



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Maestría

Metodología para el preprocesamiento y clasificación
de datos fisiológicos multimodales basado en el
modelo Valencia-Excitación

presentada por

Ing. José Alberto Morales Morante

como requisito para la obtención del grado de
Maestro en Ciencias de la Computación

Director de tesis

Dr. Juan Gabriel González Serna

Codirector de tesis

Dr. Nimrod González Franco

Cuernavaca, Morelos, México. Abril de 2021.



Cuernavaca, Mor., 14/abril/2021

OFICIO No. DCC/044/2021

Asunto: Aceptación de documento de tesis

CENIDET-AC-004-M14-OFICIO

C. DR. CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial del **C. Ing. José Alberto Morales Morante**, con número de control M18CE076, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis de grado titulado **“Metodología para el Preprocesamiento y Clasificación de Datos Fisiológicos Multimodales Basado en el Modelo Valencia-Excitación”** y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

Dr. Juan Gabriel González Serna
Doctor en Ciencias de la Computación
7820329 Director de tesis

Dr. Nimrod González Franco
Doctor en Ciencias de la Computación
11088913
Co-director de tesis

Dra. Andrea Magadán Salazar
Doctora en Ciencias Computacionales 10654097
Revisor 1

Dr. Máximo López Sánchez
Doctor en Ciencias de la Computación
7498547
Revisor 2

C.c.p. Depto. Servicios Escolares
Expediente / Estudiante
JGGS/lmz





Centro Nacional de Investigación y Desarrollo Tecnológico
Subdirección Académica

Cuernavaca, Mor., 16/abril/2021
No. de Oficio: SAC/57/2021
Asunto: Autorización de impresión de tesis

JOSÉ ALBERTO MORALES MORANTE
CANDIDATO AL GRADO DE MAESTRO 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 Preprocesamiento y Clasificación de Datos Fisiológicos Multimodales Basado en el Modelo Valencia-Excitación”*, 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.

A T E N T A M E N T E

“Excelencia en Educación Tecnológica®
“Educación Tecnológica al Servicio de México”

DR. CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO



**CENTRO NACIONAL
DE INVESTIGACIÓN
Y DESARROLLO
TECNOLÓGICO
SUBDIRECCIÓN
ACADÉMICA**

C.c.p. M.E. Guadalupe Garrido Rivera. Jefa del Departamento de Servicios Escolares
Expediente
CMAZ/CHG



Interior Internado Palmira S/N, Col. Palmira, C. P. 62490,
Cuernavaca, Morelos Tel. (01) 777 3 62 77 73, ext. 4104,
e-mail: acad_cenidet@tecnm.mx
www.tecnm.mx | www.cenidet.tecnm.mx



DEDICATORIAS

Este trabajo está dedicado a mis padres Rigoberto y María por todo el apoyo y valor que me han dado siempre y los esfuerzos que han realizado para contribuir con mi desarrollo profesional. De igual forma a mi hermano quien ha sido siempre un amigo de confianza. Y por último a mi padrino quien fue siempre un apoyo incondicional.

AGRADECIMIENTOS

Agradezco al Consejo Nacional de Ciencia y Tecnología (CONACyT) por la beca y oportunidad otorgada, así como al Tecnológico Nacional de México campus Centro Nacional de Investigación y Desarrollo Tecnológico (TecNM/CENIDET) por darme un lugar para seguir progresando profesionalmente.

De la misma forma agradezco a mi Director de Tesis el Dr. Juan Gabriel González Serna por su orientación y enseñanzas que encaminaron este trabajo. A mi Codirector, el Dr. Nimrod González Franco, y mis revisores, la Dra. Andrea Magadán Salazar y el Dr. Máximo López Sánchez por el tiempo invertido, sus observaciones y corrección de esta investigación.

Resumen

El reconocimiento emocional es uno de los conceptos más importantes de la computación afectiva y como su nombre indica consiste en el pronóstico del estado anímico de las personas. Este conocimiento puede ser de utilidad en muchas áreas como la medicina, la psicología, la pedagogía, el entretenimiento y la experiencia de usuario. Incluso fuera del contexto tecnológico este objetivo siempre ha sido muy importante debido a su naturaleza, ya que las emociones son conceptos muy abstractos y complejos a simple vista. En el último siglo se han realizado muchos descubrimientos sobre su origen y utilidad, la teoría más aceptada es que las emociones son producto del sistema nervioso autónomo como mecanismo de reacción a nuestro entorno. Con esta premisa se han desarrollado métodos para intentar predecir las emociones de una persona, ya sea por medio del tono de voz, los gestos faciales y quizás el elemento más discutido, pero de mayor valor las señales fisiológicas.

El presente trabajo de tesis se centra en el análisis de emociones a través de sensores fisiológicos de tipo electroencefalografía (EEG), electrocardiografía (ECG), y respuesta galvánica en piel (GSR). Para esto se desarrolló una metodología que implementa el uso de aprendizaje automático para la predicción de emociones en base a dos propiedades relacionadas, la valencia y la excitación. Con la ayuda de repositorios de señales fisiológicas afectivas se realizó un estudio comparativo entre diferentes algoritmos de aprendizaje automático para definir un modelo superior el cual fue implementado posteriormente en la herramienta para evaluar la experiencia de usuario (UXLab). Esta herramienta permite la grabación y visualización de diferentes sensores fisiológicos y biométricos por lo que su integración le da un valor muy importante.

Para validar los avances realizados durante la investigación, se realizaron pruebas de reconocimiento emocional con la herramienta UXLab, utilizando estímulos visuales. Los resultados obtenidos fueron satisfactorios, por lo que se pudo comprobar que las señales fisiológicas son una alternativa importante para predecir emociones.

Abstract

Emotional recognition is one of the most important concepts in affective computing, it consists of forecasting the mood of people. This knowledge can be useful in many areas such as medicine, psychology, pedagogy, entertainment and user experience. Even outside the technological context, this objective has always been very important due to its nature, since emotions are very abstract and complex concepts at first glance. In the last century many discoveries have been made about its origin and utility, the most accepted theory is that emotions are a product of the autonomic nervous system as a reaction mechanism to our environment. With this premise, methods have been developed to try to predict a person's emotions, either through the tone of voice, facial gestures and perhaps the most discussed element, but with the greatest value, physiological signals.

The present thesis work focuses on the analysis of emotions through physiological sensors such as electroencephalography (EEG), electrocardiography (ECG), and galvanic skin response (GSR). For this, a methodology was developed that implements the use of machine learning for the prediction of emotions based on two related properties, valence and arousal. With the help of repositories of affective physiological signals, a comparative study was carried out between different machine learning algorithms to define a superior model which was later implemented in the tool to evaluate user experience (UXLab). This tool allows the recording and visualization of different physiological and biometric sensors, so its integration gives it a very important value.

To validate the advances made during the research, emotional recognition tests were performed with the UXLab tool, using visual stimuli. The results obtained were satisfactory, so it could be verified that physiological signals are an important alternative to predict emotions.

Contenido

1.	Introducción.....	14
1.1	Antecedentes	2
1.2	Planteamiento del problema	3
1.3	Objetivo.....	4
1.3.1	Objetivo general	4
1.3.2	Objetivos particulares.....	5
1.4	Justificación	5
1.5	Alcances y limitaciones	6
1.5.1	Alcances del proyecto	6
1.5.2	Limitaciones del proyecto	7
1.6	Estructura del documento	7
2.	Marco teórico	8
2.1	Señales fisiológicas	8
2.1.1	Electroencefalografía.....	8
2.1.2	Electrocardiograma	12
2.1.3	Respuesta galvánica de la piel.....	15
2.2	Emociones	18
2.2.1	Modelos emocionales.....	19
3.	Estado del arte	21
3.1	Análisis del estado del arte	21
3.1.1	Adquisición de señales.....	22
3.1.2	Preprocesamiento	24
3.1.3	Características emocionales	30
3.1.4	Selección de características.....	32

3.1.5	Predicción.....	33
3.1.6	Validación de resultados	35
3.1.7	Tabla comparativa del estado del arte	38
3.1.8	Análisis de la herramienta UXLab	40
4.	Metodología de solución	46
4.1	Preparación de repositorios	47
4.1.1	DEAP - Base de datos para análisis emocionales con señales fisiológicas.....	47
4.1.2	MAHNOB-HCI Base de datos multimodal para reconocimiento de afectos y etiquetado implícito	49
4.2	Eliminación de artefactos	51
4.3	Extracción de características	52
4.4	Clasificación.....	53
4.4.1	Análisis de componentes principales (PCA).....	54
4.4.2	Máquinas de soporte vectorial.....	55
4.4.3	Bosques aleatorios	57
4.4.4	Redes neuronales	60
4.4.5	Discusión.....	63
4.5	Implementación en UXLab.....	69
4.5.1	MySignals.....	69
4.5.2	EMOTIV FLEX.....	70
4.5.3	Mejoras generales a UXLab.....	72
4.5.4	Modificaciones en el proceso de grabación.....	72
4.5.5	Modificaciones en el proceso de reproducción.....	77
4.6	EMOLEARN.....	79
4.6.1	Funcionamiento.....	80

5.	Pruebas y resultados.....	85
5.1	Plan de pruebas.....	85
5.2	Reporte de resultados.....	85
5.2.1	Pruebas funcionales con el software UXLab.....	85
5.2.2	Pruebas funcionales con EMOLEARN.....	86
5.2.3	Pruebas de reconocimiento emocional.....	87
6.	Conclusiones.....	110
6.1	Aportaciones.....	111
6.1.1	Metodología de reconocimiento emocional.....	111
6.1.2	Desarrollo de la herramienta emolearn.....	111
6.1.3	Integración del módulo de reconocimiento emocional dentro de la plataforma UXLab.....	111
6.1.4	Publicaciones.....	112
6.2	Trabajos a futuro.....	112
7.	Referencias.....	113

Lista de figuras

Figura 1:	Formas de onda de una señal EEG.....	10
Figura 2:	Ejemplo de distribución del sistema 10/20.....	12
Figura 3:	Forma de onda de una señal ECG.....	13
Figura 4:	Diagrama de conexión de un electrocardiograma de 3 canales.....	15
Figura 5:	Posiciones recomendadas para la colocación de un sensor GSR.....	17
Figura 6:	Representación del modelo Circumplex.....	20
Figura 7:	Etapas comunes de un estudio de reconocimiento emocional.....	21
Figura 8:	Tipos de artefactos en la señal EEG.....	25
Figura 9:	Tipos de artefactos en la señal ECG.....	26
Figura 10:	Artefactos causados por fluctuación (GSR).....	27

