chakraborty, B. K., Sarma, D., Bhuyan, M. K., & MacDorman, K. F. (2018). Review of constraints on vision-based gesture recognition for human–computer interaction. *IET Computer Vision*, 12(1), 3–15. <https://doi.org/https://doi.org/10.1049/iet-cvi.2017.0052>
- Chance, P. (2001). *Aprendizaje y conducta 3ª edición. México. Editorial: El Manual Moderno.*
- Chen, S.-C., She, H.-C., Chuang, M.-H., Wu, J.-Y., Tsai, J.-L., & Jung, T.-P. (2014). Eye movements predict students' computer-based assessment performance of physics concepts in different presentation modalities. *Computers & Education*, 74, 61–72. <https://doi.org/10.1016/j.compedu.2013.12.012>
- Conway, D. (2015). *The Data Science Venn Diagram.* <http://drewconway.com/zia/2013/3/26/the-data-science-venn-diagram>

- Crescenzi-Lanna, L. (2020). Multimodal Learning Analytics research with young children: A systematic review. *British Journal of Educational Technology*, 51(5), 1485–1504. <https://doi.org/10.1111/bjet.12959>
- Dahlstrom-Hakki, I., Asbell-Clarke, J., & Rowe, E. (2019). Showing Is Knowing: The Potential and Challenges of Using Neurocognitive Measures of Implicit Learning in the Classroom. *Mind, Brain, and Education*, 13(1), 30–40. <https://doi.org/10.1111/mbe.12177>
- Dalmaijer, E. (2015a). *PyGaze Analyser*. PyGaze.Org. <http://www.pygaze.org/2015/06/pygaze-analyser/>
- Dalmaijer, E. (2015b). *Webcam Eye Tracker*. <https://www.pygaze.org/2015/06/webcam-eye-tracker/>
- Dalmaijer, E. S., Mathôt, S., & Van der Stigchel, S. (2014). PyGaze: An open-source, cross-platform toolbox for minimal-effort programming of eyetracking experiments. *Behavior Research Methods*, 46(4), 913–921. <https://doi.org/10.3758/s13428-013-0422-2>
- De Luna, J., Rodríguez, E., Álvarez, F., & Torres, A. (2022). Algoritmos de Aprendizaje Automático para el Análisis de señales EEG en Neuromarketing. In M. Sánchez, A. García, & F. Álvarez (Eds.), *Transformación Digital de las Instituciones Educativas* (pp. 19–25). ALFA-OMEGA Grupo Editor S.A DE C.V.
- Del Giorgio Solfa, F., Amendolaggin, G., & Alvarado Wall, T. A. (2018). Nuevos paradigmas para el diseño de productos. *Arte e Investigación*. <https://doi.org/10.24215/24691488e012>
- Den Uyl, M. J., & Van Kuilenburg, H. (2005). The FaceReader: Online facial expression recognition. *Proceedings of Measuring Behavior*, 30(2), 589–590.
- Devy, N. P. I. R., Wibirama, S., & Santosa, P. I. (2017). Evaluating user experience of english learning interface using User Experience Questionnaire and System Usability Scale. *2017 1st International Conference on Informatics and Computational Sciences (ICICoS)*, 101–106. <https://doi.org/10.1109/ICICOS.2017.8276345>
- Dimigen, O., & Ehinger, B. V. (2021). Regression-based analysis of combined EEG and eye-tracking data: Theory and applications. *Journal of Vision*, 21(1), 3. <https://doi.org/10.1167/jov.21.1.3>

- Ding, X., Yue, X., Zheng, R., Bi, C., Li, D., & Yao, G. (2019). Classifying major depression patients and healthy controls using EEG, eye tracking and galvanic skin response data. *Journal of Affective Disorders*, 251, 156–161. <https://doi.org/10.1016/j.jad.2019.03.058>
- Dobias, M., Holub, O., & Fabian, V. (2013). An Eye tracking System: Towards Applications in Marketing. *Ad Alta: Journal of Interdisciplinary Research*, 3(2).
- Duchowski, A. (2017). *Eye tracking methodology: Theory and practice*. Springer. <https://doi.org/10.1007/978-3-319-57883-5>
- EMOTIV. (2021). *EMOTIV EPOC X 14 Channel Mobile Brainwear*. <https://www.emotiv.com/product/emotiv-epoc-x-14-channel-mobile-brainwear/#tab-description>
- Falkowska, J., Sobecki, J., & Pietrzak, M. (2016). Eye tracking usability testing enhanced with EEG analysis. *International Conference of Design, User Experience, and Usability*, 399–411. https://doi.org/10.1007/978-3-319-40409-7_38
- Fox, S. I. (2011). *Human Physiology* (12th ed.). McGraw-Hill. <https://books.google.com.mx/books?id=9YgXQwAACAAJ>
- Frey, J., Daniel, M., Castet, J., Hachet, M., & Lotte, F. (2016). Framework for electroencephalography-based evaluation of user experience. *Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems*, 2283–2294. <https://doi.org/10.1145/2858036.2858525>
- Ganglbauer, E., Schrammel, J., Deutsch, S., & Tscheligi, M. (2009). Applying psychophysiological methods for measuring user experience: possibilities, challenges and feasibility. *Workshop on User Experience Evaluation Methods in Product Development*.
- Gill, R., & Younie, S. (2021). Evaluating eye tracking technology for assessment of students with profound and multiple learning difficulties. *Pixel-Bit*. <https://doi.org/10.12795/pixelbit.88106>
- Glejzer, C. (2017). *Las bases biológicas del aprendizaje*. Universidad de Buenos Aires. Editorial de la Facultad de Filosofía y Letras.

- Godfroid, A., Winke, P., & Conklin, K. (2020). Exploring the depths of second language processing with eye tracking: An introduction. *Second Language Research*, 36(3), 243–255. <https://doi.org/10.1177/0267658320922578>
- Goleman, D. (2013). *Focus. El motor oculto de la excelencia* (Penguin Random House Grupo Editorial, Ed.; First Edition).
- Goodman, E., Kuniavsky, M., & Moed, A. (2012). *Observing the User Experience: A Practitioner's Guide to User Research*. Elsevier Science. <https://doi.org/10.1109/TPC.2013.2274110>
- Gran Ekstrand, A. C., Nilsson Benfatto, M., & Öqvist Seimyr, G. (2021). Screening for Reading Difficulties: Comparing Eye Tracking Outcomes to Neuropsychological Assessments. *Frontiers in Education*, 6, 643232. <https://doi.org/10.3389/educ.2021.643232>
- Hassan Montero, Y. (2015). Experiencia de usuario: principios y métodos. *Experiencia de Usuario: Principios y Métodos*, 9.
- Heckert, N. A., Filliben, J. J., Croarkin, C. M., Hembree, B., Guthrie, W. F., Tobias, P., & Prinz, J. (2002). *Handbook 151: Nist/sematech e-handbook of statistical methods*. N. Alan Heckert, James J. Filliben, C M. Croarkin, B Hembree, William F <https://doi.org/10.18434/M32189>
- Holbrook, R. (2021). *Feature Engineering - Mutual Information*. <https://www.kaggle.com/ryanholbrook/mutual-information>
- Hornbæk, K., & Hertzum, M. (2017). Technology acceptance and user experience: A review of the experiential component in HCI. *ACM Transactions on Computer-Human Interaction (TOCHI)*, 24(5), 1–30. <https://doi.org/https://doi.org/10.1145/3127358>
- Hu, L., & Zhang, Z. (2019). *EEG signal processing and feature extraction*. Springer. <https://doi.org/https://doi.org/10.1007/978-981-13-9113-2>
- Hudson, D. (2017). *Dificultades específicas de aprendizaje y otros trastornos: Guía básica para docentes*. Narcea, S.A. de Ediciones. <https://books.google.com.mx/books?id=UTU1DwAAQBAJ>
- Hunt, J. (2019). *A Beginners Guide to Python 3 Programming*. Springer International Publishing. <https://doi.org/https://doi.org/10.1007/978-3-030-20290-3>
- IBM. (2021). Jaccard Index. In *Machine Learning with Python course*. IBM.

- IBM. (2024, January 18). *Términos estadísticos*. IBM Cognos Analytics - Documentación. <https://www.ibm.com/docs/es/cognos-analytics/12.0.0?topic=dashboards-statistical-terms>
- IEEE. (2020). IEEE Standard for Learning Object Metadata. In *IEEE Std 1484.12.1-2020* (pp. 1–50). IEEE.
- Igual, L., & Seguí, S. (2017). Introduction to Data Science. In *Introduction to Data Science* (pp. 1–4). Springer.
- iMotions. (2021). *iMotions: Tobii Pro Glasses 3*. <https://imotions.com/hardware/tobii-pro-glasses-3/>
- İnce, R., Adanır, S. S., & Sevmez, F. (2021). The inventor of electroencephalography (EEG): Hans Berger (1873–1941). *Child's Nervous System*, *37*, 2723–2724.
- ISO/IEC. (2011). *ISO/IEC 25010:2011 Systems and software engineering - Systems and software Quality Requirements and Evaluation (SQuaRE) - System and software quality models*.
- Izdebski, K., Oliveira, A. S., Schlink, B. R., Legkov, P., Kärcher, S., Hairston, W. D., Ferris, D. P., & König, P. (2016). Usability of EEG systems: user experience study. *Proceedings of the 9th ACM International Conference on Pervasive Technologies Related to Assistive Environments*, 1–4. <https://doi.org/10.1145/2910674.2910714>
- Jain, A., Choudhury, T., Singh, R., & Kumar, P. (2018). EEG Signal Classification for Real-Time Neuro Marketing Applications. *2018 International Conference on Advances in Computing and Communication Engineering (ICACCE)*, 434–438. <https://doi.org/10.1109/ICACCE.2018.8441756>
- Jain, A., Flynn, P., & Ross, A. (2007). *Handbook of biometrics*. Springer Science & Business Media.
- Kang, J., Han, X., Song, J., Niu, Z., & Li, X. (2020). The identification of children with autism spectrum disorder by SVM approach on EEG and eye-tracking data. *Computers in Biology and Medicine*, *120*, 103722. <https://doi.org/10.1016/j.compbiomed.2020.103722>
- Karwowski, W., Rizzo, F., & Rodrick, D. (2003). Ergonomics. In H. Bidgoli (Ed.), *Encyclopedia of Information Systems* (pp. 185–201). Elsevier. <https://doi.org/10.1016/B0-12-227240-4/00061-7>

