



**EDUCACIÓN**

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO  
NACIONAL DE MÉXICO

# Tecnológico Nacional de México

Centro Nacional de Investigación  
y Desarrollo Tecnológico

## Tesis de Doctorado

Metodología para el reconocimiento de emociones  
basado en datos fisiológicos multimodales mediante  
la selección de características relevantes

presentada por

**MC. Karen Jannete Jaime Díaz**

como requisito para la obtención del grado de  
**Doctor en Ciencias de la Computación**

Director de tesis

**Dr. Juan Gabriel González Serna**

Codirector de tesis

**Dr. Dante Mujica Vargas**

Cuernavaca, Morelos, México. Diciembre de 2023.

 Centro Nacional de Investigación y Desarrollo Tecnológico	<b>ACEPTACIÓN DE IMPRESIÓN DEL DOCUMENTO DE TESIS DOCTORAL</b>	<b>Código: CENIDET-AC-006-D20</b>
		<b>Revisión: 0</b>
	<b>Referencia a la Norma ISO 9001:2008 7.1, 7.2.1, 7.5.1, 7.6, 8.1, 8.2.4</b>	<b>Página 1 de 1</b>

Cuernavaca, Mor., a 23 de noviembre de 2023

**CARLOS MANUEL ASTORGA ZARAGOZA**  
**SUBDIRECTOR ACADÉMICO**  
**PRESENTE**

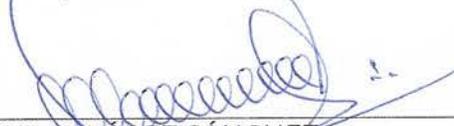
AT'n: **JUAN CARLOS ROJAS PÉREZ**  
**PRESIDENTE DEL CLAUSTRO DOCTORAL**

Los abajo firmantes, miembros del Comité Tutorial de la estudiante **KAREN JANNETE JAIME DÍAZ** manifiestan que después de haber revisado el documento de tesis titulado "METODOLOGÍA PARA EL RECONOCIMIENTO DE EMOCIONES BASADO EN DATOS FISIOLÓGICOS MULTIMODALES MEDIANTE LA SELECCIÓN DE CARACTERÍSTICAS RELEVANTES", realizado bajo la dirección del Juan Gabriel González Serna y codirección de Dante Mújica Vargas, el trabajo se **ACEPTA** para proceder a su impresión.

ATENTAMENTE

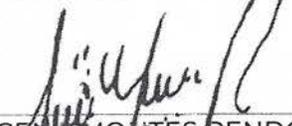
  
 JUAN GABRIEL GONZPALEZ SERNA  
 TecNM/CAMPUS CENIDET

  
 DANTE MÚJICA VARGAS  
 TecNM/CAMPUS CENIDET

  
 MÁXIMO LÓPEZ SÁNCHEZ  
 TecNM/CAMPUS CENIDET

  
 NOÉ ALEJANDRO CASTRO SÁNCHEZ  
 TecNM/CAMPUS CENIDET

  
 NIMROD GONZÁLEZ FRANCO  
 TecNM/CAMPUS CENIDET

  
 AZUCENA MONTÉS RENDÓN  
 TecNM/CAMPUS I.T. TLALPÁN

SEP TecNM Y DESARROLLO TECNOLÓGICO  
**RECIBIDO**  
 01 DIC 2023  
 LMZ  
 SUBDIRECCIÓN ACADÉMICA

EDUCACIÓN | INSTITUTO NACIONAL DE ESTADÍSTICAS Y CENSO  
**27 NOV 2023**  
 CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO  
 SERVICIOS ESCOLARES  
**RECIBIDO**  
 ESN

c.c.p: María Elena Gómez Torres / Jefa del Departamento de Servicios Escolares  
 c.c.p: María Yasmín Hernández Pérez / Jefa del Departamento C. Computacionales  
 c.c.p: Expediente



Cuernavaca, Mor.,  
No. De Oficio:  
Asunto:

04/diciembre/2023  
SAC/194/2023  
Autorización de  
impresión de tesis

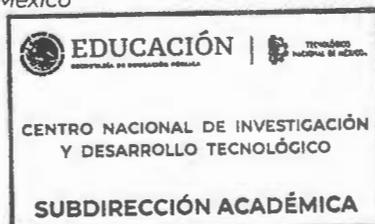
**KAREN JANNETE JAIME DÍAZ**  
**CANDIDATA AL GRADO DE DOCTORA EN CIENCIAS**  
**DE LA COMPUTACIÓN**  
**P R E S E N T E**

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **“METODOLOGÍA PARA EL RECONOCIMIENTO DE EMOCIONES BASADO EN DATOS FISIOLÓGICOS MULTIMODALES MEDIANTE LA SELECCIÓN DE CARACTERÍSTICAS RELEVANTES”**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

**ATENTAMENTE**

Excelencia en Educación Tecnológica®  
"Conocimiento y tecnología al servicio de México"



**CARLOS MANUEL ASTORGA ZARAGOZA**  
**SUBDIRECTOR ACADÉMICO**

C. c. p. Departamento de Ciencias Computacionales  
Departamento de Servicios Escolares

CMAZ/lmz



## Dedicatoria

*A Dios, que siempre me dio la fuerza necesaria para superar de la mejor forma las adversidades que se me presentaron en este periodo de mi vida y permitirme alcanzar una meta más.*

*A mis padres, María Díaz y Arturo Jaime y a mi hermana Evelyn, por creer en mí y en mis capacidades para lograr cumplir mis metas, gracias por estar siempre a mi lado e impulsarme a seguir adelante, a seguir mejorando como persona y como profesionalista. Gracias a ustedes soy esta persona, que tal vez es un poco loca y escandalosa pero siempre dedicada y enfocada en lo que quiere... a ustedes les dedico todos y cada uno de mis logros, con todo mi amor ♥♥♥*

*A Gilberto ♥, Loreli, Luis, que, aunque no nos unen lazos de sangre, forman parte de mi familia, les agradezco que siempre estuvieran alentándome a no rendirme e incluso ayudándome cuando tenía bloqueos mentales y sentía que no podía seguir; gracias por regalarme tantos momentos de felicidad... y siempre estar aguantando mis cambiantes estados de ánimo, a ustedes les doy las gracias por aparecer en mi vida.*

*A todos los amigos que conocí en este periodo de mi vida, que, a pesar de la pandemia y la distancia, me acompañaron y enriquecieron mi vida con sus opiniones, conocimientos y amistad.*

## Agradecimientos

Agradezco al Tecnológico Nacional de México campus Centro Nacional de Investigación y Desarrollo Tecnológico (TecNM/CENIDET), el haberme permitido formar parte de esta honorable institución, durante los cuatro años de investigación de mi doctorado en Ciencias de la Computación.

Así mismo agradezco al Consejo Nacional de Ciencia y Tecnología (CONACyT) por su programa de posgrados de calidad, a través del cual recibí apoyo económico durante el tiempo que fui estudiante de Doctorado.

Agradezco a mi director de tesis, el Dr. Juan Gabriel González Serna y a mi codirector el Dr. Dante Mújica Vargas, por ser mi guía y brindarme su apoyo para la culminación de mi trabajo de tesis durante mi posgrado.

A mis revisores, el Dr. Máximo López Sánchez, el Dr. Noé Castro Sánchez, el Dr. Nimrod González Franco y a la Dra. Azucena Montes Rendón, quienes, desde el comienzo de esta investigación, aportaron su tiempo y comentarios para mejorar el trabajo que se realizaba con cada una de las revisiones generadas.

## Resumen

El presente trabajo tiene como objetivo desarrollar una metodología para el reconocimiento de emociones durante el proceso de evaluación de la experiencia de usuario (UX), mediante el análisis de señales fisiológicas utilizando interfaces de usuario de productos digitales.

Para cumplir este objetivo, se buscó realizar la detección de los estados emocionales de manera automática por medio de algoritmos de aprendizaje, sin embargo, se identificó que la mayoría de conjuntos de datos existentes de señales fisiológicas emocionales, fueron generados en base a imágenes y videos, los cuales no son útiles para el análisis de emociones en el proceso de evaluación de la experiencia del usuario.

Por esta razón en esta investigación se propuso un nuevo proceso para la inducción de estados emocionales, a través de estímulos visuales basados en interfaces de usuario (UI) interactivas, lo cual permitió la creación de un conjunto de datos de emociones fisiológicas centrado en el proceso de evaluación de la experiencia del usuario.

Finalmente, la generación de dicho repositorio permitió realizar el entrenamiento de los algoritmos de aprendizaje para la clasificación de estados emocionales enfocados en la evaluación de la UX, el cual fue integrado dentro del sistema UXLab.

## Abstract

The objective of this work is to develop a methodology for the recognition of emotions during the user experience (UX) evaluation process, through the analysis of physiological signals using user interfaces of digital products.

To reach this goal, we sought to detect emotional states automatically through machine learning algorithms; however, most existing datasets of emotional physiological signals, were generated based on images and videos, which are not useful for analysis of emotions in the evaluation process of the user experience.

For this reason, in this research, we propose a new emotional induction process, through visual stimulus based on interactive user interfaces (UI), that allows the creation of a physiological emotion dataset focused on the evaluation process of user experience.

Finally, the generation of this dataset allowed the training of the learning algorithms for the classification of emotional states focused on the evaluation of the UX, which was integrated into the UXLab system.

# Índice

Capítulo 1	- 1 -
1. Introducción	- 2 -
1.1. Antecedentes	- 5 -
1.2. Descripción del problema	- 7 -
1.3. Objetivos	- 9 -
1.3.1. Objetivo general	- 9 -
1.3.2. Objetivos específicos	- 9 -
1.4. Justificación	- 10 -
1.5. Hipótesis	- 11 -
1.6. Alcances y limitaciones	- 12 -
1.6.1. Alcances	- 12 -
1.6.2. Limitaciones	- 12 -
1.7. Estructura del documento	- 13 -
Capítulo 2	- 14 -
2. Marco teórico	- 15 -
2.1. Experiencia de usuario	- 15 -
2.2. Interfaz de usuario	- 15 -
2.3. Emociones	- 16 -
2.4. Proceso de inducción emocional	- 16 -
2.5. Electroencefalograma	- 16 -
2.6. Electrocardiograma	- 16 -
2.7. Electromiograma	- 17 -
2.8. Respuesta galvánica en piel	- 17 -
2.9. Señales multimodales	- 17 -
2.10. Modelo excitación-valencia	- 17 -
2.11. Máquinas de aprendizaje	- 18 -
2.12. Aprendizaje profundo	- 18 -
Capítulo 3	- 19 -
3. Estado del arte	- 20 -
3.1. Procesos de inducción emocional	- 20 -
3.2. Repositorios de datos	- 23 -
3.3. Experiencia de usuario	- 25 -
3.4. Machine learning	- 27 -

3.5. Deep learning	- 30 -
Capítulo 4	- 35 -
4. Método de solución	- 36 -
4.1. Creación del repositorio de datos	- 37 -
4.1.1. Análisis de prototipos	- 39 -
4.1.2. Aplicación de las heurísticas Jakob Nielsen y clasificación de prototipos	- 41 -
4.1.3. Implementación del proceso de inducción emocional	- 45 -
4.2. Clasificación de emociones	- 51 -
4.2.1. Métodos para el filtrado de señales	- 51 -
4.2.2. Análisis de métodos de clasificación	- 54 -
4.3. Interfaz web	- 59 -
Capítulo 5	- 63 -
5. Resultados	- 64 -
Capítulo 6	- 104 -
6. Conclusión	- 105 -
6.1. Trabajos futuros	- 107 -
6.2. Artículos publicados	- 107 -
7. Referencias	- 108 -
	- 116 -
Anexos	- 116 -
Anexo1: Guía para preparar pruebas de Evaluación de la Experiencia de Usuario (UX)	- 117 -

## Índice de Figuras

Figura 1.1 Ejemplos imágenes IAPS ( <a href="http://www4.ujaen.es/~erpadial/IAPS.html">http://www4.ujaen.es/~erpadial/IAPS.html</a> ).....	- 3 -
Figura 1.2 Ejemplos de productos digitales ( <a href="https://cenidet.tecnm.mx/">https://cenidet.tecnm.mx/</a> <a href="https://www.telcel.com/">https://www.telcel.com/</a> <a href="https://www.google.com/">https://www.google.com/</a> ).....	- 4 -
Figura 1.3 Imagen descriptiva del problema .....	- 7 -
Figura 4.1 Arquitectura general de solución .....	- 36 -
Figura 4.2 Conociendo al usuario.....	- 46 -
Figura 4.3 Preparación de equipo y zona de trabajo.....	- 46 -
Figura 4.4 Instalar dispositivos al usuario .....	- 46 -
Figura 4.5 Iniciar grabación en plataforma UXLab e iniciar entorno de indicción.....	- 47 -
Figura 4.6 Inducción estados emocionales.....	- 48 -
Figura 4.7 Arquitectura proceso inducción emocional.....	- 49 -
Figura 4.8 Cuestionario SAM.....	- 49 -
Figura 4.9 Finalización del entorno de proceso de inducción .....	- 50 -
Figura 4.10 Desinstalación de dispositivos .....	- 50 -
Figura 4.11 Aplicar cuestionarios de estados mentales .....	- 51 -
Figura 4.12 Módulo de repetición (Hochreiter & Schmidhuber, 1997).....	- 55 -
Figura 4.13 Estructura LSTM (Hochreiter & Schmidhuber, 1997) .....	- 55 -
Figura 4.14 Estructura GRU (Cho et al., 2015).....	- 57 -
Figura 4.15 Instrucciones iniciales PIE .....	- 59 -
Figura 4.16 Interacción estímulo interactivo ( <a href="http://www.codewars.com">www.codewars.com</a> ).....	- 60 -
Figura 4.17 Cuestionario SAM.....	- 60 -
Figura 4.18 Pantalla de inicio .....	- 61 -
Figura 4.19 Pantalla de selección de datos filtrado .....	- 61 -
Figura 4.20 Pantalla de selección de características.....	- 62 -
Figura 5.1 Prueba Proceso de inducción emocional.....	- 65 -
Figura 5.2 Datos para matriz de correlación.....	- 93 -
Figura 5.3 Gráfica de correlación.....	- 93 -
Figura 5.4 Creación de objeto datos de correlación .....	- 94 -
Figura 5.5 Definición de modelo.....	- 94 -
Figura 5.6 Método de máxima verosimilitud .....	- 94 -
Figura 5.7 Corroboración datos del modelo .....	- 95 -
Figura 5.8 Estimación de parámetros .....	- 95 -
Figura 5.9 Representación correlación de valencia, activación y dominio .....	- 96 -
Figura 5.10 LSTM .....	- 98 -
Figura 5.11 GRU .....	- 99 -
Figura 5.12 Resultados con algoritmo emolern Keneth .....	- 101 -
Figura 5.13 Resultado modelo productos digitales Keneth.....	- 101 -
Figura 5.14 SAM evaluación productos digitales Keneth.....	- 102 -
Figura 5.15 Resultados con algoritmo emolern Gilberto .....	- 102 -
Figura 5.16 Resultado modelo productos digitales Gilberto .....	- 103 -
Figura 5.17 SAM evaluación productos digitales Gilberto .....	- 103 -

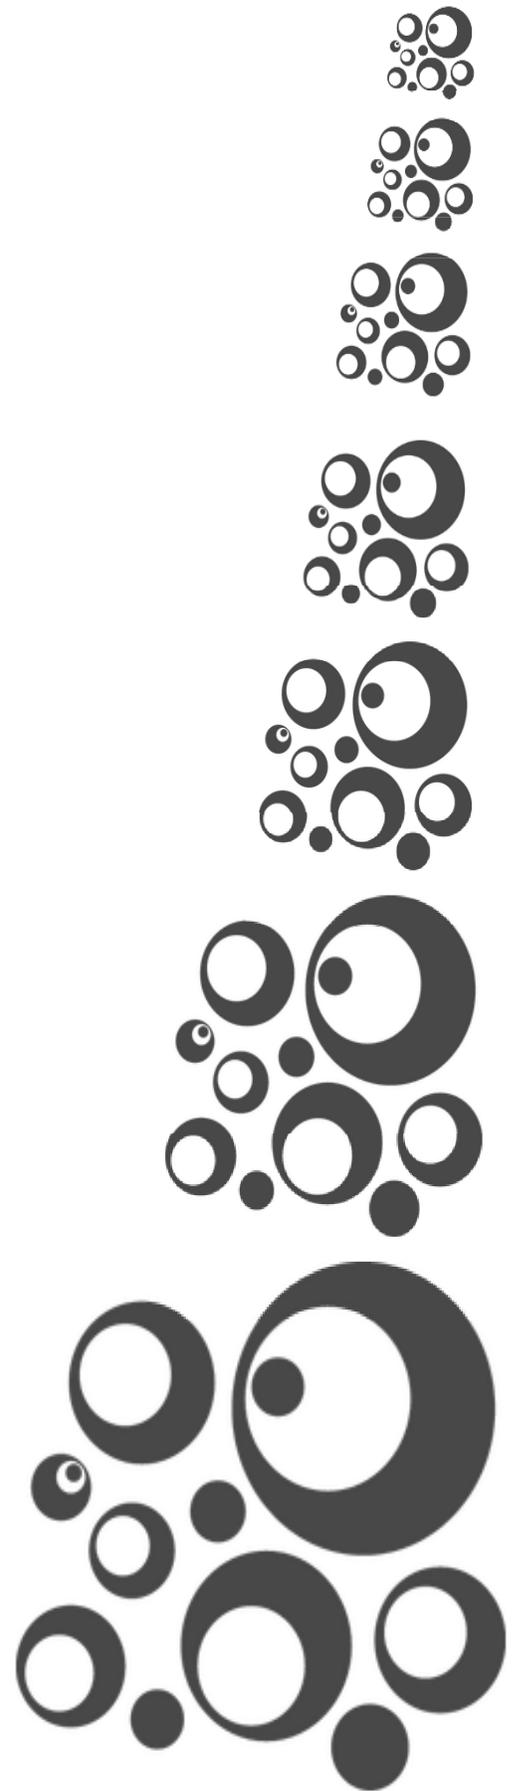
## Índice de tablas

Tabla 1.1 Tabla comparativa antecedentes.....	- 6 -
Tabla 3.1 Tabla comparativa PIE's.....	- 22 -
Tabla 3.2 Tabla comparativa bases de datos.....	- 24 -
Tabla 3.3 Tabla comparativa experiencia de usuario.....	- 26 -
Tabla 3.4 Tabla comparativa Machine Learning.....	- 28 -
Tabla 3.5 Tabla comparativa Deep Learning.....	- 32 -
Tabla 4.1 Data sets de señales fisiológicas existentes.....	- 38 -
Tabla 4.2 Páginas seleccionadas para creación de repositorio de estímulos.....	- 40 -
Tabla 4.3 Plantilla evaluación productos digitales.....	- 43 -
Tabla 4.4 Algoritmos seleccionados.....	- 54 -
Tabla 5.1 Resultado coeficiente cronbach para valencia.....	- 67 -
Tabla 5.2 Resultado coeficiente cronbach para activación.....	- 68 -
Tabla 5.3 Resultado coeficiente cronbach para dominio.....	- 69 -
Tabla 5.4 Prueba saphiro para el conjunto valencia, activación y dominio de los datos completos.....	- 73 -
Tabla 5.5 Pruebas saphiro para las columnas valencia, activación y dominio de los subconjuntos de datos de disenio.....	- 74 -
Tabla 5.6 Prueba F para los subconjuntos de diseño.....	- 75 -
Tabla 5.7 Prueba T en las variables valencia-diseño, activación-diseño y dominio-diseño ...	- 75 -
Tabla 5.8 Prueba $\chi^2$ en las variables valencia-diseño, activación-diseño y dominio-diseño...	- 76 -
Tabla 5.9 Prueba KRUSKAL-WALLIS en las variables val-diseño, act-diseño y dom-diseño.....	- 77 -
Tabla 5.10 Prueba U para los subconjuntos de buen y mal diseño con las variables val, act, dom.....	- 77 -
Tabla 5.11 Pruebas saphiro para las columnas valencia, activación y dominio de los subconjuntos de datos de experiencia.....	- 78 -
Tabla 5.12 Prueba F para los subconjuntos de experiencia.....	- 79 -
Tabla 5.13 Prueba T en las variables valencia-exp, activación-exp y dominio-exp.....	- 80 -
Tabla 5.14 Prueba $\chi^2$ en las variables valencia-exp, activación-exp, dominio-exp.....	- 80 -
Tabla 5.15 Prueba KRUSKAL-WALLIS en las variables valencia-exp, activación-exp y dominio-exp.....	- 81 -
Tabla 5.16 Prueba U para los subconjuntos con y sin experiencia con las variables val, act, dom.....	- 82 -
Tabla 5.17 Pruebas saphiro para las columnas valencia, activación y dominio de los subconjuntos de datos de sexo.....	- 83 -
Tabla 5.18 Prueba F para los subconjuntos de sexo.....	- 83 -
Tabla 5.19 Prueba T en las variables valencia-sexo, activación-sexo, dominio-sexo.....	- 84 -
Tabla 5.20 Prueba $\chi^2$ en las variables valencia-sexo, activación-sexo y dominio-sexo ..	- 85 -

Tabla 5.21 Prueba KRUSKAL-WALLIS en las variables valencia-sexo, activación-sexo y dominio-sexo .....	- 86 -
Tabla 5.22 Prueba U para los subconjuntos de hombre y mujer con las variables val, act, dom .....	- 86 -
Tabla 5.23 Pruebas saphiro para las columnas valencia, activación y dominio de los subconjuntos de datos de grupo generacional .....	- 87 -
Tabla 5.24 Prueba F para los subconjuntos de grupo generacional.....	- 88 -
Tabla 5.25 Prueba $\chi^2$ en las variables valencia-gpogeneracional, activación-gpogeneracional y dominio-gpogeneracional .....	- 89 -
Tabla 5.26 Prueba KRUSKAL-WALLIS en las variables valencia-gpogeneracional, activación-gpogeneracional y dominio-gpogeneracional.....	- 90 -
Tabla 5.27 Prueba U para las columnas valencia, activación y dominio de los subconjuntos de datos de grupo generacional .....	- 91 -
Tabla 5.28 Prueba de rachas .....	- 92 -
Tabla 5.29 Prueba $\chi^2$ en las variables valencia-activación, valencia-dominio y activación-dominio.....	- 92 -
Tabla 5.30 Rangos de frecuencia utilizados .....	- 96 -
Tabla 5.31 Características multimodales.....	- 97 -
Tabla 5.32 Resultados valencia .....	- 100 -
Tabla 5.33 Resultados activación .....	- 100 -

# Capítulo 1

## Introducción



## 1. Introducción

El estudio de las emociones y su detección es un campo estudiado por las ciencias sociales, del cual existen diversas definiciones aceptadas y ampliamente utilizadas; sin embargo, es difícil generalizar el concepto y los componentes de las emociones. En (Scherer, 2005) definen las emociones como las respuestas de un individuo ante estímulos internos o externos que se presentan en el entorno en el que se desarrollan. Tales respuestas se ven influenciadas por hechos o vivencias pasadas, las cuales juegan un papel muy importante en la interacción de las personas con su medio ambiente; por tanto, medir o identificar las emociones tiene un alto grado de subjetividad entre cada individuo.

Para poder valorar el estado emocional de una persona es necesario tener mayor claridad del proceso mediante el cual se generan las respuestas en los diferentes sistemas del cuerpo humano ante un determinado estímulo. En (Ekman et al., 1987) desarrollaron una categorización de las emociones básicas, la cual está dividida en seis clases: felicidad, tristeza, miedo, ira, disgusto y sorpresa; la ventaja de esta categorización es que permite describir las emociones de manera más sencilla.

En (Torres Valencia, 2013) menciona que los sistemas de reconocimiento de emociones tienen diversas aplicaciones, como sistemas de apoyo para tratamientos psicológicos, terapias de rehabilitación, desarrollo de nuevas interfaces humano-computadora que se basen en los estados emocionales de los usuarios, el análisis del mercado de productos, evaluación de experiencia de usuario, entre otros.

La evaluación de la experiencia de usuario al utilizar productos digitales muchas veces se ve comprometida por problemas de diseño, debido a que se da mayor énfasis a la tecnología y no se toma en cuenta al usuario hasta que los desarrollos se encuentran en una etapa final.

Evaluar la experiencia de usuario es un proceso que lleva tiempo en su ejecución y que se efectúa de forma manual por expertos, los cuales no consideran el estado emocional y cognitivo del usuario; para agilizar este proceso se propone realizar la detección de emociones de manera automática por medio de algoritmos de aprendizaje que tengan la capacidad de reconocer estados emocionales en usuarios que interactúen con las Interfaces de Usuario (UI) de productos digitales, para lograr esto es necesario contar con repositorios

de ejemplos de UI que permitan inducir estados emocionales en los usuarios finales con el propósito de conformar los repositorios de datos de señales fisiológicas multimodales para el entrenamiento de algoritmos de clasificación.

La mayoría de los trabajos relacionados a la clasificación de estados emocionales fueron desarrollados con los repositorios existentes, estos fueron creados con procesos de inducción emocional donde utilizan estímulos de videos, audios, imágenes o alguna mezcla de estos; en la Figura 1.1 se muestran algunos ejemplos de los estímulos de imágenes que utilizaron para generar los repositorios, como se puede observar son muy diferentes a los que se deben identificar al evaluar una UI de un producto digital ya que los estímulos de los repositorios son estáticos y se enfocan a un entorno social y no a interfaces estáticas o interactivas, algunos ejemplos de los estímulos que se deben utilizar para evaluar la interfaz de usuario se muestran en la Figura 1.2.



Figura 1.1 Ejemplos imágenes IAPS (<http://www4.ujaen.es/~erpadiad/IAPS.html>)

A la hora de comparar los dos tipos de estímulos, se puede identificar que son considerablemente diferentes, a pesar de que en ambos casos se estimule una emoción positiva, los niveles de activación de la emoción es diferente por el tipo de estímulo utilizado; por esta razón es necesario generar un repositorio de señales fisiológicas a partir de estímulos de IU con el cual se pueda realizar el correcto entrenamiento de los algoritmos de clasificación.

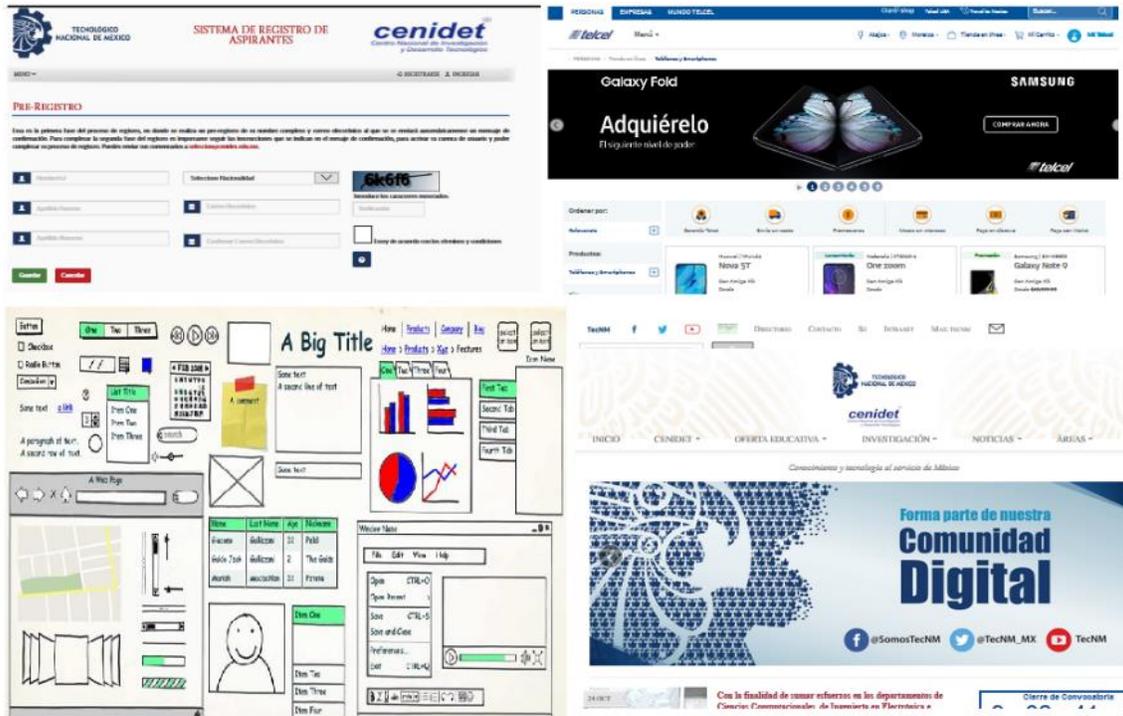


Figura 1.2 Ejemplos de productos digitales (<https://cenidet.tecnm.mx/> <https://www.telcel.com/> <https://www.google.com/>)

## 1.1. Antecedentes

A continuación, en la Tabla 1.1, se muestra una comparación de los trabajos previos que se realizaron en esta institución, los cuales cuentan con cierto grado de similitud con el trabajo realizado, y apoyaron con el desarrollo de este trabajo de tesis, de igual forma se muestra la discusión y la relación con este trabajo de tesis.

En (Balam Guzmán, 2015; González Franco, 2017), trabajaron en la identificación de estados emocionales y cognitivos a partir de la señal fisiológica obtenida del electroencefalograma y con los ritmos cerebrales e interfaces humano computadora para la extracción y análisis de los datos. El objetivo de estos trabajos fue identificar estados emocionales con una única señal fisiológica en un entorno social, en contraste, el presente trabajo de investigación utiliza señales fisiológicas multimodales y la evaluación de la experiencia de usuario.

En (Soriano Terrazas, 2018), se desarrolló una metodología para la inducción de estados emocionales, utilizando un entorno de realidad virtual, colocan a los usuarios en estados emocionales determinados, pasando por el estado neutro a la emoción a inducir y terminando nuevamente con un estado neutro. La relación con este trabajo radica en inducir estados emocionales; sin embargo, la diferencia y aporte se halla principalmente en el proceso de inducción debido a que actualmente se utilizan estímulos de imágenes, audios y videos sin interacción, a diferencia del presente trabajo que utiliza interfaces de usuario de productos digitales interactivos para realizar el proceso de inducción, que a su vez ayuda a la generación un repositorio de datos.

En (Fouilloux Quiroz, 2018), se desarrolló un sistema de grabación y sincronización de señales fisiológicas; este sistema es de gran ayuda para el presente trabajo ya que permitirá generar el repositorio de datos multimodal a partir del proceso de inducción seleccionado para los prototipos.

Tabla 1.1 Tabla comparativa antecedentes

Título	Año	Objetivo	Resultados
Modelo semántico para la gestión de técnicas de HCI mediante el monitoreo de actividad bioeléctrica (EEG) para caracterizar estados mentales y su relación con cambios en el contexto del usuario (Balam Guzmán, 2015)	2015	Identificación de dos estados (concentración y relajación) por medio de señales EEG.	Identificación de los estados concentración y relajación. Creación de 2 corpus de señales EEG.
Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario (Fouilloux Quiroz, 2018)	2018	Sistema de monitoreo de la experiencia del usuario, el cual integrara la grabación de diversas señales y dispositivos de monitoreo.	Un sistema que integra la grabación de señales (EEG, eye-tracker), cámara, micrófono. Procesa, etiqueta y sincroniza la información recolectada.
Metodología para caracterizar e inducir estados cognitivos y emocionales mediante realidad virtual inmersiva mediante realidad virtual (Soriano Terrazas, 2018)	2018	Desarrollar una metodología para la inducción de estados emocionales por medio de realidad virtual inmersiva.	Metodología para la inducción de estados emocionales por medio de un entorno de RVI y Proceso de inducción emocional de imágenes, música y video.
Metodología UXEEG para la evaluación de la Experiencia del Usuario en personas con discapacidad a partir de Interfaces Cerebro Computadora (González Franco, 2017)	2017	Evaluar la experiencia del usuario en personas con discapacidades e identificación de los estados de concentración y relajación	Demostrar que tener alguna discapacidad no afecta el uso de técnicas de medición de señales neurofisiológicas, lo cual ayudado a detectar sus estados cognitivos y/o emocionales

## 1.2. Descripción del problema

El proceso de evaluación de la experiencia de usuario (UX) para identificar problemas de usabilidad en interfaces de usuario de productos digitales, es un proceso que actualmente lo realizan expertos utilizando instrumentos convencionales, es decir, recabando información de forma manual de los datos obtenidos durante el proceso de evaluación y realizando el análisis de la información de los cuestionarios que los usuarios responden manualmente, por lo que el análisis de la UX se vuelve extenso y tedioso, adicionalmente este tipo de evaluación es subjetiva ya que los resultados finales son a criterio del experto (ver Figura 1.3). Cuando se realiza este tipo de evaluación basada en los criterios del evaluador, disminuye la precisión en la detección de emociones, así como su mapeo en la interfaz de usuario y la identificación de las áreas de interés que pudieran afectar la aceptación o el rechazo de la interfaz.

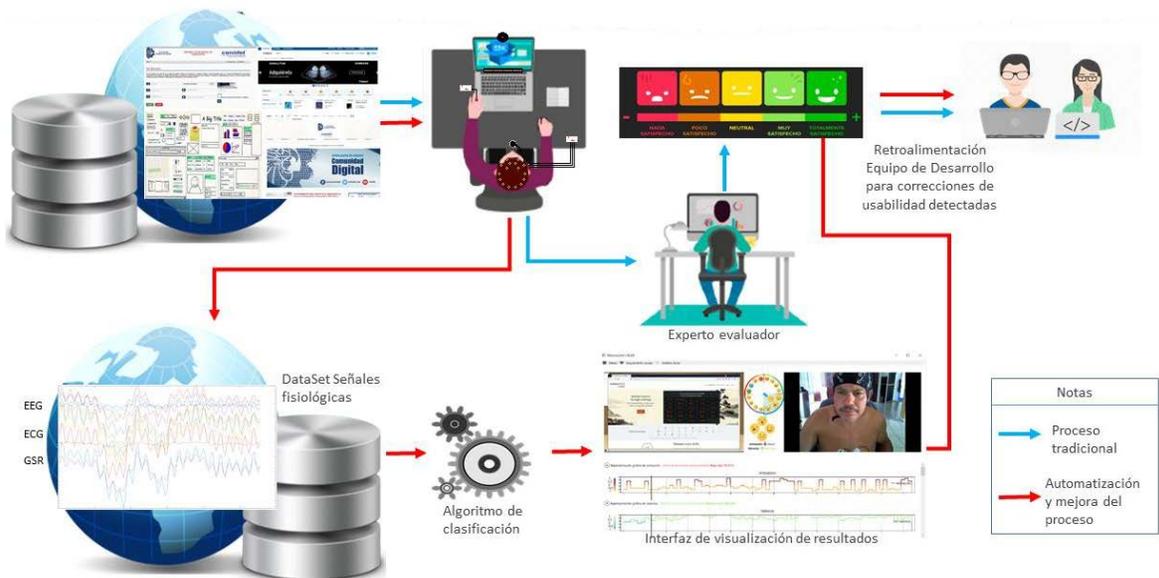


Figura 1.3 Imagen descriptiva del problema

El problema se ubica en poder agilizar el proceso de evaluación de la experiencia de usuario y de este modo conseguir eliminar o reducir la subjetividad de los expertos evaluadores en los resultados finales.

Para lograr esto se busca realizar la detección de los estados emocionales de manera automática por medio de algoritmos de aprendizaje; por ello, se encuentra la necesidad de tener sistemas que permitan evaluar la experiencia de usuario al utilizar interfaces de productos digitales.