Figura 11: Cambios discretos en la señal GSR.....	27
Figura 12: Representación de la forma de banda causada por cada filtro.	30
Figura 13: Representación de la matriz de confusión	35
Figura 14: Representación de la métrica precisión	36
Figura 15: Representación de la métrica Recall.....	37
Figura 16: Representación de la métrica Accuracy.....	38
Figura 17: Arquitectura de UXLab.....	40
Figura 18: Esquema conceptual del sistema de grabación de UXLab.	41
Figura 19: Módulo de dispositivos / UXLab.....	42
Figura 20: Visualización de sensores / UXLab.....	43
Figura 21: Integrador de grabación / UXLab.....	44
Figura 22: Reproductor de UXLab.	45
Figura 23: Arquitectura de la propuesta de solución	46
Figura 24: Proceso de grabación del repositorio DEAP	48
Figura 25: Proceso de grabación del repositorio MAHNOB.	50
Figura 26: Resultados de excitación entre repositorios.....	65
Figura 27: Resultados de excitación entre repositorios + PCA	65
Figura 28: Resultados de valencia entre repositorios	67
Figura 29: Resultados de valencia entre repositorios + PCA	68
Figura 30: Placa MySignals.....	70
Figura 31: Gorro EMOTIV EPOC FLEX.....	70
Figura 32: Nueva interfaz del módulo de dispositivos	73
Figura 33: Visualización del flujo de datos de los sensores ecg/gsr	73
Figura 34: Nueva interfaz del Integrador de grabación.	74
Figura 35: Representación de la segmentación de pruebas	75
Figura 36: Escalas emocionales	75
Figura 37: esquema conceptual del proceso de grabación de UXLab.	77
Figura 38: Elementos de la Interfaz del Reproductor UXLab	78
Figura 39: Esquema conceptual del proceso de grabación de UXLab.....	79
Figura 40: Esquema conceptual del funcionamiento de EMOLEARN.....	80
Figura 41: Menú principal de EMOLEARN.....	81

Figura 42: Sección 1: preprocesamiento (EMOLEARN)	81
Figura 43: Sección dos: extracción de características (EMOLEARN).....	82
Figura 44: Sección tres: visualizar configuración (EMOLEARN).....	83
Figura 45: Interfaz del clasificador (EMOLEARN).....	84
Figura 46: Esquemas de funcionalidades de la plataforma UXLab.....	86
Figura 47: Estímulos utilizados para las pruebas emocionales.....	87
Figura 48: Valores promedio de la encuesta SAM para alegría.....	90
Figura 49: Usuario reaccionando a estímulos de alegría.....	90
Figura 50: Valores promedio de la encuesta SAM para ansiedad.....	93
Figura 51: Usuario reaccionando a estímulos de ansiedad.....	93
Figura 52: Valores promedio de la encuesta SAM para los estímulos neutros .	96
Figura 53: Valores promedio de la encuesta SAM para tristeza.....	98
Figura 54: Usuario reaccionando a estímulos de tristeza.....	99
Figura 55: Valores promedio de la encuesta SAM para relajación.....	101
Figura 56: Usuarios reaccionando a estímulos de relajación.....	102

Lista de tablas

Tabla 1: Cuadrantes emocionales.....	19
Tabla 2: Comparación entre repositorios de señales fisiológicas.....	23
Tabla 3: Características usuales dentro de un dominio.....	32
Tabla 4: Tabla comparativa del estado del arte.....	39
Tabla 5: Componentes individuales de UXLab.....	41
Tabla 6: Características del repositorio DEAP.....	49
Tabla 7: Características del repositorio MAHNOB-HC.....	51
Tabla 8: Características del repositorio MAHNOB-HC.....	52
Tabla 9: Conjunto de características multimodales.....	53
Tabla 10: Tabla de resultados para activación con SVM.....	56
Tabla 11: Tabla de resultados para valencia con SVM.....	57
Tabla 12: Tabla de resultados para excitación con RF.....	59
Tabla 13: Tabla de resultados para valencia con RF.....	59

Tabla 14: Tabla de resultados para excitación con RN.....	62
Tabla 15: Tabla de resultados para valencia con RN.....	63
Tabla 16: Resultados de la predicción de excitación	64
Tabla 17: Resultados de la predicción de valencia	66
Tabla 18: Tabla de resultados para valencia con RN.....	71
Tabla 19: Imágenes IAPS utilizadas en el pie alegría	88
Tabla 20: Resultados obtenidos con el clasificador, estímulos de alegría	89
Tabla 21: Evaluación SAM, estímulos de alegría	89
Tabla 22: Imágenes IAPS utilizadas en el pie de ansiedad	91
Tabla 23: Resultados obtenidos con el clasificador, estímulos de ansiedad.....	92
Tabla 24: Evaluación SAM, estímulos de ansiedad	92
Tabla 25: Imágenes IAPS utilizadas en el pie para neutralidad	94
Tabla 26: Resultados obtenidos con el clasificador, estímulos neutros	95
Tabla 27: Evaluación SAM, estímulos neutros.....	95
Tabla 28: Imágenes IAPS utilizadas en el pie para tristeza	97
Tabla 29: Resultados obtenidos con el clasificador, estímulos de tristeza.....	97
Tabla 30: Evaluación SAM, estímulos de tristeza	98
Tabla 31: Imágenes IAPS utilizadas en el pie para relajación	100
Tabla 32: Resultados obtenidos con el clasificador, estímulos de relajación..	100
Tabla 33: Evaluación SAM, estímulos de relajación	101
Tabla 34: Clasificación de resultados según el alfa de Cronbach.....	102
Tabla 35: Alfa de Cronbach correspondiente a la valencia	103
Tabla 36: Alfa de Cronbach correspondiente a la valencia	104
Tabla 37: Alfa de Cronbach correspondiente al dominio.....	105
Tabla 38: Resultados de la predicción emocional.....	106
Tabla 39: Resultados de la predicción general Valencia-Excitación	107
Tabla 40: Resultados de la predicción para las clases valencia-excitación	107
Tabla 41: Resultados de la predicción de emociones, clasificador vs SAM para valencia	108
Tabla 42: Resultados de la predicción de emociones, clasificador vs SAM para excitación	109

1. Introducción

Capítulo 1. Introducción

Uno de los mecanismos más importantes que tienen los seres humanos para interactuar con su entorno son las emociones. Las emociones han sido descritas de diferentes formas con el paso del tiempo y las culturas; siendo uno de los primeros acercamientos científicos el de Charles Darwin, quien las describió como un carácter humano, heredado y con una función social comunicativa para expresar el estado de ánimo de las personas (Thanyathorn et al., 2018).

Posteriormente, el concepto ha ido transformándose conforme nuevas teorías han aparecido, actualmente muchas investigaciones han descrito a las emociones como una respuesta automática del organismo a un estímulo interno o externo (persona, situación o evento, recuerdo). Por lo general, una experiencia intensa, de corta duración y la persona suele ser muy consciente de ella (Dzedzickis, Kaklauskas y Bucinskas, 2020). Esta reacción afecta tanto al estado fisiológico y psicológico del ser humano reflejando cambios físicos. La reacción hacia una emoción siempre va acompañada de impulsos fisiológicos controlados por el sistema nervioso central y autónomo (SNC, SNA) que son relevantes para órganos y tejidos humanos como el cerebro, el corazón, piel, flujo sanguíneo, músculos, expresiones faciales, voz, etc.

La capacidad para comprender y reconocer las emociones humanas ha sido identificada como una de las áreas más importante para varios campos de investigación y podría ser una realidad gracias al entendimiento y la correcta interpretación de los procesos que se presentan en el cuerpo humano cuando una emoción viaja a través del sistema nervioso. Estos sistemas de reconocimiento emocional tienen un sinfín de aplicaciones que van desde sistemas de conducción segura, atención médica, salud mental, entornos de aprendizaje, seguridad social, entretenimiento digital multimedia, desarrollo de nuevas interfaces humano computadora (HCI) y evaluación de experiencia de usuario (UX).

Al hacer uso de los indicios emocionales de nuestro cuerpo se puede lograr que aplicaciones o dispositivos comprendan las emociones humanas utilizando sensores para capturar las diferentes fuentes bioeléctricas que produce el cuerpo humano. Conforme se ha obtenido experiencia en este campo se ha probado una gran cantidad de sensores, entre los que destacan la grabación de ondas cerebrales

mediante electroencefalograma (EEG), electrocardiograma (ECG), resistencia eléctrica en la superficie de la piel (GSR), temperatura de la piel (ST), presión de volumen sanguíneo (BVP), detección de tensión muscular en la superficie de la piel (EMG), respuesta respiratoria (RSP), etc. Sin embargo, estas señales deben de ser filtradas y procesadas previamente para poder extraer la información más importante en forma de características y con ellas desarrollar un repositorio. Este repositorio será utilizado más adelante para entrenar una máquina de aprendizaje automático la cual se encargará de la predicción emocional. La elección de este algoritmo de aprendizaje también es importante pues debe ser tomada en base a las características de las señales, el volumen del repositorio e inclusive las emociones que se aspira predecir. Por consiguiente, este trabajo de investigación se centra en crear una metodología que permita utilizar un conjunto de señales fisiológicas para poder predecir emociones por medio de *machine learning*.

1.1 Antecedentes

Dentro del grupo de investigación de Sistemas Híbridos Inteligentes del TecNM/CENIDET se ha realizado varias investigaciones que abarcan diferentes áreas relacionadas a las Interacción Humano Computadora (HCI por sus siglas en inglés) y con el uso de sensores biométricos y fisiológicos, para realizar el proceso de evaluación más de la Experiencia de Usuario (UX por sus siglas en inglés).

El primer acercamiento fue realizado por Balam (2015), quien desarrolló una investigación sobre los ritmos cerebrales, su interpretación y cómo afectan a las personas. Entre otras cosas estudió el uso y posibilidades de la Interacción Humano Computadora además de incorporar a su investigación pruebas de un sensor de electroencefalograma (EEG). El objetivo final de la investigación fue la predicción de estados mentales, se creó un pequeño corpus de señales EEG y con ayuda de las librerías propias del sensor se logró clasificar los estados de concentración y relajación.

Mas adelante Ortiz (2016) realizó una investigación relacionada a los sistemas de comunicación aumentativa y alternativa (SCAA). En este trabajo se estudiaron los problemas a los que se enfrentan las personas con discapacidades motrices y/o

de lenguaje. Con la ayuda de un sensor de electroencefalografía (EEG) y un dispositivo de seguimiento ocular (eye-tracking) se desarrolló una metodología para ayudar a expresar las ideas y pensamientos de personas con discapacidad. Además, paralelamente se realizó un estudio de reconocimiento emocional para predecir las emociones de tristeza y felicidad. Siguiendo el camino de Ortiz, González (2017) desarrolló una metodología para evaluar la Experiencia de Usuario (UX) en personas con discapacidades mediante Interfaces Cerebro Computadora (BCI por sus siglas en inglés). Con ayuda de un sensor de electroencefalografía (EEG), de técnicas de rehabilitación y técnicas de asistencia se realizó un estudio para detectar estados cognitivos, en este caso concentración y distracción. Las pruebas correspondientes se realizaron con usuarios con distintos tipos de discapacidad.

Posteriormente Fouilloux (2018) realizó una investigación para evaluar la Experiencia de Usuario (UX) a través de diferentes reacciones humanas. El resultado de este proyecto fue la herramienta UXLab capaz de grabar, sincronizar y reproducir información de electroencefalografía (EEG), *eye-tracker*, cámara web, micrófono y captura de pantalla simultáneamente, logrando sincronizar todos los datos registrados. Esta herramienta se implementó para análisis de UX a través de datos multimodales. Una de las propiedades más relevantes de UXLab es la posibilidad incluir nuevos dispositivos de monitoreo.

En el laboratorio de Sistemas Híbridos Inteligentes del TecNM/CENIDET también se desarrollaron trabajos relacionados con el análisis de emociones, Soriano (2018) demostró en su investigación que la Realidad Virtual Inmersiva (RVI) es más apta para la inducción de estados cognitivos o emocionales, pues el usuario puede aislarse del mundo real y asimilar mejor los estímulos presentados. Los resultados de este trabajo se integran de una metodología para guiar el proceso de inducción emocional y un entorno de realidad virtual para realizar el proceso.