- Kitchenham, B., & Charters, S. (2007). *Guidelines for performing systematic literature reviews in software engineering*. Technical report, ver. 2.3 ebse technical report. ebse.
- Korbach, A., Brünken, R., & Park, B. (2017). Measurement of cognitive load in multimedia learning: a comparison of different objective measures. *Instructional Science*, 45(4), 515–536. <https://doi.org/10.1007/s11251-017-9413-5>
- Kosel, C., Holzberger, D., & Seidel, T. (2021). Identifying expert and novice visual scanpath patterns and their relationship to assessing learning-relevant student characteristics. *Frontiers in Education*, 5, 612175. <https://doi.org/10.3389/educ.2020.612175>
- Kovtun, R., Radchenko, S., Natreba, A., Sudakov, O., Natarov, R., Dyka, Z., Kabin, I., & Langendörfer, P. (2020). Exploiting EEG Signals for Eye Motion Tracking. *2020 IEEE East-West Design & Test Symposium (EWDTS)*, 1–5. <https://doi.org/10.1109/EWDTS50664.2020.9225144>
- Kremer, S., Sies, T., & Lindemann, U. (2016). Designing meaningful User Experiences: Interactive Learning Experience Model. *2016 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, 286–290. <https://doi.org/10.1109/IEEM.2016.7797882>
- Lane, H. C., & D’Mello, S. K. (2019). Uses of Physiological Monitoring in Intelligent Learning Environments: A Review of Research, Evidence, and Technologies BT - Mind, Brain and Technology: Learning in the Age of Emerging Technologies. In T. D. Parsons, L. Lin, & D. Cockerham (Eds.), *Mind, Brain and Technology* (pp. 67–86). Springer International Publishing. https://doi.org/10.1007/978-3-030-02631-8_5
- Law, E. L.-C., Roto, V., Hassenzahl, M., Vermeeren, A. P. O. S., & Kort, J. (2009). Understanding, scoping and defining user experience: a survey approach. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 719–728. <https://doi.org/10.1145/1518701.1518813>
- Lee, S., Baek, J., & Han, G. (2018). Effects of using a second-screen application on attention, learning, and user experience in an educational content. *Interactive Learning Environments*, 26(3), 289–307. <https://doi.org/10.1080/10494820.2017.1324494>
- Li, S. Z. (2009). *Encyclopedia of Biometrics: I-Z*. (Vol. 2). Springer Science & Business Media.

- Liapis, A., Maratou, V., Panagiotakopoulos, T., Katsanos, C., & Kameas, A. (2023). UX evaluation of open MOOC platforms: a comparative study between Moodle and Open edX combining user interaction metrics and wearable biosensors. *Interactive Learning Environments*, 31(10), 6841–6855. <https://doi.org/10.1080/10494820.2022.2048674>
- Lindner, M. A., Eitel, A., Strobel, B., & Köller, O. (2017). Identifying processes underlying the multimedia effect in testing: An eye-movement analysis. *Learning and Instruction*, 47, 91–102. <https://doi.org/10.1016/j.learninstruc.2016.10.007>
- Liu, N.-H., Chiang, C.-Y., & Chu, H.-C. (2013). Recognizing the degree of human attention using EEG signals from mobile sensors. *Sensors*, 13(8), 10273–10286. <https://doi.org/10.3390/s130810273>
- Liu, Z., & Juan, G. (2020). Evaluation Method of User Experience of public service system Using Mobile Eye Tracking. *Proceedings of the 2020 4th International Conference on Electronic Information Technology and Computer Engineering*, 976–980. <https://doi.org/10.1145/3443467.3443890>
- Lobo, J. L., Ser, J. Del, De Simone, F., Presta, R., Collina, S., & Moravek, Z. (2016). Cognitive workload classification using eye-tracking and EEG data. *Proceedings of the International Conference on Human-Computer Interaction in Aerospace*, 1–8. <https://doi.org/10.1145/2950112.2964585>
- Lopez, E. E. R., González, D. H., Rodríguez, F. J. Á., & Gallegos, J. C. P. (2021). Comorbidities and risk factors impact of COVID-19 in Mexico: a feature utility metrics approach. *International Journal of Data Mining and Bioinformatics*, 26(1–2), 59–80. <https://doi.org/10.1504/IJDMB.2021.124109>
- López-Gil, J.-M., Virgili-Gomá, J., Gil, R., Guilera, T., Batalla, I., Soler-González, J., & García, R. (2016). Method for Improving EEG Based Emotion Recognition by Combining It with Synchronized Biometric and Eye Tracking Technologies in a Non-invasive and Low Cost Way. In *Frontiers in Computational Neuroscience* (Vol. 10, p. 85). <https://doi.org/10.3389/fncom.2016.00085>
- Madariaga, L., Nussbaum, M., Gutiérrez, I., Barahona, C., & Meneses, A. (2021). Assessment of user experience in video-based learning environments: From design guidelines to final product. *Computers & Education*, 167, 104176. <https://doi.org/10.1016/j.compedu.2021.104176>

- Maguire, M. J., Magnon, G., & Fitzhugh, A. E. (2014). Improving data retention in EEG research with children using child-centered eye tracking. *Journal of Neuroscience Methods*, 238, 78–81. <https://doi.org/10.1016/j.jneumeth.2014.09.014>
- Maia, C. L. B., & Furtado, E. S. (2016). A study about psychophysiological measures in user experience monitoring and evaluation. *Proceedings of the 15th Brazilian Symposium on Human Factors in Computing Systems*, 1–9. <https://doi.org/https://doi.org/10.1145/3033701.3033708>
- Maldonado, A., Galicia, A., & Apolar, J. (2020). Herramientas digitales de apoyo al proceso de enseñanza-aprendizaje: Repositorio de objetos de aprendizaje. *RILCO DS: Revista de Desarrollo Sustentable, Negocios, Emprendimiento y Educación*, 14, 3.
- Mandryk, R. L., Inkpen, K. M., & Calvert, T. W. (2006). Using psychophysiological techniques to measure user experience with entertainment technologies. *Behaviour & Information Technology*, 25(2), 141–158. <https://doi.org/10.1080/01449290500331156>
- Mavengere, N., & Ruohonen, M. (2019). Enhancing Virtual Learning by Improving the Learning Environment and User Experience. *International Conference on Sustainable ICT, Education, and Learning*, 125–134. https://doi.org/10.1007/978-3-030-28764-1_15
- Mele, M. L., & Federici, S. (2012). A psychotechnological review on eye-tracking systems: towards user experience. *Disability and Rehabilitation: Assistive Technology*, 7(4), 261–281. <https://doi.org/10.3109/17483107.2011.635326>
- Mendoza-Franco, G., Dorador-González, J. M., Díaz-Pérez, P., & Zarco-Hernández, R. (2021). Design of Learning Digital Tools Through a User Experience Design Methodology. In *Advances in Computer, Communication and Computational Sciences* (pp. 755–764). Springer. https://doi.org/10.1007/978-981-15-4409-5_67
- Merla, N., Díaz, H., González, M., Pedroza, J., López, S., & Rodríguez, E. (2024, May 13). *Programación Orientada a Objetos - Explicada con Tacos*. YouTube. <https://www.youtube.com/watch?v=RIKLphYtYBk>
- Morville, P. (2004, June 21). *User Experience Design*. Semantic Studios.
- Myers, B., Hollan, J., Cruz, I., Bryson, S., Bulterman, D., Catarci, T., Citrin, W., Glinert, E., Grudin, J., & Ioannidis, Y. (1996). Strategic directions in human-computer interaction.