Para poder realizar la detección de emociones por medio de algoritmos de aprendizaje, es necesario generar un repositorio de datos para su entrenamiento, el cual debe contener la información de señales fisiológicas multimodales de usuarios mientras realizan la evaluación de un producto digital con un buen y/o mal diseño, pero para lograr esto primero es necesario generar un repositorio de contenidos visuales interactivos de interfaces de usuario, etiquetar cada uno de los estímulos seleccionados (buen y/o mal diseño) y relacionarlos con emociones positivas o negativas para utilizarlas en el proceso de inducción emocional (PIE) y de este modo crear el repositorio de datos fisiológico multimodales para el entrenamiento del algoritmo para la clasificación de estados emocionales en evaluaciones UX.

### 1.3. Objetivos

A continuación, se describe el objetivo general y los objetivos específicos de este trabajo de investigación.

#### 1.3.1. Objetivo general

Obtener una metodología para el reconocimiento de emociones basado en un enfoque multimodal mediante el análisis de señales fisiológicas multimodales y su clasificación por medio de algoritmos de aprendizaje utilizando medios de inducción relacionados con contenidos interactivos de interfaces de usuario de productos digitales.

#### 1.3.2. Objetivos específicos

- Obtener un repositorio de prototipos digitales interactivos de alto nivel o prototipos finales (estos deben presentar dos diseños: que cumpla con las heurísticas de usabilidad y otro que no las cumpla total o parcialmente).
- Obtener un repositorio de señales fisiológicas multimodales (EEG, EGC y GSR) enfocado a la UX.
- Evaluar algoritmos de máquinas de aprendizaje para realizar la clasificación de los estados emocionales.
- Adaptar un algoritmo de clasificación para el reconocimiento de estados emocionales.

## 1.4. Justificación

De acuerdo con un estudio realizado por (INEGI, 2019), en México existen al menos 74.3 millones de personas con acceso a internet, por lo tanto son 74.3 millones de personas que tienen acceso a una gran cantidad de productos digitales; el tener sistemas enfocados a la experiencia de usuario y no solo que sean funcionales, apoyaría significativamente a reducir los costos de rediseño o de rehacer los sistemas desde cero.

En un estudio realizado por (The Standish Group, 2020), se identificó que de un 100% de los proyectos que siguen una metodología en cascada, el 60% de ellos tienen problemas de usabilidad y/o funcionalidad; para los proyectos que utilizan una metodología de desarrollo ágil, el 52% de estos tiene problemas de usabilidad y/o funcionalidad. Como se puede observar el porcentaje de proyectos desarrollados que tienen problemas de usabilidad y/o funcionalidad son más del 50%; por tanto, tener un sistema que permita evaluar la experiencia de usuario por medio de las emociones que se perciben mientras se evalúan o utilizan sistemas o prototipos; ayudaría significativamente a mejorar dichos productos y de este modo evitar o reducir la deserción de uso, las malas experiencias y malas valoraciones por parte de los usuarios, así como reducir los costos de tener que rediseñar o hacer nuevamente los sistemas; sin embargo, el proceso actual de evaluación de la experiencia de usuario es un proceso muy subjetivo por parte de los usuarios y el cual se realiza manualmente.

El efectuar la detección de las emociones que el usuario presencia al momento de realizar las evaluaciones de las UI por medio de sensores fisiológicos y de algoritmos de aprendizaje, permitiría reducir los tiempos de análisis de los datos, reducir y/o eliminar la subjetividad de los expertos evaluadores UX, elevar el nivel de precisión en las evaluaciones y agilizar el proceso de evaluación.

Para poder realizar la clasificación de las emociones por medio de algoritmos de aprendizaje, es necesario contar con un repositorio de datos de señales fisiológicas obtenidas durante el proceso de evaluación de productos digitales; ya que las emociones experimentadas al evaluar un sistema no son iguales a las percibidas cuando se visualiza una imagen o video de un bebé, mascota o asesinato; dado que los repositorios existentes de señales fisiológicas fueron creadas con imágenes, audios o videos de este tipo, existe la necesidad de crear un repositorio de datos para el entrenamiento el cual contenga las señales e información similar

a la que se evalúa, para poder detectar emociones y generar la retroalimentación necesaria de la evaluación de la experiencia de usuario.

## 1.5. Hipótesis

De acuerdo con la información analizada de la investigación del estado del arte, se identificaron dos nichos de investigación, el primero de ellos es la identificación de estados emocionales en el proceso de evaluación de la experiencia de usuario, ya que es un área poco explorada en la clasificación de estados emocionales y hasta el momento no se han identificado repositorios de datos de señales fisiológicas multimodales relacionados a la evaluación de la experiencia de usuario.

El segundo nicho de oportunidad se identificó en el entrenamiento de los algoritmos de clasificación de emociones con técnicas de aprendizaje profundo, debido a que estos trabajos del estado del arte únicamente consideran un tipo de señal fisiológica y no se ha trabajado con datos multimodales (señales fisiológicas EEG, ECG, GSR).

Estos nichos de oportunidad generan las siguientes hipótesis:

- Realizar el entrenamiento de los algoritmos de aprendizaje utilizando un repositorio de señales fisiológicas específico para la evaluación de la experiencia de usuario, ¿Mejorará los resultados arrojados por el algoritmo de clasificación que los obtenidos al ser entrenado con los repositorios existentes de señales fisiológicas basados en imágenes, audios y video?
- ¿Trabajar con algoritmos de Deep Learning y señales fisiológicas multimodales mejoraría la precisión al momento de realizar la clasificación de emociones?

## 1.6. Alcances y limitaciones

A continuación, se describen los alcances y limitaciones que tendrá este trabajo de investigación.

### 1.6.1. Alcances

- Se estudiarán las metodologías existentes para la inducción de estados emocionales y se definirá una para realizar el proceso.
- Se generará un repositorio de información, el cual contendrá los estímulos para inducir estados emocionales mediante interfaces de usuario con criterios de aceptación y rechazo definidos en su equipamiento.
- Se generará un repositorio de información, el cual contendrá señales fisiológicas multimodales inducidas mediante interfaces de usuario.
- La muestra con la que se generará el repositorio de señales será de al menos 15 sujetos de prueba.
- Se identificará al menos los niveles de activación y de valencia de los usuarios evaluadores de los prototipos.
- Se estudiarán los algoritmos de clasificación existentes y se seleccionará uno para realizar la clasificación de las emociones

### 1.6.2. Limitaciones

- Únicamente se trabajará con prototipos de alto nivel o nivel funcional.
- Únicamente se trabajará con prototipos interactivos con el usuario.
- No se realizará la modificación de los prototipos.
- Únicamente se utilizarán productos digitales web para esta investigación.
- Únicamente se procesarán las señales fisiológicas electroencefalograma, electrocardiograma y respuesta galvánica en piel.

## 1.7. Estructura del documento

La organización de este documento se encuentra dividida en siete capítulos, en los cuales se describe el proceso que se utilizó para el desarrollo de este trabajo, a continuación, se describe brevemente el contenido de cada capítulo.

### Capítulo II

Marco teórico: En este capítulo se muestran los términos o conceptos con mayor relevancia que se utilizarán para el entendimiento del presente documento.

### Capítulo III

Estado del arte: En este capítulo se muestran algunos trabajos similares o relacionados a los procesos de inducción emocional, repositorios de datos existentes para la detección de estados emocionales y detección de estados emocionales entre otros.

### Capítulo IV

Metodología: En este capítulo se muestra la metodología seguida para la detección, de estados emocionales durante la evaluación de la experiencia de usuario en el repositorio de datos generado.

### Capítulo V

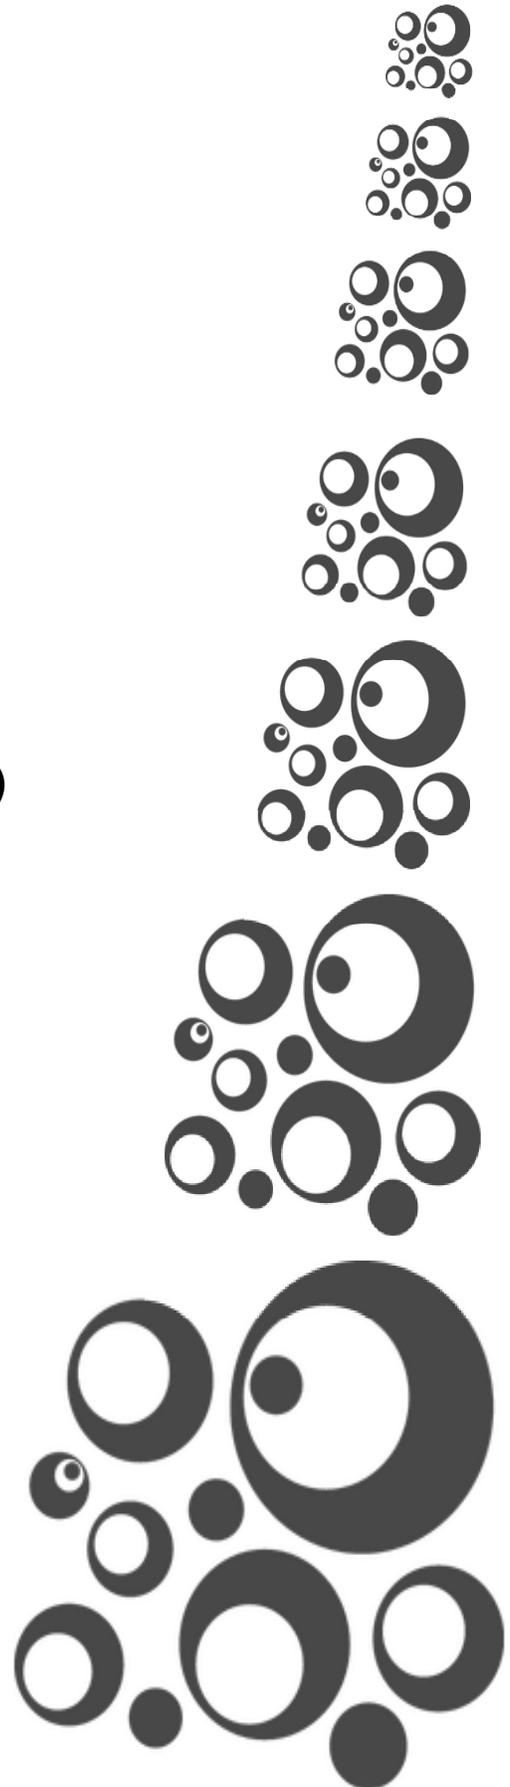
Pruebas y resultados: En este capítulo se muestran las pruebas que se le realizaron al sistema con el objetivo de evaluar la precisión y cobertura con la cual se clasificaban los datos.

### Capítulo VI

Conclusiones: En este capítulo se muestran las conclusiones del trabajo y de igual forma si se cumplieron los objetivos de este trabajo.

# Capítulo 2

## Marco teórico



## 2. Marco teórico

A continuación, se presentan los términos que tienen mayor relevancia para el entendimiento y desarrollo de esta investigación.

### 2.1. Experiencia de usuario

De acuerdo a (Pierre-Majorique Léger, Francois Courtemanche, Marc Fredette, 2015), la experiencia de usuario (UX) se define como las percepciones y respuestas que una persona tiene como resultado del uso o como resultado de anticipar el uso de un producto o servicio de tecnología de la información (TI).

En (Georges et al., 2018), mencionan que los métodos de la UX investigan cómo se sienten las personas acerca de un sistema, juego o interfaz web, en lugar de la facilidad con que lograron realizar la tarea en cuestión, cambiando el enfoque hacia el afecto del usuario, de este modo evaluar el alcance y la calidad de los usuarios se considera crítico para el desarrollo de los productos digitales.

### 2.2. Interfaz de usuario

En (Fernandez Ruiz, Angós Ullate, & Salvador Olivan, 2001), definen la interfaz de usuario como medio de comunicación entre el usuario de un producto digital y este, es todo aquel espacio gráfico y físico en donde los usuarios interactúan con el software. El diseño de estas no es un aspecto que deba dejarse hasta el final del desarrollo de un producto, sino que muy al contrario, debe ser contemplada desde el inicio del mismo, ya que una interfaz mal diseñada puede hacer que el uso de una aplicación se convierta en algo verdaderamente tortuoso y en un entorno en donde existen cientos de competidores, el usuario no dudará ni un momento en buscar una aplicación con una funcionalidad similar (o incluso menor) a cambio de una interfaz más atractiva y cómoda.

### 2.3. Emociones

En general las emociones han sido definidas por diversos autores como un cambio fisiológico o una reacción orgánica, según (Madera-carrillo, Zarabozo, Ruiz-díaz, & Berriel-saez, 2015), define las emociones como las respuestas sistemáticas que reflejan la activación central de los diversos sistemas reactivos del cuerpo y la preparación para la reacción o acción física.

De acuerdo a (Universidad de Alicante, Psicología, & Salud, 2007), las emociones son las respuestas del organismo a una excitación fisiológica, las cuales involucran un conjunto de experiencias, actitudes, creencias sobre el mundo y respuestas fisiológicas, las cuales influyen en el modo en el que se perciben las diversas situaciones.

### 2.4. Proceso de inducción emocional

De acuerdo a (García Palacios & Baños Rivera, 1999), los procedimientos de inducción emocional (PIE's), o también conocidos como estrategias de inducción emocional, son procedimientos utilizados para la inducción de diversos estados emocionales de manera artificial por medio de ambientes controlados, con la finalidad de extrapolar la relación existente entre emoción, cognición y conducta en la vida real.

### 2.5. Electroencefalograma

De acuerdo a (Guerrero Martínez, 2010), el electroencefalograma (EEG) registra la actividad eléctrica de las neuronas, la cual es obtenida como resultado de los campos eléctricos generados en el encéfalo, el cual está constituido por el cerebro, cerebelo, tallo cerebral, sumando a estos la médula espinal que conforma el sistema nervioso central. Para la obtención de este tipo de señales existen varios métodos, el que interesa para esta tesis es el método no invasivo, en el cual se colocan electrodos en la superficie del cuero cabelludo.

### 2.6. Electrocardiograma

De acuerdo a (Guerrero Martínez, 2010), el electrocardiograma (ECG), es una prueba no invasiva para registrar y observar la actividad eléctrica del corazón, en este se registran los cambios producidos por alguna actividad o respuesta del cuerpo, como tal consiste en el trazo

de las corrientes eléctricas generadas en el corazón ante diversas situaciones. Para la toma de este es necesario colocar electrodos en la superficie de la piel, habitualmente se colocan en los brazos, piernas o tórax.

## 2.7. Electromiograma

De acuerdo a (Guerrero Martínez, 2010), el electromiograma (EMG), se encarga de medir la actividad eléctrica muscular. La activación de cada fibra del músculo se produce en respuesta a un potencial de acción transmitido a través de la fibra nerviosa motora (axón), que inerva la fibra muscular y se genera la señal eléctrica del musculo.

## 2.8. Respuesta galvánica en piel

De acuerdo a (Guerrero Martínez, 2010), la respuesta galvánica en piel (GSR), también denominada actividad electrodérmica (EDA), es la medida de las continuas variaciones en las características eléctricas de la piel, por ejemplo, la conducción de la piel causada por la sudoración del cuerpo.

Para recabar las señales es necesario colocar dos electrodos en el segundo y tercer dedo de la mano, aunque se han desarrollado dispositivos como brazaletes o relojes que pueden medir esta señal.

## 2.9. Señales multimodales

De acuerdo a (Harpaz et al., 2017), las señales multimodales son el conjunto de múltiples fuentes de información, para este trabajo de investigación son el conjunto de las señales EEG, ECG, GSR.

## 2.10. Modelo excitación-valencia

De acuerdo a (Valderrama, 2016), el modelo excitación-valencia-domino consiste en tres dimensiones, valencia, excitación y dominio, donde la dimensión de valencia muestra el nivel de emoción, dependiendo del autor se puede manejar con rango de positiva a negativa o de deseable a indeseable; la dimensión de excitación se refiere a la activación o intensidad de la

emoción y puede ir de nivel bajo a alto; la dimensión del dominio se enfoca en qué tanto control se tiene sobre la emoción o sentimiento; sin embargo, la mayoría de los autores únicamente manejan las primeras dos dimensiones para fines de investigación.

### 2.11. Máquinas de aprendizaje

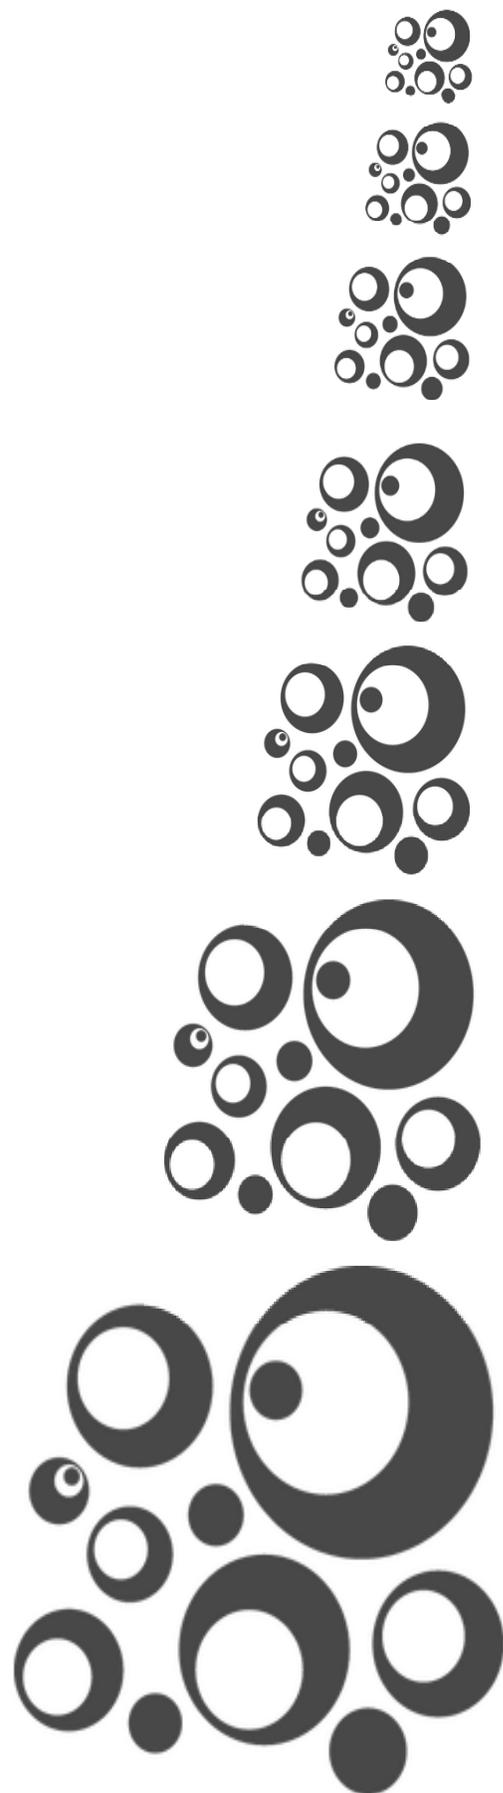
En (Y. Liu, 1965), se definen a las máquinas de aprendizaje o aprendizaje automático como una rama de la inteligencia artificial, que tiene como objetivo el aprendizaje automático de las computadoras, se centra en el desarrollo de sistemas que tengan la capacidad de adaptarse a nuevos datos de manera automática.

### 2.12. Aprendizaje profundo

De acuerdo a (Wiley, 1965), define al Deep Learning o Aprendizaje profundo como una rama de la inteligencia artificial que tiene como objetivo imitar la actividad en las capas de neuronas en la neocorteza. Dichas neuronas aprenden estructuras jerárquicas, niveles de interpretación y abstracción para comprender patrones de datos que provienen de distintos tipos de fuentes como: imágenes, videos, sonido, señales, texto, etc.

# Capítulo 3

## Estado del arte



### 3. Estado del arte

El estado del arte para este trabajo de investigación está dividido de la siguiente manera: procesos de inducción emocional, repositorios de datos, experiencia de usuario, machine learning y deep learning. para cada una de las secciones se muestra la discusión y relación con este trabajo de tesis.

#### 3.1. Procesos de inducción emocional

A continuación, en la Tabla 3.1 se muestra una comparación de investigaciones que han trabajado con procesos de inducción emocional, así como la discusión y la relación con esta investigación.

De acuerdo con la investigación de (Dur, 2017) existen diferentes métodos para realizar los procesos de inducción emocional (PIE) así como diversas mediciones para registrar las emociones generadas; donde, dependiendo del PIE a trabajar este se debe adaptar de acuerdo al estímulo a utilizar y al nivel de intensidad en la emoción que se desea inducir. Dentro de los estímulos más utilizados se encuentran: Velten (leer auto frases), realidad virtual (RV) o realidad virtual inmersiva (RVI), autobiográfico, escenas de películas (videos), imágenes afectivas (IAPS), música o audios e Interacción social, y se puede utilizar más de un estímulo durante la inducción.

Dentro de los estímulos más utilizados se encuentra el Sistema Internacional de Imágenes Afectivas (IAPS), el Sistema Internacional de Sonidos Afectivos (IADS), Geneva Affective PicturE Database (GAPED) y el repositorio de videos de (Koelstra et al., 2012).

Adicionalmente es necesario que con cada proceso se seleccione al menos un tipo de medición para identificar si los participantes se encuentran en el estado afectivo adecuado para la inducción, para ello existen diferentes métricas, dentro de las cuales las más utilizadas son: Differential Emotions Scale (DES), Positive and Negative Affect Schedule (PANAS), Mood Adjective Checklist (MAACL), Profile of Mood States (POMS), Multiple Affect Adjective Checklist (MAACL), Self-Assesment Manikin (SAM); siendo SAM y PANAS las más utilizadas en la medición de estados emocionales.

En los trabajos de (Chirico, Ferrise, Cordella, & Gaggioli, 2018; Courtemanche et al., 2018; Dur, 2017; Fernández, 2012; Georges et al., 2018; Soriano Terrazas, 2018), se muestran algunos ejemplos de procesos de inducción emocional, como se puede observar en la Tabla 3.1 los estímulos más utilizados son imágenes, audios y videos, sin embargo, esos mismos se pueden utilizar combinados con otros para generar un mayor nivel de inducción como es el caso de (Soriano Terrazas, 2018) en el que se utiliza realidad virtual inmersiva en combinación de imágenes, audios y videos.

En los trabajos de investigación para la clasificación de estados emocionales en donde generan sus propios repositorios de datos de señales fisiológicas, trabajan con estímulos de imágenes afectivas en donde, el usuario no tiene interacción directa con el estímulo, sin embargo, para este trabajo de investigación se requiere que el usuario interactúe con los estímulos que se le presenten, en este caso el estímulo a utilizar son prototipos web interactivos.

De acuerdo con el análisis de la Tabla 3.1, se ha identificado que dependiendo del tipo de estímulo a utilizar y la cantidad de estímulos que se ocupen para la inducción es el tiempo que durará el proceso y este puede variar de 20-60 min por sesión; la cantidad de usuarios promedio para realizar estas pruebas es de 26 y varía de acuerdo a la complejidad de la prueba y lo que se desea obtener para analizar.

Los trabajos de investigación del estado del arte que utilizan algún Proceso de Inducción Emocional coinciden en que independientemente del proceso que se utilice, es necesario que en todos los casos previo y posterior a realizar la inducción a los usuarios estos sean ubicados en una línea base o estado neutral, con el objetivo de que el estado emocional con el que llega el usuario a realizar la prueba no influya en el proceso, adicionalmente en caso de que la prueba conste de diferentes tipos o grados de inducción, es necesario que entre cada una de ellas el usuario regrese a un estado neutral.

Tabla 3.1 Tabla comparativa PIE's

Título	Muestras	Estímulo utilizado	Mediciones utilizadas	Duración del procedimiento
Inducción de emociones en condiciones experimentales: un banco de estímulos audiovisuales (Fernández, 2012)	60	Total 57 escenas 7 escenas por participantes	SAM (A.V.D.) DEQ LIKER	25 min 30 seg de línea base entre estímulos
Procedimientos de inducción emocional (Dur, 2017)	-	Velten (leer auto frases), RV o ERV, Autobiográfico, Escenas de películas, Imágenes Afectivas (IAPS), Música, Interacción social	Differential Emotions Scale (DES) Positive and Negative Affect Schedule (PANAS) Mood Adjective Checklist (MACL) Profile of Mood States (POMS) Multiple Affect Adjective Checklist (MAACL)	-
Physiological heatmaps: A tool for visualizing users' emotional reactions (Courtemanche et al., 2018)	44	14 imágenes del IAPS	Pearson correlation coefficient (PCC)	15 min 40 seg de línea base entre estímulos
Designing Awe in Virtual Reality an Experimental Study (Chirico, Ferrise, Cordella, & Gaggioli, 2018)	36	4 entornos Virtuales (Bosque, Montaña, la tierra desde el espacio, Neutral)	LIKER PANAS italianas	55 min
UX Heatmaps: Mapping user experience on visual interfaces (Georges et al., 2018)	26	Imágenes de 9 páginas web (la página principal)	SAM Observaciones del evaluador Entrevista a los usuarios	1 hora 1 min de línea base entre estímulos
Metodología para caracterizar e inducir estados cognitivos y emocionales mediante RVI (Soriano Terrazas, 2018)	8	RV con videos, audios e imágenes	Likert SAM PANAS	25 min 30 seg de línea base entre estímulos

### 3.2. Repositorios de datos

En la Tabla 3.2, se muestra una comparación de los trabajos relacionados con el desarrollo de repositorios de datos de señales fisiológicas multimodales, así como la discusión y la relación con este trabajo de tesis.

Los trabajos de (Bonell, Cherniz, Hadad, & Drozdowicz, 2011; Katsigiannis & Ramzan, 2018; Koelstra et al., 2012; Miranda Correa, Abadi, Sebe, & Patras, 2018; Suhaimi, Yuan, Teo, & Mountstephens, 2018), son ejemplos de trabajos de investigación para la creación de repositorios de datos de señales fisiológicas multimodales; los resultados de dichas investigaciones han sido utilizados en diversos trabajos para la detección de emociones.

Los repositorios descritos fueron generados utilizando procesos de inducción emocional, dichos procesos utilizan estímulos como imágenes, audios, videos o alguna mezcla de estos; sin embargo, a pesar de ser repositorios muy utilizados, cuando se requiere identificar estados emocionales específicos o diferentes a los convencionales como en el caso de (Prasad, Liu, Chen, & Quek, 2018), los autores optan por generar su propio repositorio de datos, debido a que lo que se planea identificar y la forma en la que se generan dichas emociones son diferentes a las que contienen los repositorios existentes.

En este trabajo de investigación, se plantea la generación de un repositorio de datos multimodal que contenga las señales fisiológicas (EEG, ECG y GSR) de usuarios mientras realizan la evaluación de la interfaz de un producto digital; debido a que no se han encontrado repositorios de este tipo dedicados a la UX y que los repositorios existentes contienen ciertos niveles de activación y valencia para cada tipo de emoción inducida, tomando en cuenta las características del estímulo utilizado en sus estudios, es necesaria la generación de nuestro propio repositorio el cual cumpla con las características que se requiere para la investigación; sin embargo, estos trabajos son de utilidad ya que muestran las bases de cómo conformar el repositorio de datos que se necesita para la investigación.

Tabla 3.2 Tabla comparativa bases de datos

Título	Año	Objetivo	Resultados	Fuente de inducción
BaseBio: base de datos de señales biomédicas accesibles desde internet (Bonell, Cherniz, Hadad, & Drozdowicz, 2011)	2011	Creación de la base de datos para almacenar señales biológicas EEG e imágenes médicas.	Una base de datos en formato MySQL donde se almacenen señales biológicas de proceso de inducción emocional y fotografías de los participantes.	Diferentes protocolos
DEAP: a Database for Emotion Analysis Using Physiological Signals (Koelstra et al., 2012)	2011	Creación de una base de datos multimodal con información de señales fisiológicas para explorar la posibilidad de clasificar dichas señales de acuerdo a estados emocionales	Una base de datos que contiene la información fisiológica (señales EEG, ECG, EMG, GSR) de diversos participantes.	Videos
DREAMER: A Database for Emotion Recognition through EEG and ECG Signals from Wireless Low-cost Off-the-Shelf Devices (Katsigiannis & Ramzan, 2018)	2017	Creación de una base de datos multimodal con información de señales fisiológicas	Una base de datos que contiene la información fisiológica (señales EEG, ECG) de diversos participantes.	Audiovisual
Modeling the Affective Space of 360 Virtual Reality Videos Based on Arousal and Valence for Wearable EEG-Based VR Emotion Classification (Suhaimi et al., 2018)	2018	Crear una base de datos conformada por los resultados obtenidos de las señales del Electroencefalograma (EEG)	Una base de datos que contiene información de señales EEG generada por medio de videos de realidad virtual 360	Videos 360
AMIGOS A dataset for Affect, Personality and Mood Research on Individuals and Groups (Miranda Correa, Abadi, Sebe, & Patras, 2018)	2018	Conformar un repositorio de datos para la investigación multimodal de afecto, personalidad y estado de ánimo en personas.	Una base de datos que contiene la información fisiológica (señales EEG, ECG) de diversos participantes y clasificarla en diferentes estados emocionales.	Videos

### 3.3. Experiencia de usuario

En la Tabla 3.3 se muestra una comparación de los trabajos relacionados con el desarrollo de repositorios de datos de señales fisiológicas multimodales, así como la discusión y la relación con este trabajo de tesis.

En (Georges et al., 2018, 2017; Pierre-Majorique Léger, Francois Courtemanche, Marc Fredette, 2015), presentan herramientas para la evaluación de la UX y tienen como objetivo identificar las emociones que se generan en los usuarios mientras interactúan con un producto digital y de este modo poder proporcionar una retroalimentación a los desarrolladores.

Las formas más comunes de realizar la evaluación de la experiencia de usuario son: la generación de mapas de calor de señales fisiológicas y el seguimiento ocular, sin embargo, a pesar de que dichas herramientas tienen la capacidad de obtener datos acerca de la UX durante la evaluación; no tienen la capacidad de realizar un diagnóstico, para ello requieren un análisis complementario de los métodos tradicionales de evaluación, es decir, cuestionarios, observación del usuario, entrevistas previas y posteriores a la evaluación.

En (Pierre-Majorique Léger, Francois Courtemanche, Marc Fredette, 2015), identificaron que los cuestionarios de autoevaluación, no proporcionan medidas imparciales ni automáticas de estados emocionales y cognitivos relacionados con la evaluación de la UX sin que éste sea consciente de que es evaluado. Por ejemplo, un usuario no puede proporcionar una explicación precisa de la frustración que siente cuando surge un problema al utilizar una interfaz, ya que en algunos casos esto se siente como algo normal o la interfaz lo llena de tanta información que el usuario no logra distinguir por completo las emociones que siente durante las diferentes etapas de la evaluación.

Estos trabajos se relacionan con la investigación debido a que realizan la evaluación de la experiencia de usuario, sin embargo, no son capaces de dar una retroalimentación automática de los estados emocionales y en el caso de este trabajo se pretende realizar dicha automatización por medio del análisis de diversas señales fisiológicas.

Tabla 3.3 Tabla comparativa experiencia de usuario

Título	Año	Objetivo	Resultados
A cloud-based lab management and analytics software for triangulated human-centered research (Pierre-Majorique Léger, Francois Courtemanche, Marc Fredette, 2015)	2018	Dar a conocer una plataforma de software basada en la nube desarrollada para la investigación triangulada centrada en el ser humano	Retroalimentación de los problemas de usabilidad por medio del análisis de actividad electrodermal, análisis facial y seguimiento ocular
UX Heatmaps: Mapping user experience on visual interfaces (Georges et al., 2018)	2018	Presentar una herramienta de evaluación de la experiencia de usuario que identifique las señales fisiológicas y de comportamiento de los usuarios mientras interactúan con un sistema.	Mapas de calor donde los usuarios centraban su visión y/o prestaban más atención a causa de la complejidad
The adoption of physiological measures as an evaluation tool in UX (Georges et al., 2017)	2017	Mostrar la utilidad de una herramienta de evaluación de experiencia del usuario.	Comentarios acerca del sistema para retroalimentación al equipo de diseño

### 3.4. Machine learning

En la Tabla 3.4, se muestra una comparación de los trabajos relacionados con la clasificación de emociones, utilizando datos de señales fisiológicas multimodales y Machine Learning, así como la discusión y la relación con este trabajo de tesis.

De acuerdo con las investigaciones de (Das, Khasnobish, & Tibarewala, 2016; Girardi, Lanubile, & Novielli, 2018; Katsigiannis, 2018; M. Liu, Fan, Zhang, & Gong, 2017; Park, Yoon, Jang, & Kim, 2017; Prasad et al., 2018; Shumailov & Gunes, 2018), muestran que el algoritmo que mejores resultados arroja al clasificar emociones es el algoritmo de máquina de soporte vectorial, con el modelo excitación-valencia; la precisión al utilizar máquinas de aprendizaje va desde un 58% hasta un 97%.

Como se mencionó anteriormente, existen repositorios de datos de señales fisiológicas, los cuales son utilizados en otros trabajos de investigación de identificación de emociones; sin embargo, dependiendo de la investigación que se realice y lo que se quiera detectar los autores deciden si realizar su propio repositorio de datos o utilizar los existentes. Dos trabajos ejemplo donde utilizan los repositorios existentes son (Girardi et al., 2018) que utiliza el repositorio DEAP y (Katsigiannis, 2018) que utiliza el repositorio DREAMER.

Gracias a estos trabajos de investigación se identificó que existe un nicho de oportunidad para la identificación de emociones durante la evaluación de la experiencia de usuario, ya que los trabajos encontrados se enfocan en temas sociales generales, para los trabajos que son enfocados en un área específica como en el caso de (Prasad et al., 2018) que tiene como objetivo identificar emociones suicidas, nos muestra la necesidad de generar un repositorio de datos propio utilizando los estímulos enfocados a lo que requieren identificar.

Tabla 3.4 Tabla comparativa Machine Learning

Título	Año	Señal				Clasificador	Métrica de evaluación	Repositorio de datos		Resultado
		EEG	ECG	GSR	EMG					
Computational Analysis of Valence and Arousal in Virtual Reality Gaming using Lower Arm Electromyograms (Shumailov & Gunes, 2018)	2018				X	SVM	F-Score	Generada	85.50%	Detección del estado emocional por medio del modelo Excitación-Valencia, mientras los usuarios interactuaban con juegos de realidad virtual
El procesamiento cognitivo en una app educativa con electroencefalograma y “Eye Tracking” (Cuesta-Cambra, Niño-González, & Rodríguez-terceño, 2017)	2017	X				Experto	SPSS S22	Generada	-	Detección de puntos de interés, estados cognitivos y emocionales mientras utilizaban la aplicación Viquiz
Emotion detection using noninvasive low cost sensor (Girardi et al., 2018)	2018	X		X	X	SVM	Precision Recall F-Score	DEAP	58%	Clasificación de estados emocionales con ayuda del modelo Excitación-Valencia y del algoritmo de máquina de soporte vectorial
Physiological signals and recognition of negative emotion (Park et al., 2017)	2017		X		X	SVM	F-score	Generada	80%	Reconocimiento de los estados emocionales: tristeza y disgusto por medio de los algoritmos Cart, KNN, NB, SVM

Human emotion recognition based on galvanic skin response signal feature selection and SVM (M. Liu et al., 2017)	2017			X			SVM	Confusion Matrix	Generada	66.67%	Reconocimiento de los emocionales: felicidad, tristeza, ira, miedo con ayuda del modelo Excitación-Valencia y del algoritmo de máquina de soporte vectorial
Physiological signal-based emotion recognition system (Hassani et al., 2018)	2018	X	X	X	X		Análisis estadístico	-	Generada	-	Al tener poca información se inclinaron por realizar la detección de las emociones felicidad, ira y neutro por medio de análisis estadístico
DREAMER: a database for emotion recognition through EEG and ECG signals form Wireless low-cost off-the-shelf devices (Katsigiannis, 2018)	2018	X	X				SVM	F-Score Anova Wilcoxon	DREAMER	62.30%	Para la validación de la base de datos realizaron la clasificación de estados emocionales con ayuda del modelo Excitación-Valencia y del algoritmo de máquina de soporte vectorial
Emotion recognition employing ECG and GSR signals as markers of Autonomic Nervous System (ANS) (Das et al., 2016)	2016		X	X			SVM	-	Generada	98.53%	Reconocimiento de los estados emocionales: tristeza, felicidad y neutra, por medio de los algoritmos Cart, KNN, NB, SVM
Sentiment analysis using EEG activities for suicidology (Prasad et al., 2018)	2018	X					SVM	Cross validation	Generada	70%	Generaron su propia base de datos para el estudio y detección de emociones suicidas a partir de los estímulos proporcionados.