1.2 Planteamiento del problema

La computación afectiva es un área de investigación en desarrollo debido a sus beneficios, su principal objetivo es desarrollar sistemas o dispositivos que puedan

inducir o detectar emociones (Picard, 1997). Con una sociedad cada vez más dependiente de la tecnología, dar la habilidad de reconocer y por ende actuar acorde al estado de ánimo de las personas parece brindar ventajas y ser de utilidad para muchos campos de desarrollo.

Actualmente, el reconocimiento de emociones se basa en dos grupos de datos: 1) Fisiológicos, impulsos eléctricos resultado del sistema nerviosos central, por ejemplo, la actividad electrodérmica en los dedos de la mano (GSR), la actividad eléctrica del corazón (ECG), la corriente producida por las contracciones de los músculos (EMG), las ondas cerebrales (EEG), etc. 2) Biométricos, se centran en el análisis de reacciones externas como expresiones faciales, tono de voz, postura del cuerpo, seguimiento ocular, entre otros. Sin embargo, el uso de datos biométricos no es tan efectivo debido a sus limitaciones, es poco confiable y de fácil alteración, mientras que los datos fisiológicos son información natural y no pueden ser alterables. Aun así, presentan sus propios desafíos como el hecho de que la instalación en el cuerpo es más liosa, los sensores económicamente accesibles para uso académico no son completamente confiables y deben de utilizarse en un ambiente controlado.

Por otra parte, no se debe centrar este análisis en un solo sensor, es necesario seleccionar un conjunto de señales fisiológicas para poder tener la información suficiente que requiere esta tarea, lo que conlleva al desarrollo de una metodología que describa el uso de este grupo de sensores y guie el proceso de predicción emocional por medio de algoritmos de aprendizaje automático. Esto involucra a su vez el desarrollo de una aplicación para la sincronización de señales fisiológicas, procesado y clasificación emocional, así mismo debe poseer la capacidad de visualizar los resultados del análisis.

1.3 Objetivo

1.3.1 Objetivo general

Implementar y evaluar algoritmos para el reconocimiento de emociones mediante el procesamiento y fusión de señales multimodales de

electroencefalografía (EEG), electrocardiograma (ECG) y respuesta galvánica en piel (GSR), basándose en el modelo valencia activación.

1.3.2 Objetivos particulares

- Definir un método de limpieza y filtrado por cada una de las señales fisiológicas.
- Definir un método de extracción de características para cada una de las señales fisiológicas.
- Identificar y evaluar los datasets de señales fisiológicas más utilizados para el reconocimiento de emociones.
- Evaluar el desempeño de diferentes algoritmos de clasificación.
- Comprimir los conocimientos y procesos desarrollados dentro de una aplicación.
- Implementar un escenario de pruebas para la inducción de estados emocionales aplicando realidad virtual.

1.4 Justificación

El reconocimiento emocional es un área muy prometedora pues alcanzar dicho objetivo podría ser la base para el futuro de muchas otras ramas, desde la medicina, seguridad, aprendizaje y el entretenimiento podrían aprovechar dicho conocimiento. Las emociones desempeñan un papel muy importante en la toma de decisiones, el comportamiento y nuestras comunicaciones sociales. Emociones positivas ayudan a mejorar la salud y la eficiencia laboral, mientras que las negativas pueden causar problemas de salud. Las acumulaciones a largo plazo de emociones negativas predisponen factores de depresión, que pueden llevar al suicidio en el peor de los casos (shu et al., 2018). Aplicaciones más cercanas podrían ser la mejora de las capacidades humanas como se vio con Ortiz (2016) o la evaluación de la experiencia de usuario (UX) pues analizar el estado de ánimo de una persona mientras interactúa con una aplicación, video o inclusive anuncios podría hablar mucho sobre el vínculo que causará con el público general.

Sin embargo, los métodos tradicionales de reconocimiento emocional (gestos y voz) han presentado muchas limitaciones y por ende poca confianza, aun así, son los más utilizados; actualmente en el mercado existen herramientas comerciales (Afectiva, 2018) que proveen este servicio. Por otra parte, la información más confiable son las señales fisiológicas, las cuales son útiles para el reconocimiento de emociones porque, a diferencia de otras señales, generalmente son independientes de la voluntad de las personas y no pueden ser controladas. Lo que podría solucionar los inconvenientes de los métodos tradicionales y mejorar su precisión. De la misma forma ya existe software que mediante datos fisiológicos (imotions, 2016) valoran la experiencia que tiene el público hacia un producto, proceso o servicio. De manera que generan retroalimentación y la ofrecen como servicio.

1.5 Alcances y limitaciones

A continuación, se presentan los alcances y limitaciones del proyecto de tesis propuesto.

1.5.1 Alcances del proyecto

- Se utilizaron sensores de electroencefalografía, electrocardiograma y respuesta galvánica en piel comerciales.
- Se desarrolló un método y software para guiar el proceso de preparación de las señales, extracción de características y desarrollo de datasets.
- La predicción de emociones se basó en el modelo valencia activación.
- Se realizó una comparación de desempeño entre los siguientes tres algoritmos de aprendizaje automático: SVM, RF, RN.
- El modelo de mejor rendimiento fue implementado dentro del software UXLab para predecir estados emocionales.
- Se desarrolló una aplicación en python para la construcción de datasets de pruebas.

- Se desarrolló un escenario de pruebas utilizando imágenes como estímulo emocional.

1.5.2 Limitaciones del proyecto

- No se propondrán estímulos emocionales.
- No se desarrollará algún nuevo algoritmo de aprendizaje.

1.6 Estructura del documento

El presente documento de tesis consta de 7 capítulos, los cuales explican de forma ordenada las etapas del desarrollo de esta investigación. Con esta sección se finaliza el capítulo de introducción donde se exponen los motivos y objetivos de la investigación. En el capítulo 2 se describen los fundamentos más significativos y necesarios para que el lector pueda comprender la información presentada y en el capítulo 3 se presenta una recopilación de los trabajos más relevantes con relación al tema propuesto. El capítulo 4 describe la metodología utilizada para resolver el problema planteado anteriormente y el capítulo 5 establece el plan de pruebas que lo complementa, los resultados obtenidos son discutidos en el capítulo 6. Finalmente, en el capítulo 7 se encuentran las referencias de este trabajo.

2. Marco teórico

En este capítulo se presentan los conceptos fundamentales en los cuales se basa el contenido del documento.

2.1 Señales fisiológicas

El sistema nervioso se divide en dos partes: el Sistema Nervioso Central (SNC) y el Sistema Nervioso Periférico (SNP). El SNP consta de los Sistemas Nervioso Autónomo (SNA) y del Sistema Nervioso Somático (SNS). El SNA está compuesto por neuronas sensoriales y motoras, que operan entre el SNC y varios órganos internos, como el corazón, los pulmones, las vísceras y las glándulas.

Dichas neuronas experimentan cambios transitorios en su conductancia en respuesta a impulsos despolarizantes, produciéndose un impulso de potencial intracelular denominado potencial de acción. Este fenómeno, que tiene como origen un intercambio iónico (proceso químico), desencadena un bioseñal de carácter puramente eléctrico “señal fisiológica” (Colomer, Naranjo, Guixeres y Alcañiz, 2018). Las señales fisiológicas responden al SNC y al SNA del cuerpo humano según el órgano o sistema de origen.

2.1.1 Electroencefalografía

El electroencefalograma (EEG) es una herramienta para monitorear la actividad cerebral mediante pequeños discos metálicos (electrodos) fijados sobre el cuero cabelludo. La señal de EEG es una de las señales fisiológicas más importantes al ser un reflejo directo de la actividad cerebral y juega un papel crucial en el estudio de los fenómenos fisiológicos del cerebro humano. En áreas como medicina se pueden realizar diagnósticos a ciertas enfermedades al analizar su comportamiento y en neuroingeniería, las personas discapacitadas pueden controlar sillas de ruedas o brazos robóticos mediante la clasificación de sus patrones.

Las señales de EEG contienen mucha información sobre las actividades psicofisiológicas, pues reflejan la actividad eléctrica de una población de neuronas en la región del cerebro donde se coloca el electrodo de medición. Analizar esta información ayuda a entender los cambios funcionales y fisiológicos del sistema

nervioso central (SNC) y a su vez comprender los cambios en las emociones (Jianhua, Zhong, Peng y Stefano, 2020). Estas señales no se pueden manipular ni falsificar para simular un estado emocional, por lo que brindan información confiable. Estudios previos han demostrado que las emociones tienen un atributo de memoria a corto plazo, es decir, las emociones continuarán durante algún tiempo hasta el próximo estímulo emocional, y este fenómeno se puede medir utilizando la electricidad cerebral (Khosrowabadi, Wahab, Ang y Baniasad, 2009).

Muchas investigaciones han informado sobre la relación entre áreas específicas del cerebro y estados emocionales. Varios estudios confirman que las bandas de frecuencia están relacionadas con las respuestas afectivas. Se puede encontrar que los ritmos altos, como el ritmo *beta* β y *gamma* γ son buenos para reconocer las emociones de valencia, y los ritmos bajos, como el ritmo *theta* θ , funcionan bien en el reconocimiento de las emociones de excitación. Yan, J., Chen, S., & Deng, S. (2019). Además, las ondas *alpha* α en la parte frontal pueden relacionarse con ansiedad o emociones similares (Demerdzieva, y Popjordanova, 2015). Sin embargo, decodificar el EEG y relacionar estas señales con una emoción específica es un problema complejo. Los estados afectivos no tienen un mapeo simple con estructuras cerebrales específicas porque diferentes emociones activan las mismas ubicaciones cerebrales o, por el contrario, una sola emoción puede activar varias estructuras (Torres, Torres, Hernández y Yoo, 2020).

2.1.1.1 Ritmos cerebrales

El rango de frecuencia de las señales de EEG es generalmente de 0,5 a 100 Hz, pero la banda de frecuencia más relevante para la cognición es el rango de baja frecuencia de 0,5 a 30 Hz. Normalmente, los investigadores lo dividen en cinco bandas de frecuencia (ver figura 1), cada una de las cuales corresponde a una función cognitiva diferente. El análisis de la onda *delta* se descartó al considerarse intrascendente para el propósito de esta investigación. A continuación, se describen algunas características de las ondas de frecuencia de una señal EEG.

- Onda *gamma* γ (> 30 Hz): Las ondas *gamma* juegan un papel importante en las actividades cognitivas del cerebro. También se relacionan con funciones de alto

nivel, como la recepción, transmisión, procesamiento, integración y retroalimentación de información además de actividades que requieren concentración.

- Onda *beta* β (13–30 Hz): Cuando el SNC está en un estado de tensión, la amplitud de la onda *alpha* se reduce mientras que su frecuencia aumenta y esta se convierte gradualmente en una onda Beta. Su aparición suele implicar que la corteza cerebral se encuentra en un estado excitado.
- Onda *alpha* α (8–13 Hz): Ocurre principalmente cuando una persona está en estado de reposo con los ojos cerrados. Las ondas *alpha* pueden reducirse significativamente o incluso desaparecer ante algunos estímulos externos, como estímulos auditivos o visuales, o cuando las personas están realizando alguna actividad mental.
- Onda *theta* θ (4–8 Hz): Se genera cuando una persona está relajada, lo que indica que el SNC se encuentra en estado de inhibición. Por lo general, se asocia con la carga de la memoria de trabajo y puede ayudar a las personas con memoria profunda y a largo plazo.
- Onda *delta* Δ (1 a 4 Hz): Suele generarse en la corteza frontal cuando la persona está en estado de sueño, falta de oxígeno o está anestesiado.