- ACM Computing Surveys (CSUR)*, 28(4), 794–809.
<https://doi.org/doi.org/10.1145/242223.246855>
- NeuroSky. (2021). *Mindwave Mobile 2: Brainwave Sensing Headset*.
<https://store.neurosky.com/pages/mindwave>
- Nielsen, J. (2020, November 15). *10 Usability Heuristics for User Interface Design*. Nielsen Norman Group. <https://www.nngroup.com/articles/ten-usability-heuristics/>
- Nielsen, J., & Landauer, T. K. (1993). A mathematical model of the finding of usability problems. *Proceedings of the INTERACT'93 and CHI'93 Conference on Human Factors in Computing Systems*, 206–213. <https://doi.org/10.1145/169059.169166>
- Norman, D., & Nielsen, J. (2020). *The Definition of User Experience (UX)*. Nielsen Norman Group.
- Olsen, J. K., Aleven, V., & Rummel, N. (2017). Exploring Dual Eye Tracking as a Tool to Assess Collaboration BT - Innovative Assessment of Collaboration. In A. A. von Davier, M. Zhu, & P. C. Kyllonen (Eds.), *Innovative Assessment of Collaboration* (pp. 157–172). Springer International Publishing. https://doi.org/10.1007/978-3-319-33261-1_10
- Ontiveros, F. (2007). *La Experiencia de Aprendizaje* (p. 7). Universidad de Ciudad del Carmen.
- OpenViBE. (2015). *OpenViBE. Software for Brain Computer Interfaces and Real Time Neurosciences*. <http://openvibe.inria.fr/>
- O'Regan, G. (2017). *Concise Guide to Software Engineering: From Fundamentals to Application Methods*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-57750-0>
- Ortíz, A. V., López, E. R., & Rodríguez, F. Á. (2022). Eyetracking para el estudio de la carga cognitiva y su relación con el desempeño académico enfocado al área de matemáticas
 Uso de herramientas de EyeTracking para evaluar la calidad de interfaces al resolver un ejercicio digital. *CONF-IRM 2022 Proceedings*.
<https://aisel.aisnet.org/confirm2022/12/>
- Özdemir, M. C., Lamas, D., & Möttus, M. (2020). Desired Content versus Digital Advertisements: An Eye-Tracking User Experience Study. *Proceedings of the 11th*

Nordic Conference on Human-Computer Interaction: Shaping Experiences, Shaping Society, 1–4. <https://doi.org/10.1145/3419249.3420088>

Pantic, M. (2014). Facial Expression Recognition. In S. Z. Li & A. K. Jain (Eds.), *Encyclopedia of Biometrics* (pp. 1–8). Springer US. https://doi.org/10.1007/978-3-642-27733-7_98-3

Pei, G., & Li, T. (2021). A Literature Review of EEG-Based Affective Computing in Marketing. In *Frontiers in Psychology* (Vol. 12, p. 720). <https://doi.org/10.3389/fpsyg.2021.602843>

Pi, Z., Chen, M., Zhu, F., Yang, J., & Hu, W. (2022). Modulation of instructor's eye gaze by facial expression in video lectures. *Innovations in Education and Teaching International*, 59(1), 15–23. <https://doi.org/10.1080/14703297.2020.1788410>

Pi, Z., Xu, K., Liu, C., & Yang, J. (2020). Instructor presence in video lectures: Eye gaze matters, but not body orientation. *Computers & Education*, 144, 103713. <https://doi.org/10.1016/j.compedu.2019.103713>

Piedragil, A. (2015). *Cómo crear una experiencia de consumo*. Entrepreneur.

Poole, A., & Ball, L. J. (2006). Eye tracking in HCI and usability research. In *Encyclopedia of human computer interaction* (pp. 211–219). IGI Global. <https://doi.org/10.4018/978-1-59140-562-7>

Putze, F., Hild, J., Kärgel, R., Herff, C., Redmann, A., Beyerer, J., & Schultz, T. (2013). Locating user attention using eye tracking and EEG for spatio-temporal event selection. *Proceedings of the 2013 International Conference on Intelligent User Interfaces*, 129–136. <https://doi.org/10.1145/2449396.2449415>

Putze, F., Popp, J., Hild, J., Beyerer, J., & Schultz, T. (2016). Intervention-free selection using EEG and eye tracking. *Proceedings of the 18th ACM International Conference on Multimodal Interaction*, 153–160. <https://doi.org/10.1145/2993148.2993199>

Rajanen, D., Clemmensen, T., Iivari, N., Inal, Y., Rızvanoğlu, K., Sivaji, A., & Roche, A. (2017). *UX Professionals' Definitions of Usability and UX – A Comparison Between Turkey, Finland, Denmark, France and Malaysia BT - Human-Computer Interaction – INTERACT 2017* (R. Bernhaupt, G. Dalvi, A. Joshi, D. K. Balkrishan, J. O'Neill, & M. Winckler, Eds.; pp. 218–239). Springer International Publishing. https://doi.org/10.1007/978-3-319-68059-0_14

- Rakshit, A., & Lahiri, R. (2016). Discriminating different color from EEG signals using Interval-Type 2 fuzzy space classifier (a neuro-marketing study on the effect of color to cognitive state). *2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)*, 1–6. <https://doi.org/10.1109/ICPEICES.2016.7853388>
- Ramírez, A. A. G., López, E. E. R., & Rodríguez, F. J. Á. (2024). XGBoost to predict STEM profiles using Electroencephalography and Eye-Tracking. *EDULEARN24 Proceedings*, 9568–9577. <https://doi.org/https://doi.org/10.21125/edulearn.2024.2316>
- Real Academia Española. (2023). Aprendizaje. In *Diccionario de la lengua española 23 ed. [versión 23.6 en línea]*. <https://dle.rae.es/aprendizaje>
- Rivera, J. C., Moncada, E. R., González, P. P., Salazar, A. F. C., & Morado, R. (2021). *Pedagogías y teorías educativas*. Jesús Castañeda Rivera. <https://books.google.com.mx/books?id=ri5AEAAAQBAJ>
- Rodrigue, M., Son, J., Giesbrecht, B., Turk, M., & Höllerer, T. (2015). Spatio-temporal detection of divided attention in reading applications using EEG and eye tracking. *Proceedings of the 20th International Conference on Intelligent User Interfaces*, 121–125. <https://doi.org/10.1145/2678025.2701382>
- Rodriguez Lopez, E. E., Alvarez Rodríguez, F. J., & Amador Rodríguez, K. Y. (2022). Exploratory study of EEG signal patterns of blind and normal-sight people in a learning environment. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, 16(2), 583–596. <https://doi.org/10.1007/s12008-022-00847-8>
- Rodriguez-Ascaso, A., Boticario, J. G., Finat, C., & Petrie, H. (2017). Setting accessibility preferences about learning objects within adaptive elearning systems: User experience and organizational aspects. *Expert Systems*, 34(4), e12187. <https://doi.org/10.1111/exsy.12187>
- Roto, V. (2011). *User experience white paper*. 12. <http://www.allaboutux.org/files/UX-WhitePaper.pdf>
- Roto, V., Lee, M., Pihkala, K., Castro, B., Vermeeren, A., Law, E., Väänänen-Vainio-Mattila, K., Hoonhout, J., & Obrist, M. (2023, May 17). *AllaboutUX.org*. Experience Platform. <https://experience.aalto.fi/all-about-ux-blog/>

- Sagirani, T., Nugroho, L. E., Santosa, P. I., & Kumara, A. (2015). User experience model in the interaction between children with special educational needs and learning media. *2015 2nd International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE)*, 72–75. <https://doi.org/10.1109/ICITACEE.2015.7437773>
- Salous, M., Putze, F., Schultz, T., Hild, J., & Beyerer, J. (2018). Investigating static and sequential models for intervention-free selection using multimodal data of EEG and eye tracking. *Proceedings of the Workshop on Modeling Cognitive Processes from Multimodal Data*, 1–6. <https://doi.org/10.1145/3279810.3279841>
- Santiago, A. U. J., González, D. H., López, E. E. R., Álvarez, & Rodríguez, F. J. (2021). Visual Preferences in children diagnosed with ASD by generating heatmaps with Eye Tracking. *2021 4th International Conference on Inclusive Technology and Education (CONTIE)*, 1–6. <https://doi.org/10.1109/CONTIE54684.2021.00009>
- Santoso, H. B., Schrepp, M., Isal, R., Utomo, A. Y., & Priyogi, B. (2016). Measuring user experience of the student-centered e-learning environment. *Journal of Educators Online*, 13(1), 58–79.
- SCCN. (2021). *What is EEGLAB?* <https://sccn.ucsd.edu/eeglab/index.php>
- Schall, A. (2015a). Develando las emociones reales de nuestros usuarios: el futuro de la investigación de experiencia del usuario. *Tendencias En La Experiencia Del Usuario (UX)*, 15(2), 37–46.
- Schall, A. (2015b). Eye tracking evaluation of user experience on large-scale displays. *International Conference on Universal Access in Human-Computer Interaction*, 98–108. https://doi.org/10.1007/978-3-319-20678-3_10
- Scharinger, C., Schüler, A., & Gerjets, P. (2020). Using eye-tracking and EEG to study the mental processing demands during learning of text-picture combinations. *International Journal of Psychophysiology*, 158, 201–214. <https://doi.org/10.1016/j.ijpsycho.2020.09.014>
- Schooler, J. W., Smallwood, J., Christoff, K., Handy, T. C., Reichle, E. D., & Sayette, M. A. (2011). Meta-awareness, perceptual decoupling and the wandering mind. *Trends in Cognitive Sciences*, 15(7), 319–326. <https://doi.org/10.1016/j.tics.2011.05.006>
- Scikit Learn. (2024). *GridSearchCV*. Scikit Learn Documentation.

- Serna, V. I. A., Soto, A. T., Soto, M. D. T., & López, E. E. R. (2025). From EEG Signal Acquisition and Classification to Mobile Integration: A Comprehensive Framework. In L. Martínez-Villaseñor & G. Ochoa-Ruiz (Eds.), *Advances in Soft Computing* (pp. 154–167). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-75543-9_12
- Shaban, A., & Pearson, E. (2020). Evaluation of user experience and cognitive load of a gamified cognitive training application for children with learning disabilities. *Proceedings of the 17th International Web for All Conference*, 1–10. <https://doi.org/10.1145/3371300.3383341>
- Sharafi, Z., Shaffer, T., Sharif, B., & Guéhéneuc, Y.-G. (2015). Eye-Tracking Metrics in Software Engineering. *2015 Asia-Pacific Software Engineering Conference (APSEC)*, 96–103. <https://doi.org/10.1109/APSEC.2015.53>
- Sharma, K., Papamitsiou, Z., & Giannakos, M. (2019). Building pipelines for educational data using AI and multimodal analytics: A “grey-box” approach. *British Journal of Educational Technology*, 50(6), 3004–3031. <https://doi.org/10.1111/bjet.12854>
- Shen, L., Xie, B., & Shen, R. (2014). Enhancing user experience in mobile learning by affective interaction. *2014 International Conference on Intelligent Environments*, 297–301. <https://doi.org/10.1109/IE.2014.63>
- Shi, Z.-F., Zhou, C., Zheng, W.-L., & Lu, B.-L. (2017). Attention evaluation with eye tracking glasses for EEG-based emotion recognition. *2017 8th International IEEE/EMBS Conference on Neural Engineering (NER)*, 86–89. <https://doi.org/10.1109/NER.2017.8008298>
- Shin, D.-H., Biocca, F., & Choo, H. (2013). Exploring the user experience of three-dimensional virtual learning environments. *Behaviour & Information Technology*, 32(2), 203–214. <https://doi.org/10.1080/0144929X.2011.606334>
- Sinha, G., Shahi, R., & Shankar, M. (2010). Human Computer Interaction. *2010 3rd International Conference on Emerging Trends in Engineering and Technology*, 1–4. <https://doi.org/10.1109/ICETET.2010.85>
- Skiena, S. S. (2017). *The data science design manual*. Springer.
- Smallwood, J., Fishman, D. J., & Schooler, J. W. (2007). Counting the cost of an absent mind: Mind wandering as an underrecognized influence on educational performance. *Psychonomic Bulletin & Review*, 14, 230–236.