### 3.5. Deep learning

En la Tabla 3.5, se muestra una comparación de los trabajos relacionados con la clasificación de emociones utilizando datos de señales fisiológicas y Deep Learning, así como la discusión y la relación con este trabajo de tesis.

Los trabajos de (Alhagry, Aly, & A., 2017; Chao, Zhi, Dong, & Liu, 2018; Chen et al., 2019; Gao, Lee, & Mehmood, 2015; Hossain & Muhammad, 2018; Liang, Oba, & Ishii, 2019; Liao, Chen, & Tai, 2018; Mehmood, Du, & Lee, 2017; Park et al., 2017; Wang et al., 2019; Xu & Plataniotis, 2017; B. Yang, Han, & Tang, 2018; Y. Yang, Wu, Qiu, Wang, & Chen, 2018; Yin, Zhao, Wang, Yang, & Zhang, 2017; Zheng, Zhu, Peng, & Lu, 2014), son muestra de trabajos de investigación para la clasificación de emociones utilizando algoritmos de Deep Learning, en estas investigaciones trabajan principalmente con el repositorio de datos DEAP, el cual es un repositorio de datos multimodal, sin embargo, a pesar de que es multimodal, los estudios donde utilizan algoritmos de aprendizaje profundo trabajan únicamente con la señal fisiológica electroencefalograma (debido a que contienen un mayor número de características con las que trabajar).

Otro de los repositorios utilizados para la clasificación de emociones es SEED, el cual cuenta únicamente con información de la señal fisiológica EEG. Adicional las investigaciones que desarrollan su propio repositorio de datos utilizan los estímulos de IAPS, IADS, Gaped; los cuales son los repositorios de estímulos utilizados en la generación de los repositorios existentes.

Dentro de los algoritmos de aprendizaje profundo más utilizados en la literatura para realizar la clasificación de estados emocionales se encuentra Restricted Boltzman Machine, Convolutional Neural Network, Deep Belief Network, Extreme Learning Machine, los cuales han obtenido una precisión que ronda entre el 69% y el 99%.

Adicional al algoritmo de clasificación se ha identificado que utilizan el modelo Excitación-Valencia para la detección del estado emocional, en trabajos como (Alhagry et al., 2017; Chao et al., 2018; Liang et al., 2019; Xu & Plataniotis, 2017; Y. Yang et al., 2018; Yin et al., 2017), en los cuales definen cuatro cuadrantes para ubicar y clasificar estados emocionales, dependiendo de si es positiva o negativa y la intensidad de ésta, en el resto de las

investigaciones realizan la clasificación en base a tres estados emocionales ([tristeza, miedo, calma], [felicidad/alegría, tristeza, neutral]).

Gracias a estos trabajos de investigación se ha identificado que existe un nicho de oportunidad para la identificación de emociones durante la evaluación de la experiencia de usuario, ya que los trabajos encontrados se enfocan en temas sociales generales, además de que trabajan únicamente con un tipo de señal fisiológica y la presente investigación tiene como objetivo trabajar con señales multimodales.

Tabla 3.5 Tabla comparativa Deep Learning

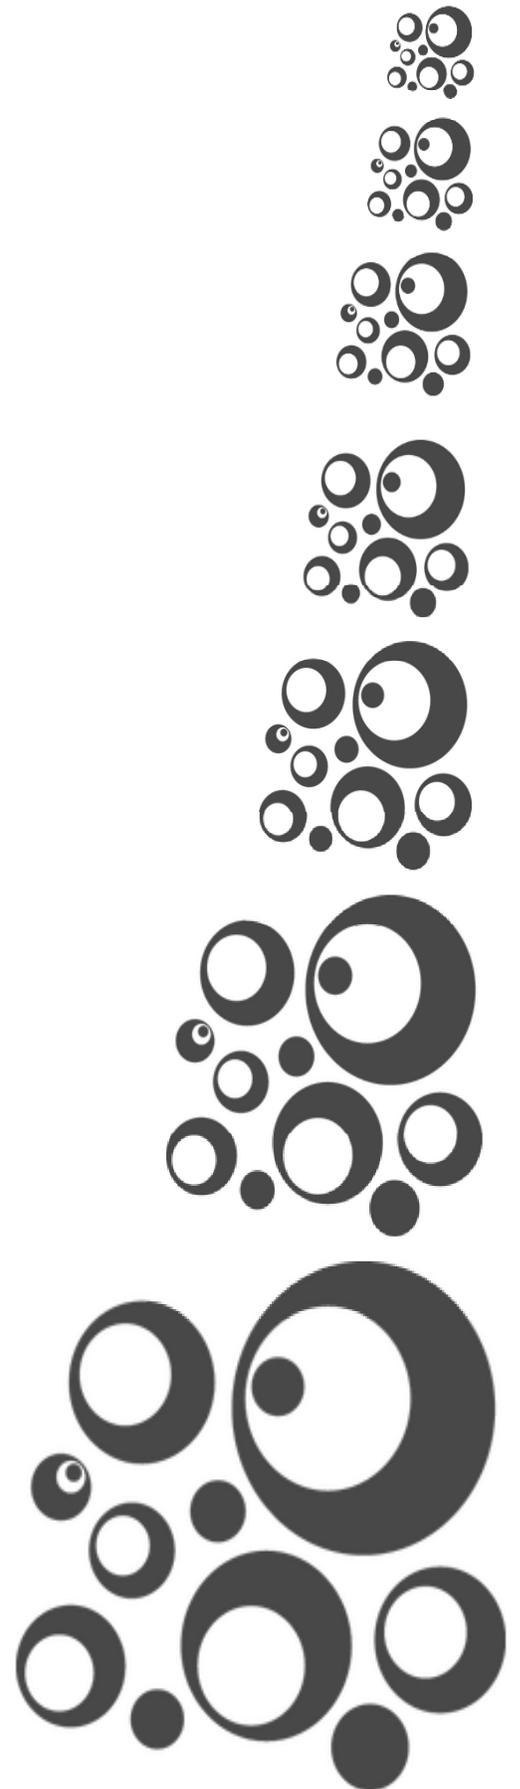
Título	Año	Señal			Clasificador	Métricas de evaluación	repositorio de datos	Resultado	
		EEG	ECG	GSR					
Deep learning of EEG Signals for emotion recognition (Gao et al., 2015)	2015	X			Restricted Boltzmann Machines (RBM)	Cross Validation	Propia	68.4%	Generaron su propia base de conocimiento de señales EEG. Identificaron 3 estados emocionales: calma, tristeza, miedo. Comparación de resultados con los algoritmos KNN, SVM
Affective states classification using EEG and semi-supervised deep learning approaches (Xu & Plataniotis, 2017)	2017	X			Restricted Boltzmann Machines (RBM)	F-Score Accuracy	DEAP	86.67%	Identificaron estados emocionales en base al modelo excitación- valencia. Compararon resultados con los obtenidos por medio de SVM-RBF
Emotion stress detection using EEG signal and Deep learning technologies (Liao et al., 2018)	2018	X			Deep BP	F-score Accuracy	Propia	80.13%	Generaron su propia base de conocimiento de señales EEG con ayuda del NeuroSky. Detectaron los estados de atención y meditación. Trabajaron sobre ondas Gamma, Beta, Alpha, Theta, Delta
EEG emotion recognition using dynamical graph convolutional neural networks and broad learning system (Wang et al., 2019)	2019	X			Broad Dynamical Graph Learning (BDGLS)	Standard deviation	SEED	93.66%	Identificaron estados emocionales por medio de la generación de nodos aleatoriamente seleccionados para encontrar los pesos de conexión deseados simultáneamente y de este modo realizar la clasificación.

Optimal feature selection and deep learning ensembles method for emotion recognition from human brain EEG sensors (Mehmood et al., 2017)	2017	X	Deep-Learning	Cross validation	Propia	73.6%	Generación de su propia base de conocimiento de señales EEG generadas por una inducción con ayuda del repositorio IAPS. Compararon inicialmente los algoritmos SVM, NB, Deep learning y random forest con ayuda de WEKA.
Three class emotions recognition based on deep learning using staked autoencoder (B. Yang et al., 2018)	2018	X	Stacked autoencoders (SAE)	Cross validation	SEED	85.5%	Identificaron que las ondas cerebrales que tienen un mayor porcentaje en la detección de emociones son las ondas gamma con un 82.56%; sin embargo, el uso de todas las señales da un mayor porcentaje de exactitud.
Emotion recognition from multi-channel EEG through parallel convolutional recurrent neural network (Y. Yang et al., 2018)	2018	X	Convolutional Neural Network (CNN)	Cross validation	DEAP	90.8%	Identificaron estados emocionales en base al modelo excitación- valencia. Compararon resultados con los obtenidos con MESAE, BDAE, LSTM
Accurate EEG-based emotion recognition on combined features using deep convolutional neural network (Chen et al., 2019)	2019	X	Convolutional Neural Network (CNN)	Cross validation	DEAP	99.3%	Identificaron el tipo de características que daba mejor resultado para la clasificación cuando se utilizaban las señales con diferentes tipos de filtros.
EEG-BASED emotion classification using deep belief networks (Zheng et al., 2014)	2014	X	Deep belief network	Confusion Matrix	Propia	87.6%	Generación de su propia base de conocimiento de señales EEG. Detectaron 2 estados emocionales positivos y negativos. Para comparar probaron los algoritmos SVM, DBN-HMM

Emotion Recognition based on EEG using LSTM Recurrent Neural Network (Alhagry et al., 2017)	2017	X	Long-Short Term Memory (LSTM)	Cross validation	DEAP	87.9%	Identificaron estados emocionales en base al modelo excitación- valencia (HAHV, HALV, LAHV, LALV) más un estado neutral. Utilizan la función ReLu para ratificar valores negativos obtenidos. Compararon resultados con los obtenidos con NB, SVM, BAYES
Recognition of Emotions Using Multichannel EEG Data and DBN-GC-Based Ensemble Deep Learning Framework (Chao et al., 2018)	2018	X	Deep belief networks with glia chains	F-Score Accuracy	DEAP	75.92%	Identificaron estados emocionales en base al modelo excitación- valencia, estos estados son: felicidad, enojo, tristeza y tranquilidad.
Emotion recognition using deep learning approach from audio-visual emotional big data (Hossain & Muhammad, 2018)	2018	X	Extreme learning machines (ELM)	Confusion Matrix Recall	Propia	99.9%	Generación de su propia base de datos de estudios con datos de video y audio de las sesiones. Las emociones que identificaron son: felicidad, tristeza y neutral.
An unsupervised EEG decoding system for human emotion recognition (Liang et al., 2019)	2019	X	Hypergraph partitioning	F-Score Cross validation	DEAP	62%	Identificaron estados emocionales en base al modelo excitación- valencia. Utilizaron la hipergrafía para la segmentación y agrupación de las señales.
Recognition of emotions using multimodal physiological signals and an ensemble deep learning model (Yin et al., 2017)	2017	X	multiple-fusion-layer based ensemble classifier of SAE (MESAE)	F-Score Cross validation	DEAP	76.17%	Identificaron estados emocionales en base al modelo excitación- valencia, estos estados son: alegría, enojo, tranquilidad, tristeza. Para comparar probaron los algoritmos SVM, NB, Least-squares support-vector machines

# Capítulo 4

## Metodología



## 4. Método de solución

Con la finalidad de alcanzar los objetivos planteados para este trabajo de investigación se diseñó la arquitectura mostrada en la Figura 4.1, la cual está conformada por 3 métodos esenciales; el primero de ellos es el de creación del repositorio de datos de señales fisiológicas multimodal, el segundo es la clasificación de estados emocionales y por último el desarrollo de la interfaz, así como la incorporación del módulo a UXLab y las pruebas correspondientes; en las subsecciones siguientes se describirán de manera más detallada las actividades realizadas en cada sección de la arquitectura.

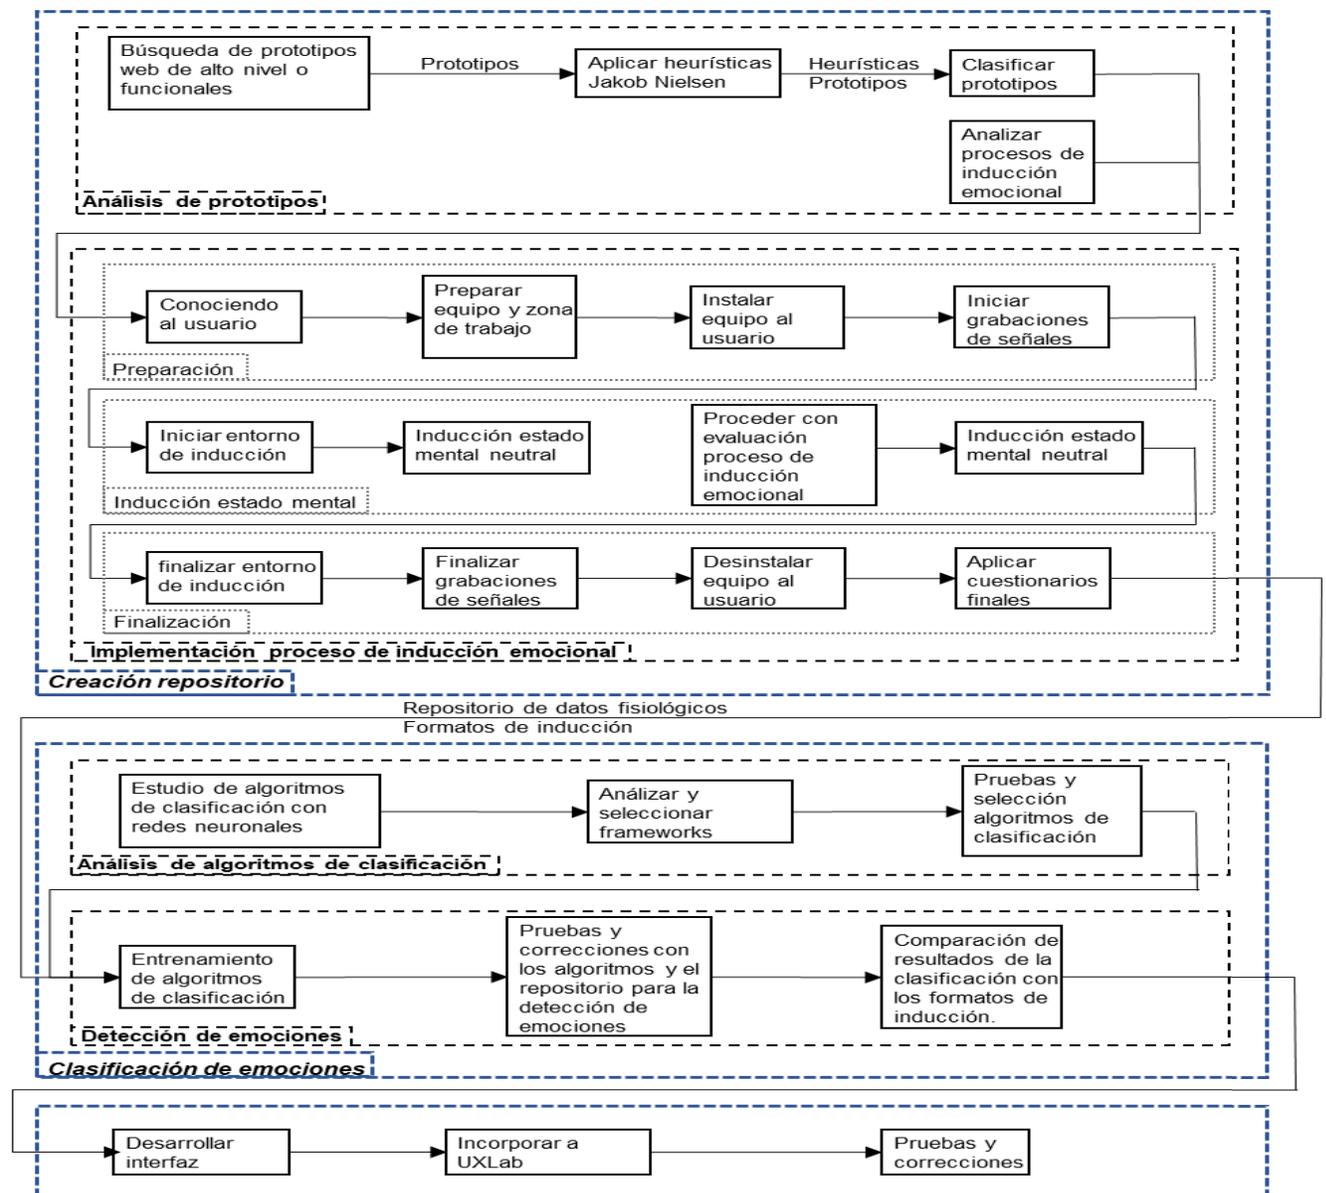


Figura 4.1 Arquitectura general de solución

## 4.1. Creación del repositorio de datos

Se realizó un análisis más detallado de los repositorios de datos existentes para identificar las características relevantes y útiles para la creación de nuestro repositorio, en la Tabla 4.1 se muestra la comparación de los repositorios más utilizados en la literatura para la clasificación de emociones.

En (Mahesh, Prassler, Hassan, & Garbas, 2019) se identificaron un conjunto de características necesarias para la creación de los repositorios de estímulos y datos fisiológicos, estos son:

- Identificar la población a la que se le realizará la inducción.
- Identificar el tipo de estímulo que se va a utilizar (estos deben ser relevantes para las actividades planeadas y conocidos para el usuario).
- Seleccionar los niveles de inducción.
- Recabar información personal de los usuarios para identificar como se encuentra antes, durante y después de la prueba.

En (Katsigiannis & Ramzan, 2018; Koelstra et al., 2012; Miranda Correa et al., 2018; Savran et al., 2006; Soleymani, Lichtenauer, Pun, & Pantic, 2012; Song et al., 2019), se presentan diversos trabajos para la creación de repositorios de datos con señales fisiológicas, en cada trabajo se presenta o describe el proceso de inducción emocional que se siguió, el tipo de estímulo utilizado, las señales recabadas, el modelo y/o emociones a detectar.

Como se puede observar en la Tabla 4.1, todos los repositorios obtienen como mínimo la señal fisiológica de electroencefalograma (EEG), esta señal es la más utilizada para llevar a cabo la clasificación de emociones, ya que de acuerdo con la literatura es la señal fisiológica que cuenta con un mayor número de características útiles para ello. Dentro de los estímulos utilizados para crear este tipo de repositorios predominan los videos de (Koelstra et al., 2012) y en segundo lugar las imágenes afectivas IAPS de (Vila & Sanchez, 2001), sin embargo, dichas imágenes y videos son de carácter social y no son útiles para esta investigación, a pesar de ello la estructura de cómo se crearon dichos repositorios y el tamaño de la muestra tomada dan las bases de las características que debe tener el repositorio a generar.

Tabla 4.1 Data sets de señales fisiológicas existentes

Data set	usr prueba	señales obtenidas	Extracción de características	Clasificador	Estímulo utilizado	Emociones detectadas
DEAP (Koelstra et al., 2012)	32	EEG, GSR, EMG, EOG	Spectral Power Features	Gaussian naive Bayes	Videos	Valencia Activación liker
SEED (Song et al., 2019)	14	EEG	PSD	SVM, KNN, DBN	Videos	Positivas Negativas Neutral
MAHnoB (Soleymani et al., 2012)	27	EEG, ECG, GSR	Spectral Power Features	SVN, Adaboost	Videos	Valencia- Activación
Dreamer (Katsigiannis & Ramzan, 2018)	23	EEG, ECG	PSD	KNN, LDA, SVM	Videos	Valencia Activación
MPED (Song et al., 2019)	23	EEG, ECG, GSR	PSD	KNN, SVN	Videos	Diversión, Felicidad, Alegría, Disgusto
eINTERFACE (Savran et al., 2006)	5	EEG, fNRS	STFT	Transferable Belief Model (TBM)	IAPS	Positivas Negativas Calma
AMIGOS (Miranda Correa et al., 2018)	40	EEG, ECG, GSR	PSD	Gaussian naive Bayes SVM	Videos	Valencia Activación

Tomando en cuenta la información mencionada, las características que se tomaron para este trabajo de investigación son:

- La población que se utilizará para realizar la inducción son estudiantes de maestría y doctorado, mínimo 10 hombres y 10 mujeres.
- Para la selección de estímulos se decidió trabajar con prototipos digitales de tipo web que sean de alto nivel o prototipos finales ya que es necesario que el usuario pueda interactuar con ellos para la inducción del estado emocional.
- Para los niveles de inducción es necesario que los prototipos sean de dos tipos, unos deben cumplir parcialmente las heurísticas de usabilidad de Jakob Nielsen y otros no deben cumplir total o parcialmente con ellas.
- Las señales fisiológicas que se obtendrán son EEG, ECG, GRS
- Las emociones a trabajar serán por medio de niveles de activación y valencia.

#### 4.1.1. Análisis de prototipos

Para realizar la generación del repositorio de datos fue necesario la identificación de los estímulos de productos digitales a utilizar, en (Pacholczyk, 2015; Universidad de Zaragoza, 2001), definen a los prototipos, como documentos, diseños o sistemas que simulan o tienen implementadas partes de un sistema final y constituyen una herramienta muy útil para hacer participar al usuario en el desarrollo del sistema y poder evaluar diversos aspectos como la usabilidad, accesibilidad y/o la funcionalidad de los productos digitales que se desarrollan.

De acuerdo con (Díaz, Harari, & Amadeo, 2013), los prototipos se pueden clasificar de diferentes maneras, por su tipo de evolución, las técnicas empleadas, los medios utilizados y/o nivel de fidelidad, estas técnicas permiten la evaluación de la usabilidad de la interfaz y se pueden desarrollar por diversos medios.

Se examinaron algunas páginas con las que los usuarios hayan tenido interacción y en total se recabaron 20, estas fueron seleccionadas ya que se puede considerar que son de uso habitual para la población seleccionada, en la Tabla 4.2 se describen las páginas seleccionadas.

Tabla 4.2 Páginas seleccionadas para creación de repositorio de estímulos

Nombre de la página	URL	Descripción
Sistema de aspirantes cenidet	<a href="http://servicios.cenidet.edu.mx:8080/Aspirantes/Welcome.do">http://servicios.cenidet.edu.mx:8080/Aspirantes/Welcome.do</a>	Sistema para el registro de aspirantes de CENIDET.
Extracción de metadatos en libros	-	Sistema para la extracción semiautomática de metadatos en libros.
Office depot	<a href="https://www.officedepot.com.mx/office-depot/en/">https://www.officedepot.com.mx/office-depot/en/</a>	Este sistema permite realizar compras y consultas en la tienda forma digital.
Codewars	<a href="https://www.codewars.com/">https://www.codewars.com/</a>	Es un sistema que permite a los usuarios entrenar sus habilidades de desarrollo en diferentes lenguajes de programación.
Packtpub	<a href="https://www.packtpub.com/">https://www.packtpub.com/</a>	Es un sistema para compra y venta de libros y videos de diversas tecnologías.
IMSS	<a href="http://www.imss.gob.mx/">http://www.imss.gob.mx/</a>	Este sistema permite a los derechohabientes del IMSS realizar citas, consultas y diversas actividades sin necesidad de ir a la institución.
Nintendo	<a href="https://www.nintendo.com/">https://www.nintendo.com/</a>	En este sistema se puede realizar la compra y consultas de videojuegos de la marca.
Walmart mi super	<a href="https://super.walmart.com.mx/?gclid=EA1aIQobChMlh6nEjIGJ6QIVg4bACh2XJA08EAAYASAAEgKHX_D_BwE&amp;gclid=aw.ds">https://super.walmart.com.mx/?gclid=EA1aIQobChMlh6nEjIGJ6QIVg4bACh2XJA08EAAYASAAEgKHX_D_BwE&amp;gclid=aw.ds</a>	En este sistema se puede realizar la compra y consultas de los productos de la canasta básica, así como de algunos otros productos que venden en las tiendas físicas.
Pullman de Morelos	<a href="http://pullman.mx/Index.php#/">http://pullman.mx/Index.php#/</a>	En este sistema se puede realizar la compra y consultas de boletos de autobús.
compucalitiv	<a href="https://www.compucalitiv.com/">https://www.compucalitiv.com/</a>	Este sistema permite la descarga de películas, juegos, series y programas de computadora de manera gratuita.
Udemy	<a href="https://www.udemy.com/mobile/ipad/">https://www.udemy.com/mobile/ipad/</a>	Es un sistema donde se puede comprar o vender cursos de todo tipo.
Prezi	<a href="https://prezi.com/es/">https://prezi.com/es/</a>	Es un sistema que permite la creación de presentaciones dinámicas.
Amazon	<a href="https://www.amazon.com.mx/">https://www.amazon.com.mx/</a>	Este sistema permite realizar compras, consultas y ventas de todo tipo de productos.
Aliexpres	<a href="https://es.aliexpress.com/">https://es.aliexpress.com/</a>	Este sistema permite realizar compras y consultas de todo tipo de productos.
Liverpool	<a href="https://www.liverpool.com.mx/tienda/home">https://www.liverpool.com.mx/tienda/home</a>	Este sistema permite realizar compras y consultas de la tienda forma digital.
Mercado libre	<a href="https://www.mercadolibre.com.mx/">https://www.mercadolibre.com.mx/</a>	Este sistema permite realizar compras, consultas y ventas de todo tipo de productos.
Elsevier	<a href="https://www.elsevier.com/es-mx">https://www.elsevier.com/es-mx</a>	Este sistema permite la búsqueda, análisis, compra y publicación de artículos académicos de impacto científico.
DD Tech	<a href="https://ddtech.mx/">https://ddtech.mx/</a>	Este sistema permite realizar compras y consultas de productos computacionales.
edx	<a href="https://www.edx.org/es">https://www.edx.org/es</a>	Es un sistema donde se puede comprar cursos de diferentes tópicos.
Coursera	<a href="https://www.coursera.org/">https://www.coursera.org/</a>	Es un sistema donde se puede comprar o vender cursos de todo tipo.

#### 4.1.2. Aplicación de las heurísticas Jakob Nielsen y clasificación de prototipos

La evaluación por medio de heurísticas es un método utilizado para encontrar y evaluar los problemas de usabilidad en el diseño de las interfaces en los sistemas; es un método de bajo costo cuyo objetivo es mejorar la interacción con el usuario, los diseños en las interfaces de los usuarios y realizar comparativas entre versiones o competidores (Pacholczyk, 2015; Sánchez, 2011).

De acuerdo con (Nielsen & Molich, 1990), la usabilidad es el atributo de calidad que mide la facilidad de utilizar interfaces web; en 1990 Nielsen diseñó 10 heurísticas para la evaluación de los sistemas web, esta lista de 10 heurísticas es la más comúnmente utilizada en la industria; son diez principios generales para el diseño de interfaces de usuario. Son llamadas “heurísticas” debido a que tienen más naturaleza de reglas de oro, que directrices específicas de usabilidad.

1. Visibilidad del estado del sistema: el sistema debe siempre mantener a los usuarios informados del estado del sistema, con una retroalimentación apropiada y en un tiempo razonable.
2. Correspondencia entre el sistema y el mundo real: el sistema debe hablar el lenguaje de los usuarios, con las palabras, las frases y los conceptos familiares a ellos, en lugar de los términos orientados al sistema. Utilizar convenciones del mundo real, haciendo que la información aparezca en un orden natural y lógico.
3. Control y libertad para el usuario: Los usuarios frecuentemente eligen funciones del sistema por error y necesitan una salida de emergencia claramente marcada, es decir, salir del estado indeseado sin tener que pasar por un diálogo extendido. Es importante disponer de opciones para deshacer y rehacer una acción.
4. Consistencia y estándares: Los usuarios no deben tener que preguntarse si las diversas palabras, situaciones, o acciones significan la misma cosa. En general se deben seguir las normas y convenciones de la plataforma sobre la que se está implementando el sistema.
5. Prevención de errores: Mejor que tener buenos mensajes de errores es el hecho de diseñar cuidadosamente las interfaces.

6. Reconocer más que recordar: Minimizar la necesidad de memorizar al usuario, haciendo visibles objetos, acciones y opciones. El usuario no debería tener que recordar la información de una interfaz a la otra. Las instrucciones para el uso del sistema, deberían ser visibles o fáciles de encontrar en cualquier momento.
7. Flexibilidad y eficiencia de uso: Los aceleradores no vistos por el usuario principiante, mejoran la interacción para el usuario experto de tal manera que el sistema puede servir para usuarios inexpertos o experimentados. Es importante que el sistema permita personalizar acciones frecuentes.
8. Un diseño estético y minimalista: No debe incluirse información que no sea aplicable o que raramente se necesite. Cada unidad adicional de la información en un diálogo compite con las unidades relevantes de la información y disminuye su visibilidad relativa.
9. Ayudar a los usuarios a reconocer, diagnosticar y recuperarse de los errores: Los mensajes de error se deben expresar en un lenguaje claro (sin códigos), indicar exactamente el problema y constructivamente sugerir una solución.
10. Ayuda y documentación: Aunque es mejor que el sistema pueda usarse sin documentación, puede ser necesario disponer de ella y adicionalmente de ayuda. Ésta debe de ser fácil de buscar, centrada en las tareas del usuario, tener información de las etapas a realizar y que no sea muy extensa.

Este tipo de evaluación se basa en la observación e interacción con la interfaz y los comentarios sobre aspectos buenos y malos encontrados en la interfaz, dichos comentarios deben ser acorde a las heurísticas mencionadas anteriormente y deben ser reportados.

El proceso de evaluación heurística (Nielsen, 1994) recomienda que se realice dicha actividad al menos por 4 expertos, cada uno debe evaluar las interfaces identificando si cumplen o no con las heurísticas. Al determinar cuál directriz ha sido violada, la usabilidad de un dispositivo puede ser determinada. Típicamente una sesión de evaluación heurística ha de durar de 1 a 2 horas. En caso de que se realice la prueba de una interfaz muy compleja, se puede dividir en varias sesiones que aborden diferentes aspectos de la interfaz. El resultado de una evaluación heurística es una lista de problemas de usabilidad que fueron transgredidas en el diseño del prototipo de acuerdo a la opinión del evaluador.

A continuación, en la Tabla 4.3 se muestra la plantilla que debe tomar el evaluador para registrar la información recabada.

Tabla 4.3 Plantilla evaluación productos digitales

<b>Nombre del producto:</b>	<Producto a evaluar>
<b>Fecha de la evaluación:</b>	<Fecha en la que se llevó a cabo la evaluación>
<b>Nombre del evaluador:</b>	<Nombre del Experto>
<b>#1 &lt;Número de heurística&gt;</b>	
<b>Heurística:</b>	<Nombre de la Heurística>
<b>Observaciones:</b>	
<Descripción del proceso donde se identificó la heurística positiva o negativa>	
<b>Evidencia:</b>	
<Donde se ha ubicado la heurística en la interfaz, así como una imagen descriptiva>	
<b>Descripción:</b>	
<Explicación de los aspectos malos o buenos de la heurística en la interfaz, se debe describir cómo se viola o cumple la heurística >	
<b>Calificación: (0-4 mientras mayor sea el valor mayor es la gravedad):</b>	
< 0 = No es un problema: No estoy de acuerdo en que esto sea del todo un problema de usabilidad. 1 = Problema Cosmético solamente: No requiere ser resuelto, a menos que exista tiempo extra en el proyecto. 2 = Problema de usabilidad Menor: Resolver esto es de baja prioridad. 3 = Problema de usabilidad Mayor: Resolver esto es de suma importancia, se debe dar alta prioridad. 4 = Catástrofe de usabilidad: imprescindible resolver este problema antes de que el producto sea liberado>	
<b>Justificación:</b>	
< ¿Cuándo, por qué y dónde sucede? >	
<b>Recomendaciones:</b>	
<En caso de que exista un problema con alguna heurística se debe proponer una posible solución>	

Tomando en cuenta la información encontrada, se realizó el análisis de las páginas web de la Tabla 4.2 por medio de las heurísticas mencionadas, la información recabada de las heurísticas individualmente se almacenó en los formatos correspondientes detallando el proceso que se llevó a cabo para obtener dicho resultado; en caso de que el sistema incumpla

más de una vez con alguna heurística, se debía repetir la plantilla correspondiente la cantidad de veces que sea necesaria para dejar la evidencia.

Los formatos generados de las evaluaciones se encuentran en el siguiente enlace:

[https://drive.google.com/open?id=1yWUa-y5\\_z3NYKJIE0Ph4xOqAgevMX\\_KR](https://drive.google.com/open?id=1yWUa-y5_z3NYKJIE0Ph4xOqAgevMX_KR)

Dentro de los resultados obtenidos se encuentra la lista de mejoras para cada página web, así como la heurística que se mejoraría al agregar dicha modificación, en el siguiente enlace se encuentra la lista de mejoras detectadas por los evaluadores al realizar las evaluaciones heurísticas.

<https://drive.google.com/open?id=1V9ZLduotA2GK7o11sF3eze--PTpN-6pd>

De acuerdo con (Dur, 2017; Fernández, 2012) para poder realizar la clasificación es necesario tomar en cuenta los siguientes puntos:

- Los resultados de todos los evaluadores
- La frecuencia de aparición de cada heurística
- Identificar cuál heurística tiene un mayor porcentaje en problemas y cuál es la que ha tenido menor problema.

Dado los resultados de los evaluadores, se identificaron las 3 heurísticas con mayor problemática en los productos digitales seleccionados, en primer lugar y con mayores problemas se encuentra la heurística número 5 “Prevención de errores”, ya que en todos los casos al menos aparece una vez con el problema de que en los campos de los formularios no se evita la introducción de caracteres especiales y/o números; en segundo lugar, se encuentra la heurística número 6 “Reconocer más que recordar”, ya que en varios casos las páginas están tan cargadas de información que navegar en ellas y encontrar lo que se está buscando es complicado para los usuarios; la última de ellas es la número 9 “Ayudar a los usuarios a reconocer, diagnosticar y recuperarse de los errores”, ya que en algunos casos los mensajes de error contienen códigos o son muy ambiguos en el error lo cual impide que el usuario solucione el problema de manera sencilla.