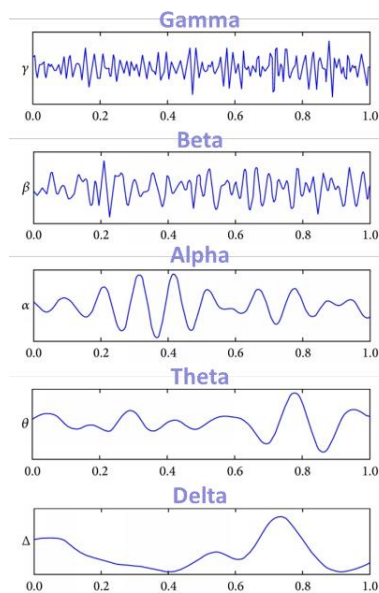


Figura 1: Formas de onda de una señal EEG.

La ilustración es extraída de Jirayucharensak et al. 2014. EEG-Based Emotion Recognition Using Deep Learning Network with Principal Component Based Covariate Shift Adaptation

2.1.1.2 Adquisición

Los sensores de electroencefalografía (EEG) consisten en cintas, diademas o gorros para la cabeza que poseen un número de electrodos que van desde 1 a 256. Donde a mayor número de electrodos mejor la calidad de la información recibida, sin embargo, este aspecto también depende de la calidad del material del dispositivo. En el mercado ha surgido una gran variedad de dispositivos EEG lo que ha elevado el número de investigaciones relacionadas a la actividad cerebral y sus procesos.

Debido a la sensibilidad de los electrodos, se requiere que los usuarios estén inmóviles cuando se inicia el procedimiento de recolección de la señal, ya que cualquier pequeño movimiento del cuerpo o de la cabeza puede separar accidentalmente los electrodos del cuero cabelludo y requerir volver a unirlos u ocasionar una señal muy contaminada, lo que podría resultar en pérdida de tiempo. Sin importar el número de electrodos, estos deben colocarse en conjuntos estandarizados de ubicaciones en el cráneo. Uno de estos conjuntos estandarizado es el sistema internacional 10/20, el cual se ha mantenido como un estándar para la colocación de electrodos desde su postulación en Jasper (1958).

Este sistema describe las ubicaciones de los electrodos a través de distancias relativas entre puntos de referencia craneales sobre la superficie de la cabeza. Los puntos de partida son el Nasión, la abolladura en la parte superior de la nariz y el Inión, que es la protuberancia ósea en la parte posterior del cráneo. Hay una línea vertical imaginaria desde el Nasión hasta el Inión, y una línea horizontal desde el lóbulo de la oreja izquierda hacia la derecha. Desde el 10% por encima del Nasión y el Inión, a lo largo de la línea vertical, se dibuja un círculo teórico alrededor de la cabeza, de ahí el 10 en el nombre. Los otros electrodos se colocan manteniendo una distancia entre electrodos del 20%, como lo indica el 20. Un ejemplo de esta distribución se muestra en la figura 2.




Figura 2: Ejemplo de distribución del sistema 10/20
 La ilustración es extraída de Bos, 2006. EEG-based Emotion Recognition The Influence of Visual and Auditory Stimuli.

2.1.2 Electrocardiograma

El electrocardiograma (ECG) es el registro de la actividad eléctrica del corazón medida normalmente entre dos puntos de la superficie del cuerpo. La señal ECG es muy valiosa pues ayuda a comprender los cambios fisiológicos del corazón bajo diferentes situaciones. Se ha utilizado para detectar varias dolencias, incluidas enfermedades cardíacas, arritmias y epilepsia. Además, se han aplicado para evaluar condiciones mentales, psicológicas y diversas investigaciones sugieren una fuerte correlación entre la actividad cardiovascular y las emociones, ya que es pueden influir en el sistema nervioso autónomo que controla el ritmo de los latidos del corazón (Pritam y Sarkar, 2020).

Al ser la actividad de las cámaras cardíacas rítmica y totalmente ordenada, la forma de onda obtenida es regular. En ella se reconocen fácilmente diversas ondas cuyas amplitudes, duraciones y morfología están bien definidas. En general, las señales de ECG constan de tres ondas principales, como se ilustra en la figura 3. La primera onda es la onda P, que indica la despolarización de la aurícula. La segunda onda es la onda QRS, que corresponde al inicio de las contracciones ventriculares. Después de que los ventrículos hayan permanecido contraídos

durante algunos milisegundos, aparece la tercera onda T. Esta onda se produce cuando el ventrículo se repolariza. Existe una cuarta onda U, a menudo no observable, se debe a potenciales residuales del músculo ventricular y a la repolarización lenta de los músculos papilares.




Figura 3: Forma de onda de una señal ECG

La ilustración es extraída de Libelium, 2019. MySignals SW eHealth and Medical IoT Development Platform Technical Guide.

2.1.2.1 Frecuencia cardíaca

Para extraer información útil de los latidos del corazón, se han utilizado diferentes métodos de estudio, siendo el análisis de variabilidad de la frecuencia cardíaca (Heart Rate Variability - HRV) uno de los procesos más utilizados para la extracción de características del ECG. Su importancia clínica se hizo evidente a finales de la década de 1980, cuando se confirmó que era un predictor de mortalidad después de un infarto agudo de miocardio y se presentó evidencia de su relación con algunos cambios fisiológicos (Marek, 1996).

El análisis de la HRV estudia la variación del tiempo entre los latidos del corazón, siendo considerada como una medida regulada por el sistema nervioso autónomo (Quintana et al., 2020). Para calcular el índice de HRV es necesario detectar cada


latido dentro de un periodo de tiempo por lo regular con un algoritmo de detección de posición QRS. Después de eso, las posiciones R detectadas (picos R) se utilizan para calcular las variaciones del intervalo RR (distancia en milisegundos entre cada pico R) de la onda del ECG.

El método de análisis de la HRV puede tratarse bajo dos dimensiones: análisis en el dominio del tiempo y análisis en el dominio de la frecuencia, sin embargo, también es común el análisis basado en métodos geométricos. En primer lugar, el análisis en el dominio del tiempo se relaciona con un conjunto de características estadísticas extraídas de la serie de tiempo del HRV. En segundo lugar, el análisis del dominio de la frecuencia se refiere a una colección de características extraídas a través de bandas de alta frecuencia (HF – High Frequency 0,15 a 0,4 Hz), baja frecuencia (LF - Low Frequency 0,04 a 0,15 Hz) y de muy baja frecuencia (VLF – Very Low Frequency 0,0033 a 0,04 Hz). El análisis de base geométrica se asocia con un conjunto de características obtenidas de las gráficas geométricas de Poincaré (Dissanayake, Rajapaksha, Ragel y Nawinne, 2019).

Diversas investigaciones han explorado la HRV y su relación con diferentes modelos emocionales como Shu et al. (2020) quienes analizaron la señal de una pulsera con fotopletimografía y obtuvieron éxito al predecir emociones de felicidad y tristeza, o Ferdinando et al. (2016) quienes pudieron predecir niveles de valencia y activación con la ayuda de señales de un sensor ECG.

2.1.2.2 Adquisición

Para adquirir señales de ECG, se colocan electrodos en la superficie de la piel. Las configuraciones de sensor más comunes incluyen sistemas de 12 conductores, de cinco conductores, de tres conductores (figura 4) o de un solo canal, estos electrodos capturan la señal eléctrica la cual es interpretada posteriormente como ondas PQR.



*Figura 4: Diagrama de conexión de un electrocardiograma de 3 canales
La ilustración es extraída de Libelium, 2019. MySignals SW eHealth and Medical IoT Development Platform Technical Guide*

La desventaja de utilizar electrodos para medir el electrocardiograma es que el sujeto puede sentirse incómodo con los electrodos debido a que están en contacto directo con la piel.

2.1.3 Respuesta galvánica de la piel

La respuesta galvánica de la piel (GSR), también conocida como actividad electrodérmica (EDA) o conductancia de la piel (SC), es una medición continua de los parámetros eléctricos de la piel humana. El principio detrás del funcionamiento de este sensor es medir la resistencia eléctrica de la piel basada en el sudor producido por el cuerpo.

El análisis de la señal GSR es uno de los métodos más utilizados para reconocer estados emocionales, especialmente para las relacionadas con la excitación. Muchos estudios a lo largo de los años han indicado que el cambio en la conductancia en la piel y el nivel de excitación están casi linealmente asociadas (Liu, Fan, Zhang y Gong, 2016). La señal GSR es el resultado de la superposición de dos componentes principales, los componentes tónico y fásico. La señal tónica es el componente de variación lenta que representa el estado psicofisiológico general de un sujeto. El componente fásico representa las variaciones rápidas

influenciadas por las emociones y el nivel de excitación. Fásico y tónico se basan en diferentes mecanismos neuronales y, en consecuencia, ambos transmiten información relevante y no redundante sobre la actividad del sistema nervioso autónomo (Greco, 2019). Por ejemplo, cuando un sujeto se sobresalta o experimenta ansiedad, habrá un rápido aumento de la conductancia de la piel debido al aumento de la actividad de las glándulas sudoríparas (Goshvarpour et al., 2017).

El comportamiento eléctrico de la piel no está bajo el control consciente de las personas ya que, según la teoría tradicional, dependen de la variación de la reacción del sudor, que refleja cambios en el sistema nervioso simpático (Udovicic, Derek, Russo y Sikora, 2017).

2.1.3.1 Análisis de la señal


Dado que una señal GSR contiene información útil relacionada con su amplitud y frecuencia, por lo general, se analiza en los dominios de tiempo y frecuencia mediante la aplicación de diversas técnicas de extracción de características (Shukla et al., 2019).

Con respecto a las características del dominio del tiempo, se consideran parámetros estadísticos de la señal, por ejemplo, el valor medio de la señal, la desviación estándar, la curtosis o la asimetría. En otros casos se consideran características relacionadas a eventos dentro de la señal. Las características relacionadas con eventos se refieren la definición de umbrales, con el fin de restringir el análisis solo a respuestas no despreciables, y descartando aquellos pequeños cambios en la señal que no alcanzan los umbrales y por lo tanto no son relevantes. Ejemplos de estas características son el conteo de picos, el tiempo medio de elevación o la proporción de valores negativos. Por otra parte, las características del dominio de la frecuencia se han centrado en el análisis de estimación de densidad espectral (PSD) por medio de diferentes técnicas como es la Transformada de Fourier rápida (FFT), o utilizando el método de Welch.

2.1.3.1 Adquisición

Los sensores GSR tienen varias ventajas en el aspecto de usabilidad pues son más adecuados y baratos para recopilar señales de una persona sin comprometer su comodidad y privacidad por lo que su uso se ha extendido en el campo del reconocimiento y la experiencia de usuario.

Los sensores de respuesta galvánica utilizan dos electrodos especiales que contienen puntos de contacto de Ag / AgCl (cloruro de plata) para conducir un pequeño voltaje a la piel y miden la conducción o resistencia de corriente en la piel. Cuando las glándulas sudoríparas se vuelven más activas, secretan humedad hacia la superficie de la piel. Eso cambia el equilibrio de iones positivos y negativos y afecta la propiedad de flujo de las corrientes eléctricas en la piel (Dzedzickis, Kaklauskas and Bucinskas, 2020). Existe una gran variedad de posibilidades para colocar electrodos (Figura 5), pero los cambios en las reacciones del sudor provocadas por estímulos emocionales, son notadas principalmente en la superficie de las manos, los dedos y las plantas (Ayata, Yaslan, y Kamasak, 2017).