- Smith, R. E., Smoll, F. L., & Schutz, R. W. (1990). Measurement and correlates of sport-specific cognitive and somatic trait anxiety: The sport anxiety scale. *Anxiety Research*, 2(4), 263–280. <https://doi.org/10.1080/08917779008248733>
- Sotoodeh, M. S., Taheri-Torbati, H., Hadjikhani, N., & Lassalle, A. (2021). Preserved action recognition in children with autism spectrum disorders: Evidence from an EEG and eye-tracking study. *Psychophysiology*, 58(3), e13740. <https://doi.org/10.1111/psyp.13740>
- Soussou, W., Rooksby, M., Forty, C., Weatherhead, J., & Marshall, S. (2012). EEG and eye-tracking based measures for enhanced training. *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 1623–1626.
- Strohl, J., Gonzalez, C., Sauser, J., Montazeri, S., & Griepentrog, B. (2015). Creating forms and disclosures that work: using eye tracking to improve the user experience. *International Conference on Universal Access in Human-Computer Interaction*, 121–131. https://doi.org/10.1007/978-3-319-20678-3_12
- Szajerman, D., & Napieralski, P. (2017). Joint analysis of simultaneous EEG and eye tracking data for video picture. *2017 18th International Symposium on Electromagnetic Fields in Mechatronics, Electrical and Electronic Engineering (ISEF) Book of Abstracts*, 1–2. <https://doi.org/10.1109/ISEF.2017.8090693>
- Talone, A. B., Basavaraj, P., & Wisniewski, P. J. (2017). Enhancing human-computer interaction and user experience education through a hybrid approach to experiential learning. *Proceedings of the 18th Annual Conference on Information Technology Education*, 83–88. <https://doi.org/10.1145/3125659.3125685>
- Thakur, A. (2020). *Approaching (Almost) Any Machine Learning Problem*. Amazon Digital Services LLC - Kdp. <https://books.google.es/books?id=ZbgAEAAAQBAJ>
- The R Foundation. (2023). *What is R? R Project*. <https://www.r-project.org/about.html>
- Tobii AB. (2023). Tobii Pro Nano User Manual. In *Tobii Pro Nano User Manual v2.5* (p. 26). Tobii AB.
- Tobii LatAm. (2021a). *Tobii Pro: Products*. <https://www.tobiipro.com/es/products/>
- Tobii LatAm. (2021b). *Webinar: Ejecución y Métricas*.
- Tobii LatAm. (2021c). *Webinar: Metodología y Planificación del estudio*.
- Troop, M., White, D., Wilson, K. E., & Zeni, P. (2020). The User Experience Design for Learning (UXDL) Framework: The Undergraduate Student Perspective. *The Canadian*

Journal for the Scholarship of Teaching and Learning, 11(3).
<https://doi.org/10.5206/cjsotl-rcacea.2020.3.8328>

Tsai, M.-J., Hou, H.-T., Lai, M.-L., Liu, W.-Y., & Yang, F.-Y. (2012). Visual attention for solving multiple-choice science problem: An eye-tracking analysis. *Computers & Education*, 58(1), 375–385. <https://doi.org/10.1016/j.compedu.2011.07.012>

U.S. Department of Health & Human Services. (2023a, May 18). *User Experience Basics*. Usability.Gov. <https://www.usability.gov/what-and-why/user-experience.html>

U.S. Department of Health & Human Services. (2023b, May 22). *Usability Evaluation Basics*. Usability.Gov. <https://www.usability.gov/what-and-why/usability-evaluation.html>

Velázquez, C., Muñoz, J., Álvarez, F., & Garza, L. (2006). La determinación de la calidad de objetos de aprendizaje. *VII Encuentro Internacional de Ciencias de La Computación ENC, 2006*, 346–351.

Vermeeren, A. P., Law, E. L., Roto, V., Obrist, M., Hoonhout, J., & Vaananen-Vainio-Mattila, K. (2010). *All UX evaluation methods*. All About UX. <https://www.allaboutux.org/all-methods>

Vettori, S., Dzhelyova, M., Van der Donck, S., Jacques, C., Van Wesemael, T., Steyaert, J., Rossion, B., & Boets, B. (2020). Combined frequency-tagging EEG and eye tracking reveal reduced social bias in boys with autism spectrum disorder. *Cortex*, 125, 135–148. <https://doi.org/10.1016/j.cortex.2019.12.013>

Villarreal, Y., Morales, M., Béliz, N., González, E., Gómez, B., & López, V. (2016). Objetos de Aprendizaje. *El Tecnológico*, 26(1), 18–19.

Villegas, A., Rodríguez, E., & Álvarez, F. (2024). Aplicación de técnicas de eye-tracking para la mejora de las pruebas y procesos de desarrollo de software. *Abstraction and Application*, 45, 141–162.

Von Ahn, L. (2023, October 26). *How to Make Learning as Addictive as Social Media* | Luis Von Ahn | TED. TED Talks. https://youtu.be/P6FORpg0KVo?si=_9fgAFZn1R64L3C3

Voss, K. E., Spangenberg, E. R., & Grohmann, B. (2003). Measuring the Hedonic and Utilitarian Dimensions of Consumer Attitude. *Journal of Marketing Research*, 40(3), 310–320. <https://doi.org/10.1509/jmkr.40.3.310.19238>

- Wang, H., Pi, Z., & Hu, W. (2019). The instructor's gaze guidance in video lectures improves learning. *Journal of Computer Assisted Learning*, 35(1), 42–50. <https://doi.org/10.1111/jcal.12309>
- Wang, J., Antonenko, P., Celepkolu, M., Jimenez, Y., Fieldman, E., & Fieldman, A. (2019). Exploring Relationships Between Eye Tracking and Traditional Usability Testing Data. *International Journal of Human-Computer Interaction*, 35(6), 483–494. <https://doi.org/10.1080/10447318.2018.1464776>
- Wiklund-Engblom, A. (2010). Triangulating methods for exploring the link between user experience and e-learning. *Proceedings of the 14th International Academic MindTrek Conference: Envisioning Future Media Environments*, 171–177. <https://doi.org/10.1145/1930488.1930525>
- Yao, L., Liu, Y., Li, W., Zhou, L., Ge, Y., Chai, J., & Sun, X. (2014). Using Physiological Measures to Evaluate User Experience of Mobile Applications. In D. Harris (Ed.), *Engineering Psychology and Cognitive Ergonomics* (pp. 301–310). Springer International Publishing.
- Zaki, T., Khan, N. I., & Islam, M. N. (2021). Evaluation of User's Emotional Experience Through Neurological and Physiological Measures in Playing Serious Games. In A. Abraham, V. Piuri, N. Gandhi, P. Siarry, A. Kaklauskas, & A. Madureira (Eds.), *Intelligent Systems Design and Applications* (pp. 1039–1050). Springer International Publishing.
- Zardari, B. A., Hussain, Z., Arain, A. A., Rizvi, W. H., & Vighio, M. S. (2021). Development and validation of user experience-based e-learning acceptance model for sustainable higher education. *Sustainability*, 13(11), 6201. <https://doi.org/10.3390/su13116201>
- Zheng, W.-L., Dong, B.-N., & Lu, B.-L. (2014). Multimodal emotion recognition using EEG and eye tracking data. *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 5040–5043. <https://doi.org/10.1109/EMBC.2014.6944757>
- Zuñiga, M. I. C., López, E. E. R., Rodríguez, F. J. Á., & Soto, A. T. (2022). Eye tracking for detection of ADHD patterns in children between 6 to 8 years-old. *2022 International Conference on Inclusive Technologies and Education (CONTIE)*, 1–7. <https://doi.org/10.1109/CONTIE56301.2022.10004422>

ANEXOS.

En esta sección final de anexos, se presenta el material complementario y de apoyo a la investigación, como experimentaciones previas y la productividad científica durante el doctorado.

ANEXO A. PRODUCTIVIDAD CIENTÍFICA.

ANEXO B. PROTOCOLO DE REVISIÓN SISTEMÁTICA DE LITERATURA (RSL).

ANEXO C. CONCENTRADO DE ARTÍCULOS FINALES Y CRITERIOS DE CALIDAD.

ANEXO D. CARTA DE CONSENTIMIENTO INFORMADO (FORMATO)

ANEXO E. TESIS Y TESINAS DIRIGIDAS DURANTE EL DCAT

ANEXO A. PRODUCTIVIDAD CIENTÍFICA.

ARTÍCULOS DE REVISTA INDEXADA JCR.