La heurística con menor problema y con menor veces de aparición es la número 8 “Un diseño estético y minimalista”, ya que en general las páginas mantienen su diseño en todas las pestañas, mensajes y acciones que contiene.

### 4.1.3. Implementación del proceso de inducción emocional

Para poder implementar y adecuar un proceso de inducción emocional a partir de productos digitales, fue necesario aplicar las técnicas utilizadas en algunos trabajos de investigación del estado del arte (Tabla 3.1).

Dentro de la institución se desarrolló el trabajo de investigación de (Soriano Terrazas, 2018), el cual contiene las características mencionadas identificadas, y añade dos etapas más que ayudan a complementar el proceso para obtener de mejor manera los datos fisiológicos, este trabajo utiliza un proceso de inducción emocional a partir de estímulos de realidad virtual inmersiva y se planea utilizar y adaptar para la investigación; con el objetivo de generar un proceso de inducción emocional el cual utilice como estímulos algunos productos digitales de tipo web, a diferencia de los procesos existentes donde el usuario no interactúa con el estímulo de forma activa, en esta adaptación el usuario deberá interactuar con el estímulo para que se produzca la inducción del estado emocional.

A continuación, se describen las etapas que conforman el proceso generado, el cual está conformado de las siguientes etapas: iniciación o preparación, inducción de estados mentales y finalización.

#### Etapa 1 Iniciación

Esta etapa está conformada por 4 fases, la primera de ellas es “Conociendo al Usuario”, en esta fase se debe informar a los usuarios sobre el objetivo de la prueba, los dispositivos que se utilizarán e instalarán en su cuerpo; se le aplicará un cuestionario demográfico y cuestionarios para identificar si el usuario se encuentra bien tanto física como mentalmente antes de poder presentar la prueba. En la Figura 4.2 se muestra el diagrama de actividades del proceso, así como los participantes.

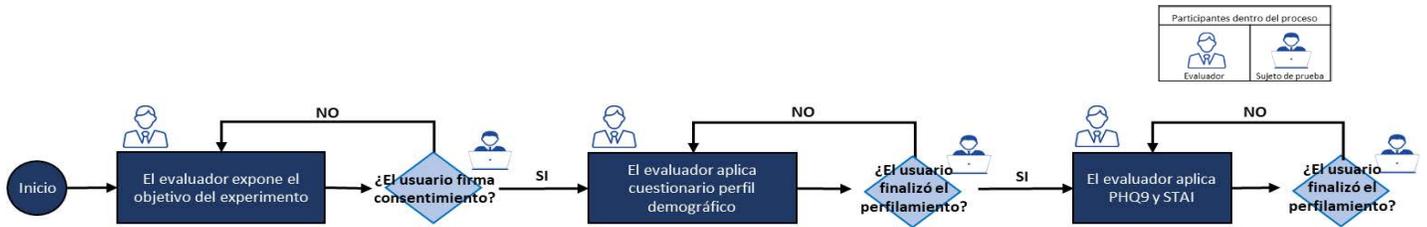


Figura 4.2 Conociendo al usuario

La segunda fase “Preparar el Equipo y Zona de Trabajo”, en esta fase se establece una serie de actividades a realizar para obtener un correcto funcionamiento de los dispositivos, así como la zona de trabajo y comodidad para el usuario, es decir, las condiciones ambientales y ergonómicas a las que estará expuesto el usuario, en la Figura 4.3 se muestran las actividades a realizar.

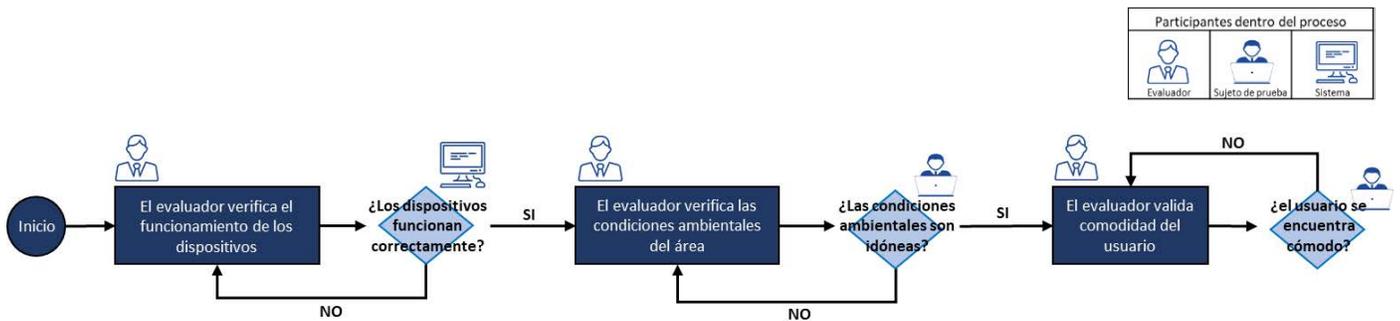


Figura 4.3 Preparación de equipo y zona de trabajo

La tercera fase “Instalar Dispositivos al Usuario”, esta fase se inicia con la instalación de los sensores biométricos (Electrocardiograma ECG y Respuesta Galvánica en Piel GSR) y se valida el correcto funcionamiento de ellos en la plataforma UXLab, posteriormente se realiza la instalación del gorro Emotiv EPOC Flex, para la obtención de las señales de Encefalograma y se valida el correcto funcionamiento de ellos. Durante la instalación de los dispositivos el evaluador debe considerar la comodidad del usuario y la correcta colocación de los dispositivos,

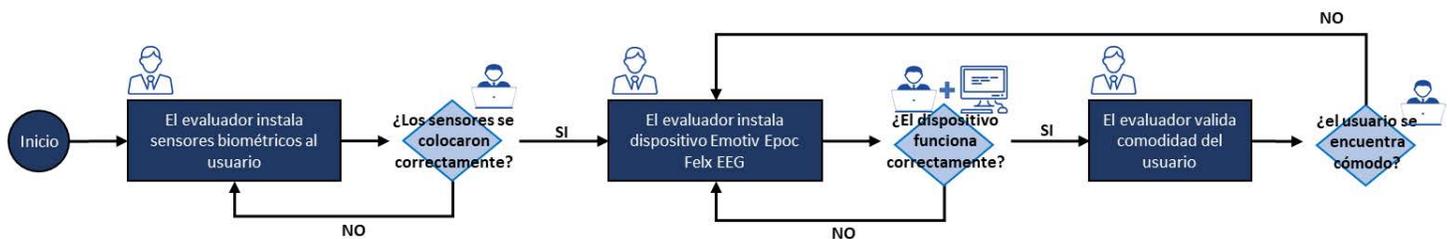


Figura 4.4 Instalar dispositivos al usuario

ya que el tener problemas en la colocación o que el usuario no se sienta cómodo influirá de manera negativa en los resultados, en la Figura 4.4 se muestran las actividades a realizar.

Adicionalmente, para estas dos fases se ha generado un manual de instalación para preparar las pruebas de Evaluación de la Experiencia de Usuario (UX) el cual se puede ver en el Anexo1.

La última fase “Iniciar la grabación en plataforma UXLab e Iniciar entorno de inducción”, en esta fase una vez que se ha validado el correcto funcionamiento de todos los dispositivos, el ambiente y la comodidad del usuario, se debe iniciar la plataforma de grabación UXLab y validar que la plataforma inicie correctamente, posteriormente se debe crear y validar el perfil del usuario, al perfil se le debe asignar una clave, esta debe contener en los primeros caracteres las iniciales del usuario, posteriormente el número de la prueba y finalmente la fecha en que se realiza cada sección separada por un guion (NNN-001-aaaammdd); una vez validada la información se procede a iniciar la grabación de las señales con la plataforma e iniciar el entorno para el proceso de inducción, en la Figura 4.5 se muestran las actividades a realizar.

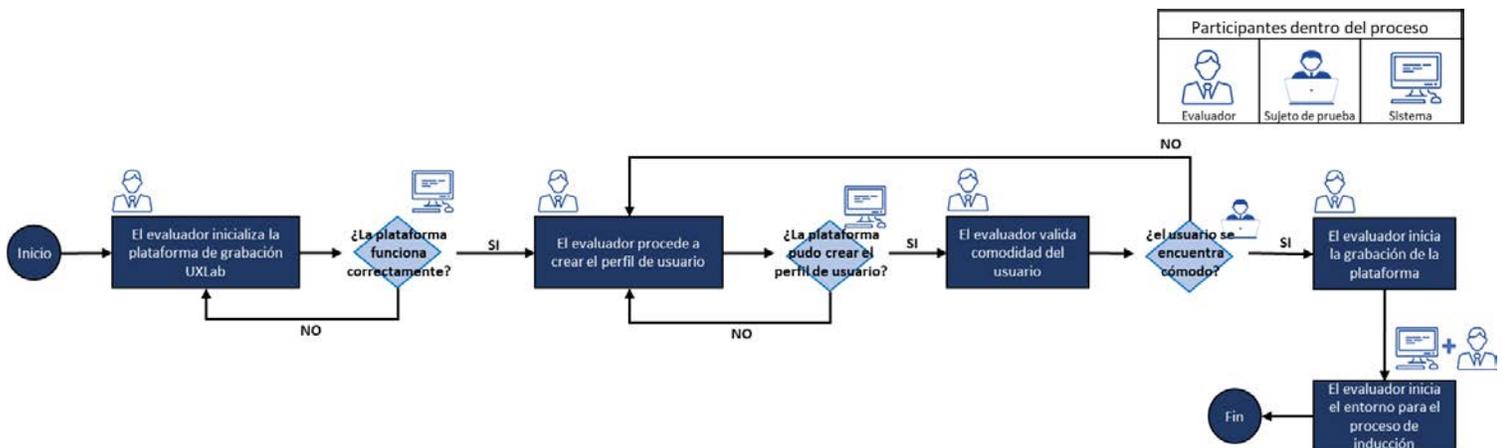


Figura 4.5 Iniciar grabación en plataforma UXLab e iniciar entorno de inducción

## Etapa 2 Inducción de estados emocionales

En esta etapa se describe el proceso de inducción de estados emocionales con productos digitales de tipo web (Figura 4.6); en esta etapa la mayor parte de la interacción se realiza entre el sistema y el sujeto de pruebas.

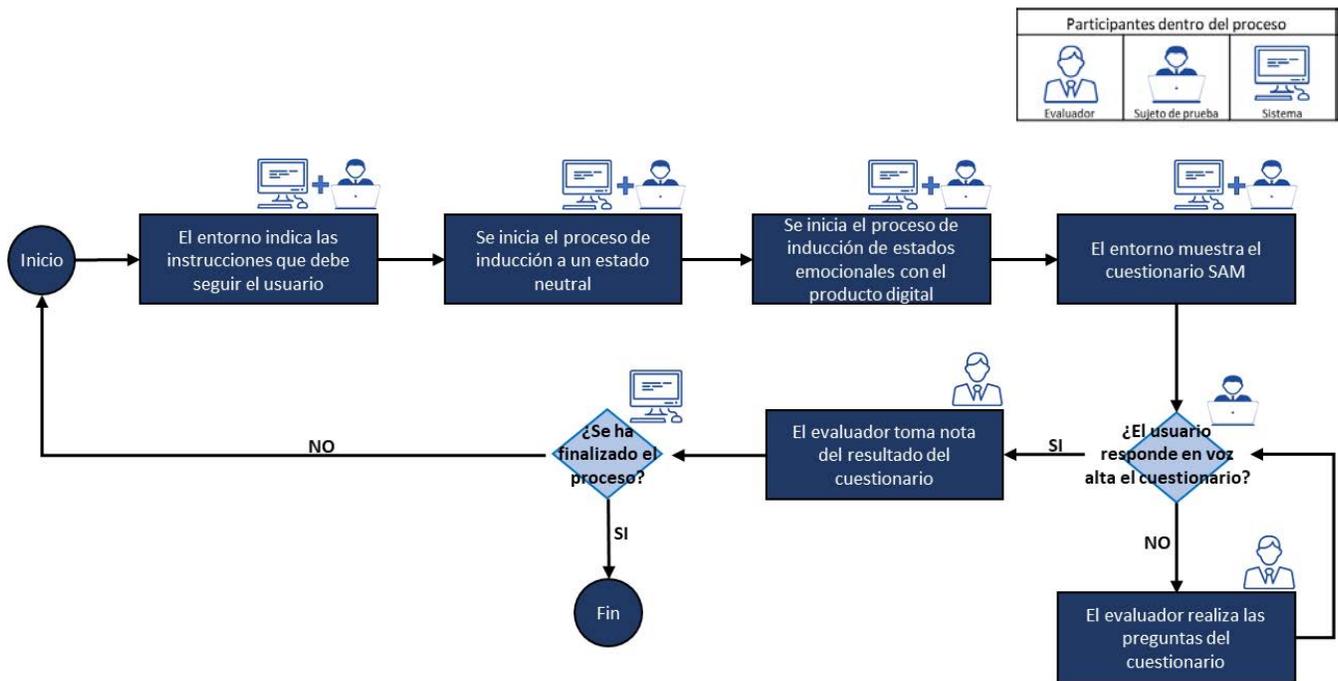


Figura 4.6 Inducción estados emocionales

El sistema es el encargado de proporcionar las instrucciones que debe seguir el sujeto de pruebas en cada sección; el proceso de inducción inicia colocando al sujeto de prueba en una línea base o estado neutral, es decir, tiene que encontrarse en un estado de relajación, este proceso durará en total 2 minutos, de los cuales el sujeto debe estar 1 minuto con los ojos cerrados y 1 minuto con los ojos abiertos observando un símbolo o imagen que el sistema le mostrará; posteriormente inicia la inducción con los estímulos seleccionados, es decir, los productos digitales; este proceso de inducción se muestra en la Figura 4.7 y está conformado por 2 secciones, cada una de ellas es una inducción con un producto digital diferente, para este trabajo se utilizarán 16 productos digitales los cuales serán distribuidos en 8 sesiones de inducción.

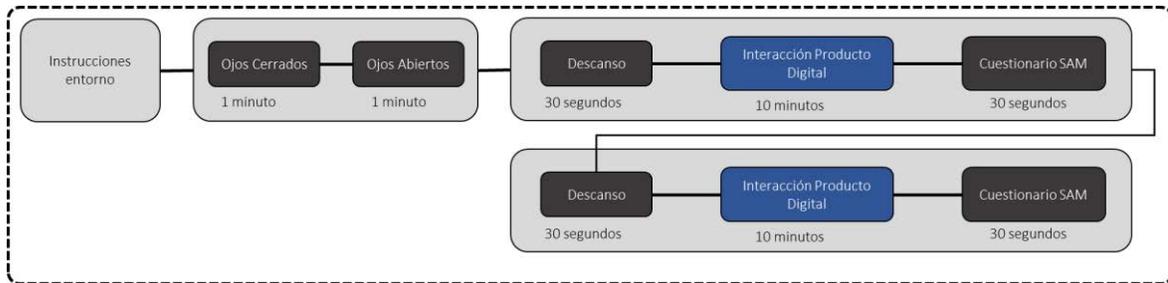


Figura 4.7 Arquitectura proceso inducción emocional

Al finalizar la interacción con el estímulo, el sistema le presentará al usuario el cuestionario SAM (Figura 4.8), el usuario debe responder en una escala del 1 al 9 como se sintió al interactuar con el sistema, la primera línea de la imagen se refiere a valencia, es decir, si la interacción les provocó una sensación positiva o negativa; la segunda línea es la activación, es decir, que tan intensa sintió la emoción y la tercera línea es el dominio, es decir, que tanto puede controlar la emoción; el evaluador será el responsable de tomar nota de los resultados del cuestionario, en caso de que el sujeto de pruebas no responda el cuestionario el evaluador será el responsable de solicitar las respuestas.

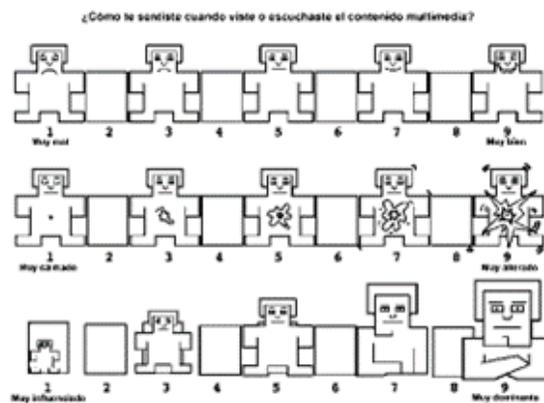


Figura 4.8 Cuestionario SAM

Una vez que el usuario respondió el cuestionario el sistema iniciará un proceso de descanso mental con la pantalla oscura, este descanso durará 30 segundos y tiene como objetivo hacer que el sujeto de pruebas se encuentre en un estado neutral al finalizar la interacción con el estímulo.

### Etapa 3 Finalización

Esta etapa está conformada por 3 fases, la primera de ellas es “Finalización del entorno del proceso de inducción y grabación de señales fisiológicas”, esta fase inicia cuando el sistema informa al usuario que ha terminado la inducción, el evaluador procederá a detener la grabación de la plataforma UXLab y debe validar que esta se haya detenido de manera correcta, una vez que suceda esto la plataforma UXLab iniciará el proceso de guardado de la información recabada en la prueba; este es un proceso que puede tardar unos minutos, mientras tanto el evaluador debe informar al usuario que se ha concluido la prueba de inmersión, en la Figura 4.9 se muestran las actividades mencionadas.

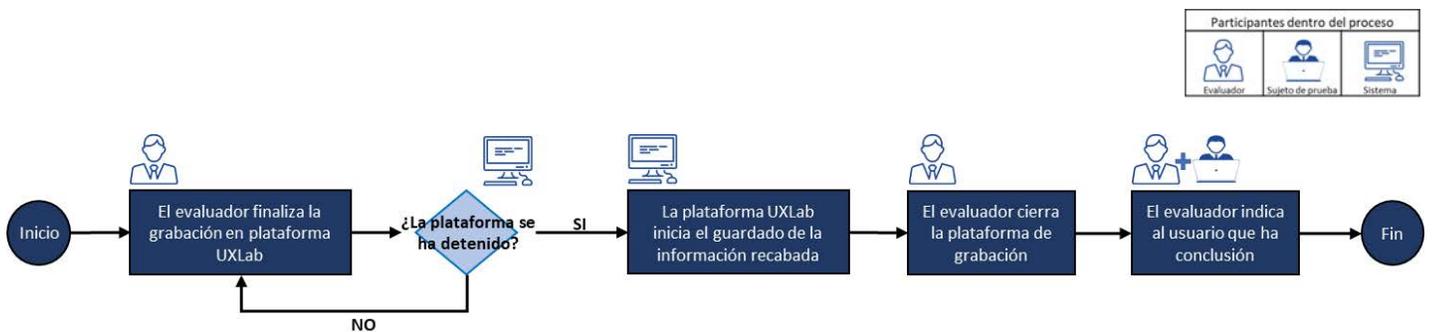


Figura 4.9 Finalización del entorno de proceso de inducción

La segunda fase “Desinstalación de dispositivos” (Figura 4.10) en esta fase el evaluador procede a retirar los sensores biométricos y el gorro Emotiv Epoc Flex; en caso de que haga falta desinstalar algún dispositivo el usuario deberá indicar al evaluador para que proceda a retirar por completo los sensores.

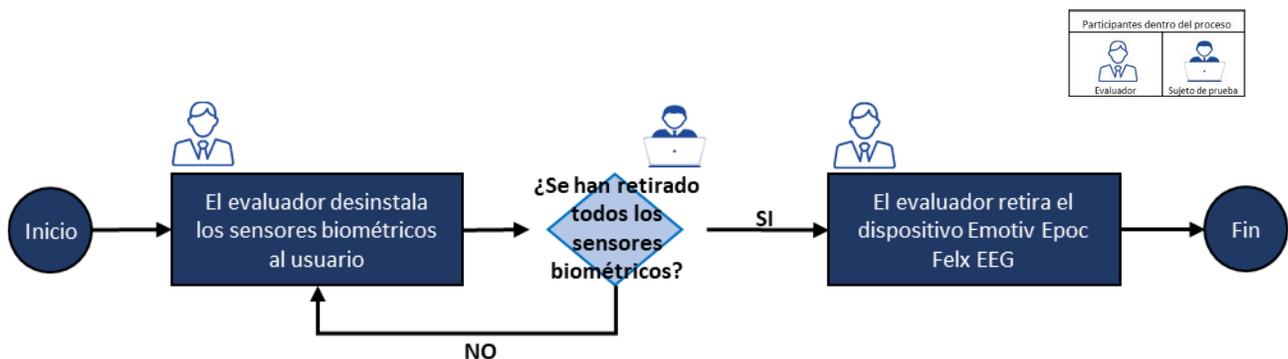


Figura 4.10 Desinstalación de dispositivos

La última fase “Aplicar cuestionarios de estados mentales” (Figura 4.11), en esta fase el evaluador debe explicar al usuario de que trata el cuestionario PANAS y pedirle que lo responda, una vez que finalice el evaluador debe de validar que el usuario se encuentre en un estado emocional neutral o positivo, de lo contrario debe aplicar un PIE para inducir dicho estado y poder finalizar la prueba por completo.

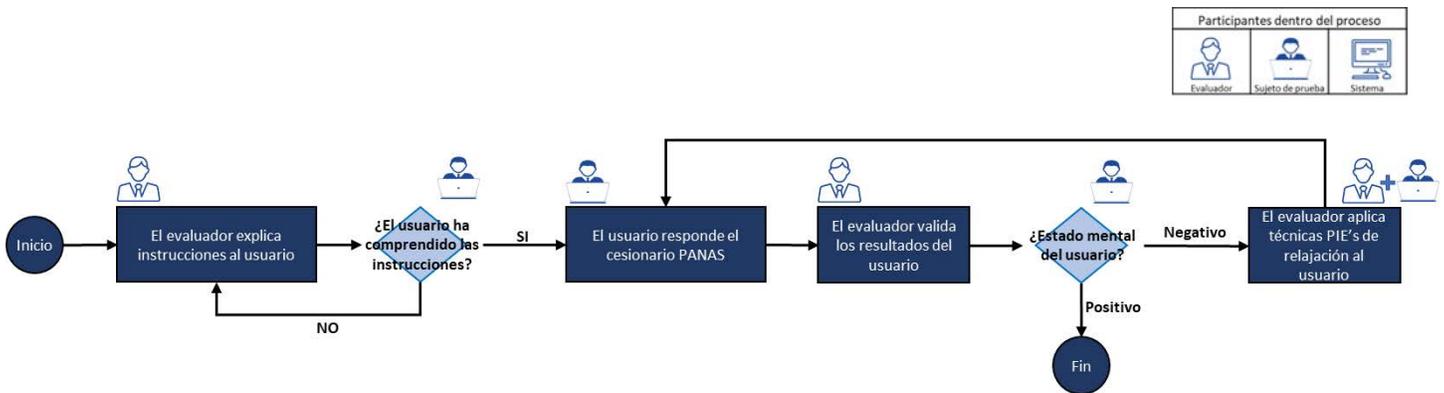


Figura 4.11 Aplicar cuestionarios de estados mentales

## 4.2. Clasificación de emociones

De acuerdo con el análisis realizado en el estado del arte, se identificaron los métodos más utilizados para realizar el filtrado de las señales fisiológicas, así como los algoritmos más utilizados para realizar la clasificación o detección de estados emocionales y los frameworks que permiten trabajar con los diversos algoritmos de clasificación.

### 4.2.1. Métodos para el filtrado de señales

Realizar el filtrado de señales es una herramienta muy útil para separar, restaurar, corregir o limpiar señales; a continuación, se describen en orden los filtros más utilizados en los trabajos para la detección de emociones a partir de señales fisiológicas.

El filtro más utilizado en los trabajos es el paso banda y para entenderlo se debe considerar primero el paso bajo y el paso alto; el paso bajo (lp) de acuerdo con (Real Academia de Ingeniería, 2020) nos dice que se encarga de eliminar los componentes de frecuencias altas del espectro de una señal situada por encima de la frecuencia de corte; por otro lado el paso alto (hp) se encarga de eliminar los componentes de frecuencias bajas del espectro de una señal situada por debajo de la frecuencia de corte. El paso banda (bp) se encarga de delimitar una banda de frecuencias definiendo un punto de corte inferior y otro superior.

Otro de los filtros utilizados en el estado del arte es la Transformada Discreta de Fourier (DFT), de acuerdo con (Folland, 1992) este filtro es utilizado para el análisis y procesamiento de las frecuencias de las señales, las cuales deben estar definidas en un tiempo discreto y un dominio finito y suelen ser generadas a partir de funciones continuas como por ejemplo la voz; la transformada expande la señal por triangulación de base de senos y cosenos, expresando una señal con sus diferentes frecuencias por medio de la superposición lineal de las funciones armónicas.

La DFT involucra un muestreo, un truncado y la convolución de la señal resultante, adicionalmente no debe de existir una pérdida o distorsión de la señal, para evitar que exista dicha pérdida de información se debe muestrear la frecuencia a una superior a la indicada en el límite de Nyquist; el objetivo del truncado y la convolución es obtener una señal periódica a partir de una porción de la señal original; si se identifica que la muestra es una señal periódica significa que la señal original también lo es, sin embargo, después de realizar un muestreo se debe verificar que la señal original sea periódica, si el resultado muestra que es así quiere decir que la TF y DFT son equivalentes.

Aunque DFT permite representar una señal en sus frecuencias, no permite una resolución en tiempo, es decir, se pueden conocer los componentes principales de la frecuencia, pero no en qué momento ocurrió; este conflicto se puede solucionar recurriendo a la Transformada Rápida de Fourier (FFT), la cual calcula la transformada por segmentos, teniendo una representación tiempo-frecuencia de la señal que permite conocer sus frecuencias en la ubicación del tiempo.

De acuerdo con (Sidney Burus, Gopinath, & Guo, 1998) la transformada de wavelet es utilizada para aproximar funciones o señales de acuerdo a la escala de resolución, esto utilizando un conjunto de funciones base llamadas wavelets, también puede ser utilizada para representar características de interés localizadas en una señal y para la remoción de componentes de alta frecuencia de los datos.

El proceso de filtrado o eliminación de ruido utilizando la transformada de wavelet está conformado por el cálculo de los coeficientes wavelet, umbralización (segmentación) y reconstrucción de la señal a partir de los coeficientes umbralizados.

El cálculo de coeficientes consiste en aplicar la transformada de wavelet discreta (DWT) la cual está formada por dos procesos, en el primero de ellos se filtra la señal utilizando un filtro paso bajo y uno paso alto de descomposición y en el segundo se utiliza el submuestreo de las subseñales de salida obtenidas del filtro paso bajo; la salida del filtro paso bajo corresponde a los coeficientes de aproximación de la señal, mientras, que la salida del filtro paso alto contiene los coeficientes de detalle.

El proceso de umbralización consiste en seleccionar los coeficientes que superen un umbral determinado para considerarlos en la reconstrucción de la señal, mientras que los coeficientes por debajo de este umbral son eliminados; Para umbralizar los coeficientes, se debe estimar el ruido presente en la señal, escalar dicho valor y aplicar el umbral.

El proceso de reconstrucción de la señal consiste en el sobre muestreo y filtrado de los coeficientes utilizando filtros paso bajo y paso alto de reconstrucción, esta reconstrucción es realizada a todos los coeficientes de los niveles de descomposición.

La selección del filtro a utilizar depende de que es lo que se desea detectar y el tipo de señal con la que se trabaja; en los trabajos del estado del arte que utilizan repositorios ya creados toman los filtros utilizados por los creadores para realizar el filtrado en sus trabajos; a menos que deseen detectar algún dato en particular utilizan otro tipo de filtrado, en los trabajos donde crean sus repositorios normalmente utilizan el filtro paso banda o si el mismo algoritmo de clasificación permite realizar el filtrado de la señal omiten el paso previo de filtrado.

Adicionalmente se debe tomar en cuenta los dispositivos utilizados para la extracción de las señales fisiológicas, ya que en algunos casos los dispositivos arrojan la señal ya filtrada, tal es el caso del dispositivo EEG que se utiliza en este trabajo; de acuerdo con la página Emotiv Epoc Flex para la versión que se utiliza de 32 electrodos, indica que las señales arrojadas son filtradas por medio del paso banda.

### 4.2.2. Análisis de métodos de clasificación

De acuerdo con el análisis realizado en el estado del arte se identificaron los algoritmos más utilizados para realizar la clasificación o detección de estados emocionales; en la Tabla 4.4 se muestran dichos algoritmos, así como el rango de precisión que se detectó de acuerdo a los trabajos analizados, el tipo de señal con el que se trabajó y la emoción o modelo más utilizado para detectar con el algoritmo. Analizando dicha información se decidió trabajar con los algoritmos de LSTM y GRU, los cuales se describen a continuación,

Tabla 4.4 Algoritmos seleccionados

Algoritmo	Señal	Resultados	Emoción
Long short term memory (LSMT)	EEG	88% - 90%	Modelo Act/Val
k-nearest neighbors (KNN)	EEG	77% - 93%	Modelo Act/Val
Gated Recurrent Unit (GRU)	EEG	87% - 91%	Modelo Act/Val
Deep belief network	EEG	75% - 88%	Modelo Act/Val

#### Long short term memory

Para resolver el problema del desvanecimiento del gradiente surgieron las redes de memoria a corto/largo plazo (long short term memory), este tipo de redes neuronales recurrentes fueron creadas y descritas en 1997 por (Hochreiter & Schmidhuber, 1997) y también son conocidas como redes LSTM, ellas cuentan con la capacidad de aprender cadenas o dependencias de datos a largo plazo, de acuerdo con la literatura, comparadas con las RNN tradicionales generan una mayor cantidad de ejecuciones exitosas y aprende de manera más rápida ya que está diseñada para superar los problemas de flujos de errores y dependencias a largo plazo, debido a que su función principal es recordar información durante largos periodos de tiempo, para lograrlo utiliza un algoritmo basado en gradientes con una arquitectura que permite un flujo de error constante mejor conocido como constant error carousel (CEC).

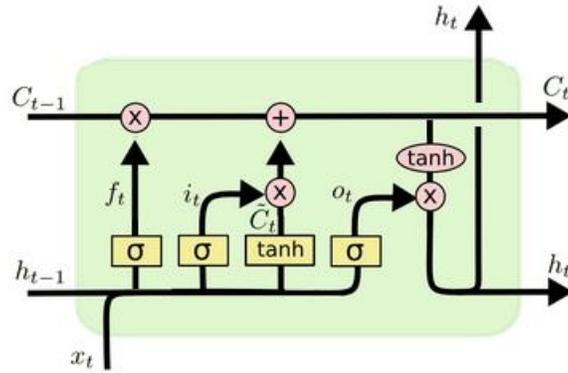


Figura 4.12 Módulo de repetición (Hochreiter & Schmidhuber, 1997)

Las LSTM, mantienen la estructura tipo cadena de las RNN estándar, sin embargo, cambia el módulo de repetición (Figura 4.12), ya que en lugar de tener solo una capa *tanh* se tienen 4 capas que interactúan; en la Figura 4.13 se observa la estructura, donde las flechas horizontales llevan a cada vector de un nodo al otro, los círculos rosas son las operaciones a realizar, los recuadros amarillos serían las capas de redes, las líneas que se unen indican comunicación y las líneas que se separan es una copia.

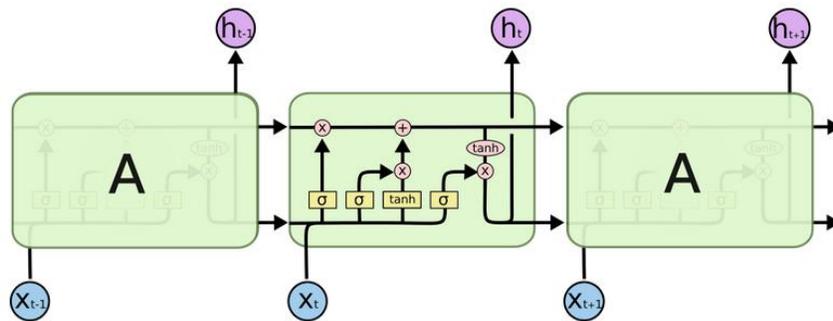


Figura 4.13 Estructura LSTM (Hochreiter & Schmidhuber, 1997)

Las LSTM tienen la capacidad de agregar o eliminar información a los estados de las celdas y es regulada por las “puertas” y cuenta con 3 de ellas para controlar y proteger la información. Estas puertas están compuestas por una capa de red neuronal sigmoide y una operación de multiplicación puntual; en esta la capa sigmoide genera números entre 0 y 1 donde el valor 0 indica que no permitirá pasar información y el valor 1 indica que permitirá el paso de información.

El proceso que se lleva a cabo inicia determinando que información será excluida del estado de la celda, para llevar a cabo esta decisión se utiliza una capa sigmoide  $\sigma$  llamada “puerta de olvido” (1), la cual toma los datos de entrada  $h_{t-1}$  y  $x_t$  para generar una salida  $f_t$  con valores entre 0 y 1 para cada dato en el estado de la celda ( $C_{t-1}$ ), donde  $W_f, W_i, W_c, W_o$  son las matrices de parámetros y  $b_f, b_i, b_c, b_o$  son los vectores de sesgo.

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (1)$$

Lo siguiente a realizar es decidir qué de la nueva información se almacenará en el estado de la celda, para ello se utiliza una capa sigmoide  $\sigma$  llamada “puerta de entrada” (2) la cual decide los valores a actualizar ( $i_t$ ) y posteriormente se aplica una capa  $\tanh$  (3) la cual genera un vector con los nuevos valores candidatos ( $\tilde{C}_t$ ) los cuales podrían agregarse al estado.

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (3)$$

Una vez obtenida la información se procede a actualizar el estado de la celda anterior ( $C_{t-1}$ ) al nuevo estado ( $C_t$ ) de ser necesario, para ello se multiplica el estado anterior por  $f_t$  y se suma  $i_t * \tilde{C}_t$  para generar los nuevos valores candidatos (4).

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

Por último, se debe determinar qué se mostrará en la salida y esto se basará en el estado final de la celda además de que será una versión filtrada de esta; para ello lo primero es utilizar una capa sigmoide para determinar que partes del estado obtenido se utilizan  $o_t$  (5), posteriormente este estado se coloca en la celda  $\tanh$  y es multiplicado por la salida sigmoide  $C_t$  (6).

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

## Gated recurrent unit (GRU)

Otro algoritmo que surgió para resolver el problema del desvanecimiento del gradiente es el presentado y creado por (Cho et al., 2015), este tipo de red neuronal se considera una variante del LSTM pero con una estructura simplificada, ya que no tienen un estado de celda independiente  $C_t$  solo cuentan con un estado oculto  $h_t$  (Figura 4.14). Al igual que las LSTM las GRU usa puertas para controlar el flujo de información, sin embargo, para este tipo de red se utilizan las puertas de actualización y reinicio, que son dos vectores los cuales deciden qué información pasa a la salida; lo especial de estos vectores es que pueden ser entrenados para el almacenamiento de la información

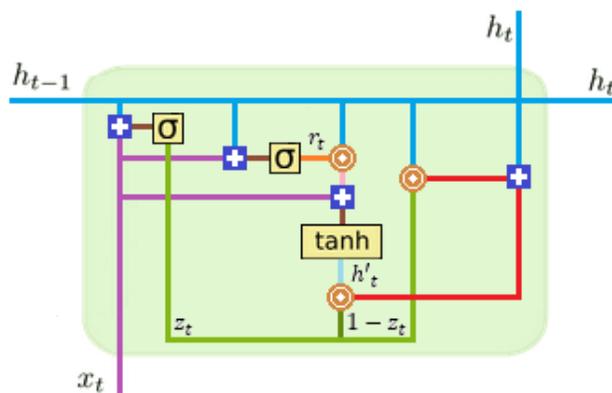


Figura 4.14 Estructura GRU (Cho et al., 2015)

La arquitectura de las GRU mantiene la estructura tipo cadena de las RNN estándar, sin embargo, en cada marca de tiempo  $t$  toma una entrada  $x_t$  y el estado oculto  $h_{t-1}$  de la marca de tiempo anterior, para obtener de salida un nuevo estado oculto  $h_t$  que será la que entre a la siguiente marca de tiempo.