*Figura 5: Posiciones recomendadas para la colocación de un sensor GSR
La ilustración es extraída de Dzedzickis, Kaklauskas y Bucinskas, 2020. Human Emotion Recognition: Review of Sensors and Methods Sensors*

2.2 Emociones

El origen y la definición de las emociones son uno de los debates más interesantes y extensos pues aún no está completamente resuelto. El primer acercamiento científico fue realizado por Charles Darwin en su obra titulada “Expresión de las Emociones en los Animales y en el Hombre” donde describe las emociones humanas como reacciones innatas y universales, las cuales son un producto de la evolución y herencia compartida con el resto de los animales. Más adelante William James y Carl Lange, desarrollaron de forma individual teoría similares sobre las emociones y su origen fisiológico. A su teoría se le conoce como James-Lange (Cannon, 1927) y establece que el sistema nervioso autónomo utiliza mecanismos fisiológicos como la aceleración del ritmo cardíaco o espasmos musculares para reaccionar a nuestras experiencias. Ya en el siglo XX Walter Cannon y Philip Bard desarrollaron una nueva teoría, aunque igualmente de forma individual y tomando como base la teoría James-Lange sobre las emociones conocida hoy en día como Cannon-Bard (Dror, 2014). Ellos destacaron que las emociones provocan dos efectos: activación de nuestras respuestas fisiológicas y la sensación de la emoción subjetiva en el cerebro provocadas por el sistema nervioso autónomo y somático. Además, sugieren que las señales fisiológicas son iguales para todas las emociones. En otros campos, como el de las ciencias sociales, existen diferentes definiciones sobre el concepto de emoción, sin embargo, no son contrarias, se considera como emoción a las reacciones de un individuo ante un estímulo interno o externo, teniendo en cuenta que éstas son subjetivas y dependen de la percepción de cada persona.

Paul Ekman menciona que hay ciertas características de las emociones básicas, como que son rasgos de herencia ya que no se pueden aprender, que mostramos las mismas emociones en la misma situación y de forma similar. Además de que expresamos patrones fisiológicos similares al reaccionar a una emoción (Nazmi, James y Jason, 2020).

2.2.1 Modelos emocionales

Ekman desarrolló uno de los modelos emocionales más influyentes pues resumió todas las emociones en solo seis: felicidad, tristeza, ira, miedo, sorpresa y disgusto (Ekman, 1972). Otros autores también desarrollaron sus propios modelos como Plutchik (1984) quien propone que hay ocho emociones básicas (alegría, confianza, miedo, sorpresa, tristeza, disgusto, ira y anticipación) descritas en un modelo de rueda situadas dependiendo de diferentes características como intensidad, antagonismo o tipología.

La mayoría de los trabajos de reconocimiento emocional ya sea con señales fisiológicas o reacciones audiovisuales, se centran en reconocer emociones concretas, por ejemplo, felicidad o tristeza, sin embargo, últimamente se ha vuelto popular utilizar el modelo Valencia-Excitación (Russell, 1980).

2.2.1.1 Modelo valencia excitación

Russell propuso representar los estados emocionales en un espacio bipolar de dos dimensiones. La dimensión horizontal, también llamada valencia, corresponde a las emociones positivas / negativas, mientras que la dimensión vertical, conocida como excitación, se corresponde con las emociones activas / inactivas. Según este concepto, las emociones pueden ser definidas en regiones dentro del plano emocional como una combinación de valencia/activación y al ubicarlas dentro de un plano cartesiano es posible clasificar cualquier tipo de emoción por medio de sus cuadrantes. En la tabla 1 se describen los cuadrantes emocionales y las emociones que se le relacionan.

Tabla 1: Cuadrantes emocionales

Valencia	Excitación	Emociones
Positiva	Alta	<i>Alerta, Excitado, Exaltado, Feliz, Satisfecho</i>
Positiva	Baja	<i>Contento, Sereno, Relajado, Calmado, Placido</i>
Negativa	Alta	<i>Tenso, Nervioso, Estresado, Molesto, Asustado</i>
Negativa	Baja	<i>Triste, Deprimido, Aburrido, Cansado, Aburrido</i>

Capítulo 2. Marco Teórico

En la figura 6 se puede apreciar el concepto general del modelo Circumplex.




Figura 6: Representación del modelo Circumplex
La ilustración es adaptada de J. Russell, 1980. *Journal of Personality and Social Psychology*.

3. Estado del arte

En este capítulo se presenta el análisis del estado del arte de las investigaciones relacionadas con el reconocimiento de emociones a través de señales fisiológicas.

3.1 Análisis del estado del arte

Durante los últimos años se ha incrementado el interés en el reconocimiento de emociones derivado de la disponibilidad de sensores fisiológicos de uso personal ya que anteriormente estos dispositivos solían ser exclusivamente para uso médico y usualmente de un tamaño considerable. Gracias a esto se han desarrollado múltiples investigaciones, cada una realizando su propia aportación en diferentes aspectos como el uso de sensores, aplicación, clasificación y nivel de resultados. Actualmente se ha establecido una estructura en común que siguen todas las investigaciones de reconocimiento emocional, en la figura 7 se puede visualizar las etapas que representan dicha estructura.




Figura 7: Etapas comunes de un estudio de reconocimiento emocional

3.1.1 Adquisición de señales

Durante esta etapa se realiza la selección de los sensores fisiológicos con los que se va a trabajar y se desarrolla un protocolo de pruebas para elaborar un repositorio o se solicita el acceso a alguno.

3.1.1.1 Protocolo de pruebas

En este protocolo se convoca un grupo de participantes quienes son utilizados para obtener las señales fisiológicas. Las pruebas suelen consistir en la conexión de los participantes a los sensores seleccionados mientras se les aísla en un ambiente tranquilo y se les solicita visualizar un conjunto de estímulos con la intención de provocar ciertas emociones o sensaciones. Durante el transcurso de la prueba se recopilan las señales fisiológicas y se etiquetan de acuerdo con el estímulo de manera que se puede tener seguridad en que dichas señales corresponden a un nivel de emoción.

Usualmente se utilizan imágenes, o videos como estímulo debido a la fuerte relación entre los recuerdos emocionales a estos recursos. Actualmente se puede encontrar una gran cantidad de repositorios con material de estímulo donde resaltan el Sistema Internacional de Imágenes Afectivas, IAPS (Lang, Bradley, y Cuthbert, 2008) y el conjunto de imágenes estandarizadas afectivas abiertas, OASIS (Kurdi, Lozano, y Banaji, 2016) debido a su enorme utilización y extenso contenido. Sin embargo, muchos trabajos han resaltado el desempeño de otro tipo de estímulos, por ejemplo, Kim y Andre (2008) encontraron que la música genera patrones de cambio con ciertas señales fisiológicas, Becerra y otros (2018) pudieron reconocer el gusto o disgusto de ciertos olores por medio del análisis del sensor EEG, inclusive se ha comprobado el efecto de tranquilidad que provoca a los musulmanes leer el Corán por medio del análisis de sensores EEG y ECG (Al-Galal, Al-Shaikhli, y Rahman, 2016). No obstante, últimamente se ha sugerido el uso de estímulos por medio de realidad virtual inmersiva debido a su capacidad de producir experiencias simuladas que crean la sensación de estar en el mundo real o en ambientes singulares. Permitiendo evaluar la interacción en entornos espaciales y con condiciones de laboratorio y aislamiento, Banaei y otros (2017) utilizaron la

electroencefalografía para estudiar los cambios en las variables valencia-excitación utilizando 17 sujetos quienes caminaron por diferentes habitaciones simuladas mediante realidad virtual. Marín-Morales y otros (2018) diseñaron cuatro salas virtuales para provocar cada una de las cuatro posibles combinaciones del modelo valencia-excitación, y mediante el registro de la electroencefalografía y electrocardiografía calcularon su precisión a través de sesenta participantes.

3.1.1.2 Bases de datos de reconocimiento emocional

El proceso de desarrollo de un repositorio de señales fisiológicas es muy importante y a la vez una tarea muy laboriosa. Afortunadamente muchos estudios se han esforzado en dar acceso a este tipo de bases de datos, recopilando señales de distintos sensores mediante pruebas sistemáticas de predicción emocional. La selección de un repositorio sobre los demás depende de las características de la investigación y otro conjunto de factores donde sobresale los sensores, el tipo de estímulo, cantidad de participantes, duración de pruebas, contexto, y anotaciones. En la tabla 2 se describen los repositorios más relevantes para el objetivo de este trabajo y las características importantes para el mismo.

Tabla 2: Comparación entre repositorios de señales fisiológicas

Trabajo	Sensores	Estímulos	# U	# P	Duración	Anotación
MAHNOB-HC (Soleymani et al., 2012).	EEG, ECG, GSR, Respiración, Temperatura. Seguimiento ocular, Audio, Video.	Video	27	20	Variable 35-117 seg.	Valencia Excitación
DEAP (Koelstra et al., 2012)	EEG, BVP (HR), EMG, GSR, Respiración, Temperatura. EOG y video.	Video - Música	32	40	1 minuto	Valencia Excitación
AMIGOS (Correa et al., 2018)	EEG, ECG, GSR. Audio y Video.	Video	40	16	250 seg.	Valencia Excitación
ASCERTAIN (Subramanian et al., 2018)	EEG, ECG, GSR. EMO	Video	58	36	Variable 51-128 seg.	Valencia Excitación

DREAMER (Katsigiannis et al., 2017)	EEG, ECG	Video	23	18	Variable 65–393 seg.	Valencia Excitación
DECAF (Abadi et al., 2015)	MEG, ECG, EMG. EOG y video.	Video - Música	30	40	1 minuto	Valencia Excitación

Nota: U = Usuarios, P = Pruebas

3.1.2 Preprocesamiento

La etapa de preprocesamiento se utiliza para limpiar las señales y mejorar su calidad, usualmente las señales fisiológicas son débiles y se contaminan de muchas formas debido a que los sensores que se utilizan suelen ser de menor calidad comparados a equipo médico profesional. Esta contaminación o ruido se le conoce como artefactos, y es la información no deseada que se combina con la señal eléctrica, a veces, creando obstáculos para un correcto análisis. Por ende, es necesario eliminarlos utilizando métodos de procesamiento de señales adecuados al origen de cada uno.

3.1.2.1 Artefactos en la señal EEG

Según muchos estudios las señales de EEG se generan desde la corteza cerebral y siempre están contaminadas por diferentes alteraciones. En el trabajo de Jiang, Bian, y Tian (2019) se describen los siguientes tipos de artefactos.

- Artefactos oculares: generan importantes alteraciones en las señales EEG. El origen de estos artefactos es el movimiento ocular y los parpadeos que pueden propagarse por el cuero cabelludo y ser registrados por la actividad del EEG. Estas señales se pueden registrar usando electrooculograma (EOG).
- Artefactos por actividad muscular: surge de diferentes grupos de músculos y pueden ser causados por cualquier actividad muscular (EMG) por ejemplo la contracción y el estiramiento, sin embargo, también se presentan cuando el sujeto habla, olfatea o traga.
- Artefactos cardíacos: son ocasionados cuando los electrodos se colocan sobre o cerca de un vaso sanguíneo y capturan el movimiento de expansión y contracción del corazón.