1. *Exploratory study of EEG signal patterns of blind and normal-sight people in a learning environment.* (Publicado en IJIDeM, 2022). **Referencia:** (Rodriguez Lopez et al., 2022).

Derivado de las primeras pruebas realizadas con EEG. Publicado en 3er semestre.

International Journal on Interactive Design and Manufacturing (IJIDeM)
<https://doi.org/10.1007/s12008-022-00847-8>

ORIGINAL PAPER



Exploratory study of EEG signal patterns of blind and normal-sight people in a learning environment

Eduardo Emmanuel Rodriguez Lopez¹  · Francisco Javier Alvarez Rodriguez¹  ·
 Karla Yuritzzi Amador Rodriguez² 

Received: 22 January 2021 / Accepted: 27 January 2022
 © The Author(s), under exclusive licence to Springer-Verlag France SAS, part of Springer Nature 2022

Abstract
 The EEG has allowed a great advance in development of neurosciences and clinical field, but it has also had a great impact in other areas such as technology or education. There are several studies focused on detecting attention, but few of them are aimed at people with blindness. Thus, in the present research, an exploratory method is proposed for detection of similarities and differences of EEG signals of 5 blind and 10 normal-sight people in a learning environment based on interaction (watching or listening) with popular science videos. Regarding analysis, Information Gain was applied, this technique for decision trees can be defined as the amount of information enhanced in the nodes before splitting them for making subsequent decisions. Therefore, although there was not performed the construction of a decision tree, the incidence of the main EEG signals (Delta, Theta, Alpha, Beta and Gamma) in the attention levels of the participants for this specific environment can be identified. Finally, the results show that the average levels of attention for both groups are around 50%, and the most influential waves were Delta, Theta and Alpha. It should be noted that this study is an initial analysis and is not intended to be conclusive, as a larger number of participants is needed, as well as the application of more in-depth processing methods.

Keywords EEG · Learning · Attention · Blind people · Normal-sight people

1 Introduction

Currently there are several ways to study the human brain, one of the most used is the electroencephalogram (EEG). Broadly speaking, this study consists of recording the brain's electrical activity (variations in electrical potential) using electrodes on the scalp [1–3]. Although the EEG is commonly used in medicine to diagnose sleep or brain disorders [4], it has also applications on psychology and neuroscience, and in recent years it has reached other areas, such as edu-

cation, for example to detect mental stress or memory load in students [5–7]. One of the reasons of this development is the fact that the EEG is an affordable and very efficient tool to study the brain [8], for which it has been very well integrated in different disciplines. Thus, as far as education is concerned and thanks to the application of other computer tools such as Machine Learning, Data Mining or Artificial Intelligence, different ways of examining how people learn have been developed, especially focused on the analysis of user attention [9–11].

2. *Comorbidities and risk factors impact of COVID-19 in Mexico: A Feature Utility Metrics Approach* (Publicado en IJDMB, 2022). **Referencia:** (Lopez et al., 2021).
Derivado de los análisis realizados en la materia optativa de *Data Science y Machine Learning aplicado*. Publicado en 3er semestre.

Comorbidities and risk factors impact of COVID-19 in Mexico: a feature utility metrics approach

Eduardo Emmanuel Rodríguez López*,
Daniel Hernández González,
Francisco Javier Álvarez Rodríguez
and Julio Cesar Ponce Gallegos

Universidad Autónoma de Aguascalientes,
Aguascalientes, Mexico

Email: emlopez@correo.uaa.mx

Email: dhgonzalez_21@hotmail.com

Email: fjalvar@correo.uaa.mx

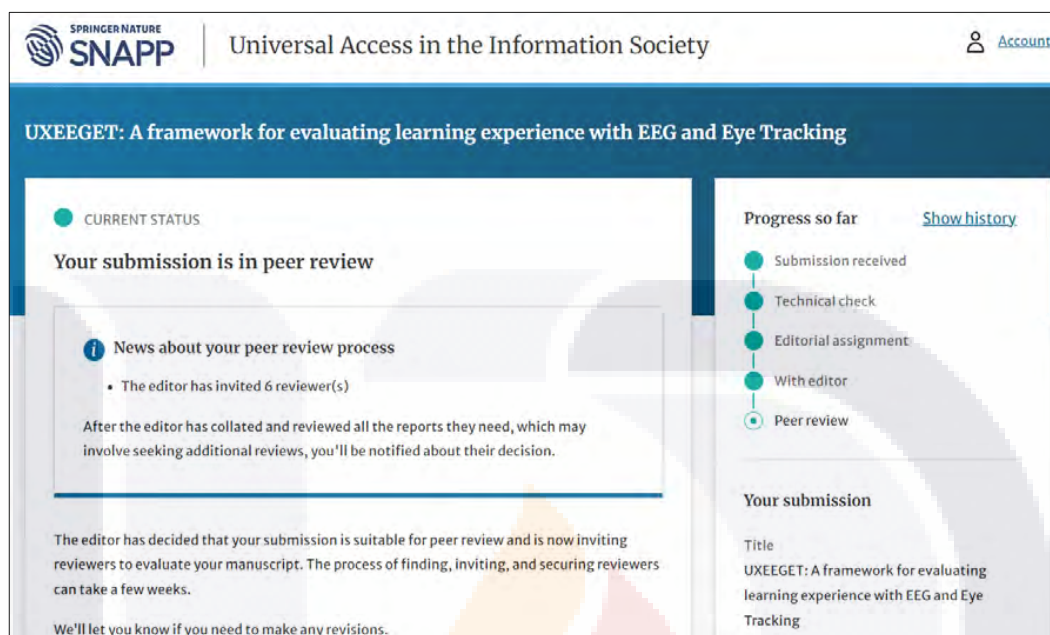
Email: jcponce@correo.uaa.mx

*Corresponding author

Abstract: By applying Machine Learning, it is possible to determine the impact of the main comorbidities and risk factors associated with COVID-19 based on an analysis of official Mexican Secretary of Health data. This analysis was performed using Feature Utility Metrics: Mutual Information (MI), Permutation Importance (PI) and Partial Dependence Plot (PDP) with two different learning models (RandomForest and XGBoost), finding similarities between these metrics. According to these models, the main comorbidities and risk factors associated with COVID-19 are Age, Gender, Obesity, Diabetes and Hypertension. Regarding MI and PI (RandomForest), the main risk factor is Age, while for PI (XGBoost) is Obesity. Finally, the PDP graph for Age, shows that the associated probability of risk of COVID-19 infection increases considerably after 60-years-old. Therefore, it was confirmed that the main comorbidities and risk factors associated with COVID-19 in Mexico are coherent with the diseases and conditions most present in the population.

Keywords: comorbidities; COVID-19 risk factors; mutual information; permutation importance; feature utility metrics.

3. *UXEEGET: A framework for evaluating learning experience with EEG and Eye Tracking*. Artículo enviado a Universal Access in the Information Society, octubre 2024. Se adjunta evidencia de envío.



ARTÍCULOS EN FOROS/CONGRESOS Y REVISTAS COMO COAUTOR.

1. *Visual Preferences in children diagnosed with ASD by generating heatmaps with Eye Tracking*.
Publicado en las memorias del 4th International Conference on Inclusive Technologies and Education (CONTIE 2021). **Referencia:** (Santiago et al., 2021)
2. *Eyetracking para el estudio de la carga cognitiva y su relación con el desempeño académico enfocado al área de matemáticas*.
Publicado en Proceedings del International Conference on Information Resources Management (CONF-IRM 2022). **Referencia:** (Ortíz et al., 2022)
3. *Trend prediction technique for Computer Visual Syndrome (CVS) with eye tracking as support*.
Publicado en las memorias del 5th International Conference on Inclusive Technologies and Education (CONTIE 2022). **Referencia:** (Campos et al., 2022)

4. *Eye tracking for detection of ADHD patterns in children between 6 to 8 years-old.*
Publicado en las memorias del 5th International Conference on Inclusive Technologies and Education (CONTIE 2022). **Referencia:** (Zuñiga et al., 2022)
5. *Algoritmos de Aprendizaje Automático para el Análisis de señales EEG en Neuromarketing.*
Publicado en Transformación Digital de las Instituciones Educativas, del Congreso Nacional – Congreso Internacional de Informática y Computación de la ANIEI (CNCIIC 2022). **Referencia:** (De Luna et al., 2022).
6. *Aplicación de técnicas de eye-tracking para la mejora de las pruebas y procesos de desarrollo de software.*
Publicado en Abstraction and Application – Derivado de la participación en el 11th International Conference in Software Engineering Research and Innovation (CONISOFT 2023).
Referencia: (Villegas et al., 2024).
7. *XGBoost to predict STEM profiles using Electroencephalography and Eye-tracking.*
Publicado en las memorias de 16th International Conference on Education and New Learning Technologies (EDULEARN 24). **Referencia:** (Ramírez et al., 2024).
8. *From EEG Signal Acquisition and Classification to Mobile Integration: A Comprehensive Framework.*
Publicado en Advances in Soft Computing del Mexican International Conference on Artificial Intelligence (MICA I 2024). **Referencia:** (Serna et al., 2025)
9. *Modelo para la evaluación objetiva de interfaces mediante el análisis de patrones de atención visual obtenidos con eye-tracking.*
Pendiente de publicar en las memorias de las Jornadas Iberoamericanas de Ingeniería de Software e Ingeniería del Conocimiento (JIISIC 2024). **Referencia:** Pendiente de publicar.

10. FalsiFind: A Mobile AI-Powered Application for On-Device Fake News Detection.

Enviado a IEEE Latin America Transactions, octubre 2024.



ANEXO B. PROTOCOLO DE REVISIÓN SISTEMÁTICA DE LITERATURA (RSL).