La primera de las puertas es la de actualización  $z_t$ , la cual es la encargada de la memoria a largo plazo, es decir, es la que determina cuanta información pasada será enviada; para realizar este cálculo (7) se toma la entrada  $x_t$  y se multiplica por el peso  $W^{(z)}$ ; de igual forma se multiplica  $h_{t-1}$  el cual contiene la información anterior y se multiplica por su peso  $U^{(z)}$ ; una vez que se tienen ambos resultados, se suman y se les aplica una función de activación sigmoide.

$$z_t = \sigma(W^{(z)}x_t + U^{(z)}h_{t-1}) \quad (7)$$

La siguiente puerta es la de reinicio  $r_t$ , esta es la encargada de la memoria de corto plazo, es decir, es la encargada de decidir cuanta de la información anterior se debe olvidar; para realizar este cálculo (8) se toma la entrada  $x_t$  y se multiplica por el peso  $W^{(r)}$ ; de igual forma se multiplica  $h_{t-1}$  el cual contiene la información anterior y se multiplica por su peso  $U^{(r)}$ ; una vez que se tiene los ambos resultados, se suman y se les aplica una función de activación sigmoide; como se puede observar ambas fórmulas son similares la diferencia entre ellas radica en los pesos.

$$\mathbf{r}_t = \sigma(\mathbf{W}^{(r)}\mathbf{x}_t + \mathbf{U}^{(r)}\mathbf{h}_{t-1}) \quad (8)$$

Siguiendo el diagrama mostrado en la Figura 4.14 el siguiente paso sería el contenido de la memoria actual el cual ayuda a determinar cómo afectan las puertas en el resultado final, para ello se introduce un nuevo contenido de memoria que utilizará la puerta de reinicio para almacenar la información relevante; esto se realiza de la siguiente forma (9), primero se multiplica  $x_t$  por el peso  $W$  luego se multiplica  $h_{t-1}$  por el peso  $U$ ; una vez obtenidos los datos se calcula el producto Hadamard entre la puerta de reinicio  $r_t$  y el resultado de la segunda multiplicación, esto determinará qué información de los datos anteriores será eliminada; por último se suman los resultados de las operaciones anteriores y se aplica una función tanh.

$$\mathbf{h}'_t = \tanh(\mathbf{W}\mathbf{x}_t + \mathbf{r}_t \odot \mathbf{U}\mathbf{h}_{t-1}) \quad (9)$$

Finalmente, se calcula la memoria final en el paso de tiempo actual, para ello se calcula el vector  $h_t$  el cual contiene la información de la unidad actual y la trasfiere a la red, para realizar esta acción se necesita de la compuerta de actualización, la cual determina que se recolectará de la memoria actual  $h_t$  y de las anteriores  $h_{t-1}$ . Para realizar este proceso (10) se calcula el producto Hadamard en conjunto para  $z_t$  y  $h_{t-1}$ ; y conjunto para  $1 - z_t$  y  $h'_t$ . Por último, se suman los resultados obtenidos de las operaciones anteriores.

$$\mathbf{h}_t = z_t \odot \mathbf{h}_{t-1} + (1 - z_t) \odot \mathbf{h}'_t \quad (10)$$

### 4.3. Interfaz web

Esta actividad consistió en desarrollar dos interfaces web, una para la interacción del usuario con el PIE y otra para la interacción con el sistema para la extracción de características; se utilizó HTML y JavaScript para generar la interfaz y la interacción con el lenguaje PYTHON.

La primera interfaz es la encargada de controlar el proceso de inducción emocional y se conforma de la siguiente manera, las pantallas iniciales se enfocan en proporcionar a los usuarios las instrucciones necesarias para colocarlos en un estado mental neutral, en la Figura 4.15 se muestran las pantallas con dichas instrucciones.

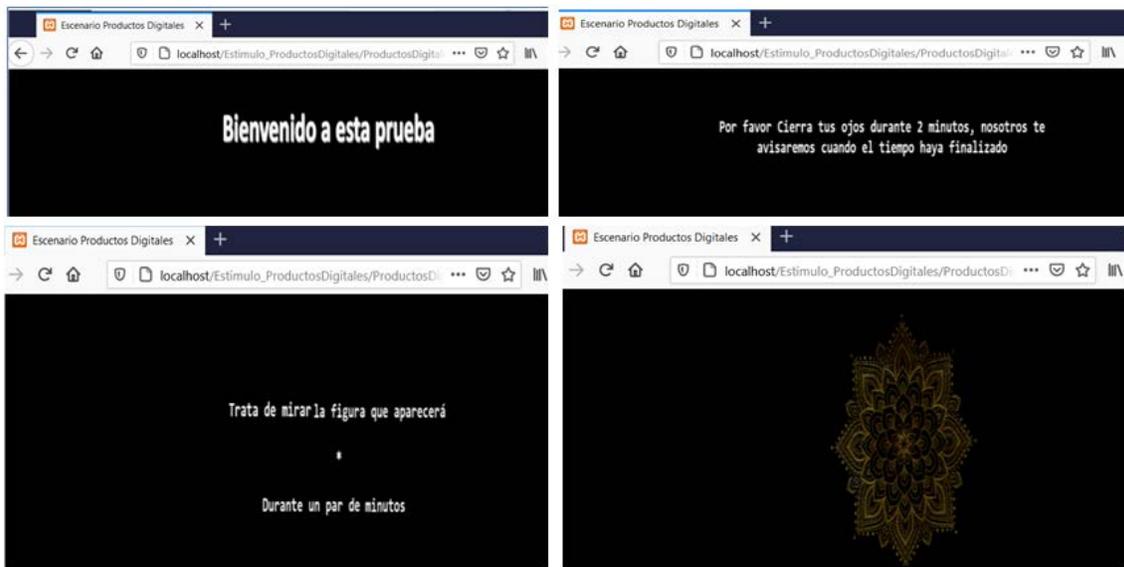


Figura 4.15 Instrucciones iniciales PIE

En la siguiente pantalla se le muestra al usuario una página web con la cual debe interactuar de acuerdo a las instrucciones previas (Figura 4.16), mientras el usuario realiza las actividades el entorno mantiene el control del tiempo de interacción del usuario con el estímulo.

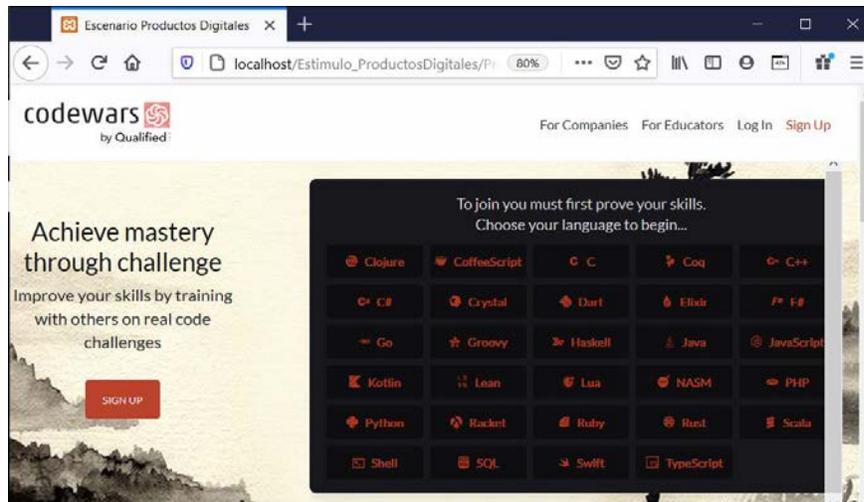


Figura 4.16 Interacción estímulo interactivo (www.codewars.com)

La siguiente pantalla de esta interfaz web (Figura 4.17) es la encargada de proporcionar el momento de descanso entre estímulos y es proyectada antes de iniciar la interacción y posterior a la interacción con la página web, esto se realiza con la finalidad de que el usuario se ubique en un estado mental neutro y darle un momento de descanso para el llenado del cuestionario SAM.

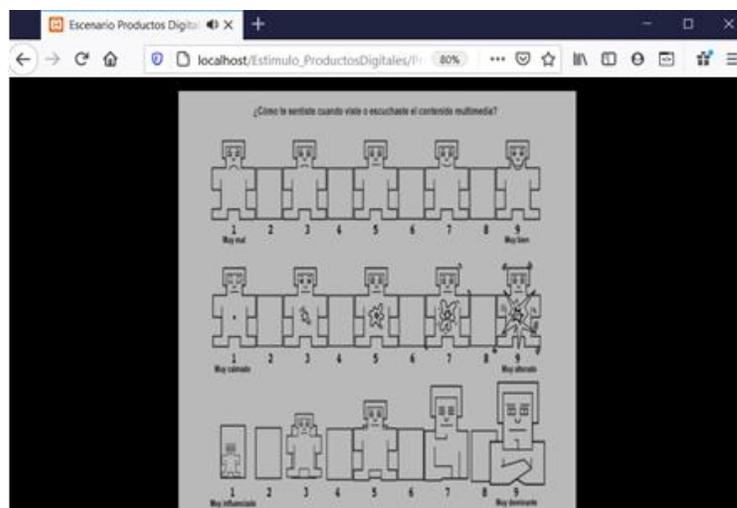


Figura 4.17 Cuestionario SAM

La segunda interfaz permite la interacción del usuario con el módulo de extracción de características. En la Figura 4.18 se muestra la pantalla principal.

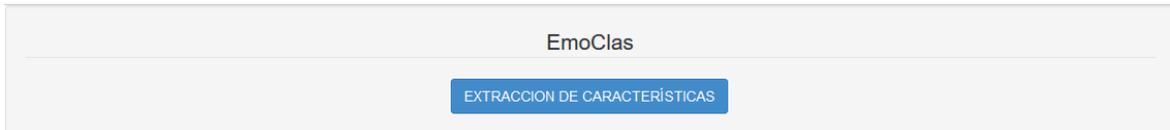


Figura 4.18 Pantalla de inicio

Al seleccionar el botón de extracción de características, aparece la pantalla de la Figura 4.19, en esta pantalla se debe ingresar la ruta de la carpeta que contiene el data set con el cual se trabajará para la extracción de características; en esta pantalla también se seleccionan las señales con las que se trabajará y se ingresan las frecuencias de corte para el filtrado de la señal.

SELECCIÓN DE SEÑAL	FRECUENCIA	FILTRO PASO BANDA LIMITE INFERIOR	FILTRO PASO BANDA LIMITE SUPERIOR
<input type="checkbox"/> EEG	128	4	45
<input type="checkbox"/> ECG	128	2	20
<input type="checkbox"/> GSR	128	0.01	0.2

At the bottom of the form are two buttons: 'SIGUIENTE' (Next) and 'HOME'.

Figura 4.19 Pantalla de selección de datos filtrado

Al dar clic en el botón siguiente nos dirige a la pantalla de la Figura 4.20, en esta pantalla para la señal fisiológica EEG se indican los electrodos utilizados y su ubicación; también muestra las características con las que cuenta cada señal, aquí se deben seleccionar las características que se extraerán para cada señal. Al dar clic en el botón extraer características, se lanza la petición a Python y se inicia con el proceso.

# EXTRACCIÓN DE CARACTERÍSTICAS

Seleccione las características que desee extraer para cada tipo de señal

## ECG

- Ritmo cardiaco
- Derivación estandar del ritmo cardiaco
- HRV
- RMSSD
- SDNN
- Proporción de energía [0,04-0,15]-[0,15-0,5]
- Baja frecuencia [0,01 – 0,08]Hz
- Media frecuencia [0,08 – 0,15]Hz
- Alta frecuencia [0,15 – 0,5]Hz
- Potencia spectral 0-6 HZ
- Espectro poincare

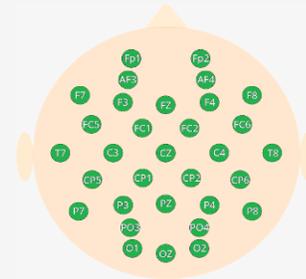
## GSR

- Promedio de resistencia en piel
- Promedio 1er derivada
- Promedio de 1er derivada (valores negativos)
- Proporción de valores negativos
- Número de mínimos locales
- Tiempo promedio de subida de señal
- Densidad espectral de potencia [0 – 0.24]Hz
- Densidad espectral de potencia [0.24 – 0.48]Hz
- Densidad espectral de potencia [0.48 – 0.72]Hz
- Densidad espectral de potencia [0.72 – 0.96]Hz
- Densidad espectral de potencia [0.96 – 1.2]Hz
- Densidad espectral de potencia [1.2 – 1.44]Hz
- Densidad espectral de potencia [1.44 – 1.68]Hz
- Densidad espectral de potencia [1.68 – 1.92]Hz
- Densidad espectral de potencia [1.92 – 2.16]Hz
- Densidad espectral de potencia [2.16 – 2.4]Hz

## EEG

- THETA
- ALPHA
- BETA
- GAMMA
- ASIMETRIA

¡Aviso! Por el momento solo se puede trabajar con los electrodos en color verde



¡Nota! LOS ARCHIVOS DE CARACTERÍSTICAS GENERADOS SE ALMACENARAN EN LA CARPETA DEL DATASET

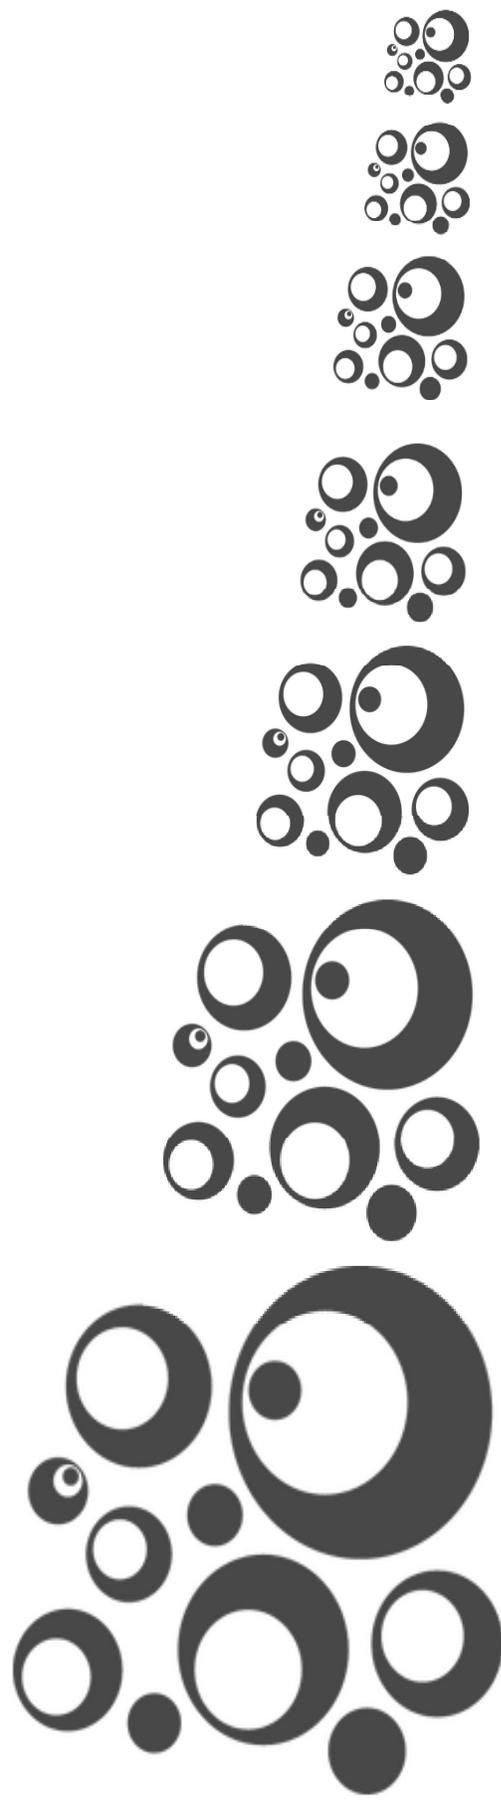
EXTRAER CARACTERÍSTICAS

HOME

Figura 4.20 Pantalla de selección de características

# Capítulo 5

## Resultados



## 5. Resultados

En este capítulo se presentan los resultados obtenidos de la generación del repositorio de señales fisiológica, el algoritmo de clasificación y el resultado de la integración en UXLab.

Se realizaron pruebas con usuarios que cumplieran parte o completamente con las características que deberían tener los usuarios finales, en estas pruebas se realizó el proceso de inducción como lo realizaría un usuario final, con la diferencia de que las actividades de interacción con el estímulo eran diferentes a las del usuario final; con el objetivo de que estas pruebas fueran lo más similares a las finales, también se realizó la instalación de los sensores biométricos y se utilizó el mismo software y hardware. En la Figura 5.1 se muestra un ejemplo de las pruebas realizadas; el algoritmo que utilizaba UXLab para la clasificación de emociones, fue entrenado con los repositorios existente de señales fisiológicas y como se puede observar en la figura los resultados arrojados muestran que el usuario esta aburrido o con sueño, sin embargo al revisar el cuestionario SAM del usuario y preguntarle cómo se sentía durante la evaluación indicaba que estaba muy concentrado y activo; este escenario se repitió con otras pruebas previas, lo cual nos dio muestra de que es necesario tener un adecuado repositorio de datos para realizar el entrenamiento de los algoritmos de clasificación.

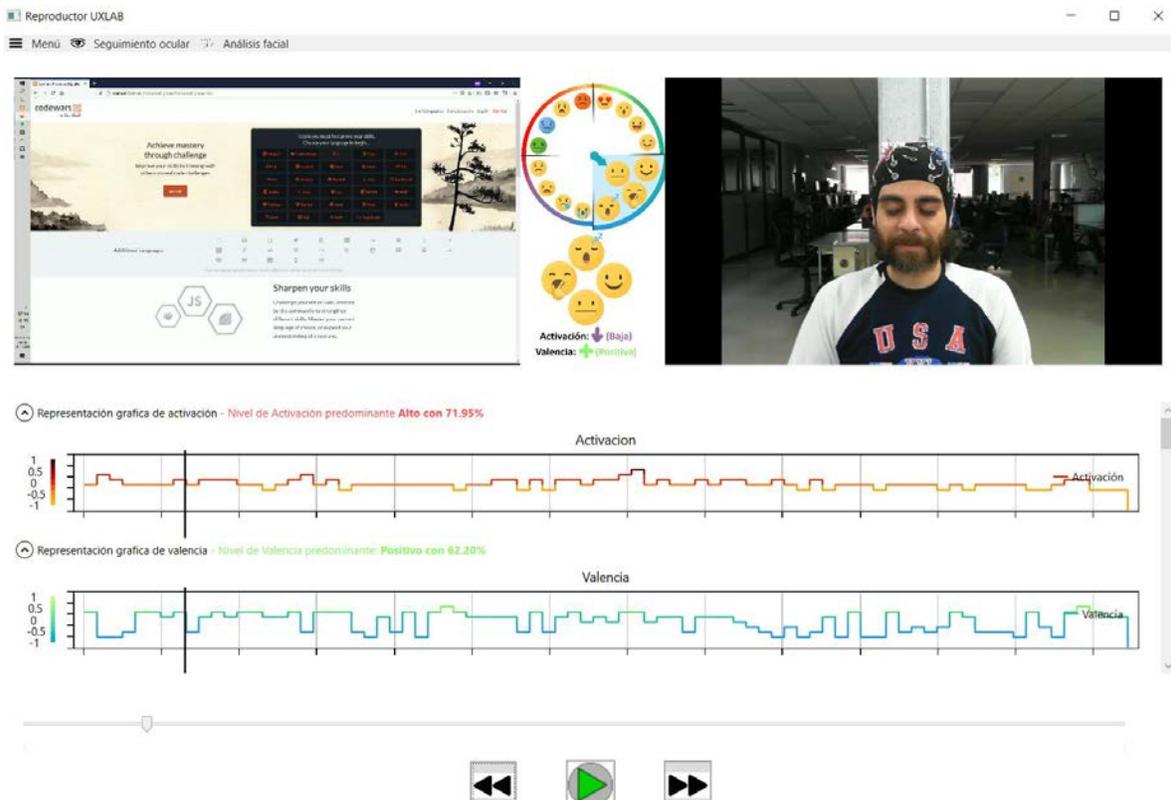


Figura 5.1 Prueba Proceso de inducción emocional

Los resultados obtenidos del proceso de inducción por todos los usuarios fueron en total 526 documentos, los cuales se encuentran conformados por información del usuario, consentimientos, descripciones de actividades, calificación de los usuarios a las actividades y los cuestionarios SAM y PANAS; además se tienen 597 archivos de señales fisiológicas de electroencefalograma, electrocardiograma y respuesta galvánica en piel; adicionalmente se recabó información de seguimiento ocular, video de la pantalla y cámara web.

Para comprobar la confiabilidad de los resultados obtenidos con el instrumento de evaluación SAM se utilizó el alfa de Cronbach (1), este coeficiente permite estimar la fiabilidad de un instrumento utilizado a través de un conjunto de ítems que se espera que midan el mismo producto (Frías-navarro & Valencia, 2019).

(1)

$$\alpha = \frac{K}{K-1} \left[ 1 - \frac{\sum Vi}{Vt} \right]$$

Donde:

- Ítem es el número de páginas evaluadas
- K es el número de ítems
- Vi es la varianza de cada ítem
- $\sum Vi$  es la suma de las varianzas
- Vt = varianza total

Interpretación:

- Si el resultado de  $\alpha$  es mayor a 0.8 el nivel de eficiencia es alto
- Si el resultado de  $\alpha$  se encuentra entre 0.6 y 0.8 el nivel de eficiencia es bueno
- Si el resultado de  $\alpha$  se encuentra entre 0.4 y 0.6 el nivel de eficiencia es moderado
- Si el resultado de  $\alpha$  se encuentra entre 0.2- 0.6 el nivel de eficiencia es bajo
- Si el resultado de  $\alpha$  es menor a 0.2 el nivel de eficiencia es muy bajo

Como se puede observar en la Tabla 5.1 el resultado del coeficiente alfa para valencia es de 0.8688, que dentro de la interpretación de confiabilidad se encuentra en un nivel alto de fiabilidad.

Tabla 5.1 Resultado coeficiente cronbach para valencia

Total	Prezi	Udemy	Edx	Aliexpres	Liverpool	DDTech	Elsevier	Amazon	IMSS	Nintendo	Computicali	Cenidet	Pullman	Walmart	Paekt	Codewars	varianza
122	4	4	9	7	9	9	9	9	4	4	9	9	9	9	8	7	4.8064
71	4	4	4	4	3	7	7	6	2	3	3	5	3	5	3	5	4.8064
132	7	9	9	8	9	8	9	9	7	8	8	9	8	9	7	8	3.04
79	7	9	7	7	9	7	5	7	3	4	1	1	1	1	5	3	3.2736
89	8	8	8	5	8	9	9	8	1	2	1	5	5	4	4	4	3.8656
86	8	8	8	6	7	5	7	8	1	3	2	4	3	5	5	6	4.0896
89	5	7	6	6	5	6	7	7	6	3	4	5	6	4	7	5	2.1536
93	7	7	5	5	3	7	7	3	5	8	7	5	4	6	5	7	4.0896
89	6	5	7	3	5	5	5	5	5	8	5	7	5	6	6	3	3.8656
93	7	7	5	5	7	7	7	8	5	8	7	5	4	6	7	3	4.0896
89	6	5	7	3	5	5	5	7	5	8	5	7	5	6	7	5	2.1536
122	8	9	8	8	9	9	8	8	6	8	8	7	4	8	6	8	4.8064
101	9	9	7	7	5	8	9	8	1	3	3	7	7	9	7	4	3.04
65	1	7	5	5	6	5	5	7	2	4	2	5	1	7	2	2	3.2736
88	9	8	7	7	3	8	9	1	3	2	3	7	3	7	6	7	4.8064
93	7	7	5	5	7	7	7	7	4	5	3	5	7	7	5	5	3.8656
90	4	8	7	7	6	8	8	7	5	5	6	7	2	2	3	4	4.0896
57	1	7	2	2	2	4	6	8	1	3	2	3	5	8	1	1	2.1536
97	5	9	5	4	8	8	8	7	3	8	1	8	8	8	3	8	4.8064
80	3	7	3	3	4	4	4	4	4	5	6	7	6	5	5	6	3.04
79	3	7	5	5	6	7	5	6	3	5	4	3	4	7	4	5	4.0896
107	5	5	7	7	9	7	9	9	9	5	3	9	7	9	9	9	3.8656
76	4	5	5	5	5	5	5	5	3	5	5	5	5	3	7	5	4.0896
64	7	2	2	2	3	6	7	3	2	3	7	5	3	6	2	2	2.1536
87	4	5	5	6	8	8	7	9	4	7	2	3	3	5	7	4	4.0896
79	5	7	4	4	3	6	6	5	5	5	4	5	4	5	5	6	3.04
71	5	5	5	4	6	5	5	5	4	4	2	4	4	4	4	3	3.8656
2.7904																	2.7904

Alfa	0.8688
K(#item)	16.000
suma Vi (varianza ítem)	59.469
Vt(Varianza total)	320.582

Como se puede observar en la Tabla 5.2 el resultado del coeficiente alfa para activación es de 0.8868, que dentro de la interpretación de confiabilidad se encuentra en un nivel alto de fiabilidad.

Tabla 5.2 Resultado coeficiente cronbach para activación

Codevars	Packt	Walmart	Pullman	Cenidet	Computali	Nintendo	IMSS	Amazon	Elsevier	DDTech	Liverpool	Aliexpres	Edx	Udemy	Prezi	Total	varianza
7	1	1	1	1	3	3	7	1	1	1	1	3	5	3	7	46	
5	7	5	6	6	5	6	7	4	7	3	3	6	7	8	8	93	
3	1	2	1	2	2	5	5	2	1	2	1	2	1	2	2	34	
9	3	1	9	3	8	9	7	3	5	7	9	3	5	9	7	97	
9	9	3	5	6	2	1	1	7	8	9	9	3	4	6	7	89	
6	5	5	7	3	7	3	4	5	7	6	7	6	4	7	7	89	
7	5	5	4	6	4	4	4	6	6	6	7	6	6	4	6	86	
1	1	5	6	3	5	6	5	5	5	6	7	6	5	6	6	78	
6	3	1	5	5	5	3	6	3	6	4	3	7	5	4	5	71	
6	5	8	3	7	8	8	6	8	8	9	9	8	8	9	8	118	
5	5	9	5	5	5	4	7	7	7	7	5	5	7	5	7	95	
7	5	6	6	7	3	5	5	6	4	3	3	5	6	5	7	83	
3	6	2	5	3	6	8	7	7	4	7	3	7	4	3	2	77	
5	1	5	5	3	1	3	1	5	3	5	3	5	3	5	5	58	
5	5	7	7	3	2	7	5	3	3	2	1	7	8	7	4	76	
3	2	9	7	5	7	7	9	5	8	9	9	5	7	5	8	105	
3	4	2	1	5	8	7	5	8	9	9	9	9	9	9	7	104	
6	5	6	5	5	6	5	6	5	5	4	6	5	5	5	6	85	
3	3	5	6	6	6	3	7	6	4	6	6	7	7	7	6	88	
7	3	1	5	3	7	7	1	1	3	1	3	5	7	7	9	70	
3	3	3	3	3	3	3	7	3	3	3	3	3	3	3	3	52	
3	6	5	3	4	7	7	7	6	7	7	7	7	7	5	3	91	
3	1	5	2	3	5	7	7	2	2	2	2	6	7	2	3	59	
4	5	6	3	5	4	6	5	6	5	6	7	7	4	7	5	85	
3	4	5	4	4	3	4	4	6	5	6	6	7	5	5	4	75	
4.1856	4.1536	5.6096	4.0864	2.4224	4.2656	4.1024	4.08	4.08	4.8384	6.32	7.4944	2.96	3.3664	4.1696	3.8176		
										Alfa	0.8591						
										K(#ítem)	16.0						
										suma Vi(varianza ítem)	70.0						
										Vt(Varianza total)	359.4						

Como se puede observar en la Tabla 5.3 el resultado del coeficiente alfa para dominio es de 0.8383, que dentro de la interpretación de confiabilidad se encuentra en un nivel alto de fiabilidad.

Tabla 5.3 Resultado coeficiente cronbach para dominio

CodeWars	Packet	Walmart	Pullman	Cenidet	Compucaali	Nintendo	IMSS	Amazon	Elsevier	DDTech	Liverpool	Aliexpres	Edx	Udemy	Prezi	Total	varianza
6	9	9	9	9	7	3	2	9	9	9	9	6	7	9	4	116	
5	3	5	5	7	4	6	8	3	5	5	5	6	7	6	6	86	
7	9	9	9	9	7	8	7	9	8	7	9	8	9	9	7	131	
5	7	5	1	3	7	9	7	7	5	7	3	5	5	5	3	84	
9	9	9	7	7	5	3	5	7	8	9	9	3	5	7	8	110	
5	5	5	4	3	3	6	3	6	3	6	7	6	3	7	6	78	
6	7	4	5	7	4	5	6	7	6	7	5	4	4	6	4	87	
5	7	7	7	5	5	6	5	6	5	5	5	5	6	5	4	88	
4	8	9	5	4	5	5	4	5	4	5	5	4	5	5	5	82	
5	5	8	4	7	8	8	5	8	8	9	9	6	8	9	7	114	
7	5	1	5	5	5	4	7	5	5	3	7	5	5	5	5	79	
7	5	9	7	7	6	7	5	7	3	9	5	5	6	5	5	98	
7	4	8	3	7	6	2	4	3	7	2	5	7	3	7	6	81	
5	9	5	5	5	5	5	3	5	5	7	5	5	7	5	5	86	
3	3	7	8	7	5	5	6	6	6	3	2	6	7	5	5	84	
5	3	8	8	3	2	6	8	5	7	9	3	2	3	5	7	84	
5	7	8	9	9	3	9	5	8	8	8	8	5	8	9	4	113	
5	6	6	6	7	7	5	4	7	5	7	5	7	6	6	5	94	
3	5	5	4	3	4	4	3	5	5	4	4	3	6	4	3	65	
3	9	7	3	5	9	9	1	5	5	5	5	3	5	7	9	90	
5	5	5	5	7	7	7	5	5	3	7	5	4	5	4	3	82	
6	3	5	7	5	7	6	3	6	5	7	8	5	7	4	6	90	
7	9	9	9	5	2	7	3	9	7	6	8	6	7	2	3	99	
4	5	5	4	5	4	6	5	6	5	6	7	4	5	7	5	83	
3	4	3	3	4	4	4	3	3	5	3	3	3	5	5	4	59	
2.2016	4.5184	4.5664	4.7776	3.44	3.2224	3.52	3.2576	2.9536	2.6976	4.24	4.2944	2.0736	2.4224	3.1136	2.4544		
																Alfa	0.8383
																K(#item)	16.0
																suma Vi(varianza ítem)	53.8
																Vt(Varianza total)	251.1

Se realizó la validación del análisis estadístico utilizando el enfoque experimental de Wohlin, extrayendo los datos obtenidos de los cuestionarios SAM llenados por los sujetos de prueba durante la evaluación de las páginas web, esto con el propósito de identificar que tanto influye el grupo generacional, sexo y expertis en la valencia, activación y dominio que experimentan los usuarios durante la evaluación; adicional se utilizaron los datos recabados de los cuestionarios iniciales aplicados a los sujetos de prueba.

#### Ideas

1. El diseño de la página web impacta en los niveles de activación, valencia y dominio de los sujetos de prueba
2. El expertis del sujeto de prueba impacta en sus niveles de activación, valencia y dominio
3. El sexo del sujeto de prueba impacta en sus niveles de activación, valencia y dominio
4. El grupo generacional del sujeto de prueba impacta en sus niveles de activación, valencia y dominio
5. Existe una correlación entre activación y valencia, activación y dominio, valencia y dominio

#### Datos del estudio

- Población/Universo: población mexicana
- Población de interés: personas en México que tengan conocimiento en el uso de páginas web
- Población investigada: personas con edad mayor o igual a 15 años y menor a 50 años en México
- Muestra a analizar: personas con nivel educativo mayor o igual a medio superior documentados en los cuestionarios aplicados a los usuarios, dicha clasificación fue tomada de acuerdo a la Clasificación Internacional Normalizada de la Educación por sus siglas C.I.N.E. (unesco, 2013)

## Variables para el estudio

- Sexo: sexo del sujeto de prueba Mujer/Hombre
- Grupo generacional: son 3 grupos, personas con edad menor o igual a 20 años pertenecen al grupo 1, personas entre 21 y 30 años pertenecen al grupo 2 y personas mayores de 31 años pertenecen al grupo 3
- Diseño: buen o mal diseño tomado de la clasificación de las heurísticas de Jacob Nielsen
- Expertis: si los sujetos de prueba han utilizado las páginas varias veces en el año
- Valencia: es un rango de emociones que va desde muy desagradable 1 hasta agradable 9
- Activación: se refiere al nivel de intensidad de las emociones y va desde calmado 1 hasta muy activo 9
- Dominio: se refiere a que tan controlado o influenciado se ve por la emoción y va de muy influenciado 1 hasta muy dominante 9.

Selección de sujetos: Casos que cumplan las características solicitadas para las pruebas.

- El sujeto de pruebas debe estar dentro del rango de edad (15 a 50)
- Tener o estar en un nivel educativo mínimo de preparatoria
- Tener noción del uso de páginas web

El grupo de pruebas con el que se trabajó fueron o son estudiantes del Centro Nacional de Investigación y Desarrollo Tecnológico

Diseño del experimento: es cuasi experimental porque no se tiene una muestra muy grande ni aleatoria.

Instrumentos: Formulario de captura de datos (Cuestionario conociendo al usuario, SAM)

Validez: Interna.

Descripción de la data set generada de los cuestionarios seleccionados: el data set contiene los datos registrados por el sujeto de prueba en el cuestionario SAM, los cuales están descritos de acuerdo a los niveles de: valencia, activación y dominio para las 16 páginas web seleccionadas; adicionalmente se cuenta con la información sobre la clasificación de las páginas, es decir, la clasificación de acuerdo a un buen o mal diseño; el sexo, grupo generacional y expertis de los sujetos de prueba, así como los nombres de las páginas.

El análisis de estos datos se realizó por medio de una serie de pruebas que se describen a continuación:

**Normalidad:** se utiliza para determinar si un conjunto de datos está bien modelado por una distribución normal y se realiza por medio de la prueba de saphiro.

**Prueba F:** se utiliza para comprobar el supuesto de homogeneidad de varianzas o supuesto de homocedasticidad, esta prueba contrasta la hipótesis nula de que dos poblaciones normales tienen la misma varianza y se aplica a poblaciones que tienen una distribución normal.

**Prueba T:** es aplicada para identificar si la variable tomada es significativa para el estudio.

**$\chi^2$  de Pearson:** se aplica sobre dos variables y saber si dos características son independientes o tienen una asociación.