Es necesario el desarrollo de un proceso de filtrado y eliminación de artefactos para la correcta adquisición de la señal EEG, en la figura 8 se muestra un ejemplo de una señal EEG y el tipo de artefactos que la albergan.




Figura 8: Tipos de artefactos en la señal EEG
La ilustración es extraída de Jiang, Bian y Tian, 2019. Removal of Artifacts from EEG Signals: A Review.

3.1.2.2 Artefactos en la señal ECG

Existen principalmente cuatro tipos de artefactos encontrados en las señales de ECG: desviación de línea de base, interferencia de línea eléctrica, ruido EMG y artefactos de movimiento de electrodos (Kher, 2019).

- La desviación de la línea de base es el efecto en el que el eje de la base (eje x) de una señal parece “desviarse” o moverse hacia arriba y hacia abajo en lugar de estar recto. Esto hace que toda la señal cambie de su base normal. Se debe a electrodos inadecuados (impedancia de la piel del electrodo), al movimiento del sujeto y a la respiración (respiración). Ver figura 9-a.
- La interferencia de líneas eléctricas es generada por cualquier campo electromagnético cercano al sensor por lo que se recomienda realizar la adquisición de la señal en un ambiente aislado. Dicho ruido se caracteriza por una interferencia sinusoidal de 50 o 60 Hz. Ver figura 9-b.
- La señal ECG también se ve afectada por el ruido EMG. La presencia de ruido muscular representa un problema importante ya que oscurecen por completo la onda QRS. Ver figura 9-c.

- Los artefactos por movimiento del electrodo son causados principalmente por el estiramiento de la piel que altera la impedancia alrededor del electrodo. Ocurren principalmente en el rango de 1 a 10 Hz. En el ECG, estos artefactos se manifiestan como formas de onda de gran amplitud que a veces se confunden con complejos QRS. Ver figura 9-d.




Figura 9: Tipos de artefactos en la señal ECG
a) desviación de línea de base, b) interferencia de línea eléctrica, c) ruido EMG, d) artefactos de movimiento
Las ilustraciones son extraídas de Kher, 2019. *Signal Processing Techniques for Removing Noise from ECG Signals*.

3.1.2.3 Artefactos en la señal GSR

El GSR cambia en una magnitud de tiempo de segundos, con una frecuencia de 1Hz o menos. Por lo tanto, cualquier fluctuación constante que aparezca en la señal GSR a una frecuencia más alta puede considerarse un artefacto (Tobiipro, 2020). Los tipos más comunes son el ruido eléctrico a 50/60 Hz (figura 10).

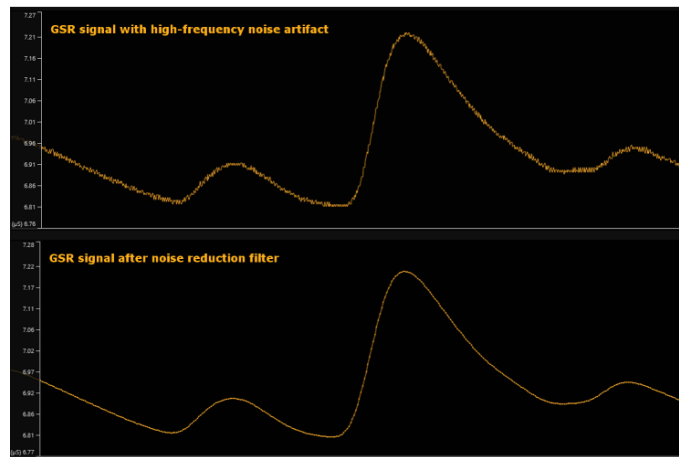


Figura 10: Artefactos causados por fluctuación (GSR)

La ilustración pertenece al sitio: GSR Artifacts <https://www.tobiipro.com/learn-and-support/learn/GSR-essentials/gsr-artifacts>.

Los cambios discretos y rápidos también pueden aparecer en una señal GSR. Estos cambios suelen ser más rápidos que la conductancia de la piel y pueden tener una amplitud variable. Un movimiento de electrodo muy rápido puede causar este tipo de artefactos (figura 11).




Figura 11: Cambios discretos en la señal GSR

La ilustración pertenece al sitio: GSR Artifacts <https://www.tobiipro.com/learn-and-support/learn/GSR-essentials/gsr-artifacts>.

3.1.2.4 Eliminación de artefactos

La limpieza y eliminación de artefactos de la señal es un proceso imprescindible, pues de este depende el correcto análisis de la señal. Por esta razón existen una

gran variedad de métodos de solución, en el estado del arte se pueden consultar diferentes procesos. Por ejemplo, el uso de wavelets para transformar la señal en dominio del tiempo al dominio de la frecuencia (Taran y Bajaj, 2019). También la transformada de Fourier de tiempo corto ha demostrado ser eficaz para remover los errores de la señal por medio del análisis de la frecuencia (Kwon, Shin, y Kim, 2018). (Yan, Chen y Deng, 2019) eludieron este proceso al utilizar el concepto de función de ventana para extraer los diferentes ritmos cerebrales directamente de la señal EEG. (Liu, Qiu, Zheng y Lu, 2019) aplicaron el análisis de correlación canónica (CCA) como una técnica de separación de fuente ciega (BSS) para separar el ruido de la señal eléctrica. Sin embargo, el método de eliminación de artefactos de mayor uso son los filtros.

En el procesamiento de señales, un filtro es un dispositivo o proceso que elimina algunos componentes o características no deseados de una señal. La característica definitoria de los filtros es la supresión completa o parcial de algún aspecto de la señal. Muy a menudo, esto significa eliminar algunas frecuencias o bandas de frecuencia. La mayoría del ruido eléctrico se puede eliminar con un filtro de paso bajo, mientras que el paso alto sirve para eliminar la tendencia de una señal, sin embargo, esto ocasiona que ésta cambie sus rangos. Para el procesamiento de señales en esta investigación se utilizaron los siguientes filtros:

Filtro de paso bajo: Este tipo de filtro tiene la función de dejar pasar todas las frecuencias desde 0 Hz hasta la frecuencia límite o frecuencia de corte (f_c) mientras que las frecuencias mayores a este límite son atenuadas (Cheveigné y Nelken, 2019). En la fórmula 1 se muestra su función de transferencia $H(s)$.

$$H(s) = A \frac{\omega c}{s + \omega c} \quad (1)$$

Donde:

s = Transformada de Laplace

A = Ganancia del filtro

ωc = Frecuencia de corte en radianes/seg.

Filtro de paso alto: Permite el paso de señales cuyas frecuencias estén comprendidas por encima de una frecuencia de corte y rechaza todas aquellas que estén entre 0 Hz y dicha frecuencia de corte (Cheveigné y Nelken, 2019). En la fórmula 2 se muestra su función de transferencia $H(s)$.

$$H(s) = A \frac{s}{s + \omega c} \quad (2)$$

Donde:

s = Transformada de Laplace

A = Ganancia del filtro

ωc = Frecuencia de corte en radianes/seg.

Filtro de paso de banda: El filtro pasa banda cumple la función de dejar pasar ciertas frecuencias, localizadas dentro de un ancho de banda determinado, y atenúa las que se encuentran fuera de este ancho. Son la frecuencia de corte inferior (f_i) y la frecuencia de corte superior (f_s) las que determinan, a partir de su posición, cuáles serán las frecuencias inferiores a f_i y mayores a f_s a atenuar (Cheveigné y Nelken, 2019). En la fórmula 3 se muestra su función de transferencia $H(s)$.

$$H(s) = A \frac{s (\omega c_2 - \omega c_1)}{s^2 + s(\omega c_2 - \omega c_1) + \omega c_2 \omega c_1} \quad (3)$$

Donde:

s = Transformada de Laplace

A = Ganancia del filtro

ω_0 = Frecuencia central en radianes/seg

ωc_2 = Frecuencia de corte mayor que ωc_1 .

ωc_1 = Frecuencia de corte menor que ωc_2 .

Filtro rechaza banda: también llamado “filtro elimina banda” o “filtro notch” este filtro elimina en su salida todas las señales que tengan una frecuencia comprendida entre una frecuencia de corte inferior (f_i) y otra de corte superior (f_s). Por tanto, estos filtros eliminan una banda completa de frecuencias. En la fórmula 4 se muestra su función de transferencia $H(s)$.

$$H(s) = A \frac{s^2 + \omega_{c2} \omega_{c1}}{s^2 + s(\omega_{c2} - \omega_{c1}) + \omega_{c2} \omega_{c1}} \quad (4)$$

Donde:

s = Transformada de Laplace

A = Ganancia del filtro

ω_0 = Frecuencia central en radianes/seg

ω_{c2} = Frecuencia de corte mayor que ω_{c1} .

ω_{c1} = Frecuencia de corte menor que ω_{c2} .

La figura 12 representa el comportamiento de cada filtro en términos de la frecuencia.




Figura 12: Representación de la forma de banda causada por cada filtro

La ilustración pertenece al sitio: Filter (signal processing) [https://en.wikipedia.org/wiki/Filter_\(signal_processing\)](https://en.wikipedia.org/wiki/Filter_(signal_processing)).

3.1.3 Características emocionales

Una vez que las señales fisiológicas son limpiadas y se eliminan las deficiencias se procede a la etapa de extracción de características. Las características son métricas que describen las propiedades de cada señal y ayudan a incrementar la información que está oculta a simple vista mediante la transformación de sus

dimensiones. Las características pueden pertenecer al dominio temporal, estadístico o espectral (frecuencia), ser lineales o no lineales y unimodales o multimodales. La mayoría de los trabajos se enfocan en el uso de características en el dominio temporal, estadístico y espectral esto debido a que son análisis relacionados a las propiedades de las señales eléctricas. Los investigadores deben elegir cuales, y cuántas características van a utilizar, diseñar el código para su cálculo y finalmente desarrollar un dataset con las características extraídas de su conjunto de señales fisiológicas. Jang y otros (2015) se centraron en el análisis de características estadísticas para predecir aburrimiento, dolor y sorpresa utilizando señales como ECG, GSR, SKT y PPG, los resultados obtenidos fueron buenos para dolor y aburrimiento y regulares para sorpresa. En (Campbell, Phinyomark, y Scheme, 2019) se utilizan características basadas únicamente en el dominio del tiempo para predecir dolor mediante señales de ECG, GSR y EMG, esto generó muy buen desempeño alcanzando hasta el 80% de precisión. El dominio con mayor relevancia en el estado del arte es el de frecuencia pues varios sensores dependen únicamente de estas características, por ejemplo, la electroencefalografía, que como se analizó anteriormente sus propiedades se esconden detrás de las ondas de frecuencia (alpha, beta, theta, delta, gamma), las cuales pueden ser analizadas por diferentes técnicas como la transformada rápida de Fourier (Murugappan, 2013), transformada de Fourier discreta (Degirmenci y otros, 2018), estimación de Welch (Hasan y otros, 2020). Las características menos usuales debido a sus requerimientos son las no lineales, usualmente se asocian a señales complejas como EEG y ECG. En (Goshvarpour y Abbasi, 2017) se analizan características no lineales derivadas de la variabilidad del ritmo cardíaco para la predicción de felicidad, tranquilidad, tristeza y miedo. Aun con esto, lo más recomendable es desarrollar un dataset con características de diferentes dominios para proveer la mayor cantidad de información posible al clasificador. Por ejemplo, los repositorios emocionales MAHNOB-HC (Soleymani et al., 2012), DEAP (Koelstra et al., 2012), AMIGOS (Correa et al., 2018), DREAMER (Katsigiannis et al., 2017), etc. fusionan características en el dominio del tiempo y frecuencia, esta misma estrategia es la

más usual vista en el estado del arte. Los tipos de características más utilizadas y su descripción se describen en la tabla 3.