Basado en la guía de (Kitchenham & Charters, 2007).

Antecedentes.

La evaluación de Experiencia de Usuario (*UX*, por sus siglas en inglés) consiste en el análisis de los sentimientos, pensamientos, interacción y reacción que tiene un usuario al realizar una actividad (Benyon, 2019). Regularmente suele asociarse la *UX* al campo de la Ingeniería de Software, sobre todo con conceptos como la Usabilidad o la Interacción Humano – Computadora (*HCI*, por sus siglas en inglés), pero bajo ciertas adecuaciones puede adaptarse para emplearse en ambientes fuera de la computación.

Justamente, una de las áreas donde la *UX* puede ser aplicada es el aprendizaje, puesto que existen variedad de estudios enfocados al respecto, por ejemplo, basados en ambientes de *e-learning* o gamificación (Alexiou & Schippers, 2018; Santoso et al., 2016). Si, además a los estudios tradicionales de *UX* se incorporan tecnologías y herramientas biométricas como el EEG o *Eye Tracking*, es más preciso conocer de manera objetiva la interacción que tiene un usuario con un ambiente u objeto de aprendizaje. No se mide el aprendizaje en sí mismo, sino que se pretende entender la experiencia del aprendizaje.

Dado que en la actualidad se avanza hacia estrategias de aprendizaje más digitales, la combinación de estas tecnologías permitirá conocer y diseñar mejores contenidos que sean de mayor utilidad para los estudiantes de cualquier nivel educativo. Por lo anterior, se plantea una RSL sobre la aplicación de técnicas de *UX* en combinación con EEG y/o *Eye tracking*, y temas afines, como estudios previos de combinación de estas técnicas biométricas o del *UX* enfocado al aprendizaje.

Preguntas de investigación de la RSL.

Las preguntas de investigación para esta RSL son:

1. ¿Existen modelos de *UX* relacionados con el aprendizaje/enseñanza?
2. ¿Cómo son los modelos de *UX* que implementan EEG y *Eye Tracking* a la vez?

3. ¿Qué metodologías de *Data Science* se pueden utilizar para procesar datos provenientes de EEG y *Eye Tracking*?

4. ¿Qué metodologías de investigación se pueden aportar desde el *marketing*?

Proceso de búsqueda.

El proceso de búsqueda consistirá en un trabajo manual de consulta en las bases de datos de artículos científicos y repositorios de referencias bibliográficas más importantes en el área de Ingeniería de Software, tecnología y ciencias en general.

Fuentes de búsqueda: Las búsquedas se realizarán en las principales bases de datos de artículos científicos y repositorios de referencias bibliográficas más relevantes, y que además tengan convenio vigente con la Universidad Autónoma de Aguascalientes, o bien que sean *Open Access*. Estas son:

- IEEE Xplore
- Science Direct Elsevier
- Springer Link
- ACM Digital Library
- PubMed
- ArXiv
- Academic Search Ultimate EBSCO
- Directory of Open Access Journals (DOAJ)
- Web of Science (WOS)

Criterios de inclusión.

Se tomarán en cuenta artículos publicados entre el 2010 – 2021 y que cumplan con alguno de los siguientes puntos:

- Modelo o *framework* de *UX* orientado al aprendizaje.
- Modelo o *framework* de procesamiento de datos conjunto de EEG o *Eye Tracking*, sea o no con relación a la *UX*.
- Investigaciones de EEG o *Eye Tracking* con relación al aprendizaje o áreas afines.

Criterios de exclusión.

Se excluirán artículos que presenten lo siguiente:

- Que no cumplan o no tengan relación con alguno de los puntos definidos en los criterios de inclusión.
- Que estén incompletos o con acceso parcial.
- Que estén fuera del periodo 2010 – 2021.
- Que sean capítulos de libro.

Cuando un artículo se encuentre en más de un repositorio se tomará la versión más completa descartando el duplicado.

Proceso de selección de estudios.

Los artículos pasarán por una selección preliminar basada en los resultados de búsqueda con las cadenas definidas en cada repositorio o base de datos; y por un proceso de selección detallada basada en la relación de título de cada artículo y el *abstract*.

Medición de calidad.

Previo a la lectura completa de los artículos que hayan pasado la selección, se definirán los criterios de calidad para garantizar la relación directa con el tema de investigación. Estos son:

1. Objetivo de investigación próximo al interés de búsqueda.
2. Metodología de investigación aplicada con rigor científico y apegada al uso de EEG y/o *Eye Tracking*.
3. Resultados con rigor y conclusiones pertinentes.

Se busca que los artículos en esta etapa presenten por lo menos uno de los criterios de calidad.

Recolección de datos.

De los artículos consultados se toman en cuenta:

- Título
- Autores
- Año de publicación
- Revista / Conferencia
- Base de datos o repositorio en que se aloja

- Tema (Relación con las preguntas de investigación de la RSL).

Análisis de datos.

Los datos serán concentrados en hojas de cálculo y representados a maneras de tablas y gráficas por cada proceso de selección preliminar y detallada. Además, se generará una gráfica de contribución de cada base de datos o repositorio de artículos científicos y se elaborará una tabla principal sobre los artículos de lectura completa considerando si cumplieron o no los criterios de calidad junto a una breve descripción de cada trabajo de investigación.

Divulgación.

Se plantea generar un artículo sobre los resultados de la RSL para un revista indexada y así poder compartir los hallazgos con la comunidad científica.

Referencias del Protocolo de la RSL.

- Alexiou, A., & Schippers, M. C. (2018). Digital game elements, user experience and learning: A conceptual framework. *Education and Information Technologies*, 23(6), 2545–2567. <https://doi.org/10.1007/s10639-018-9730-6>
- Benyon, D. (2019). *Designing User Experience*. Pearson Educación. <https://books.google.es/books?id=MXqFDwAAQBAJ>
- Kitchenham, B., & Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering. Technical report, ver. 2.3 ebse technical report. ebse.
- Santoso, H. B., Schrepp, M., Isal, R., Utomo, A. Y., & Priyogi, B. (2016). Measuring user experience of the student-centered e-learning environment. *Journal of Educators Online*, 13(1), 58–79.

ANEXO C. CONCENTRADO DE ARTÍCULOS FINALES Y CRITERIOS DE CALIDAD.

En la siguiente tabla se muestra una breve descripción de los artículos finales luego de realizar la lectura completa y verificar su cumplimiento de los criterios de calidad.

Tabla Anexa 1 Concentrado de artículos finales y criterios de calidad (Elaboración del autor).

Título del artículo	Referencia	Base de datos	Descripción general	Relación Directa	Criterio de calidad
Attention Evaluation with Eye Tracking Glasses for EEG-based Emotion Recognition	(Shi et al., 2017)	IEEE Xplore	Se propone un <i>framework</i> para reconocimiento de emociones basado en EEG y <i>Eye Tracking</i> (Fig. 9)	Sí	2
Designing Meaningful UX Interactive Learning Experience Model	(Kremer et al., 2016)	IEEE Xplore	Se propone un modelo para la Experiencia de Aprendizaje Interactivo y se muestra, como un antecedente interesante, el modelo ExodUX (Fig. 10)	Sí	1
Discriminating Different Color from EEG Signals using Interval-Type 2 Fuzzy Space Classifier	(Rakshit & Lahiri, 2016)	IEEE Xplore	Por medio de técnicas de Machine Learning se describe la relevancia de los colores a través de un análisis de señales EEG.	No	

EEG and Eye-Tracking Based Measures for Enhanced Training	(Soussou et al., 2012)	IEEE Xplore	Se muestran mediciones generales de EEG y <i>Eye Tracking</i> .	No	
EEG Signal Classification for Real-Time Neuro Marketing Applications	(Jain et al., 2018)	IEEE Xplore	Se muestran aspectos muy generales del procesamiento de señales EEG y una aplicación al Marketing.	No	
Enhancing User Experience in Mobile Learning by Affective Interaction	(Shen et al., 2014)	IEEE Xplore	Se expone un estudio de UX basado en el aprendizaje con dispositivos móviles.	No	
Evaluating User Experience of English Learning Interface using UX Questionnaire and System Usability Scale	(Devy et al., 2017)	IEEE Xplore	Se muestra un estudio en el que se aplican dos técnicas de evaluación de UX tradicionales en aprendizaje de lengua inglesa.	No	
Exploiting EEG Signals for Eye Motion Tracking	(Kovtun et al., 2020)	IEEE Xplore	Se presenta un estudio que combina EEG y <i>Eye Tracking</i> (con el desarrollo de un sistema propio) desde un enfoque muy técnico.	No	
Eye tracking and EEG synchronization to analyze microsaccades during a workload task	(Bodala et al., 2015)	IEEE Xplore	Se presenta un estudio de EEG y <i>Eye Tracking</i> enfocado al análisis de las microsacadas	No	

			desde un enfoque muy técnico.		
In the Twinkling of an Eye Synchronization of EEG and Eye Tracking based on blink signatures	(Bøekgaard et al., 2014)	IEEE Xplore	De manera similar al estudio anterior, esta investigación se enfoca en el análisis del parpadeo.	No	
Joint analysis of simultaneous EEG and Eye tracking data for video picture	(Szajerman & Napieralski, 2017)	IEEE Xplore	Se presenta un estudio simple y general del procesamiento de EEG y <i>Eye Tracking</i> .	No	
Multimodal Emotion Recognition using EEG and Eye Tracking Data	(Zheng et al., 2014)	IEEE Xplore	Se utilizan EEG y <i>Eye Tracking</i> para el reconocimiento de emociones y se propone un <i>framework</i> .	Sí	1,2
UX Model in the Interaction between Children with Special Educational Needs and Learning Media	(Sagirani et al., 2015)	IEEE Xplore	Se presenta un modelo de <i>UX</i> para niños con necesidades de educación especiales.	No	
Improving data retention in EEG research with children using child-centered eye tracking	(Maguire et al., 2014)	Science Direct Elsevier	Se muestra una aplicación de <i>Eye Tracking</i> y EEG basada en estudios de atención en niños.	Sí	1,2
The identification of children with autism spectrum disorder by SVM approach on EEG and eye-tracking data	(Kang et al., 2020)	Science Direct Elsevier	Se muestra un estudio basado en EEG y <i>Eye Tracking</i> con el procesamiento de	No	