**Kruskal Wallis:** también conocido como test H, es un método no paramétrico para probar si un grupo de datos proviene de la misma población. No asume normalidad en los datos. Es una prueba que emplea rangos para contrastar la hipótesis de que k muestras han sido obtenidas de una misma población.

**Prueba U:** efectúa una comparación estadística de la media y determina si existe una diferencia entre la variable dependiente y los grupos independientes, con el objetivo de mostrar si la distribución de la variable dependiente es la misma para los grupos.

Se aplica inicialmente la validación de Normalidad al conjunto completo de datos, donde se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es aceptada dando como resultado una distribución normal.

H0: La muestra proviene de una distribución normal.

H1: La muestra no proviene de una distribución normal.

La prueba de saphiro se aplica para la validación de normalidad y se realiza de forma individual a las columnas de valencia activación y dominio dando como resultado los siguientes datos:

Tabla 5.4 Prueba saphiro para el conjunto valencia, activación y dominio de los datos completos

Variables	Val	Act	Dom
w	0.93419	0.95072	0.9387
p-value	1.749e-08	6.33e-07	4.394e-0.8

Como se puede observar en la Tabla 5.4 el resultado de p-value para valencia es de 1.749e-08, para activación es de 6.33e-07 y para dominio es de 4.394e-08; en los 3 casos los resultados son menores que el alfa 0.05, por tanto, la hipótesis nula es aceptada y nos dice que la muestra tiene una distribución normal.

Una vez que se encuentra validada la normalidad de los campos se procede a realizar la comprobación de las ideas de arriba.

**Comprobación idea uno:** el diseño de la página web impacta en los niveles de activación, valencia y dominio de los sujetos de prueba.

Para realizar la comprobación de la idea lo primero que se debe realizar es el agrupamiento de los datos, para ello se toman los datos de la columna "Disenio" y se crean 2 subconjuntos, los que tienen buen diseño y los que tienen mal diseño.

Por tanto, es necesario aplicar nuevamente la prueba de saphiro para validar la normalidad de los nuevos subconjuntos.

Tabla 5.5 Pruebas saphiro para las columnas valencia, activación y dominio de los subconjuntos de datos de disenio

Variables	w	p-value
Val-GDiseño	0.93433	7.579e-08
Val-BDiseño	0.95705	9.615e-06
Act-GDiseño	0.95082	2.264e-06
Act-BDiseño	0.95293	3.651e-06
Dom-GDiseño	0.95082	2.264e-06
Dom-BDiseño	0.94453	5.804e-07

Como se puede observar en la Tabla 5.5 el resultado de p-value para valencia del subconjunto de buen diseño es de 7.579e-08, para valencia del subconjunto de mal diseño es de 7.579e-08, para activación del subconjunto de buen diseño es de 2.264e-06, para activación del subconjunto de mal diseño es de 2.264e-06, para dominio del subconjunto de buen diseño es de 2.264e-06 y para dominio del subconjunto de mal diseño es de 5.804e-07; en todos los casos los resultados son menores que el alfa 0.05, por tanto, la hipótesis nula es aceptada y nos dice que la muestra tiene una distribución normal.

Una vez que se encuentra validada la normalidad de los campos se procede a realizar la prueba F, para ello se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es rechazada.

H0: La muestra no encontró diferencias significativas entre las varianzas.

H1: La muestra encontró diferencias significativas entre las varianzas.

La prueba F se aplica utilizando los datos de los subconjuntos creados para compararlos, es decir, las valencias obtenidas en las páginas con buen diseño contra las valencias obtenidas en las páginas con un mal diseño, como se puede observar en la Tabla 5.6 en la comparación de los subconjuntos con valencia el resultado es de 0.395, para los subconjuntos con activación es de 0.5459 y para los subconjuntos con dominio es de 0.1416; en los tres casos los resultados de p-value son mayores que el alfa 0.05, por tanto, la hipótesis nula es aceptada y nos dice que no se encontraron diferencias significativas entre las varianzas de los grupos.

Tabla 5.6 Prueba F para los subconjuntos de diseño

Variables	F	Num df	p-value
Val GDiseño-Val BDiseño	0.88623	199	0.395
Act GDiseño-Act BDiseño	1.0895	199	0.5459
Dom GDiseño-Dom BDiseño	0.81153	199	0.1416

A continuación, se realiza la prueba T para identificar si la variable tomada es significativa; dado que la prueba se enfoca en la valencia, activación y dominio, la variable que se verificará su significancia respecto a las otras es el diseño. Para aplicar esta prueba se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es rechazada.

H0: no hay diferencia entre las medias poblacionales

H1: si hay diferencia entre las medias poblacionales

La prueba T se aplica de forma conjunta para valencia-diseño, activación-diseño, dominio-diseño, en la Tabla 5.7 se observa un p-value de 8.915e-12 con valencia-diseño este resultado es menor que el alfa 0.05, por tanto, se dispone de evidencia para considerar que existe una diferencia entre los resultados de la valencia y las páginas con buen diseño o mal diseño.

En la Tabla 5.7 se observa un p-value de 0.003845 con activación-diseño y de 0.6925 para dominio-diseño, para los dos casos el resultado es mayor que el alfa 0.05, por tanto, no se dispone de evidencia para considerar que existe una diferencia entre los resultados de la activación y dominio con las páginas ya sea que tengan buen diseño o mal diseño.

Tabla 5.7 Prueba T en las variables valencia-diseño, activación-diseño y dominio-diseño

Variabes	Val-Diseño	Act-Diseño	Dom-Diseño
T	7.0329	2.9077	0.39574
df	396.56	397.27	393.74
p-value	8.915e-12	0.003845	0.6925

A continuación, se realiza la prueba  $\chi^2$  de Pearson la cual se aplica sobre dos variables para saber si dos características son independientes o tienen una asociación, dado que la prueba se enfoca en la valencia, activación y dominio, la variable que se verificará su dependencia respecto a las otras es el diseño. Para aplicar esta prueba se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es rechazada.

H0: Las variables no son dependientes.

H1: Las variables son dependientes.

La prueba  $\chi^2$  de Pearson se aplica de forma conjunta para valencia-diseño, activación-diseño, dominio-diseño, en la Tabla 5.8 se observa un p-value de 1.146e-07 con valencia-diseño, este resultado es menor que el nivel de significancia  $\alpha$  (alfa) de 0.05, por lo tanto, podemos decir que las variables son dependientes.

En la Tabla 5.8 se observa un p-value de 0.08789 con dominio-diseño y de 0.4124 para activación-diseño, para los dos casos el resultado es mayor que el nivel de significancia alfa de 0.05, por tanto, podemos decir que las variables son independientes.

Tabla 5.8 Prueba  $\chi^2$  en las variables valencia-diseño, activación-diseño y dominio-diseño

Variables	Val-Diseño	Act-Diseño	Dom-Diseño
X-squared	47.663	13.773	8.2188
df	8	8	8
p-value	1.146e-07	0.08789	0.4124

A continuación, se realiza la prueba Kruskal Wallis, también conocido como test H, la cual es la alternativa no paramétrica al test AnOVA de una vía para datos no igualados. Es un test que emplea rangos para contrastar la hipótesis de que k muestras han sido obtenidas de una misma población. Bajo ciertas simplificaciones puede considerarse que el test de Kruskal-Wallis compara las medianas.

Se estableció un nivel de significancia de  $\alpha$  de 0.05. Para ser aceptada o rechazada una hipótesis se evalúa el p-value resultante, si este es menor al  $\alpha$  la H0 se rechaza y se acepta la H1.

H0: Todas las muestras provienen de la misma población

H1: Al menos una muestra no proviene de la misma población

En la Tabla 5.9 se observa un p-value de 1.207e-07 con Val-diseño, para este caso el resultado es menor que el nivel de significancia alfa de 0.05, por tanto, podemos decir que esta muestra proviene de una población con una distribución distinta, es decir, la clasificación de las páginas web evaluadas varían su Valencia en base a su buen o mal diseño.

Tabla 5.9 Prueba KRUSKAL-WALLIS en las variables val-diseño, act-diseño y dom-diseño

Variables	Val-Diseño	Act-Diseño	Dom-Diseño
Kruskal-Wallis	47.544	13.738	8.1982
df	8	8	8
p-value	1.207e-07	0.08885	0.4144

A continuación, se realiza la prueba U, la cual realiza una comparación estadística de la media y determina si existe una diferencia entre la variable dependiente y los grupos independientes. De esta forma, puede mostrar si la distribución de la variable dependiente es la misma para los grupos.

Se estableció un nivel de significancia de  $\alpha$  de 0.05. Para ser aceptada o rechazada una hipótesis se evalúa el p-value resultante, si este es menor al  $\alpha$  la H0 se rechaza y se acepta la H1

H0: Las muestras comparadas provienen de la misma población

H1: Las muestras comparadas no provienen de la misma población

En la Tabla 5.10 se observa un p-value de 2.134e-11 con Val\_GDiseño-Val\_BDiseño y de 0.003615 para Act\_GDiseño-Act\_BDiseño, para los dos casos el resultado es menor que el nivel de significancia alfa de 0.05, por tanto, podemos decir que las variables no provienen de la misma población, es decir, existe una diferencia entre la Valencia y la activación de las páginas web que tienen buen diseño y las que tienen mal diseño.

Tabla 5.10 Prueba U para los subconjuntos de buen y mal diseño con las variables val, act, dom

Variables	W	p-value
Val_GDiseño-Val_BDiseño	27654	2.134e-11
Act_GDiseño-Act_BDiseño	23325	0.003615
Dom_GDiseño-Dom_BDiseño	20525	0.6438

Analizando la información obtenida de las pruebas realizadas para el subconjunto de diseño, se llegó a la conclusión de que el tipo de diseño tiene impacto sobre las variables valencia y activación; y una dependencia sobre la variable valencia.

Estas pruebas realizaron con este grupo se repitieron de igual forma para los grupos de las variables expertis, sexo y grupo generacional.

**Comprobación idea 2:** El expertis del sujeto de prueba impacta en sus niveles de activación, valencia y dominio.

Para realizar la comprobación de la idea lo primero que se debe realizar es el agrupamiento de los datos, para ello se toman los datos de la columna "expertis" y se crean 2 subconjuntos, los que tienen y no tienen experiencia de acuerdo a los datos proporcionados.

Es necesario aplicar nuevamente la prueba de saphiro para validar la normalidad de los nuevos subconjuntos.

Como se puede observar en la Tabla 5.11 el resultado de p-value para valencia del subconjunto con experiencia es de 1.548e-07, para valencia del subconjunto sin expertis es de 2.864e-05, para activación del subconjunto con expertis es de 1.061e-06, para activación del subconjunto sin expertis es de 6.364e-06, para dominio del subconjunto con expertis es de 8.356e-08 y para dominio del subconjunto sin expertis es de 4.596e-06 en todos los casos los resultados son menores que el alfa 0.05, por tanto, la hipótesis nula es aceptada y nos dice que la muestra tiene una distribución normal.

Tabla 5.11 Pruebas saphiro para las columnas valencia, activación y dominio de los subconjuntos de datos de experiencia

Variables	w	p-value
Val-ConExp	0.94529	1.548e-07
Val-SinExp	0.95574	2.864e-05
Act-ConExp	0.95349	1.061e-06
Act-SinExp	0.94861	6.364e-06
Dom-ConExp	0.9425	8.356e-08
Dom-SinExp	0.947	4.596e-06

Una vez que se encuentra validada la normalidad de los campos se procede a realizar la prueba F, para ello se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es rechazada.

H0: La muestra no encontró diferencias significativas entre las varianzas.

H1: La muestra encontró diferencias significativas entre las varianzas.

La prueba F se aplica utilizando los datos de los subconjuntos creados para compararlos, es decir, las valencias obtenidas con los usuarios que tienen expertis contra las valencias obtenidas con los usuarios que no tienen expertis, como se puede observar en la Tabla 5.12, en la comparación de los subconjuntos con valencia el resultado es de 0.906, para los subconjuntos con activación es de 0.7923 y para los subconjuntos con dominio es de 0.7526; en los tres casos los resultados de p-value son mayores que el alfa 0.05, por tanto, la hipótesis nula es aceptada y nos dice no encontraron diferencias significativas entre las varianzas de los grupos.

Tabla 5.12 Prueba F para los subconjuntos de experiencia

Variables	F	Num df	p-value
Val ConExp-Val SinExp	1.018	226	0.906
Act ConExp-Act SinExp	0.96389	226	0.7923
Dom ConExp-Dom SinExp	1.0472	226	0.7526

A continuación, se realiza la prueba T para identificar si la variable tomada es significativa; dado que la prueba se enfoca en la valencia, activación y dominio, la variable que se verificará su significancia respecto a las otras es el expertis. Para aplicar esta prueba se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es rechazada.

H0: No hay diferencia entre las medias poblacionales

H1: Si hay diferencia entre las medias poblacionales

La prueba T, se aplica de forma conjunta para valencia-expertis, activación-expertis, dominio-expertis. En la Tabla 5.13, para el subconjunto valencia-expertis se observa un p-value de 0.0001726 y para el subconjunto de dominio-expertis un p-value de 0.01916, ambos resultados son menores que el alfa 0.05, por tanto, se dispone de evidencia para considerar

que existe una diferencia entre los resultados obtenidos de la valencia y del dominio de acuerdo al expertis del usuario.

En la Tabla 5.13, se observa un p-value de 0.07344 en el subconjunto de activación-expertis, para este caso el resultado es mayor que el alfa 0.05, por tanto, no se dispone de evidencia para considerar que existe una diferencia entre los resultados de la activación con las páginas, ya sea que tengan o no expertis en el uso de páginas web mostradas.

Tabla 5.13 Prueba T en las variables valencia-exp, activación-exp y dominio-exp

Variables	Val-Exp	Act-Exp	Dom-Exp
T	-3.7945	1.7953	-2.3526
df	372	366.85	374.54
p-value	0.0001726	0.07344	0.01916

A continuación, se realiza la prueba  $\chi^2$  de Pearson, esta se aplica sobre dos variables para saber si dos características son independientes o tienen una asociación, dado que la prueba se enfoca en la valencia, activación y dominio, la variable que se verificará su dependencia respecto a las otras es el expertis. Para aplicar esta prueba se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es rechazada.

H0: Las variables no son dependientes.

H1: Las variables son dependientes.

La prueba  $\chi^2$  de Pearson se aplica de forma conjunta para valencia-expertis, activación-expertis, dominio-expertis. En la Tabla 5.14 se observa un p-value de 0.116 para el subconjunto de valencia-expertis, para activación-expertis de 0.6637 y para el subconjunto de dominio-expertis de 0.8046, en todos los casos el resultado es mayor que el nivel de significancia de alfa de 0.05, por tanto, la hipótesis nula es aceptada, lo cual nos indica que las variables son independientes.

Tabla 5.14 Prueba  $\chi^2$  en las variables valencia-exp, activación-exp, dominio-exp

Variables	Val-Exp	Act-Exp	Dom-Exp
X-squared	17.911	5.8526	4.5484
df	8	8	8
p-value	0.116	0.6637	0.8046

A continuación, se realiza la prueba Kruskal Wallis, también conocido como test H, la cual es la alternativa no paramétrica al test Anova de una vía para datos no igualados. Es un test que emplea rangos para contrastar la hipótesis de que k muestras han sido obtenidas de una misma población. Bajo ciertas simplificaciones puede considerarse que el test de Kruskal-Wallis compara las medianas.

Se estableció un nivel de significancia de  $\alpha$  de 0.05. Para ser aceptada o rechazada una hipótesis se evalúa el p-value resultante, si este es menor al  $\alpha$  la H0 se rechaza y se acepta la H1.

H0: Todas las muestras provienen de la misma población

H1: Al menos una muestra no proviene de la misma población

En la Tabla 5.15 se observa un p-value de 0.02225 con Val-Exp, para este caso el resultado es menor que el nivel de significancia alfa de 0.05, por tanto, podemos decir que esta muestra proviene de una población con una distribución distinta, es decir, la clasificación de las páginas web evaluadas varían su Valencia en base al expertis que tenga el usuario

Tabla 5.15 Prueba KRUSKAL-WALLIS en las variables valencia-exp, activación-exp y dominio-exp

Variables	Val-Exp	Act- Exp	Dom- Exp
Kruskal-Wallis	17.866	13.563	8.8162
df	8	8	8
p-value	0.02225	0.09388	0.358

A continuación, se realiza la prueba U, la cual realiza una comparación estadística de la media y determina si existe una diferencia entre la variable dependiente y los grupos independientes. De esta forma, puede mostrar si la distribución de la variable dependiente es la misma para los grupos.

Se estableció un nivel de significancia de  $\alpha$  de 0.05. Para ser aceptada o rechazada una hipótesis se evalúa el p-value resultante, si este es menor al  $\alpha$  la H0 se rechaza y se acepta la H1.

H0: Las muestras comparadas provienen de la misma población

H1: Las muestras comparadas no provienen de la misma población

En la Tabla 5.16 se observa un p-value de 0.0001785 con Val\_ConExp-Val\_SinExp y de 0.02688 para Dom\_ConExp-Dom\_SinExp, para los dos casos el resultado es menor que el nivel de significancia alfa de 0.05, por tanto, podemos decir que las variables no provienen de la misma población, es decir, existe una diferencia entre la Valencia y el dominio de las páginas web cuando se tiene experiencia en el uso de ellas.

Tabla 5.16 Prueba U para los subconjuntos con y sin experiencia con las variables val, act, dom

Variables	W	p-value
Val_ConExp-Val_SinExp	15391	0.0001785
Act_ConExp-Act_SinExp	21546	0.09163
Dom_ConExp-Dom_SinExp	17148	0.02688

Analizando la información obtenida de las pruebas realizadas para el subconjunto de expertis, se llegó a la conclusión de que el expertis del sujeto de prueba tiene impacto sobre las variables valencia y dominio; y una dependencia sobre la variable valencia.

**Comprobación idea 3:** El sexo del sujeto de prueba impacta en sus niveles de activación, valencia y dominio

Para realizar la comprobación de la idea lo primero que se debe realizar es el agrupamiento de los datos, para ello se toman los datos de la columna “sexo” y se crean 2 nuevos subconjuntos. Es necesario aplicar nuevamente la prueba de saphiro para validar la normalidad de los nuevos subconjuntos.

Como se puede observar en la Tabla 5.17, el resultado de p-value para valencia del subconjunto Data\_H es de 1.479e-08, para valencia del subconjunto Data\_M es de 0.000121, para activación del subconjunto Data\_H es de 6.98e-08, para activación del subconjunto Data\_M es de 0.000295, para dominio del subconjunto Data\_H es de 7.419e-08 y para dominio del subconjunto Data\_M es de 2.053e-07, en los 6 casos los resultados son menores que el alfa 0.05, por tanto, la hipótesis nula es aceptada y nos dice que la muestra tiene una distribución normal.

Tabla 5.17 Pruebas saphiro para las columnas valencia, activación y dominio de los subconjuntos de datos de sexo

Variables	w	p-value
Val-Hombre	0.94508	1.479e-08
Val-Mujer	0.94964	0.000121
Act-Hombre	0.95124	6.98e-08
Act-Mujer	0.95464	0.000295
Dom-Hombre	0.95148	7.419e-08
Dom-Mujer	0.90641	2.053e-07

Una vez que se encuentra validada la normalidad de los campos se procede a realizar la prueba F, para ello se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es rechazada.

H0: La muestra no encontró diferencias significativas entre las varianzas.

H1: La muestra encontró diferencias significativas entre las varianzas.

La prueba F se aplica utilizando los datos de los subconjuntos creados para compararlos, es decir las valencias obtenidas con los usuarios de sexo masculino contra las valencias obtenidas con los usuarios de sexo femenino.

Como se puede observar en la Tabla 5.18, con las comparaciones para los subconjuntos de activación es de 0.9316 y para los subconjuntos de dominio es de 0.7795. En los 2 casos los resultados de p-value son mayores que el alfa 0.05, por tanto, la hipótesis nula es aceptada, lo cual nos indica que no se encontraron diferencias significativas entre las varianzas de los grupos.

Tabla 5.18 Prueba F para los subconjuntos de sexo

Variables	F	Num df	p-value
Val(Hombre-Mujer)	1.3758	271	0.04199
Act(Hombre-Mujer)	0.98979	271	0.9316
Dom(Hombre-Mujer)	0.96103	271	0.7795

A continuación, se realiza la prueba T para identificar si la variable tomada es significativa; dado que la prueba se enfoca en la valencia, activación y dominio, la variable que se verificará su significancia respecto a las otras es el sexo. Para aplicar esta prueba se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es rechazada.

H0: no hay diferencia entre las medias poblacionales

H1: si hay diferencia entre las medias poblacionales

La prueba T, se aplica de forma conjunta para valencia-sexo, activación-sexo, dominio-sexo. En la Tabla 5.19, para el subconjunto valencia-sexo se observa un p-value de 0.298, para el subconjunto de activación-sexo un p-value de 0.3039 y para el subconjunto de dominio-sexo un p-value de 0.07105. En los 3 casos los resultados de p-value son mayores que el alfa 0.05, por tanto, no se dispone de evidencia para considerar que existe una diferencia entre los resultados de la valencia, activación y dominio con las páginas ya sea que sean hombre o mujer.

Tabla 5.19 Prueba T en las variables valencia-sexo, activación-sexo, dominio-sexo

Variables	Val-sexo	Act-sexo	Dom-sexo
T	1.0426	-1.0302	1.8131
df	288.09	247.68	244.42
p-value	0.298	0.3039	0.07105

A continuación, se realiza la prueba  $\chi^2$  de Pearson, la cual se aplica sobre dos variables para saber si dos características son independientes o tienen una asociación. La variable que se verificará su dependencia respecto a la valencia, activación y dominio es el sexo.

Para aplicar esta prueba se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$  la hipótesis 0 es rechazada.

H0: Las variables no son dependientes.

H1: Las variables son dependientes.

La prueba  $\chi^2$  de Pearson se aplica de forma conjunta para valencia-sexo, activación-sexo, dominio-sexo. En la Tabla 5.20 se observa un p-value de 0.05343 para el subconjunto de valencia-sexo, un p-value de 0.2432 para el subconjunto de activación-sexo y un p-value de 0.06046 para dominio-sexo. En los 3 casos los resultados de p-value son mayores que el alfa 0.05, por tanto, la hipótesis nula es aceptada, lo cual nos indica que las variables son independientes.

Tabla 5.20 Prueba  $\chi^2$  en las variables valencia-sexo, activación-sexo y dominio-sexo

Variables	Val-sexo	Act-sexo	Dom-sexo
X-squared	16.527	10.321	21.449
df	8	8	8
p-value	0.05343	0.2432	0.06046

A continuación, se realiza la prueba KRUSKAL WALLIS, también conocido como test H, la cual es la alternativa no paramétrica al test AnOVA de una vía para datos no igualados. Es un test que emplea rangos para contrastar la hipótesis de que k muestras han sido obtenidas de una misma población. Bajo ciertas simplificaciones puede considerarse que el test de Kruskal-Wallis compara las medianas.

H0: Todas las muestras provienen de la misma población

H1: Al menos una muestra no proviene de la misma población

Se estableció un nivel de significancia de  $\alpha$  de 0.05. Para ser aceptada o rechazada una hipótesis se evalúa el p-value resultante, si este es menor al  $\alpha$  la H0 se rechaza y se acepta la H1.

En la Tabla 5.21 se observa un p-value de 0.03593 con Val-Sexo y de 0.006169 con Act-Sexo, para estos casos el resultado es menor que el nivel de significancia alfa de 0.05, por tanto, podemos decir que esta muestra proviene de una población con una distribución distinta, es decir, la clasificación de las páginas web evaluadas varían su Valencia y activación en base al sexo del evaluador.

Tabla 5.21 Prueba KRUSKAL-WALLIS en las variables valencia-sexo, activación-sexo y dominio-sexo

Variables	Val-Sexo	Act-Sexo	Dom- Sexo
Kruskal-Wallis	16.486	10.295	21.395
df	8	8	8
p-value	0.03593	0.2449	0.006169

A continuación, se realiza la prueba U, la cual realiza una comparación estadística de la media y determina si existe una diferencia entre la variable dependiente y los grupos independientes. De esta forma, puede mostrar si la distribución de la variable dependiente es la misma para los grupos.

Se estableció un nivel de significancia de  $\alpha$  de 0.05. Para ser aceptada o rechazada una hipótesis se evalúa el p-value resultante, si este es menor al  $\alpha$  la H0 se rechaza y se acepta la H1

H0: Las muestras comparadas provienen de la misma población

H1: Las muestras comparadas no provienen de la misma población

En la Tabla 5.22 se observa un p-value de 0.02337 con Dom(Hombre-Mujer), para este caso el resultado es menor que el nivel de significancia alfa de 0.05, por tanto, podemos decir que la variable no proviene de la misma población, es decir, existe una diferencia entre el Dominio mostrado durante el uso de las páginas web según el género del sujeto de prueba.

Tabla 5.22 Prueba U para los subconjuntos de hombre y mujer con las variables val, act, dom

Variables	W	p-value
Val(Hombre-Mujer)	18742	0.2112
Act(Hombre-Mujer)	16420	0.354
Dom(Hombre-Mujer)	19808	0.02337

Analizando la información obtenida de las pruebas realizadas, se llegó a la conclusión de que el sexo tiene impacto el nivel del dominio mostrado, al menos en esta muestra.

**Comprobación idea 4:** El grupo generacional del sujeto de prueba impacta en sus niveles de activación, valencia y dominio.

Para realizar la comprobación de la idea lo primero que se debe realizar es el agrupamiento de los datos, para ello se toman los datos de la columna "grupo\_generacional" y se crean nuevos subconjuntos.

Es necesario aplicar nuevamente la prueba de saphiro para validar la normalidad de los nuevos subconjuntos.

Como se puede observar en la Tabla 5.23 el resultado de p-value para valencia del subconjunto Edad\_G1 es de 0.003205, para valencia del subconjunto Edad\_G2 es de 8.53e-06, para valencia del subconjunto Edad\_G3 es de 3.53e-06, para activación del subconjunto Edad\_G1 es de 0.001365, para activación del subconjunto Edad\_G2 es de 2.798e-06, para activación del subconjunto Edad\_G3 es de 9.964e-06, para dominio del subconjunto Edad\_G1 es de 0.0005974, para dominio del subconjunto Edad\_G2 es de 9.4748e-06 y para dominio del subconjunto Edad\_G3 es de 2.328e-06, en todos los casos los resultados son menores que el alfa 0.05, por tanto, la hipótesis nula es aceptada y nos dice que la muestra tiene una distribución normal.

Tabla 5.23 Pruebas saphiro para las columnas valencia, activación y dominio de los subconjuntos de datos de grupo generacional

Variables	w	p-Value
Val-G1	0.92093	0.003205
Val-G2	0.95481	8.53e-06
Val-G3	0.94142	3.53e-06
Act-G1	0.9102	0.001365
Act-G2	0.94981	2.798e-06
Act-G3	0.94696	9.964e-06
Dom-G1	0.89931	0.0005974
Dom-G2	0.94748	9.4748e-06
Dom-G3	0.93911	2.328e-06

Una vez que se encuentra validada la normalidad de los campos se procede a realizar la prueba F, para ello se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es rechazada.

H0: La muestra no encontró diferencias significativas entre las varianzas.

H1: La muestra encontró diferencias significativas entre las varianzas.

La prueba F se aplica utilizando los datos de los subconjuntos creados para compararlos, es decir las valencias obtenidas con los usuarios que tienen un grupo generacional contra las valencias obtenidas con los usuarios que tienen otro grupo generacional.

Como se puede observar en la Tabla 5.24, en la comparación de los subconjuntos con valencia para G1-G2 el resultado es de 0.2006, para G1-G3 es de 0.8324, para los subconjuntos con valencia para G2-G3 es de 0.1163, para los subconjuntos con activación para G1-G2 el p-value es de 0.0738, para G2-G3 es de 0.2063; para los subconjuntos con dominio para G1-G2 es de 0.6454, para G1-G3 es de 0.6539 y para G2-G3 es de 0.997. En todos estos casos los resultados de p-value son mayores que el alfa 0.05, por tanto, la hipótesis nula es aceptada, lo cual nos indica que no se encontraron diferencias significativas entre las varianzas de los grupos.

El resultado para activación en G1-G2 de p-value es de 0.006138 que es menor que el alfa 0.05, por tanto, la hipótesis nula es rechazada, lo cual nos indica se encontraron diferencias significativas entre las varianzas de los grupos.

Tabla 5.24 Prueba F para los subconjuntos de grupo generacional

Variables	F	Num df	denom df	p-value
Val(G1-G2)	1.3193	47	191	0.2006
Val(G1-G3)	1.0404	47	159	0.8324
Val(G2-G3)	0.7886	191	159	0.1163
Act(G1-G2)	1.8008	47	191	0.006138
Act(G1-G3)	1.4876	47	159	0.073
Act(G2-G3)	0.8261	191	159	0.2063
Dom(G1-G2)	1.0992	47	191	0.6454
Dom(G1-G3)	1.0994	47	159	0.6539
Dom(G2-G3)	1.0001	191	159	0.997

A continuación, se realiza la prueba  $\chi^2$  de Pearson, la cual se aplica sobre dos variables para saber si dos características son independientes o tienen una asociación. La variable que se verificará su dependencia respecto a la valencia, activación y dominio es el grupo\_generacional.

Para aplicar esta prueba se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$  la hipótesis 0 es rechazada.

H0: Las variables no son dependientes.

H1: Las variables son dependientes.

La prueba  $\chi^2$  de Pearson se aplica de forma conjunta para valencia- grupo\_generacional, activación-grupo\_generacional, dominio- grupo\_generacional. En la Tabla 5.25 se observa un p-value de 0.02473 para el subconjunto valencia-grupo\_generacional, para el subconjunto activación-grupo\_generacional se observa un p-value de 8.875e-06 y para el subconjunto dominio-grupo\_generacional se tiene un p-value de 0.0004432. En los 3 casos el resultado es menor que el alfa de 0.05, por tanto, la hipótesis nula es rechazada, lo cual nos indica que las variables son dependientes.

Tabla 5.25 Prueba  $\chi^2$  en las variables valencia-gpogeneracional, activación-gpogeneracional y dominio-gpogeneracional

Variables	Val-Gen_group	Act-Gen_group	Dom-Gen_group
X-squared	28.884	52.565	41.661
df	16	16	16
p-value	0.02473	8.875e-06	0.0004432

Analizando la información obtenida de las pruebas realizadas para el subconjunto grupo generacional, se llegó a la conclusión de que el grupo generacional tiene dependencia en la valencia, activación y dominio.

A continuación, se realiza la prueba Kruskal Wallis, también conocido como test H, la cual es la alternativa no paramétrica al test Anova de una vía para datos no igualados. Es un test que emplea rangos para contrastar la hipótesis de que k muestras han sido obtenidas de una misma población. Bajo ciertas simplificaciones puede considerarse que el test de Kruskal-Wallis compara las medianas.

Se estableció un nivel de significancia de  $\alpha$  de 0.05. Para ser aceptada o rechazada una hipótesis se evalúa el p-value resultante, si este es menor al  $\alpha$  la H0 se rechaza y se acepta la H1.

H0: Todas las muestras provienen de la misma población

H1: Al menos una muestra no proviene de la misma población

En la Tabla 5.26 se observa un p-value de 0.02358 con Act-GpoGen, para este caso el resultado es menor que el nivel de significancia alfa de 0.05, por tanto, podemos decir que esta muestra proviene de una población con una distribución distinta, es decir, la clasificación de las páginas web evaluadas varían su activación de acuerdo al grupo generacional que lo evalúa.

Tabla 5.26 Prueba KRUSKAL-WALLIS en las variables valencia-gpogeneracional, activación-gpogeneracional y dominio-gpogeneracional

Variabales	Val-GpoGen	Act-GpoGen	Dom-GpoGen
Kruskal-Wallis	10.465	17.702	7.9234
df	8	8	8
p-value	0.2339	0.02358	0.441

A continuación, se realiza la prueba U, la cual realiza una comparación estadística de la media y determina si existe una diferencia entre la variable dependiente y los grupos independientes. De esta forma, puede mostrar si la distribución de la variable dependiente es la misma para los grupos.

Se estableció un nivel de significancia de  $\alpha$  de 0.05. Para ser aceptada o rechazada una hipótesis se evalúa el p-value resultante, si este es menor al  $\alpha$  la H0 se rechaza y se acepta la H1

H0: Las muestras comparadas provienen de la misma población

H1: Las muestras comparadas no provienen de la misma población

En la Tabla 5.27 se observa un p-value de 0.007959 con Dom(G2-G3), para este caso el resultado es menor que el nivel de significancia alfa de 0.05, por tanto, podemos decir que las variables no provienen de la misma población, es decir, existe una diferencia entre el dominio percibido durante de evaluación de las páginas web entre el grupo 2 y 3.

Tabla 5.27 Prueba U para las columnas valencia, activación y dominio de los subconjuntos de datos de grupo generacional

Variables	W	p-value
Val(G1-G2)	4660	0.9035
Val(G1-G3)	3749.5	0.8033
Val(G2-G3)	15020	0.7185
Act(G1-G2)	4515	0.8278
Act(G1-G3)	3953.5	0.7542
Act(G2-G3)	16103	0.4291
Dom(G1-G2)	5216.5	0.1506
Dom(G1-G3)	3741.5	0.7826
Dom(G2-G3)	12878	0.007959

Al realizar el análisis de los datos obtenidos en las pruebas con los subconjuntos, se concluyó que el grupo generacional tiene impacto en la activación y dominio que presentan los usuarios al interactuar con las páginas.

**Comprobación idea 5:** Existe una correlación entre activación y valencia, activación y dominio, valencia y dominio.

Estas 3 variables se trabajaron en conjunto para ver qué relación o dependencia tienen entre sí, para ello en primer lugar se realizó la prueba de rachas esta se aplica para identificar si la variable tomada fue generada de manera aleatoria. Para aplicar esta prueba se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es mayor al  $\alpha$  la hipótesis 0 es aceptada.

H0: La muestra es aleatoria.

H1: La muestra no es aleatoria.

La prueba de rachas se aplica de forma individual a las columnas de valencia activación y dominio Tabla 5.28, para el caso de valencia el p-value es de 0.0002036, dado que el resultado es menor que el Alpha 0.05 se rechaza H0, es decir, la muestra no es aleatoria; Para el caso de activación el p-value es de 0.297 y para dominio es de 0.2182 dado que el resultado es mayor que el Alpha 0.05, se acepta H0, es decir, la muestra es aleatoria.

Tabla 5.28 Prueba de rachas

Variables	Val	Act	Dom
Statistic	-3.7146	-1.0428	1.2313
Runs	120	150	138
n1	187	170	183
n2	126	148	98
n	313	318	281
p-value	0.0002036	0.297	0.2182

A continuación, se realiza la prueba  $\chi^2$  de Pearson, esta se aplica sobre dos variables para saber si dos características son independientes o tienen una asociación, dado que la prueba se enfoca en la valencia, activación y dominio se trabajó con una mezcla de ellas. Para aplicar esta prueba se plantean dos hipótesis y se toma un nivel de significancia de  $\alpha$  (alfa) de 0.05, si el valor resultante de p-value es menor al  $\alpha$ , la hipótesis 0 es rechazada.

H0: Las variables no son dependientes.

H1: Las variables son dependientes.

La prueba  $\chi^2$  de Pearson se aplica de forma conjunta para valencia-activación, valencia-dominio, activación-dominio, en la Tabla 5.29 se observa un p-value de 2.2e-16 con valencia-activación, de 2.2e-16 para valencia-dominio y de 2.2e-16 para activación-dominio. Dado que el resultado es menor que el nivel de significancia de alfa de 0.05, podemos decir que las variables son dependientes.