Tabla 3: Características usuales dentro de un dominio

Dominio	Descripción
Tiempo	Las características basadas en el dominio del tiempo describen propiedades físicas o funciones matemáticas en referencia al gráfico producido por los cambios de la señal con el tiempo. Cuando alguna de estas propiedades utiliza una unidad de medida como los segundos, minutos u horas entonces se encuentra en el dominio del tiempo. Por ejemplo, los valores máximos o mínimos cuyo propósito es señalar los valores al margen dentro de la señal, o la tasa de cruce por cero que suma el número de veces que la señal de tiempo pasa por el valor cero.
Estadístico	Las características estadísticas como su nombre indica describen propiedades relacionadas a la rama de la estadística. Por lo mismo son cifras descriptivas construidas a partir de información poblacional o muestral por medio de los valores de la señal. Por ejemplo, las medidas media, mediana o moda que representan los valores comunes dentro de la señal, o la desviación estándar que indica qué tan dispersos están los datos con respecto a la media.
Frecuencia	Las características basadas en el dominio de la frecuencia son medidas o propiedades relacionadas a esta, en lugar del tiempo. Un gráfico en el dominio del tiempo muestra los cambios en una señal durante un lapso, y el dominio de la frecuencia muestra la cantidad de señal que existe dentro de una banda de frecuencia. Por ejemplo, la transformada de Fourier, convierte una función de tiempo en una integral de ondas sinusoidales de varias frecuencias, cada una de las cuales simboliza un componente de frecuencia.
No lineal	Las características no lineales proporcionan métricas que caracterizan el comportamiento caótico en las señales. Por ejemplo, el espectro de Poincaré y sus descriptores (SD1, SD2) los cuales son propiedades relacionados al cálculo de la recurrencia.

3.1.4 Selección de características

La selección de características es una etapa opcional dentro de la estructura de la clasificación emocional, usualmente se utiliza para reducir el volumen del dataset si éste es muy extenso o debido a que no se tiene una certeza del rendimiento de sus características. Por lo tanto, es importante eliminar las características que podrían no tener ninguna correlación entre los diferentes estados emocionales ya que estas características no correlacionadas reducen el rendimiento de los clasificadores. Para lograr esto existen algoritmos con la función de calcular cuáles son las características más relevantes y ordenarlas por su importancia.

Dentro del estado del arte se han empleado un sinnúmero de técnicas para reducir la dimensionalidad de características, siendo una de las etapas más abiertas a la experimentación debido a que se relaciona más a los aspectos analíticos de la investigación y menos a los emocionales. Por ejemplo, el trabajo de (Becerra et al., 2018) aplicó cuatro algoritmos relacionados a la teoría “Rough set (conjuntos imprecisos)” la cual maneja la incertidumbre inherente a información incompleta e imprecisa para predecir emociones mediante electroencefalograma, gracias a esta implementación pudieron detectar las características con mayor relación a la valencia y excitación, así como resaltar la importancia de las bandas de frecuencia *alpha* y *theta* para la predicción de valencia. En (Lee y Yoo, 2018) se aplicó un algoritmo de disminución de características basado en la divergencia de Kullback-Leibler para calcular la diferencia o relación entre características y obtener un conjunto más correlacionado. Ross y otros (2019) implementaron el famoso algoritmo LASSO, este es un método de análisis de regresión donde el tamaño absoluto de los coeficientes de regresión se penaliza reduciéndolos. Cuanto mayor sea la magnitud de los coeficientes, mayor será la importancia de esa característica. Reduciendo su conjunto de características a la mitad. Entre todas las técnicas de selección de características analizadas la de mayor eficacia con relación a beneficios fue el análisis de componentes principales (PCA) como se puede ver en (Zhang y otros, 2018) este algoritmo ayudó a la reducción de un dataset de 600 características a solo 136 sin perder precisión e inclusive mejorar ligeramente los resultados. También Marín y otros (2018) emplearon exitosamente PCA para reducir su repositorio emocional de 209 características a solamente 19, conservando así el 95% de la variabilidad del conjunto de datos, lo que significa que estas características explicaban la mayoría de los estados emocionales.

3.1.5 Predicción

Después de seleccionar las características que son relevantes para los estados emocionales y construir un dataset en base a éstas, se puede iniciar la etapa de predicción. En esta etapa se entrena un clasificador con el dataset de características

para predecir los estados emocionales que correspondan con los estímulos utilizados.

Seleccionar un algoritmo de aprendizaje automático es una tarea muy importante ya que el modelo que se desarrolle será el elemento que más influya en los resultados después del propio dataset. En el estado del arte se pueden encontrar un sinnúmero de trabajos que utilizan diferentes algoritmos, algunos muy complejos como los que implementan Deep learning. En (Ranganathan, Chakraborty, Panchanathan, 2016) se presentaron cuatro modelos diferentes de redes convolucionales para predecir una escala completa de emociones (en total 23), para esto desarrollaron su propio repositorio y con el modelo de mejor rendimiento alcanzaron una precisión promedio del 80% para cada emoción. Por otra lado Lin, Li y Sun (2017) desarrollaron un modelo de red convolucional utilizando el repositorio DEAP (Koelstra et al., 2012) consiguió un 80% de precisión para ambas características, valencia y excitación, similar a este trabajo Siddharth y Sejnowski (2019) desarrollaron un modelo de convolución-deconvolución que permitió alcanzar el mismo 80% de precisión pero no solo con DEAP, en este trabajo se utilizaron otros repositorios como MAHNOB (Soleymani et al., 2012), DREAMER (Katsigiannis et al., 2017) y AMIGOS (Correa et al., 2018). Sin embargo, algunos trabajos pasan de utilizar estas técnicas para centrarse en la predicción con otros algoritmos de aprendizaje automático más sencillos obteniendo resultados similares. En (Ali et al., 2018) se implementaron los algoritmos KNN (Vecinos cercanos), NB (Naive bayes), ANN (Red neuronal artificial), SVM (máquinas de soporte vectorial) y un modelo de red neuronal celular para predecir las variables valencia y excitación con un repositorio propio, los resultados fueron variados pero el modelo de SVM pudo concretar un 80% de precisión para ambas propiedades. Fabiano y Canavan (2019) entrenaron los modelos de SVM, RF (bosques aleatorios), NB y un modelo de red neuronal con su propio repositorio para predecir un conjunto de 6 emociones básicas donde la felicidad y miedo alcanzaron el 90% de precisión. En este trabajo se tomaron estas investigaciones para la selección de los algoritmos que han demostrado un mejor desempeño, por lo que se implementó

el modelo de máquinas de soporte vectorial, bosques aleatorios y un modelo de red neuronal para acercarse a los modelos con Deep learning

3.1.6 Validación de resultados

La validación de resultados es la etapa final en el proceso de reconocimiento emocional que consiste en la evaluación y comparación de los modelos programados a partir de pruebas de entrenamiento y predicción con el dataset desarrollado. El resultado de estas pruebas suele ser una matriz de confusión, la cual es utilizada para el cálculo de métricas especializadas en la medición de diferentes aspectos del modelo en cuestión.

3.1.6.1 Matriz de confusión

La matriz de confusión es una herramienta estadística para la interpretación de los resultados obtenidos por un clasificador (shu et al., 2018). Esta se describe en cuestión de cuatros valores:

- Verdaderos positivos. número de predicciones correctas de clase positiva
- Falsos Negativos. número de predicciones incorrectas de clase negativa
- Falsos Positivos. número de predicciones incorrectas de clase positiva
- Verdaderos negativos. número de predicciones correctas de clase negativa

En la figura 13 se puede visualizar este concepto en forma de conjuntos.

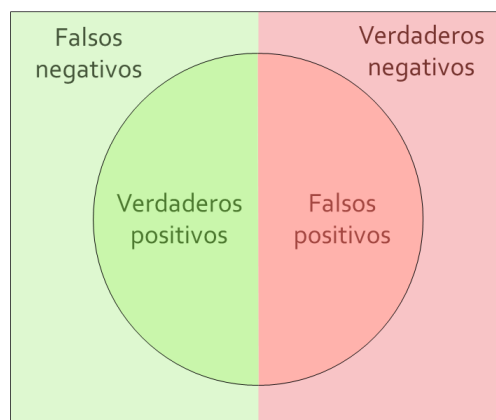


Figura 13: Representación de la matriz de confusión

A continuación, se describen las métricas establecidas para la evaluación de los modelos de predicción.

3.1.6.2 Precision

En español precisión, es una métrica que cuantifica el número de predicciones positivas correctas realizadas. Se calcula como la proporción de verdaderos positivos, dividida por el número total de ejemplos positivos predichos (shu et al., 2018). La fórmula 5 describe su cálculo y la figura 14 su representación en conjuntos.

$$Precision = \frac{VP}{VP + FP} \quad (5)$$

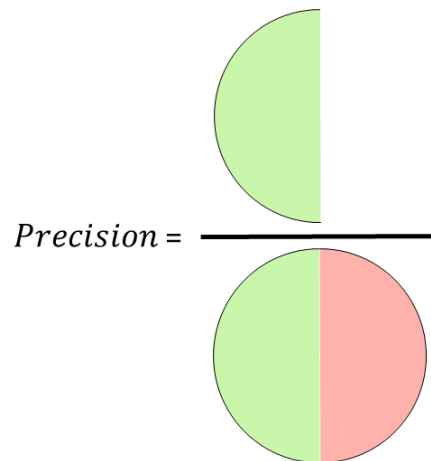


Figura 14: Representación de la métrica precisión

3.1.6.3 Recall

En español recuerdo, es una métrica que cuantifica el número de verdaderos positivos acertados a partir de todas las predicciones positivas que podrían haberse realizado (shu et al., 2018). A diferencia de la precisión que solo comenta las predicciones positivas correctas de todas las predicciones positivas, el recuerdo proporciona un indicador de las predicciones positivas perdidas. De esta forma, Recall proporciona una noción de la cobertura total de la clase positiva. La fórmula 6 describe su cálculo y la figura 15 su representación en conjuntos.

$$Recall = \frac{VP}{VP + FN} \quad (6)$$

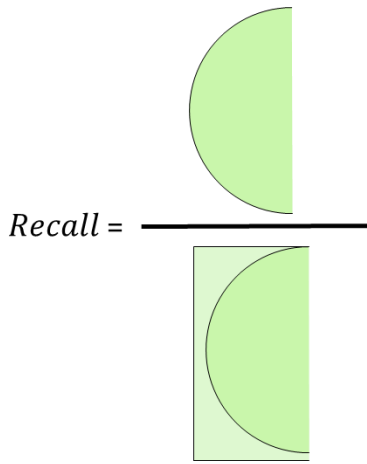


Figura 15: Representación de la métrica Recall

3.1.6.4 F1-score

En español *Valor-F* o también conocido como *f1*, es una métrica ampliamente utilizada debido a que es la medida predilecta para resumir el rendimiento de un modelo (shu et al., 2018). Por sí solo, ni la precisión ni el *recall* validan totalmente el modelo. Se puede tener una precisión excelente con un *recall* terrible y viceversa. Por lo que *F1/F-measure* proporciona una forma de combinar el rendimiento de la *precision* y *recall* en una sola métrica. La fórmula 7 describe su cálculo.

$$F1 = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (7)$$

Accuracy

En español Exactitud, es una forma de medir la frecuencia con la que el algoritmo clasifica un conjunto de datos correctamente. La precisión es el número de predicciones correctamente clasificadas de todas las predicciones. Más formalmente, se define como el número de verdaderos positivos y verdaderos

negativos dividido por el número de verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos (shu et al., 2018). La fórmula 8 describe su cálculo y la figura 16 su representación en conjuntos.