			SVM para la identificación de niños con Trastorno del Espectro Autista.		
Creating Forms and Disclosures that Work Using Eye Tracking to Improve the User Experience	(Strohl et al., 2015)	Springer Link	Se presenta un estudio basado en <i>Eye Tracking</i> para reconocer puntos clave del diseño de Formas de consentimiento.	No	
Eye Tracking Evaluation of UX on Large-Scale Displays	(Schall, 2015b)	Springer Link	Se presenta un estudio basado en <i>Eye Tracking</i> para medir la UX al mirar pantallas grandes enfocadas a noticias.	No	
Eye Tracking Usability Testing Enhanced with EEG Analysis	(Falkowska et al., 2016)	Springer Link	Se muestra un estudio de medición de Usabilidad basado en <i>Eye Tracking</i> y mejorado con EEG. Además, se presentan métricas interesantes de <i>Eye Tracking</i> parecidas a las descritas en la Sección II.	Sí	1,2
Processing EEG Signals Towards the Construction of a User Experience Assessment Method	(Carrillo et al., 2015)	Springer Link	Se muestra un estudio basado en la aplicación de Redes Neuronales para el procesamiento de señales EEG para la	Sí	1,2

			construcción de un método de evaluación de Experiencia de Usuario.		
Design of Learning Digital Tools Through a User Experience Design Methodology	(Mendoza-Franco et al., 2021)	Springer Link	Se presenta el diseño de herramientas de aprendizaje digital para la creación de una metodología de <i>UX</i>	Sí	1
Enhancing Virtual Learning by Improving the Learning Environment and User Experience	(Mavengere & Ruohonen, 2019)	Springer Link	Se presenta un estudio que busca promover el Aprendizaje Virtual mediante la mejora del Ambiente Virtual y la <i>UX</i>	Sí	1
Desired Content versus Digital Advertisements: An Eye Tracking User Experience Study	(Özdemir et al., 2020)	ACM Digital Library	Se muestra un estudio basado en Eye Tracking para encontrar diferencias con el tiempo de exposición de contenido publicitario	No	
Cognitive Workload Classification using Eye Tracking and EEG Data	(Lobo et al., 2016)	ACM Digital Library	Se muestra un clasificador de carga cognitiva para pilotos (de aeronaves) utilizando algoritmos de ML mediante estudios	No	

			de EEG y Eye Tracking		
Enhancing Human-Computer Interaction and User Experience Education through a Hybrid Approach to Experiential Learning	(Talone et al., 2017)	ACM Digital Library	Se presenta un programa de consultoría de HCI y UX para empresas, dirigido por miembros de la facultad de IT de la UCF, con mentoría por estudiantes de posgrados y aplicado por estudiantes de pregrado de IT.	No	
Evaluation of User Experience of service system Using Mobile Eye Tracking	(Z. Liu & Juan, 2020)	ACM Digital Library	Se presenta un estudio de usabilidad del sistema recaudador de impuestos en China mediante la aplicación de eye tracking.	No	
Evaluation of user experience and cognitive load of a gamified cognitive training application for children with learning disabilities	(Shaban & Pearson, 2020)	ACM Digital Library	Se muestra el diseño y evaluación mediante técnicas de UX de un videojuego educativo para niños con problemas de aprendizaje (centrado en carga cognitiva)	No	
Intervention-free selection using EEG and eye tracking	(Putze et al., 2016)	ACM Digital Library	Se muestra un método de selección en GUI	No	

			mediante combinación de EEG y Eye tracking (comportamiento de mirada y actividad cerebral) basado en fijaciones y ERPs		
Investigating static and sequential models for intervention-free selection using multimodal data of EEG and eye tracking	(Salous et al., 2018)	ACM Digital Library	Se presenta una comparación de diferentes modelos secuenciales para un método de selección sin intervención basado en eye tracking y EEG	No	
Locating user attention using eye tracking and EEG for spatio-temporal event selection	(Putze et al., 2013)	ACM Digital Library	Se propone un método de detección de atención del usuario a través de la aplicación de eye tracking (espacial) y EEG (temporal)	Sí	2,3
Spatio-Temporal Detection of Divided Attention in Reading Applications Using EEG and Eye Tracking	(Rodrigue et al., 2015)	ACM Digital Library	Se presenta el desarrollo de un clasificador de tipos de atención (normal y dividida) durante la lectura mediante la aplicación de EEG y eye tracking	Sí	2
Triangulating methods for exploring the link between user experience and e-learning	(Wiklund-Engblom, 2010)	ACM Digital Library	Se muestra un <i>framework</i> de métodos de evaluación de UX	Sí	1

			en un entorno de e-learning		
Usability of EEG Systems: User Experience Study	(Izdebski et al., 2016)	ACM Digital Library	Se presenta un estudio de usabilidad y UX de distintos sistemas de adquisición de EEG	No	
A Literature Review of EEG-Based Affective Computing in Marketing	(Pei & Li, 2021)	PubMed	Se presenta una completa revisión de técnicas, métodos y estudios previos de EEG aplicados al marketing (ERPs, Componentes de tiempo-frecuencia, clasificación y reconocimiento de estados afectivos).	No	
A psychotechnological review on eye-tracking systems: towards user experience.	(Mele & Federici, 2012)	PubMed	Se presenta una revisión sistemática de la literatura sobre la aplicación del eye tracking en el campo de la UX	Sí	1,2
Classifying major depression patients and healthy controls using EEG, eye tracking and galvanic skin response data.	(Ding et al., 2019)	PubMed	Se muestra un estudio sobre la clasificación de pacientes con Trastorno Depresivo Mayor a partir de varios modelos de ML utilizando Eye Tracking, EEG y GSR.	No	

Combined frequency-tagging EEG and eye tracking reveal reduced social bias in boys with autism spectrum disorder.	(Vettori et al., 2020)	PubMed	Se muestra un estudio basado en EEG y Eye Tracking para la identificación de características de niños entre 8-12 años con TEA y con desarrollo neurotípico	No	
EEG and Eye Tracking Signatures of Target Encoding during Structured Visual Search.	(Brouwer et al., 2017)	PubMed	Se presenta un estudio basado en EEG y Eye Tracking (Duración de Fijación, Tamaño de pupila, SRP y ERPs) para el reconocimiento de objetivos durante vista con alta y baja carga cognitiva	Sí	2,3
Is EEG Suitable for Marketing Research? A Systematic Review	(Bazzani et al., 2020)	PubMed	Se presenta una revisión sistemática de la literatura concerniente a la aplicación del EEG en el Neuromarketing, resaltando sus ventajas y limitaciones.	No	
Method for Improving EEG Based Emotion Recognition by Combining It with Synchronized Biometric and Eye Tracking Technologies in a	(López-Gil et al., 2016)	PubMed	Se presenta un clasificador de reconocimiento de emociones utilizando EEG, eye tracking y otras	Sí	2

Non-invasive and Low Cost Way.			técnicas biométricas (Empática Wristband, EDA, PVP, aceleración, ritmo cardiaco y temperatura)		
Preserved action recognition in children with autism spectrum disorders: Evidence from an EEG and eye-tracking study.	(Sotoodeh et al., 2021)	PubMed	Se muestra un estudio de correlación entre dos experimentos (basados en EEG y eye tracking) con niños con y sin TEA con respecto a la manera en que procesan las representaciones de estímulos de movimiento biológico	No	
Regression-based analysis of combined EEG and eye-tracking data: Theory and applications.	(Dimigen & Ehinger, 2021)	PubMed	Se presenta un <i>framework</i> para analizar el movimiento ocular relacionado con la actividad cerebral (EEG) mediante el análisis de FRPs	Sí	2
Using eye-tracking and EEG to study the mental processing demands during learning of text-picture combinations.	(Scharinger et al., 2020)	PubMed	Se muestra un estudio de la investigación de <i>Text Picture Integration</i> (TPI) mediante EEG y eye tracking para	Sí	2,3

			procesamiento mental.		
Framework for Electroencephalography-based Evaluation of User Experience	(Frey et al., 2016)	ArXiv	Se presenta un framework de evaluación de carga de trabajo, atención y de interacción mediante EEG.	Sí	1,2
Setting accessibility preferences about learning objects within adaptive e-learning systems: User experience and organizational aspects.	(Rodriguez-Ascaso et al., 2017)	Academic Search Ultimate EBSCO	Se presenta una investigación basada en la evaluación de la UX y accesibilidad de ambientes e-learning.	Sí	1,2
Exploring the user experience of three-dimensional virtual learning environments.	(Shin et al., 2013)	Academic Search Ultimate EBSCO	Se muestra una investigación de exploración de UX de sistemas 3D de aprendizaje.	No	
Assessment of user experience in video-based learning environments: From design guidelines to final product.	(Madariaga et al., 2021)	Academic Search Ultimate EBSCO	Se muestra una investigación concerniente a la evaluación sistemática de UX de objetos de aprendizaje.	Sí	1,2
Effects of using a second-screen application on attention, learning, and user experience in an educational content.	(Lee et al., 2018)	Academic Search Ultimate EBSCO	Se presenta un estudio sobre el impacto del uso de pantallas auxiliares (segundas pantallas) en la atención, rendimiento y carga cognitiva en	Sí	1