Tabla 5.29 Prueba  $\chi^2$  en las variables valencia-activación, valencia-dominio y activación-dominio

Variables	Val-Act	Val-Dom	Act-Dom
X-squared	248.55	287.75	314.18
df	64	64	64
p-value	2.2e-16	2.2e-16	2.2e-16

Se aplica la prueba de correlación (Figura 5.2) para generar la matriz de correlación a los datos de valencia, activación y dominio.

```
%%R
cor(DF_VAD$Valencia, DF_VAD$Activacion)

[1] -0.1310824

%%R
cor(DF_VAD$Valencia, DF_VAD$Dominio)

[1] 0.3605575

%%R
cor(DF_VAD$Activacion, DF_VAD$Dominio)

[1] -0.02253258

%%R
aux <- DF_VAD[,1:3]
cor(aux)

      Valencia  Activacion   Dominio
Valencia  1.0000000 -0.13108238  0.36055753
Activacion -0.1310824  1.00000000 -0.02253258
Dominio    0.3605575 -0.02253258  1.00000000

%%R
corrplot(cor(aux), method="number", type="upper")
```

Figura 5.2 Datos para matriz de correlación

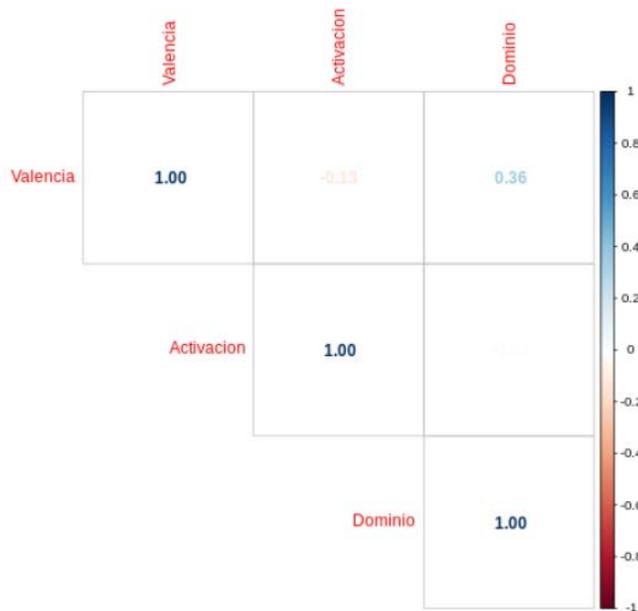


Figura 5.3 Gráfica de correlación

De acuerdo con (Manzano Patiño, 2018) el modelo de ecuaciones estructurales permite estudiar la relación que hay entre variables, para este caso la técnica del modelo utiliza la matriz de correlación. Lo primero que se realiza es almacenar la matriz en un objeto (Figura 5.4)

```
%%R
MatrizCorrelacion_VAD <- cor(aux)
MatrizCorrelacion_VAD
```

	Valencia	Activacion	Dominio
Valencia	1.0000000	-0.13108238	0.36055753
Activacion	-0.1310824	1.00000000	-0.02253258
Dominio	0.3605575	-0.02253258	1.00000000

Figura 5.4 Creación de objeto datos de correlación

Posteriormente se debe definir el modelo de los datos, creando un objeto el cual contenga las combinaciones que se están buscando comprobar (Figura 5.5).

```
%%
modelo <- '
          Dominio ~ Activacion
          Dominio ~ Valencia
          '
```

Figura 5.5 Definición de modelo

Para obtener las relaciones entre variables, se utiliza el método de máxima verosimilitud, el cual recibe el objeto que se acaba de crear "modelo", la matriz de correlación "MatrizCorrelacion", el tamaño de la data set y el estimador que en este caso es el modelo con el que se trabaja "ML" (Figura 5.6).

```
%%R
solucionAlModelo <- sem( modelo,
  sample.cov = MatrizCorrelacion_VAD,
  sample.nobs = dim(DF_VAD)[1],
  std.lv = TRUE,
  estimator = "ML")
```

Figura 5.6 Método de máxima verosimilitud

Una vez que se tiene el resultado se debe corroborar, para ello se utiliza Chi-cuadrado para ver si los datos reflejan la realidad de los datos (Figura 5.7).

```
%%R
solucionAlModelo

lavaan 0.6-7 ended normally after 11 iterations

Estimator              ML
Optimization method    NLMINB
Number of free parameters 3

Number of observations  224

Model Test User Model:

Test statistic          0.000
Degrees of freedom      0
```

Figura 5.7 Corroboración datos del modelo

En (Escobedo, Hernández, Estebané, & Martínez, 2016) nos dice que para determinar el grado en que el modelo general predice la matriz de correlaciones, el estadístico-radio de verosimilitud Chi-cuadrado tiene un ajuste aceptable si los valores libres de Chi-cuadrado son de 2 a 3 y con límites hasta de 5, para este caso se obtuvieron 3 grados de libertad por tanto está dentro del rango y tiene un ajuste correcto.

Para obtener de manera más fiable la relación entre valencia, activación y dominio, se realiza la estimación de los parámetros (Figura 5.8). Donde las columnas de interés son el lhs que son las hipótesis de relación, pvalue es la relación y std.lv la significancia. Si p-value es menor a 0.05 se obtiene una relación significativa, la columna std.lv indica la dirección y magnitud, es decir, si es negativa uno de los valores sube el otro baja y si es positiva ambos incrementan o decremantan.

```
#Mostrar los parámetros/coeficientes estimados
parametros_solucionAlModelo <- parameterestimates( solucionAlModelo, standardized=TRUE )
parametros_solucionAlModelo
```

	lhs	op	rhs	est	se	z	pvalue	ci.lower	ci.upper	std.lv
1	Dominio	~	Activacion	0.025	0.047	0.535	0.593	-0.067	0.117	0.025
2	Dominio	~	Valencia	0.364	0.047	7.737	0.000	0.272	0.456	0.364
3	Dominio	~~	Dominio	0.867	0.061	14.142	0.000	0.747	0.987	0.867
4	Activacion	~~	Activacion	0.998	0.000	NA	NA	0.998	0.998	0.998
5	Activacion	~~	Valencia	-0.131	0.000	NA	NA	-0.131	-0.131	-0.131
6	Valencia	~~	Valencia	0.998	0.000	NA	NA	0.998	0.998	0.998
	std.all		std.nox							
1				0.025				0.025		
2				0.364				0.364		
3				0.869				0.869		
4				1.000				0.998		
5				-0.131				-0.131		
6				1.000				0.998		

Figura 5.8 Estimación de parámetros

A continuación, se realiza una representación de estas relaciones (Figura 5.9), en donde se muestra que mientras aumenta la valencia aumenta el dominio, y cuando la activación aumenta el dominio disminuye.

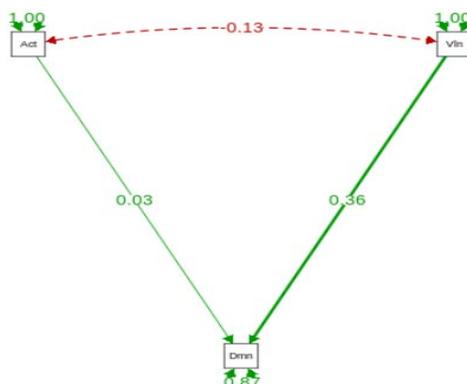


Figura 5.9 Representación correlación de valencia, activación y dominio

Para realizar la clasificación de emociones se tomaron en cuenta los algoritmos analizados y se seleccionaron las Long short term memory (LSTM) y las Gated Recurrent Unit (GRU) debido a que en la literatura arrojaban los mejores resultados a la hora de realizar la clasificación, adicionalmente se replicó y adaptó la red neuronal utilizada para la clasificación de emociones del sistema UXLab para que trabajara con el repositorio de datos creado.

Para poder realizar la clasificación, se generó un módulo para el preprocesamiento de las señales fisiológicas, el cual fue programado en lenguaje Python 3.7. Este módulo está conformado por el filtrado de las señales y la extracción de características.

El filtro utilizado para la limpieza de las señales fue el paso banda, a continuación, en la Tabla 5.30 se muestran los rangos utilizados y recomendados para los dispositivos con los que se trabajó.

Tabla 5.30 Rangos de frecuencia utilizados

Señal	Frecuencia	Rangos de corte
EEG	128	4-45 Hz
ECG	128	2-20 Hz
GSR	128	0.01-.02 Hz

Para esta investigación se seleccionaron las características que pertenecen a los trabajos relevantes del estado del arte y que probaron su eficacia mediante pruebas de aprendizaje automático. Algunos ejemplos son (Kim, Jonghwa and André, 2008; Koelstra et al., 2012; Miranda Correa et al., 2018; Wang et al., 2019). En la Tabla 5.31 se muestran las características mencionadas.

Tabla 5.31 Características multimodales

Señal	Características
EEG	<ul style="list-style-type: none"> <li>• Potencia Espectral de las ondas: theta (4 - 8 hz), alpha (8 - 12 hz), beta (12 – 30hz) y gamma (30 – 45 hz). Con un total de 128.</li> <li>• Asimetría entre los 14 pares de electrodos en las cuatro bandas de theta, alpha, beta, y gamma). Con un total de 56.</li> </ul>
ECG	<ul style="list-style-type: none"> <li>• Promedio y desviación estándar de la frecuencia cardiaca. Con un total de 2.</li> <li>• HRV</li> <li>• Media cuadrática de diferencias sucesivas (RMSSD).</li> <li>• Desviación estándar de NNI sucesivos (SDNN).</li> <li>• Proporción de energía entre las bandas de frecuencia [0,04-0,15] Hz y [0,15-0,5] Hz. Baja frecuencia [0,01 – 0,08]Hz, Media frecuencia [0,08 – 0,15]Hz y alta frecuencia [0,15 – 0,5]Hz de los componentes del espectro del ritmo cardiaco. Con un total de 3.</li> <li>• Potencias espectrales en las bandas de 0-6 HZ. Con un total de 60.</li> <li>• Espectro poincare. Con un total de 3.</li> </ul>
GSR	<ul style="list-style-type: none"> <li>• Promedio de resistencia en piel</li> <li>• Promedio de la primera derivada</li> <li>• Promedio de la primera derivada para valores negativos</li> <li>• Proporción de los valores negativos con respecto a todas las muestras</li> <li>• Número de mínimos locales</li> <li>• Tiempo promedio de subida de la señal</li> <li>• Densidad espectral de potencia en las bandas [0 – 2,4]Hz. Con un total de 10.</li> </ul>

La programación de los algoritmos se realizó en Python 3.7 utilizando el framework Keras y en el sistema operativo Linux. El archivo de características generado con el preprocesamiento y con el que se entrenaron las redes cuenta con un total de 273 características x 200 filas de datos.

Como se puede observar en la Figura 5.10 el algoritmo LSTM finalizó con éxito el entrenamiento, sin embargo, los datos recabados para el entrenamiento No fueron suficientes para el tipo de algoritmo entrenado lo que conllevó un sobre entrenamiento del modelo.

```

Layer (type)                 Output Shape                 Param #
-----
lstm (LSTM)                  (None, 318, 15)            17340
batch_normalization (BatchNorm) (None, 318, 15)            60
dense (Dense)                (None, 318, 2)              22
Total params: 17,432
Trainable params: 17,402
Non-trainable params: 30
Model summary None
K: (1, 318, 273)
2022-06-20 18:58:58.132143: I tensorflow/compiler/mlir/mlir_graph_optimization_pass.cc:185] None of the MLIR Optimization Passes are enabled (registered 2)
Epoch 1/15
2022-06-20 18:58:59.346501: I tensorflow/stream_executor/cuda/cuda_dnn.cc:369] Loaded cuDNN version 8202
1/1 [====] - ETA: 0s - loss: 0.8872 - accuracy: 0.5346WARNING:tensorflow:Model was constructed with shape (None, 318, 273) for input
input_1, description="created by layer 'lstm_input'", but it was called on an input with incompatible shape (None, 88, 273).
1/1 [====] - 2s 2s/step - loss: 0.8872 - accuracy: 0.5346 - val_loss: 0.7260 - val_accuracy: 0.9625
Epoch 2/15
1/1 [====] - 0s 20ms/step - loss: 0.8411 - accuracy: 0.6478 - val_loss: 0.7100 - val_accuracy: 0.9625
Epoch 3/15
1/1 [====] - 0s 20ms/step - loss: 0.8274 - accuracy: 0.5660 - val_loss: 0.7035 - val_accuracy: 0.9500
Epoch 4/15
1/1 [====] - 0s 21ms/step - loss: 0.8232 - accuracy: 0.3491 - val_loss: 0.7001 - val_accuracy: 0.9375
Epoch 5/15
1/1 [====] - 0s 20ms/step - loss: 0.7903 - accuracy: 0.5631 - val_loss: 0.6997 - val_accuracy: 0.9500
Epoch 6/15
1/1 [====] - 0s 20ms/step - loss: 0.7851 - accuracy: 0.5692 - val_loss: 0.6971 - val_accuracy: 0.9500
Epoch 7/15
1/1 [====] - 0s 21ms/step - loss: 0.7834 - accuracy: 0.7579 - val_loss: 0.6969 - val_accuracy: 0.9500
Epoch 8/15
1/1 [====] - 0s 21ms/step - loss: 0.7788 - accuracy: 0.7547 - val_loss: 0.6971 - val_accuracy: 0.9500
Epoch 9/15
1/1 [====] - 0s 22ms/step - loss: 0.7750 - accuracy: 0.7547 - val_loss: 0.6979 - val_accuracy: 0.9500
Epoch 10/15
1/1 [====] - 0s 20ms/step - loss: 0.7725 - accuracy: 0.7484 - val_loss: 0.6930 - val_accuracy: 0.9250
Epoch 11/15
1/1 [====] - 0s 21ms/step - loss: 0.7679 - accuracy: 0.7579 - val_loss: 0.6926 - val_accuracy: 0.9250
Epoch 12/15
1/1 [====] - 0s 21ms/step - loss: 0.7684 - accuracy: 0.7547 - val_loss: 0.6921 - val_accuracy: 0.9250
Epoch 13/15
1/1 [====] - 0s 21ms/step - loss: 0.7636 - accuracy: 0.7484 - val_loss: 0.6910 - val_accuracy: 0.9125
Epoch 14/15
1/1 [====] - 0s 21ms/step - loss: 0.7628 - accuracy: 0.7484 - val_loss: 0.6912 - val_accuracy: 0.9125
Epoch 15/15
1/1 [====] - 0s 22ms/step - loss: 0.7621 - accuracy: 0.7484 - val_loss: 0.6900 - val_accuracy: 0.9125
Evaluando modelo
Test Accuracy: 0.913

Model summary None
K: (1, 318, 273)
2022-06-20 18:59:58.668252: I tensorflow/compiler/mlir/mlir_graph_optimization_pass.cc:185] None of the MLIR Optimization Passes are enabled (registered 2)
Epoch 1/20
2022-06-20 18:59:59.895549: I tensorflow/stream_executor/cuda/cuda_dnn.cc:369] Loaded cuDNN version 8202
1/1 [====] - ETA: 0s - loss: 0.8628 - accuracy: 0.8176WARNING:tensorflow:Model was constructed with shape (None, 318, 273) for input
input_1, description="created by layer 'lstm_input'", but it was called on an input with incompatible shape (None, 88, 273).
1/1 [====] - 2s 2s/step - loss: 0.8628 - accuracy: 0.8176 - val_loss: 0.7774 - val_accuracy: 0.8875
Epoch 2/20
1/1 [====] - 0s 21ms/step - loss: 0.8396 - accuracy: 0.7610 - val_loss: 0.7732 - val_accuracy: 0.8875
Epoch 3/20
1/1 [====] - 0s 22ms/step - loss: 0.8243 - accuracy: 0.7956 - val_loss: 0.7690 - val_accuracy: 0.9000
Epoch 4/20
1/1 [====] - 0s 20ms/step - loss: 0.8179 - accuracy: 0.8019 - val_loss: 0.7673 - val_accuracy: 0.9000
Epoch 5/20
1/1 [====] - 0s 20ms/step - loss: 0.8127 - accuracy: 0.8019 - val_loss: 0.7650 - val_accuracy: 0.9000
Epoch 6/20
1/1 [====] - 0s 22ms/step - loss: 0.8103 - accuracy: 0.7956 - val_loss: 0.7629 - val_accuracy: 0.9000
Epoch 7/20
1/1 [====] - 0s 20ms/step - loss: 0.8038 - accuracy: 0.8010 - val_loss: 0.7610 - val_accuracy: 0.9000
Epoch 8/20
1/1 [====] - 0s 22ms/step - loss: 0.8003 - accuracy: 0.8019 - val_loss: 0.7592 - val_accuracy: 0.9000
Epoch 9/20
1/1 [====] - 0s 20ms/step - loss: 0.7961 - accuracy: 0.8019 - val_loss: 0.7577 - val_accuracy: 0.9000
Epoch 10/20
1/1 [====] - 0s 20ms/step - loss: 0.7926 - accuracy: 0.7907 - val_loss: 0.7562 - val_accuracy: 0.9000
Epoch 11/20
1/1 [====] - 0s 24ms/step - loss: 0.7890 - accuracy: 0.8050 - val_loss: 0.7547 - val_accuracy: 0.9000
Epoch 12/20
1/1 [====] - 0s 25ms/step - loss: 0.7857 - accuracy: 0.8050 - val_loss: 0.7531 - val_accuracy: 0.9000
Epoch 13/20
1/1 [====] - 0s 25ms/step - loss: 0.7822 - accuracy: 0.8050 - val_loss: 0.7515 - val_accuracy: 0.9000
Epoch 14/20
1/1 [====] - 0s 23ms/step - loss: 0.7762 - accuracy: 0.8050 - val_loss: 0.7491 - val_accuracy: 0.9000
Epoch 15/20
1/1 [====] - 0s 25ms/step - loss: 0.7720 - accuracy: 0.8050 - val_loss: 0.7456 - val_accuracy: 0.8875
Epoch 16/20
1/1 [====] - 0s 23ms/step - loss: 0.7652 - accuracy: 0.8019 - val_loss: 0.7424 - val_accuracy: 0.8750
Epoch 17/20
1/1 [====] - 0s 21ms/step - loss: 0.7593 - accuracy: 0.8050 - val_loss: 0.7452 - val_accuracy: 0.8625
Epoch 18/20
1/1 [====] - 0s 20ms/step - loss: 0.7560 - accuracy: 0.8019 - val_loss: 0.7424 - val_accuracy: 0.8625
Epoch 19/20
1/1 [====] - 0s 21ms/step - loss: 0.7527 - accuracy: 0.8019 - val_loss: 0.7350 - val_accuracy: 0.8625
Epoch 20/20
1/1 [====] - 0s 20ms/step - loss: 0.7468 - accuracy: 0.7987 - val_loss: 0.7350 - val_accuracy: 0.8500
Evaluando modelo
Test Accuracy: 0.829

```

Figura 5.10 LSTM

Como se puede observar en la Figura 5.11 al igual que el algoritmo LSTM el algoritmo GRU, también finaliza con éxito el entrenamiento, sin embargo, de igual forma sufre un sobre aprendizaje por la cantidad de datos utilizada y el tipo de algoritmo.

```

Layer (type)          Output Shape          Param #
-----
gru (GRU)             (None, 318, 5)       4200
batch_normalization (BatchNo (None, 318, 5)       20
dense (Dense)         (None, 318, 2)       12
-----
Total params: 4,232
Trainable params: 4,222
Non-trainable params: 10

Model summary None
x: (1, 318, 273)
2022-06-20 19:00:52.742645: I tensorflow/compiler/mlir/mlir_graph_optimization_pass.cc:1851 None of the MLIR Optimization Passes are enabled (registered 2)
Epoch 1/10
2022-06-20 19:00:53.967268: I tensorflow/stream_executor/cuda/cuda_dnn.cc:369] Loaded cuDNN version 8202
1/1 [-----] - ETA: 0s - loss: 0.8997 - accuracy: 0.3994WARNING:tensorflow:Model was constructed with shape (None, 318, 273) for input KerasTensor('input', description='created by layer 'gru input')', but it was called on an input with incompatible shape (None, 88, 273).
1/1 [-----] - 2s 2s/step - loss: 0.8997 - accuracy: 0.3994 - val_loss: 0.9740 - val_accuracy: 0.8250
Epoch 2/10
1/1 [-----] - 0s 20ms/step - loss: 0.8974 - accuracy: 0.3994 - val_loss: 0.9960 - val_accuracy: 0.8875
Epoch 3/10
1/1 [-----] - 0s 20ms/step - loss: 0.8603 - accuracy: 0.4403 - val_loss: 0.9930 - val_accuracy: 0.8875
Epoch 4/10
1/1 [-----] - 0s 19ms/step - loss: 0.8580 - accuracy: 0.4403 - val_loss: 0.9886 - val_accuracy: 0.8875
Epoch 5/10
1/1 [-----] - 0s 19ms/step - loss: 0.8567 - accuracy: 0.4403 - val_loss: 0.9843 - val_accuracy: 0.8875
Epoch 6/10
1/1 [-----] - 0s 20ms/step - loss: 0.8554 - accuracy: 0.4403 - val_loss: 0.9801 - val_accuracy: 0.8875
Epoch 7/10
1/1 [-----] - 0s 22ms/step - loss: 0.8541 - accuracy: 0.4403 - val_loss: 0.9759 - val_accuracy: 0.8875
Epoch 8/10
1/1 [-----] - 0s 20ms/step - loss: 0.8528 - accuracy: 0.4403 - val_loss: 0.9719 - val_accuracy: 0.8875
Epoch 9/10
1/1 [-----] - 0s 21ms/step - loss: 0.8515 - accuracy: 0.4403 - val_loss: 0.9679 - val_accuracy: 0.8875
Epoch 10/10
1/1 [-----] - 0s 20ms/step - loss: 0.8503 - accuracy: 0.4403 - val_loss: 0.9639 - val_accuracy: 0.8875
Evaluando modelo
Test Accuracy: 0.887

```

```

Layer (type)          Output Shape          Param #
-----
gru (GRU)             (None, 318, 5)       4200
batch_normalization (BatchNo (None, 318, 5)       20
dense (Dense)         (None, 318, 2)       12
-----
Total params: 4,232
Trainable params: 4,222
Non-trainable params: 10

Model summary None
x: (1, 318, 273)
2022-06-20 19:00:52.742645: I tensorflow/compiler/mlir/mlir_graph_optimization_pass.cc:1851 None of the MLIR Optimization Passes are enabled (registered 2)
Epoch 1/10
2022-06-20 19:00:53.967268: I tensorflow/stream_executor/cuda/cuda_dnn.cc:369] Loaded cuDNN version 8202
1/1 [-----] - ETA: 0s - loss: 0.8997 - accuracy: 0.3994WARNING:tensorflow:Model was constructed with shape (None, 318, 273) for input KerasTensor('input', description='created by layer 'gru input')', but it was called on an input with incompatible shape (None, 88, 273).
1/1 [-----] - 2s 2s/step - loss: 0.8997 - accuracy: 0.3994 - val_loss: 0.9740 - val_accuracy: 0.8250
Epoch 2/10
1/1 [-----] - 0s 20ms/step - loss: 0.8974 - accuracy: 0.3994 - val_loss: 0.9960 - val_accuracy: 0.8875
Epoch 3/10
1/1 [-----] - 0s 20ms/step - loss: 0.8603 - accuracy: 0.4403 - val_loss: 0.9930 - val_accuracy: 0.8875
Epoch 4/10
1/1 [-----] - 0s 19ms/step - loss: 0.8580 - accuracy: 0.4403 - val_loss: 0.9886 - val_accuracy: 0.8875
Epoch 5/10
1/1 [-----] - 0s 19ms/step - loss: 0.8567 - accuracy: 0.4403 - val_loss: 0.9843 - val_accuracy: 0.8875
Epoch 6/10
1/1 [-----] - 0s 20ms/step - loss: 0.8554 - accuracy: 0.4403 - val_loss: 0.9801 - val_accuracy: 0.8875
Epoch 7/10
1/1 [-----] - 0s 22ms/step - loss: 0.8541 - accuracy: 0.4403 - val_loss: 0.9759 - val_accuracy: 0.8875
Epoch 8/10
1/1 [-----] - 0s 20ms/step - loss: 0.8528 - accuracy: 0.4403 - val_loss: 0.9719 - val_accuracy: 0.8875
Epoch 9/10
1/1 [-----] - 0s 21ms/step - loss: 0.8515 - accuracy: 0.4403 - val_loss: 0.9679 - val_accuracy: 0.8875
Epoch 10/10
1/1 [-----] - 0s 20ms/step - loss: 0.8503 - accuracy: 0.4403 - val_loss: 0.9639 - val_accuracy: 0.8875
Evaluando modelo
Test Accuracy: 0.887

```

Figura 5.11 GRU

Por último, se replicó y adaptó el algoritmo utilizado para la clasificación de emociones dentro del sistema UXLab y los algoritmos SVM, RF, RN. En la Tabla 5.32 y Tabla 5.33, se observan los resultados obtenidos de todos los algoritmos de clasificación utilizando las métricas de Precision, Recall, F1-score, Accuracy, para las variables valencia y activación; como se puede observar en ambos casos el algoritmo que arroja mejores resultados es la RN.

Tabla 5.32 Resultados valencia

VALENCIA				
Algoritmo	Precision	Recall	F1-score	Accuracy
SVM	0.666667	0.800000	0.727273	0.700000
RF	0.823529	0.7	0.756757	0.775000
RN	0.941176	0.842105	0.888889	0.900000
LSTM	-	-	-	0.85
GRU	-	-	-	0.88

Tabla 5.33 Resultados activación

ACTIVACIÓN				
Algoritmo	Precision	Recall	F1-score	Accuracy
SVM	0.450000	0.500000	0.473684	0.500000
RF	0.476190	0.555556	0.512821	0.525000
RN	0.550000	0.990	0.709677	0.55
LSTM	-	-	-	0.85
GRU	-	-	-	0.88

A continuación, se muestran algunos ejemplos de los resultados obtenidos del algoritmo dentro del reproductor de UXLab. En la Figura 5.12, se observa el resultado de la evaluación de un producto digital con un mal diseño utilizando el algoritmo entrenado con imágenes. La interpretación del resultado indica que el usuario se sentía con un estado emocional positivo, sin embargo, al preguntarle al usuario este indicaba que estaba un tanto desconcertado debido a que la página no era intuitiva y no pudo terminar con las actividades solicitadas dentro de la evaluación de la misma.



Figura 5.12 Resultados con algoritmo emolern Keneth

En la Figura 5.13, se observa el resultado de la evaluación, ahora utilizando el algoritmo entrenado con productos digitales, la interpretación del resultado indica que el usuario se sentía con un estado emocional negativo. Al realizar la comparación con los resultados del SAM llenado por el usuario (Figura 5.14), se observa que la emoción sentida se encuentra en un estado negativo cercano al neutral ya que, aunque no pudo terminar con las actividades marcadas se encontraba familiarizado con las páginas de codificación y estaba un tanto acostumbrado a los problemas que encontraba.



Figura 5.13 Resultado modelo productos digitales Keneth

Formato SAM

PROCESO DE INDUCCIÓN EMOCIONAL

Nombre del usuario: Kenneth William Rojas Rojas

Fecha: 1/1

Emoción(es) inducida(s): \_\_\_\_\_

Instrucciones: Por favor, contestar cada estímulo que se muestra en la siguiente tabla, califique cada una de las opciones de acuerdo con el estímulo recibido en las fases del proceso PIE con el rango de 1 a 9.

Sesión	Valencia									Activación									Dominio								
	Muy desagradable	Desagradable	Neutral	Agradable	Muy agradable	Muy Calmado	Calmado	Neutral	Activado	Muy activado	Muy influenciado	Influenciado	Neutral	Dominante	Muy Dominante												
51.1	1	2	3	4	5	6	7	8	9	1	2	3	4	5	6	7	8	9	1	2	3	4	5	6	7	8	9

Todos los derechos reservados. El contenido de este documento es propiedad de CENIDET®, es confidencial y con derechos de autor. Cualquier reproducción total o parcial está estrictamente prohibida sin el permiso escrito de CENIDET®.

Figura 5.14 SAM evaluación productos digitales Keneth

A continuación, en la Figura 5.15 se muestran los resultados de la evaluación de un producto digital con un Buen diseño utilizando el algoritmo entrenado con imágenes. La interpretación del resultado indica que el usuario se sentía con un estado emocional negativo, sin embargo, al preguntarle al usuario este nos comentó que se encontraba interesado debido a que es una página con la que está familiarizado y tiene productos que le interesan.

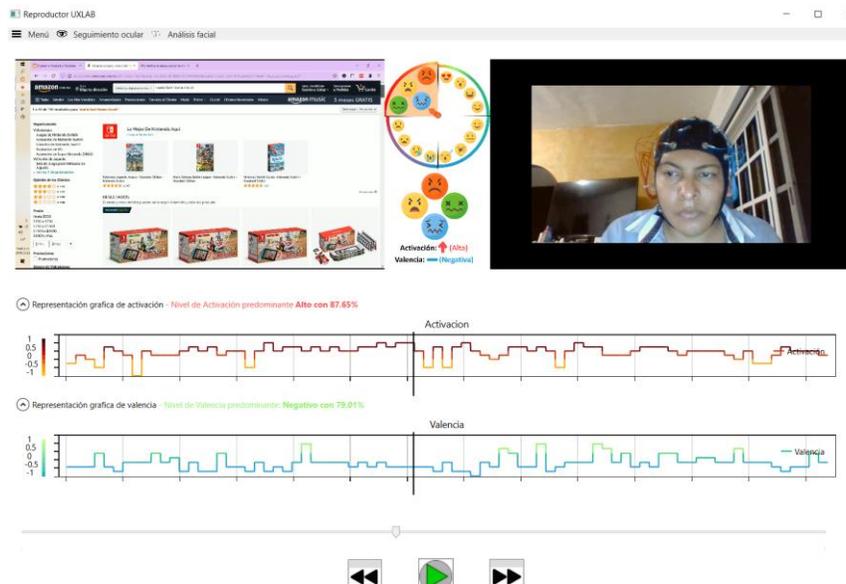


Figura 5.15 Resultados con algoritmo emolern Gilberto

En la Figura 5.16, se observa el resultado de la evaluación, ahora utilizando el algoritmo entrenado con productos digitales, la interpretación del resultado indica que el usuario se sentía con un estado emocional positivo y al realizar la comparación con los resultados del SAM llenado por el usuario (Figura 5.17), se observa que la emoción sentida se encuentra en un estado positivo.

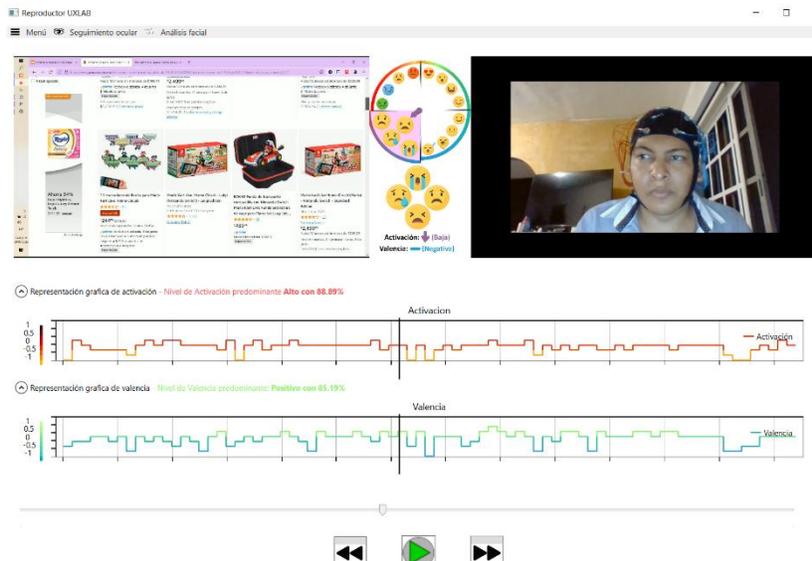


Figura 5.16 Resultado modelo productos digitales Gilberto

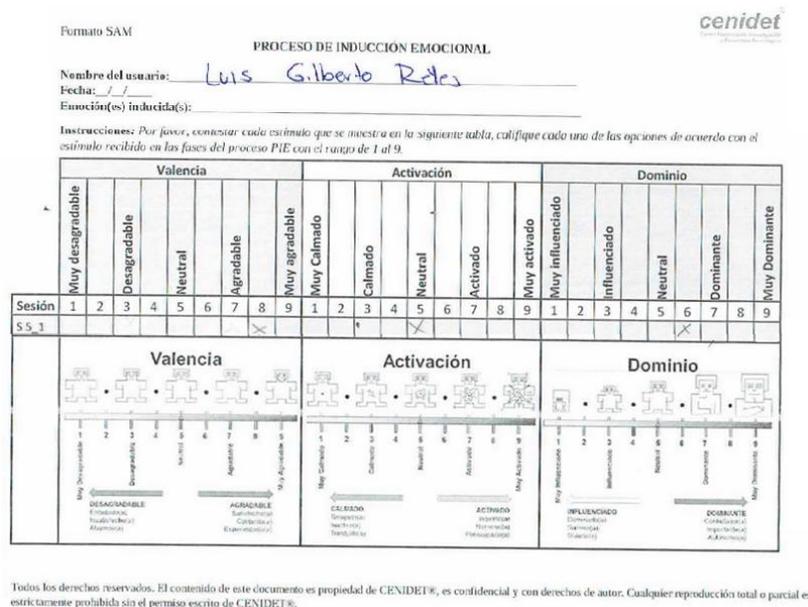
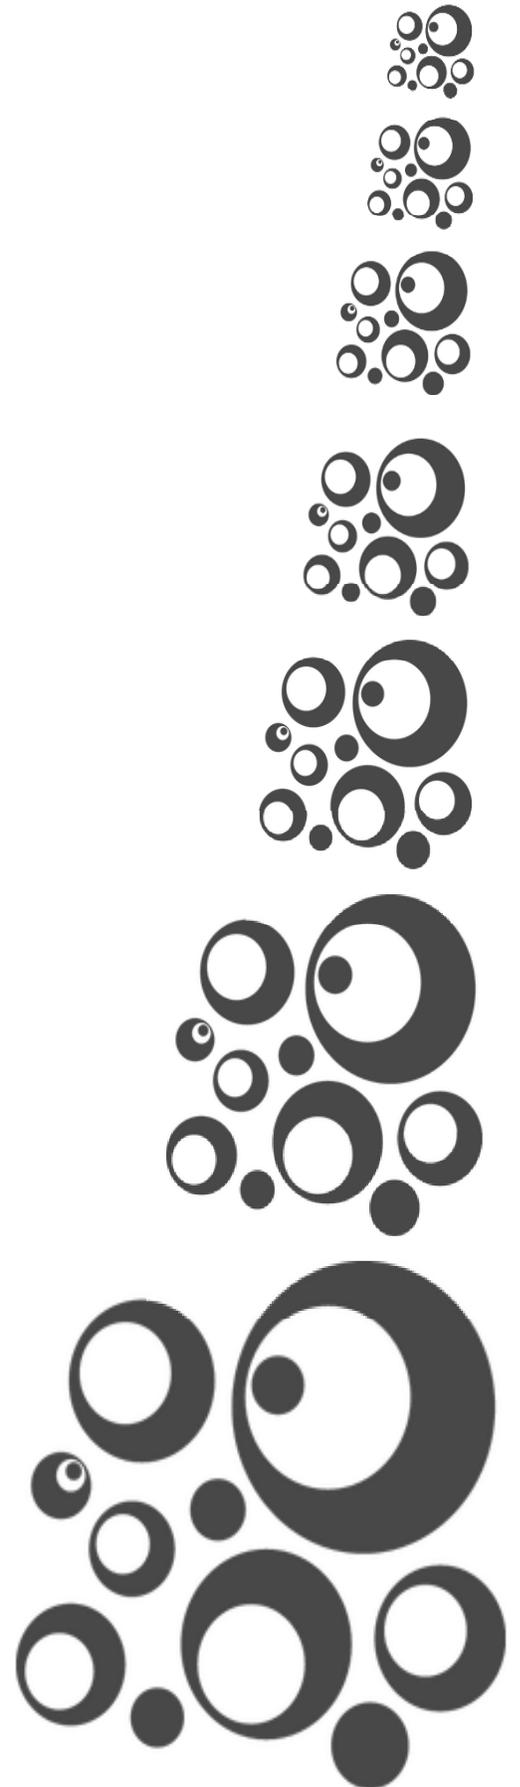


Figura 5.17 SAM evaluación productos digitales Gilberto

# Capítulo 6

## Conclusiones



## 6. Conclusión

Al analizar la información recabada durante la creación del repositorio de datos con los procesos de inducción y realizar la comprobación de la fiabilidad de la muestra, nos permitió concluir que se cumplió el objetivo de crear un proceso de inducción emocional que tomara en cuenta las características necesarias para permitir la interacción activa de los usuarios con los productos digitales web y de este modo lograr inducir a los usuarios a diferentes estados emocionales.

Al de realizar el análisis estadístico para la validación de los datos obtenidos de los cuestionarios SAM y conociendo al usuario, se ha logrado determinar la relación que existe entre las variables analizadas.

Se identificó que existe una relación entre la variable valencia que registran los usuarios y el diseño que presentan las páginas web, es decir, existe una relación entre el buen o mal diseño que presenta la página y la valencia percibida por el usuario; se llegó a una conclusión similar a la que obtuvieron en el trabajo de (Schrepp, Otten, Blum, & Thomaschewski, 2021) donde realizan la evaluación de la dependencia de la estética con la usabilidad de la página utilizando únicamente capturas de pantalla de las mismas y sin que exista una interacción activa con las páginas.

De igual forma se identificó la relación que existe entre las variables activación y dominio con el grupo generacional; la cual nos indica que estas dos variables tienen una dependencia directa con el grupo generacional del usuario que está realizando la evaluación.

Se observó que la valencia es la variable que más debe ser cuidada debido a que en mayor medida es la más afectada por factores externos. Así mismo, se identificó que las variables diseño y grupo generacional son las variables que más influyen en la evaluación de la experiencia del usuario y por tanto deben ser tomadas en consideración para el proceso de generación de un repositorio de datos.

Esto nos conlleva a concluir que se cumplió de forma exitosa el objetivo de crear un repositorio de señales fisiológicas multimodales.

Al realizar la codificación de los algoritmos de aprendizaje se identificó que, los algoritmos de aprendizaje profundo LSTM y GRU sufrían de un sobre aprendizaje por la cantidad de

datos que contiene el repositorio de datos generado, esto a pesar de que se superó el promedio de datos que indicaban en los repositorios existentes.

De igual forma se realizaron pruebas con los algoritmos SVM, RN, RF, los cuales, al ser entrenados con el repositorio creado, no sufrieron de sobre aprendizaje y dieron mejores resultados. De estos algoritmos el que dio mejores resultados fue la RN, la cual fue utilizada para la generación del modelo de clasificación.

Así mismo se ejecutó la comparación de los resultados obtenidos al momento de realizar la clasificación de estados emocionales con el algoritmo entrenado con productos digitales y el algoritmo entrenado con imágenes estáticas. Se observó una mejoría en los resultados presentados en el reproductor de UXLab al momento de realizar la clasificación de estados emocionales durante la evaluación de productos digitales.

Todos estos resultados ayudaron a aceptar una de las hipótesis “Mejorará los resultados arrojados por el algoritmo de clasificación que los obtenidos al ser entrenado con los repositorios existentes de señales fisiológicas basados en imágenes, audios y video”, ya que efectivamente al entrenar un algoritmo con un repositorio adecuado a la evaluación que se realiza la precisión obtenida de los resultados de la clasificación aumenta.

## 6.1. Trabajos futuros

La segunda hipótesis generada con este trabajo “Trabajar con algoritmos de Deep Learning y señales fisiológicas multimodales mejoraría la precisión al momento de realizar la clasificación de emociones”, no logró ser aceptada debido a que el repositorio de datos generado no contaba con la información suficiente para realizar las pruebas necesarias para aceptarla o refutarla.

Por tal motivo para complementar este trabajo, se propone:

- Aumentar el repositorio de datos existente, para realizar entrenamientos de algoritmos de aprendizaje profundo y comprobar si estos mejoran la precisión al momento de realizar la clasificación de estados emocionales.
- Realizar clasificación de estados emocionales durante la evaluación de productos digitales con solo 1 señal fisiológica, esto con el objetivo de comprobar si se obtiene mejores resultados al momento de clasificar estados emocionales como en algunos trabajos del estado del arte.

## 6.2. Artículos publicados

A largo de este periodo de investigación se han escrito y publicado dos artículos, uno de ellos dentro de la revista IEEE Latin America Transactions, el cual lleva por título **“Assessment of an emotions’ induction technique using stimuli from interactive digital products”** y uno más dentro en la Jornada de Ciencia y Tecnología Aplicada el cual lleva por título **“Evaluación de un proceso de inducción emocional utilizando estímulos de productos digitales interactivos”**.

## 7. Referencias

- Alhagry, S., Aly, A., & A., R. (2017). Emotion Recognition based on EEG using LSTM Recurrent Neural Network. *International Journal of Advanced Computer Science and Applications*, 8(10), 8–11. <https://doi.org/10.14569/ijacsa.2017.081046>
- Balam Guzmán, L. A. (2015). Modelo semántico para la gestión de técnicas de HCI mediante el monitoreo de actividad bioeléctrica (EEG) para caracterizar estados mentales y su relación con cambios en el contexto del usuario (Centro Nacional de Investigación y Desarrollo Tecnológico). Retrieved from [https://www.academia.edu/25361922/Modelo\\_sema\\_ntico\\_para\\_la\\_gestio\\_n\\_de\\_te\\_cnicas\\_de\\_HCI\\_mediante\\_el\\_monitoreo\\_de\\_actividad\\_bioele\\_ctrica\\_EEG\\_para\\_caracterizar\\_estados\\_mentales\\_y\\_su\\_relacio\\_n\\_con\\_cambios\\_en\\_el\\_contexto\\_del\\_usuario?auto=download](https://www.academia.edu/25361922/Modelo_sema_ntico_para_la_gestio_n_de_te_cnicas_de_HCI_mediante_el_monitoreo_de_actividad_bioele_ctrica_EEG_para_caracterizar_estados_mentales_y_su_relacio_n_con_cambios_en_el_contexto_del_usuario?auto=download)
- Bonell, C., Cherniz, A. S., Hadad, A., & Drozdowicz, B. (2011). BaSeBio : base de datos de señales biomédicas accesible desde Internet. *Anales Del XVIII Congreso Argentino de Bioingeniería y VII Jornadas de Ingeniería Clínica (SABI)*. Retrieved from <http://www.sabi2011.fi.mdp.edu.ar/proceedings/>
- Chao, H., Zhi, H., Dong, L., & Liu, Y. (2018). Recognition of Emotions Using Multichannel EEG Data and DBN-GC-Based Ensemble Deep Learning Framework. *Computational Intelligence and Neuroscience*, 2018. <https://doi.org/10.1155/2018/9750904>
- Chen, J. X., Zhang, P. W., Mao, Z. J., Huang, Y. F., Jiang, D. M., & Zhang, Y. N. (2019). Accurate EEG-Based Emotion Recognition on Combined Features Using Deep Convolutional Neural Networks. *IEEE Access*, 7(c), 44317–44328. <https://doi.org/10.1109/ACCESS.2019.2908285>
- Chirico, A., Ferrise, F., Cordella, L., & Gaggioli, A. (2018). Designing awe in virtual reality: An experimental study. *Frontiers in Psychology*, 8(JAN), 1–14. <https://doi.org/10.3389/fpsyg.2017.02351>
- Cho, K., Xu, K., Ba, J. L., Kiros, R., Courville, A., Salakhutdinov, R., ... Bengio, Y. (2015). Show, attend and tell: Neural image caption generation with visual attention. *32nd International Conference on Machine Learning, ICML 2015*, 3, 2048–2057.
- Courtemanche, F., Léger, P. M., Dufresne, A., Fredette, M., Labonté-Lemoyne, É., & Sénécal, S. (2018). Physiological heatmaps: A tool for visualizing users' emotional reactions. *Multimedia Tools and Applications*, 77(9), 11547–11574. <https://doi.org/10.1007/s11042-017-5091-1>

- Cuesta-Cambra, U., Niño-González, J.-I., & Rodríguez-terceño, J. (2017). El procesamiento cognitivo en una app educativa con electroencefalograma y «Eye Tracking». *Comunicar*, XXV(52), 41–50. <https://doi.org/10.3916/C52-2017-04>
- Das, P., Khasnobish, A., & Tibarewala, D. N. (2016). Emotion recognition employing ECG and GSR signals as markers of ANS. *Conference on Advances in Signal Processing, CASP 2016*, 37–42. <https://doi.org/10.1109/CASP.2016.7746134>
- Díaz, J., Harari, I., & Amadeo, A. P. (2013). *Guía de Recomendaciones para Diseño de Software Centrado en el Usuario*. Retrieved from <http://sedici.unlp.edu.ar/handle/10915/32172>
- Dur, N. (2017). *Procedimientos de inducción emocional (Universitat Jaume I)*. Retrieved from <http://hdl.handle.net/10234/173365>
- Ekman, P., Friesen, W. V., O'Sullivan, M., Chan, A., Diacoyanni-Tarlatzis, I., Heider, K., ... Tzavaras, A. (1987). Universals and Cultural Differences in the Judgments of Facial Expressions of Emotion. *Journal of Personality and Social Psychology*, 53(4), 712–717. <https://doi.org/10.1037/0022-3514.53.4.712>
- Escobedo, M., Hernández, A. J., Estebané, V., & Martínez, G. (2016). Modelos de Ecuaciones Estructurales: Características, Fases, Construcción, Aplicación y Resultados structural equation modeling: features, phases, construction, implementation and results. *Revista Ciencia y Trabajo*, 18(55), 16–22. Retrieved from [https://scielo.conicyt.cl/scielo.php?script=sci\\_arttext&pid=S0718-24492016000100004](https://scielo.conicyt.cl/scielo.php?script=sci_arttext&pid=S0718-24492016000100004)
- Fernández, C. (2012). *Inducción de emociones en condiciones experimentales: Un banco de estímulos audiovisuales*.
- Fernandez Ruiz, M. J., Angós Ullate, J. M., & Salvador Olivan, J. A. (2001). Interfaces de usuario: Diseño de la visualización de la información como medio para mejorar la gestión del conocimiento y los resultados obtenidos por el usuario. V Congreso ISKO - España, 12. Retrieved from [https://www.researchgate.net/publication/28281670\\_Interfaces\\_de\\_usuario\\_diseno\\_de\\_la\\_visualizacion\\_de\\_la\\_informacion\\_como\\_medio\\_de\\_mejorar\\_la\\_gestion\\_del\\_conocimiento\\_y\\_los\\_resultados\\_obtenidos\\_por\\_el\\_usuario](https://www.researchgate.net/publication/28281670_Interfaces_de_usuario_diseno_de_la_visualizacion_de_la_informacion_como_medio_de_mejorar_la_gestion_del_conocimiento_y_los_resultados_obtenidos_por_el_usuario)
- Folland, G. B. (1992). *Fourier analysis and its applications* (Pacific Gr; Pacific Grove (California), Ed.).

- Fouilloux Quiroz, D. E. (2018). Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario. Centro Nacional de Investigación y Desarrollo Tecnológico.
- Frías-navarro, D., & Valencia, U. De. (2019). APUNTES DE CONSISTENCIA INTERNA DE LAS PUNTUACIONES DE UN INSTRUMENTO DE MEDIDA. Retrieved from <https://www.uv.es/friasnav/AlfaCronbach.pdf>
- Gao, Y., Lee, H. J., & Mehmood, R. M. (2015). Deep learning of EEG signals for emotion recognition. 2015 IEEE International Conference on Multimedia and Expo Workshops, ICMEW 2015, 2, 1–5. <https://doi.org/10.1109/ICMEW.2015.7169796>
- García Palacios, A., & Baños Rivera, R. M. (1999). Eficacia de dos procedimientos de inducción del estado de ánimo e influencia de variables moduladoras. *Revista de Psicopatología y Psicología Clínica*, 4(1), 15–26. <https://doi.org/10.5944/rppc.vol.4.num.1.1999.3870>
- Georges, V., Courtemanche, F., Sénécal, S., Baccino, T., Fredette, M., & Léger, P. M. (2018). UX heatmaps: Mapping user experience on visual interfaces. *Conference on Human Factors in Computing Systems - Proceedings*, 4850–4860. <https://doi.org/10.1145/2858036.2858271>
- Georges, V., Courtemanche, F., Sénécal, S., Léger, P. M., Nacke, L., & Pourchon, R. (2017). The Adoption of Physiological Measures as an Evaluation Tool in UX. *HCI in Business, Government and Organizations. Interacting with Information Systems*, 10293, 139–153. <https://doi.org/10.1007/978-3-319-58481-2>
- Girardi, D., Lanubile, F., & Novielli, N. (2018). Emotion detection using noninvasive low cost sensors. 2017 7th International Conference on Affective Computing and Intelligent Interaction, ACII 2017, 2018-Janua(August), 125–130. <https://doi.org/10.1109/ACII.2017.8273589>
- González Franco, N. (2017). Metodología UXEEg para la evaluación de la Experiencia del Usuario en personas con discapacidad a partir de Interfaces Cerebro Computadora. Centro Nacional de Investigación y Desarrollo Tecnológico.
- Guerrero Martínez, J. F. (2010). Bioseñales. Retrieved from [http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib\\_material/IB\\_T2\\_OCW.pdf](http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib_material/IB_T2_OCW.pdf)
- Hassani, S., Bafadel, I., Bekhatro, A., Al Blooshi, E., Ahmed, S., & Alahmad, M. (2018). Physiological signal-based emotion recognition system. 4th IEEE International Conference on

- Engineering Technologies and Applied Sciences, ICETAS 2017, 2018-Janua(Cdc), 1–5.  
<https://doi.org/10.1109/ICETAS.2017.8277912>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9, 1735–1780. <https://doi.org/https://doi.org/10.1162/neco.1997.9.8.1735>
- Hossain, M. S., & Muhammad, G. (2018). Emotion recognition using deep learning approach from audio–visual emotional big data. *Information Fusion*, 49(November 2017), 69–78.  
<https://doi.org/10.1016/j.inffus.2018.09.008>
- INEGI. (2019). Encuesta Nacional sobre Disponibilidad y Uso de Tecnologías de la Información en los Hogares (ENDUTIH) 2018. Comunicado de prensa. In Instituto Nacional de Estadística y Geografía (INEGI). Retrieved from  
[https://www.inegi.org.mx/contenidos/saladeprensa/boletines/2019/OtrTemEcon/ENDUTIH\\_2018.pdf](https://www.inegi.org.mx/contenidos/saladeprensa/boletines/2019/OtrTemEcon/ENDUTIH_2018.pdf)
- Katsigiannis, S. (2018). DREAMER : A Database for Emotion Recognition Through EEG and ECG Signals From Wireless Low-cost Off-the-shelf Devices,. *IEEE Journal of Biomedical and Health Informatics*, 22(1), 98–107. <https://doi.org/10.1109/JBHI.2017.2688239>
- Katsigiannis, S., & Ramzan, N. (2018). DREAMER: A Database for Emotion Recognition Through EEG and ECG Signals from Wireless Low-cost Off-the-Shelf Devices. *IEEE Journal of Biomedical and Health Informatics*, 22(1), 98–107.  
<https://doi.org/10.1109/JBHI.2017.2688239>
- Kim, Jonghwa and André, E. (2008). Emotion recognition based on physiological changes in music listening. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30.  
<https://doi.org/10.1109/TPAMI.2008.26>
- Koelstra, S., Patras, I., Mühl, C., Nijholt, A., Soleymani, M., Pun, T., ... Ebrahimi, T. (2012). DEAP: A database for emotion analysis; Using physiological signals. *IEEE Transactions on Affective Computing*, 3(1), 18–31. <https://doi.org/10.1109/T-AFFC.2011.15>
- Liang, Z., Oba, S., & Ishii, S. (2019). An unsupervised EEG decoding system for human emotion recognition. *Neural Networks*, 116, 257–268. <https://doi.org/10.1016/j.neunet.2019.04.003>
- Liao, C. Y., Chen, R. C., & Tai, S. K. (2018). Emotion stress detection using EEG signal and deep learning technologies. *Proceedings of 4th IEEE International Conference on Applied System Innovation 2018, ICASI 2018*, (2), 90–93. <https://doi.org/10.1109/ICASI.2018.8394414>

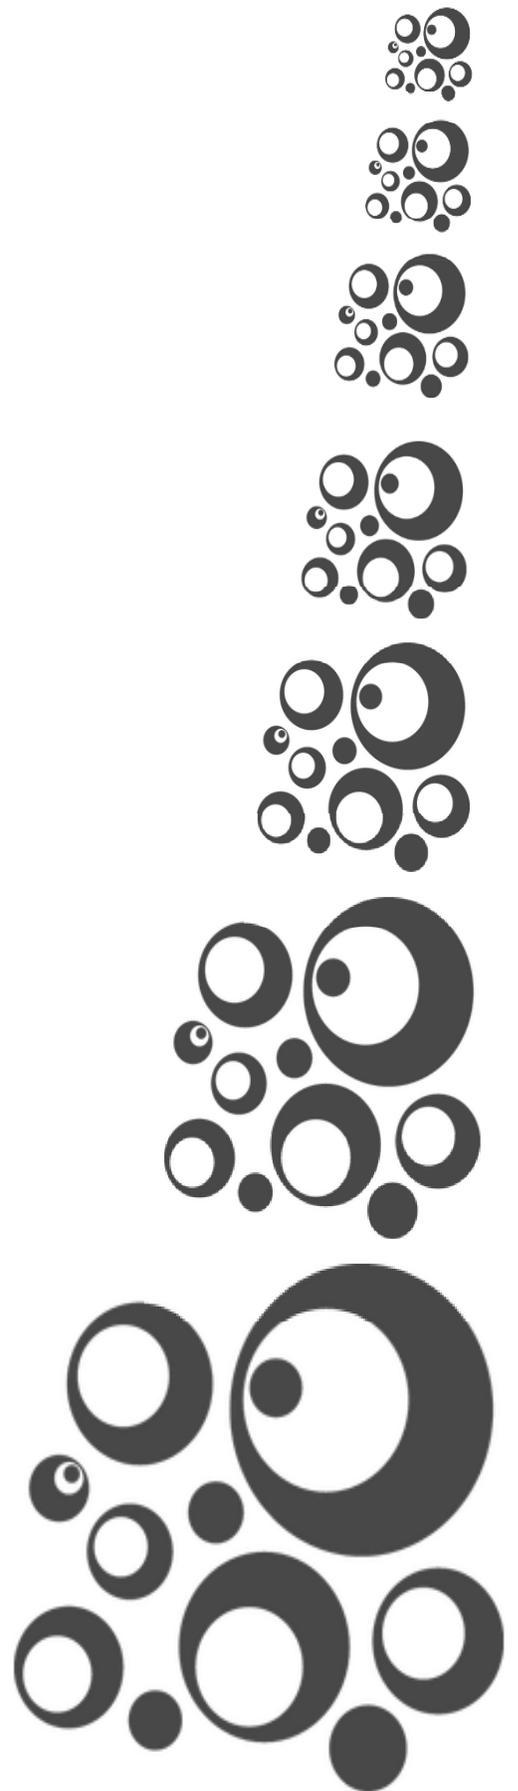
- Liu, M., Fan, D., Zhang, X., & Gong, X. (2017). Human Emotion Recognition Based on Galvanic Skin Response Signal Feature Selection and SVM. *Proceedings - 2016 International Conference on Smart City and Systems Engineering, ICSCSE 2016*, 157–160. <https://doi.org/10.1109/ICSCSE.2016.0051>
- Liu, Y. (1965). Python Machine Learning By Example. In P. Publishing (Ed.), *The British Journal of Psychiatry* (Vol. 111). <https://doi.org/10.1192/bjp.111.479.1009-a>
- Madera-carrillo, H., Zarabozo, D., Ruiz-díaz, M., & Berriel-saez, P. (2015). El Sistema Internacional de Imágenes Afectivas ( IAPS ) en población mexicana.
- Mahesh, B., Prassler, E., Hassan, T., & Garbas, J. U. (2019). Requirements for a Reference Dataset for Multimodal Human Stress Detection. *2019 IEEE International Conference on Pervasive Computing and Communications Workshops, PerCom Workshops 2019*, 492–498. <https://doi.org/10.1109/PERCOMW.2019.8730884>
- Manzano Patiño, A. P. (2018). Introducción a los modelos de ecuaciones estructurales. *Investigación En Educación Médica*, 7(25), 67–72. <https://doi.org/10.1016/j.riem.2017.11.002>
- Mehmood, R. M., Du, R., & Lee, H. J. (2017). Optimal feature selection and deep learning ensembles method for emotion recognition from human brain EEG sensors. *IEEE Access*, 5, 14797–14806. <https://doi.org/10.1109/ACCESS.2017.2724555>
- Miranda Correa, J. A., Abadi, M. K., Sebe, N., & Patras, I. (2018). AMIGOS: A Dataset for Affect, Personality and Mood Research on Individuals and Groups. *IEEE Transactions on Affective Computing*, 3045(i), 1–14. <https://doi.org/10.1109/TAFFC.2018.2884461>
- Nielsen, J. (1994). Usability inspection methods. *Conference on Human Factors in Computing Systems - Proceedings, 1994-April*, 413–414. <https://doi.org/10.1145/259963.260531>
- Nielsen, J., & Molich, R. (1990). Heuristic evaluation of user interfaces. *Conference on Human Factors in Computing Systems - Proceedings, (April)*, 249–256. <https://doi.org/10.1145/97243.97281>
- Pacholczyk, D. (2015). UX DESIGN PROCESS & DOCUMENTATION (Vol. 3). Retrieved from <https://www.uxpin.com/studio/ebooks/guide-to-ux-design-process-and-documentation/>
- Park, B. J., Yoon, C., Jang, E. H., & Kim, D. H. (2017). Physiological signals and recognition of negative emotions. *International Conference on Information and Communication Technology Convergence: ICT Convergence Technologies Leading the Fourth Industrial Revolution*,

- ICTC 2017, 2017-Decem, 1074–1076. <https://doi.org/10.1109/ICTC.2017.8190858>
- Pierre-Majorique Léger, Francois Courtemanche, Marc Fredette, S. S. (2015). A Cloud-Based Lab Management and Analytics Software for Triangulated Human-Centered Research. [https://doi.org/10.1007/978-3-030-01087-4\\_11](https://doi.org/10.1007/978-3-030-01087-4_11)
- Prasad, D. K., Liu, S., Chen, S. H. A., & Quek, C. (2018). Sentiment analysis using EEG activities for suicidology. *Expert Systems with Applications*, 103, 206–217. <https://doi.org/10.1016/j.eswa.2018.03.011>
- Real Academia de Ingeniería. (2020). Diccionario Español de Ingeniería. Retrieved from <http://diccionario.raing.es/es/lema/filtro-paso-bajo>
- Sánchez, W. (2011). La usabilidad en Ingeniería de Software : definición y características. In *Innovación. Reporte de investigación*. Retrieved from [http://www.redicces.org.sv/jspui/bitstream/10972/1937/1/2. La usabilidad en Ingeniería de Software- definicion y características.pdf](http://www.redicces.org.sv/jspui/bitstream/10972/1937/1/2.La%20usabilidad%20en%20Ingenieria%20de%20Software-%20definicion%20y%20caracteristicas.pdf)
- Savran, A., Ciftci, K., Chanel, G., Mota, J. C., Viet, L. H., Sankur, B., ... Rombaut, M. (2006). Emotion Detection in the Loop from Brain Signals and Facial Images. *ENTERFACE*, 06(January), 69–80.
- Scherer, K. R. (2005). What are emotions? and how can they be measured? *Social Science Information*, 44(4), 695–729. <https://doi.org/10.1177/0539018405058216>
- Schrepp, M., Otten, R., Blum, K., & Thomaschewski, J. (2021). What causes the dependency between perceived aesthetics and perceived usability? *International Journal of Interactive Multimedia and Artificial Intelligence*, 6(6), 78–85. <https://doi.org/10.9781/ijimai.2020.12.005>
- Shumailov, I., & Gunes, H. (2018). Computational analysis of valence and arousal in virtual reality gaming using lower arm electromyograms. 2017 7th International Conference on Affective Computing and Intelligent Interaction, ACII 2017, 2018-Janua, 164–169. <https://doi.org/10.1109/ACII.2017.8273595>
- Sidney Burus, C., Gopinath, R. A., & Guo, H. (1998). *Introduction to Wavelets and Wavelet Transforms: A Primer*.
- Soleymani, M., Lichtenauer, J., Pun, T., & Pantic, M. (2012). A multimodal database for affect recognition and implicit tagging. *IEEE Transactions on Affective Computing*, 3(1), 42–55. <https://doi.org/10.1109/T-AFFC.2011.25>

- Song, T., Zheng, W., Lu, C., Zong, Y., Zhang, X., & Cui, Z. (2019). MPED: A multi-modal physiological emotion database for discrete emotion recognition. *IEEE Access*, 7, 12177–12191. <https://doi.org/10.1109/ACCESS.2019.2891579>
- Soriano Terrazas, J. (2018). Metodología para caracterizar e inducir estados cognitivos y emocionales mediante realidad virtual inmersiva. Centro Nacional de Investigación y Desarrollo Tecnológico.
- Suhaimi, N. S., Yuan, C. T. B., Teo, J., & Mountstephens, J. (2018). Modeling the affective space of 360 virtual reality videos based on arousal and valence for wearable EEG-based VR emotion classification. *Proceedings - 2018 IEEE 14th International Colloquium on Signal Processing and Its Application, CSPA 2018, (March)*, 167–172. <https://doi.org/10.1109/CSPA.2018.8368706>
- The Standish Group. (2020). *Chaos Report 2020 : Beyond Infinity Overview*. Retrieved from <https://standishgroup.myshopify.com/collections/frontpage/products/premium-membership-and-chaos-report>
- Torres Valencia, C. A. (2013). Desarrollo de una metodología para el reconocimiento de emociones basado en un enfoque multimodal mediante la extracción y selección discriminante de características. Retrieved from <http://repositorio.utp.edu.co/dspace/bitstream/handle/11059/3820/6213822T693.pdf?sequence=1>
- unesco. (2013). Clasificación Internacional Normalizada de la Educación (CINE) 2011. In *Clasificación Internacional Normalizada de la Educación (CINE) 2011*. <https://doi.org/10.15220/978-92-9189-129-0-spa>
- Universidad de Alicante, D., Psicología, D., & Salud. (2007). *La Emoción*. Retrieved from <http://www.psb.ua.es>
- Universidad de Zaragoza, E. (2001). *Manual de Técnicas para el Diseño Participativo de Interfaces de Usuario de Sistemas basados en Software y Hardware*. Retrieved from [http://www.disenomovil.mobi/multimedia\\_un/01\\_intro\\_ux/alejandro\\_florian\\_que\\_es\\_ux.pdf](http://www.disenomovil.mobi/multimedia_un/01_intro_ux/alejandro_florian_que_es_ux.pdf)
- Valderrama, C. E. (2016). Análisis Espectral de parámetros fisiológicos para la detección de emociones en el consumidor. Retrieved from [https://www.researchgate.net/publication/303471081\\_Analsis\\_espectral\\_de\\_parametros\\_fisiologicos\\_para\\_la\\_deteccion\\_de\\_emociones\\_en\\_el\\_consumidor](https://www.researchgate.net/publication/303471081_Analsis_espectral_de_parametros_fisiologicos_para_la_deteccion_de_emociones_en_el_consumidor)

- Vila, J., & Sanchez, M. (2001). El Sistema Internacional de Imágenes Afectivas (IAPS): Adaptación española. Segunda parte. *Revista de Psicología General y Aplicada*, (March 2015). <https://doi.org/233721592>
- Wang, X. H., Zhang, T., Xu, X. M., Chen, L., Xing, X. F., & Chen, C. L. P. (2019). EEG Emotion Recognition Using Dynamical Graph Convolutional Neural Networks and Broad Learning System. *Proceedings - 2018 IEEE International Conference on Bioinformatics and Biomedicine, BIBM 2018*, 1240–1244. <https://doi.org/10.1109/BIBM.2018.8621147>
- Wiley, J. F. (1965). R Deep Learning Essentials. In P. Publishing (Ed.), *The British Journal of Psychiatry* (Vol. 111). <https://doi.org/10.1192/bjp.111.479.1009-a>
- Xu, H., & Plataniotis, K. N. (2017). Affective states classification using EEG and semi-supervised deep learning approaches. *2016 IEEE 18th International Workshop on Multimedia Signal Processing, MMSP 2016*, 1–6. <https://doi.org/10.1109/MMSP.2016.7813351>
- Yang, B., Han, X., & Tang, J. (2018). Three class emotions recognition based on deep learning using staked autoencoder. *Proceedings - 2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics, CISP-BMEI 2017*, 2018-Janua, 1–5. <https://doi.org/10.1109/CISP-BMEI.2017.8302098>
- Yang, Y., Wu, Q., Qiu, M., Wang, Y., & Chen, X. (2018). Emotion Recognition from Multi-Channel EEG through Parallel Convolutional Recurrent Neural Network. *Proceedings of the International Joint Conference on Neural Networks*, 2018-July, 1–7. <https://doi.org/10.1109/IJCNN.2018.8489331>
- Yin, Z., Zhao, M., Wang, Y., Yang, J., & Zhang, J. (2017). Recognition of emotions using multimodal physiological signals and an ensemble deep learning model. *Computer Methods and Programs in Biomedicine*, 140, 93–110. <https://doi.org/10.1016/j.cmpb.2016.12.005>
- Zheng, W. L., Zhu, J. Y., Peng, Y., & Lu, B. L. (2014). EEG-based emotion classification using deep belief networks. *Proceedings - IEEE International Conference on Multimedia and Expo, 2014-Septe(Septmber)*, 1–6. <https://doi.org/10.1109/ICME.2014.6890166>

# Anexos



# Anexo1: Guía para preparar pruebas de Evaluación de la Experiencia de Usuario (UX)

## Objetivo

Explicar las condiciones, requisitos y prerrequisitos para realizar pruebas de evaluación de la experiencia de usuario y para la recolección de los datos durante la ejecución tanto ambientales, de ergonomía y condiciones para que el usuario sea viable para la ejecución de pruebas.

### Consideraciones ambientales y área de pruebas:

- Se recomienda utilizar una habitación aislada de ruido e interferencias de personas.
- Se recomienda que el usuario que realizará la evaluación sea el único presente en el espacio/lugar para realiza la prueba/evaluación.
- Se recomienda evitar todo ruido externo o interno que distraiga al usuario.
- Se recomienda que la temperatura ambiente mínima sea de 22°C.
- Se recomienda utilizar la misma silla con descansabrazos para todas las evaluaciones.
- Se recomienda controlar el ambiente externo al área de pruebas para evitar ruido o sonidos que distraigan al usuario.
- Se recomienda garantizar un nivel de luz apropiado y controlado.
- El evaluador debe evitar el contacto físico o visual con el usuario durante la prueba.
- Para el monitoreo de la grabación del usuario el evaluador deberá utilizar otro monitor o computadora de ser necesario.

### Consideraciones de software:

- Tener instalado y funcionando el programa Eyewidget.
- Tener instalado y funcionando el programa UXLab grabador
- Tener instalado y funcionando el programa UXLab reproductor
- Tener instalado y funcionando el producto digital a evaluar.

### Consideraciones de hardware:

- Se debe utilizar una pantalla entre las 22 a 32 pulgadas.
- La pantalla debe tener de preferencia una resolución de 1920 x 1080 pixeles.
- Se debe ajustar la intensidad de brillo del monitor para que sea cómodo para el sujeto de pruebas.
- Para el sensor de seguimiento ocular la distancia entre recomendada debe ser entre 45 a 100 centímetros, los ojos del usuario deben estar de frente al sensor, evitar el uso de lentes.
- Verificar que no se encuentre un modem, router, antena, etc., en la misma habitación donde se realizarán las pruebas, para evitar que los sensores fisiológicos reciban campos magnéticos externos.

- Para los sensores de recopilación de datos fisiológicos se debe tomar en cuenta las siguientes consideraciones:
  - » Para el uso adecuado del BCI EMOTV Flex se recomienda medir el diámetro encefálico del usuario, se cuentan con tres medidas: 54, 56 y 58 cms.
  - » Realizar una carga completa del BCI EMOTV Flex antes de realizar las pruebas.
  - » Verificar que no estén dañados los electros, las terminales de conexión y cables de los diferentes sensores.
  - » Verificar en la pantalla del software UXLab que el sensor ECG esté correctamente conectado y recibiendo datos fisiológicos.
  - » Verificar en la pantalla del software UXLab que el sensor GSR esté correctamente conectado y recibiendo datos fisiológicos.
  - » Verificar en la pantalla del software UXLab que el sensor de seguimiento ocular esté correctamente conectado y recibiendo datos.
  - » Verificar en la pantalla del software UXLab que la cámara de video está captando la cara del usuario esté correctamente conectado y recibiendo datos.

**Notas:**

- ✓ Tomar en cuenta que el tiempo aproximado para poner en funcionamiento la BCI EMOTIV Flex es de entre 25 y 30 minutos.
- ✓ Al momento de colocar el EMOTIV Flex validar todos los electrodos tengan la cantidad suficiente de gel conductor, en caso de ser necesario colocar más, puede ser con un cotonete o con un aplicador con boquilla adecuada para aplicarlo directamente en los electrodos.
- ✓ Al terminar cada una de las pruebas, es necesario realizar la limpieza de los electrodos con un paño seco o papel absorbente.

**Consideraciones del sujeto de prueba:**

- Previo a realizar las pruebas, al usuario se le debieron aplicar los test definidos en la metodología UX.
- Verificar que el usuario esté de acuerdo en realizar las pruebas y de haber firmado el consentimiento de las mismas en el formato definido por la metodología.
- El usuario debe estar informado de las características y del entorno a utilizar durante las pruebas.
- Se debe solicitar al usuario que acuda a las pruebas en un lapso de dos a tres horas después del desayuno o de la comida.
- Se debe solicitar al usuario no utilizar ningún producto para el cabello antes de la prueba (gel, ceras, cremas, spray, etc.)
- Se debe solicitar al usuario que acuda a la prueba con la cabeza limpia, sin haber utilizado acondicionador para cabello.
- El cabello del usuario debe estar seco y de preferencia corto o un muy grueso.
- Tratar que el usuario se encuentre relajado y tranquilo antes de iniciar la prueba.