			entornos educativos.		
An eye tracking system: towards applications in marketing?	(Dobias et al., 2013)	Academic Search Ultimate EBSCO	Se presenta una revisión de literatura sobre la aplicación del Eye tracking en el marketing. Ya se cuenta con un artículo similar con antecedentes más actuales.	No	
Development and Validation of User Experience-Based E-Learning Acceptance Model for Sustainable Higher Education	(Zardari et al., 2021)	DOAJ	Se presenta un modelo basado en UX sobre la aceptación de ambientes de e-learning en educación superior.	No	
The User Experience Design for Learning (UXDL) Framework: The Undergraduate Student Perspective	(Troop et al., 2020)	DOAJ	Se presenta un modelo de diseño de UX enfocado al aprendizaje de alumnos de educación superior.	Sí	1,3
Building pipelines for educational data using AI and multimodal analytics: A grey-box approach	(Sharma et al., 2019)	Web of Science	Se presenta la aplicación de técnicas de Machine Learning a partir de datos multimodales para el análisis de aprendizaje.	Sí	1,2
Evaluating Eye Tracking Technology for Assessment of Students with Profound and Multiple Learning Difficulties	(Gill & Younie, 2021)	Web of Science	Se muestra un estudio enfocado a la aplicación de eye tracking enfocado	Sí	1,2

			en estudiantes con PMLD.		
Exploring Dual Eye Tracking as a Tool to Assess Collaboration	(Olsen et al., 2017)	Web of Science	Se muestra un estudio en el que se aplica eye tracking dual para medir el aprendizaje colaborativo.	No	
Uses of Physiological Monitoring in Intelligent Learning Environment: A Review of Research Evidence and Technologies	(Lane & D'Mello, 2019)	Web of Science	Se presenta una revisión de las tecnologías biométricas más comunes empleadas en el aprendizaje.	No	
Showing Is Knowing: The Potential and Challenges of Using Neurocognitive Measures of Implicit Learning in the Classroom	(Dahlstrom-Hakki et al., 2019)	Web of Science	Se muestra un estudio sobre la aplicación de tecnologías multimodales neurocognitivas en ambientes de aprendizaje.	Sí	1,3
Multimodal Learning Analytics research with young children: A systematic Review	(Crescenzi-Lanna, 2020)	Web of Science	Se presenta una revisión sistemática de la literatura sobre el análisis de aprendizaje multimodal en niños menores de 6 años.	No	
Instructor presence in videolectures: Eye gaze matters but not body orientation	(Pi et al., 2020)	Web of Science	Se presenta un estudio sobre la influencia que tiene la mirada y la posición del profesor (en video lecturas) en el	No	

			desempeño de aprendizaje de los alumnos.		
Measurement of cognitive load in multimedia effect in Testing: A Comparison of different objective measures	(Korbach et al., 2017)	Web of Science	Se presenta un estudio para medir la carga cognitiva de los alumnos mediante la aplicación de eye tracking.	Sí	1,3
Identifying process underlying the multimedia effect in testing: An eye-movement analysis	(Lindner et al., 2017)	Web of Science	Se presenta un estudio que compara la influencia de las figuras (imágenes), mediante eye tracking, en la resolución de tareas de opción múltiple	Sí	1,2
Eye movements predict student's computer-based assessment performance of physics concepts in different presentation modalities	(Chen et al., 2014)	Web of Science	Se muestra un estudio basado en la predicción de respuesta a partir de los movimientos oculares medidos con eye tracking.	Sí	2,3
Modulation of instructor's eye gaze by facial expression in video lectures	(Pi et al., 2022)	Web of Science	Se presenta un estudio sobre la influencia de la mirada y expresión facial del profesor (en video lecturas) con respecto a la atención de los alumnos	No	
Identifying expert and novice visual scanpath patterns and	(Kosel et al., 2021)	Web of Science	Se muestra un estudio sobre la	No	

their relationship to assessing learning-relevant student characteristics			comparación de scanpaths de profesores expertos y novatos en la medición de características de aprendizaje de diferentes alumnos.		
Visual attention for solving multiple-choice science problem: An eye-tracking analysis	(Tsai et al., 2012)	Web of Science	Se presenta un estudio sobre la atención visual de seis estudiantes universitarios durante la resolución de una actividad de opción múltiple sobre ciencias.	Sí	2,3
The instructor's gaze guidance in video lectures improves learning	(H. Wang et al., 2019)	Web of Science	Se muestra un estudio sobre la influencia de la mirada del profesor en el desempeño y aprendizaje de los estudiantes (en video lecturas)	No	
Exploring the depths of second language processing with eye tracking: An Introduction	(Godfroid et al., 2020)	Web of Science	Se presenta un estudio sobre los comportamientos visuales de estudiantes de una segunda lengua (mediante eye tracking)	No	
Screening for reading difficulties: Comparing eye tracking outcomes to	(Gran Ekstrand et al., 2021)	Web of Science	Se presenta un estudio enfocado a niños con	No	

neuropsychological assessments			problemas de lectura mediante la comparación de métricas de eye tracking y evaluación neuropsicológica.		
-----------------------------------	--	--	---	--	--



ANEXO D. CARTA DE CONSENTIMIENTO INFORMADO
(FORMATO)



Carta de Consentimiento Informado

Proyecto: Evaluación de la experiencia de aprendizaje en estudiantes de programación

Fecha: _____

Nombre completo del participante: _____

Descripción de la actividad: Durante la experimentación llevada a cabo por el equipo Alpha, y bajo la supervisión del M.C.C. Eduardo Emmanuel Rodríguez López, usted será expuesto(a) a un video didáctico de unos 5 minutos de duración que explica la Programación Orientada a Objetos. Mientras observe el video, se registrarán datos de seguimiento ocular mediante el dispositivo Tobii Pro Nano y señales electroencefalográficas a través de la diadema MindWave Mobile. La duración total del experimento será menor a 10 minutos.

Tratamiento de datos: Todos los datos recopilados serán tratados con estricta confidencialidad, y se utilizarán exclusivamente para fines de esta investigación. No se divulgará información que pueda identificar personalmente al participante.

Voluntariedad: Su participación en este proyecto es totalmente voluntaria. Usted tiene derecho a retirarse del estudio en cualquier momento sin consecuencias ni justificación.

Contacto: Si tiene alguna duda o inquietud sobre el proyecto, se puede contactar con Manuel González Martínez al correo al228552@edu.uaa.mx

Al firmar esta carta, usted indica que comprende la información anterior y que da su consentimiento para participar en el proyecto.

Nombre y firma del Participante

Nombre y firma del Experimentador

Nombre y firma del Testigo

ANEXO E. TESIS Y TESINAS DIRIGIDAS DURANTE EL DCAT

En este anexo, en la Tabla 11 se muestran las tesinas y tesis dirigidas o codirigidas durante los cuatro años del DCAT.

Tabla Anexa 2 Trabajos dirigidos durante el DCAT (Elaboración propia, 2024)

María Isabel Cordero Zúñiga, ICI	Periodo 2021 – 2022	Tesina
<i>Eye tracking</i> para la detección de patrones de TDAH en niños de entre 6 y 8 años.		
Sergio Adal Ruíz Campos, ICI	Periodo 2021 - 2022	Tesina
<i>Eye tracking</i> para la detección de vista cansada y disminución del Síndrome Visual Informático.		
Jessica de Luna García, ICI	Periodo 2021 – 2022	Tesina
Algoritmos de <i>Machine Learning</i> en <i>Neuromarketing</i> .		
Giancarlo Ramírez Díaz de León, ICI	Periodo 2022 - 2023	Tesina
Procesamiento de Ondas cerebrales para la identificación de emociones.		
Cristian Pinto Méndez, ICI	Periodo 2022 - 2023	Tesina
Propuesta inicial de un modelo predictivo para la detección temprana de tendencias depresivas.		
Vanessa Isabel Arellano Serna, ICI	Periodo 2023 - 2024	Tesina
Uso de señales EEG para la clasificación de comandos mentales por medio de modelos de aprendizaje automático y su potencial aplicación para el control de dispositivos móviles.		
Airam Nataly Merla Pedroza, ICI	Periodo 2023 - 2024	Tesina
Entrenamiento de un Modelo de <i>Deep Learning</i> para la Detección y Clasificación de Residuos Sólidos Urbanos en Zonas Terrestres de Dificil Acceso.		
Joaquín Emiliano Pedroza Gutiérrez, ICI	Periodo 2023 - 2024	Tesina
Comparación de modelos de <i>Machine Learning</i> (XBoost, SVM, <i>Random Forest</i> , KNN y <i>Deep Learning</i>) en datos biométricos (EEG y <i>Eye Tracking</i>).		
Manuel González Martínez, ICI	Periodo 2023 - 2024	Tesina
Aplicación móvil para la detección de <i>Fake News</i> utilizando Inteligencia Artificial.		
Hiram Daniel Díaz Ruíz, ICI	Periodo 2023 - 2024	Tesina

Optimización De La Movilidad En El Campus Central De La UAA Mediante El Uso De Una Aplicación Móvil de Navegación Y Técnicas De *UX*.

Ángel Eduardo Villegas Ortíz, MCCMA Periodo 2022 - 2024 Tesis de maestría

Modelo para la Aplicación del Análisis del Comportamiento de Mirada Mediante *Eyetracking* de la Interacción Usuario- Sistema para Mejorar la Calidad de la UX y Mejorar los Procesos de Desarrollo de Software. **

** Codirigida con el Dr. Francisco Javier Álvarez Rodríguez.