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN} \quad (8)$$

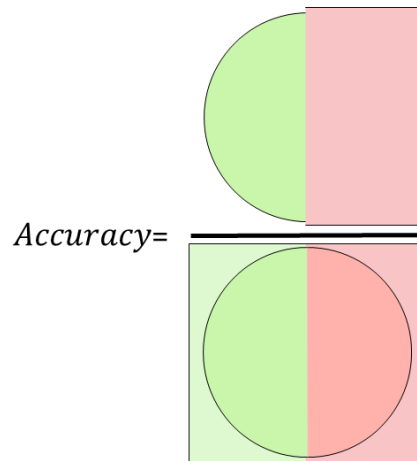


Figura 16: Representación de la métrica Accuracy

3.1.7 Tabla comparativa del estado del arte

A continuación, se presenta una tabla comparativa que muestra los trabajos que se han desarrollado en el área de reconocimiento emocional utilizando señales fisiológicas. La tabla 4 se distribuye de izquierda derecha siguiendo la estructura común descrita anteriormente, al principio se selecciona el tipo de señales que se emplearon o si se utilizó algún repositorio, posteriormente el tipo de estímulo y el tipo de características utilizadas, finalmente se describe el modelo de clasificación y el tipo de emoción que se predijo acompañado del mayor porcentaje de precisión alcanzado durante alguna de sus pruebas.

Capítulo 3. Estado del arte

Tabla 4: Tabla comparativa del estado del arte

Trabajo	Señales fisiológicas										Método de inducción					Extracción de características				Método de clasificación	Emociones	Precisión promedio
	EEG	ECG	EMG	GSR	PPG	Temperatura	Respiración	Rostro / Voz	DEAP	MANHOB	Videos	Música	Imágenes	VR	Otro	Domínio frecuencia	Domínio Tiempo	Estadísticas	No lineales			%
(Verma y Tiwary, 2014)									✓		✓	✓			✓				✓	SVM, MLP, KNN, MMC	Miedo Amor Ira Nostalgia Encanto Alegría Diversión Shook Tristeza Melancolía	80%
(Jang, Park, Kim y Sohn, 2015)		✓		✓	✓	✓						✓			✓	✓	✓			LDA,CART, SOM, NB0, y SVM	Aburrimiento, Dolor y Sorpresa	70%
(Ranganathan, Chakraborty, Panchanathan, 2016)		✓					✓	✓							✓	✓			✓	Cuatro modelos de redes convolucionales de creencias profundas (CDBN)	23 reacciones emocionales	80%
(Guendil, Lachiri, Maoui, Pruski, 2016)		✓	✓	✓			✓				✓								✓	SVM	Modelo valencia - excitación	80%
(Thammasan, Hagad, Fukui y Numao, 2017)	✓	✓		✓								✓			✓	✓	✓			SVM	Modelo valencia - excitación	50%
(Lin, Li y Sun, 2017)									✓		✓	✓			✓	✓	✓			Red neuronal convolucional	Modelo valencia - excitación	80%
(Girardi, Lanubile y Novielli, 2017)	✓		✓	✓							✓				✓	✓	✓			SVM, NB, J48	Modelo valencia - excitación	60%
(Ali et al., 2018)		✓		✓		✓				✓	✓				✓	✓	✓			KNN, NB, ANN, SVM y un modelo de red neuronal celular	Modelo valencia - excitación	80%
(Zhang et al., 2018)		✓	✓	✓	✓						✓						✓			Árbol de decisión de aumento de gradiente (GBDT)	Felicidad, Miedo, Tristeza e ira	90%
(Lee y Yoo, 2018)		✓		✓		✓					✓				✓	✓				LDA, QDA y un Modelo de red neuronal	Emocion negativa	90%
(Kwon, Shin y Kim, 2018)	✓			✓							✓				✓		✓			Red neuronal convolucional	Modelo valencia - excitación	70%
(Akalin & Köse, 2018)	✓			✓							✓				✓					SVM, NB, KNN	Modelo valencia - excitación	70%
(Degirmenci, Ozdemir, Sadighzadeh y Akan, 2018)	✓										✓				✓					SVM, NB, LDA	Modelo valencia - excitación	80%
(Fabiano y Canavan, 2019)									✓		✓				✓	✓	✓			SVM, RF, NB y un modelo de red neuronal feedforward	Ira Felicidad Miedo Vergüenza Dolor Tristeza Sorpresa Disgusto	90%
(Siddharth y Sejnowski, 2019)									✓	✓	✓	✓			✓	✓				Modelo de red de convolución-deconvolución	Modelo valencia - excitación	80%
(Ross et al., 2019)		✓		✓										✓	✓	✓				SVM DT RF KNN	Experiencia de usuauo	60%
(Oh, Lee y Kim, 2020)					✓		✓				✓				✓	✓				Red neuronal convolucional	Felicidad, Miedo, Sorpresa, Tristeza, Disgusto e ira	80%
(Tan, Ceballos y Kasabov, 2020)										✓	✓				✓	✓				Red neuronal Spiking	Valencia	70%
(Ayata, Yaslan y Kamasak, 2020)									✓		✓	✓					✓			SVM, RF, LR	Modelo valencia - excitación	70%
Tesis	✓	✓		✓					✓	✓	✓	✓			✓	✓				SVM, RF y un modelo de red neuronal	Modelo valencia - excitación	70%

3.1.8 Análisis de la herramienta UXLab

UXLab es una plataforma de software para la captura, sincronización y visualización de datos multimodales, por ejemplo: video del rostro, captura de pantalla, datos de señales fisiológicas como EEG, ECG y GSR, seguimiento ocular y audio. Esta plataforma fue desarrollada como parte de la tesis “Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario (Fouilloux, 2018). Sin embargo, el objetivo final de UXLab es utilizar las grabaciones para la evaluación de la experiencia de usuario (UX por sus siglas en inglés), por lo que con el tiempo se han integrado nuevas funciones. Como resultado de esta investigación se integró un módulo para el análisis emocional que toma como entrada las señales fisiológicas y devuelve un valor de valencia y otro de activación, con esta información se puede rastrear una emoción y crear un recorrido de las diferentes emociones experimentadas por un usuario a lo largo de una prueba con UXLab. La figura 17 representa la arquitectura final de UXLab y de sus componentes, la aportación de esta investigación se puede ver en el análisis emocional por medio de datos fisiológicos.

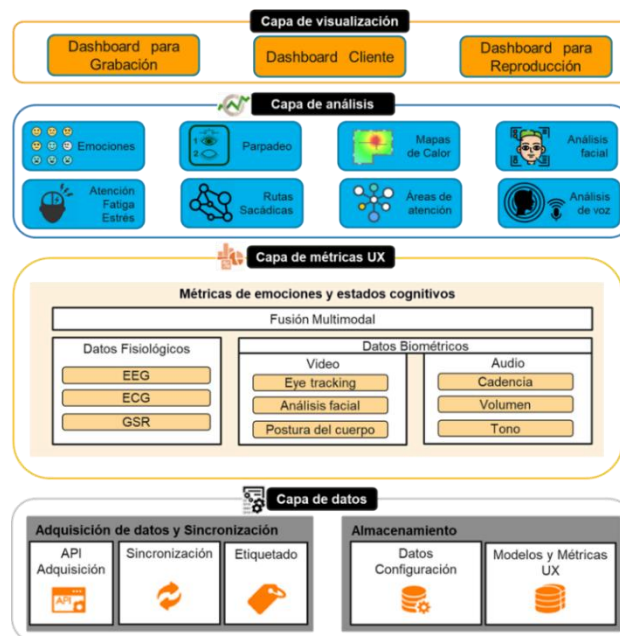


Figura 17: Arquitectura de UXLab

La ilustración es extraída de González, 2019. UXLab Arquitectura. Todos los derechos reservados 2019. Adaptado con permiso del autor.

La Plataforma UXLab consta de dos aplicaciones, la primera es el sistema de grabación encargado de capturar las señales fisiológicas, seguimiento ocular, captura de pantalla, audio y cámara web durante un periodo de tiempo, la segunda es el sistema reproductor que permite visualizar una grabación anteriormente guardada, en ésta se presenta un panel de datos que plasma de manera sincronizada la información capturada con cada sensor.

3.1.8.1 Sistema de grabación

Como se mencionó anteriormente UXLab puede grabar distintos sensores fisiológicos y biométricos, en la tabla 5 se mencionan y clasifican estos componentes.

Tabla 5: Componentes individuales de UXLab

Fisiológicos	Biométricos	Computadora
Electroencefalograma (EEG)	Audio	Captura de pantalla
Electrocardiograma (ECG)	Seguimiento ocular	Cámara Web
Respuesta Galvánica en Piel (GSR)		

El esquema del sistema de grabación se muestra en la figura 18.

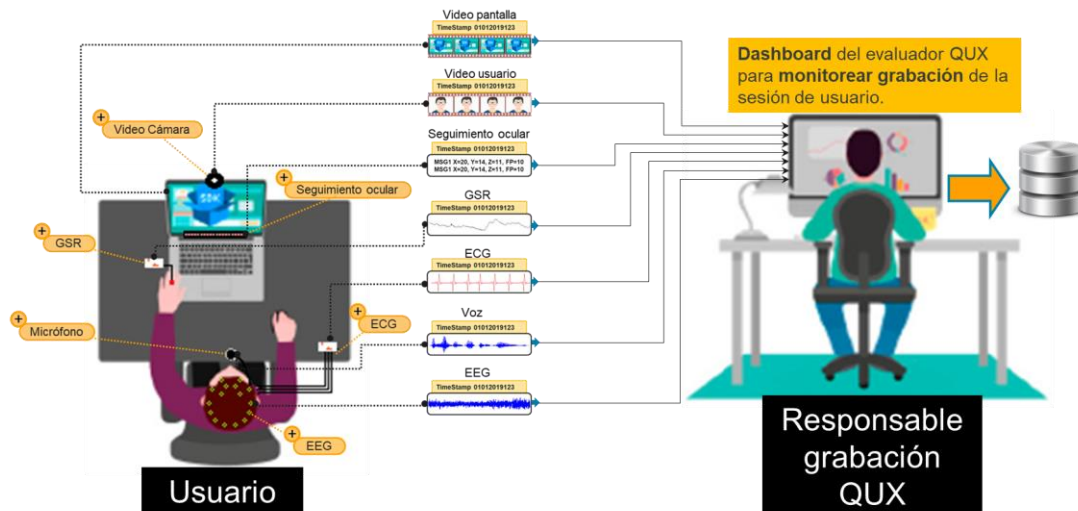


Figura 18: Esquema conceptual del sistema de grabación de UXLab
 La ilustración es extraída de Fouilloux, 2018. Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario.

El sistema de grabación consta de dos componentes el “Modulo de dispositivos” con la función de encender y administrar los sensores y el “Integrador de grabación” encargado de iniciar y detener las grabaciones.

3.1.8.2 Módulo de dispositivos

El módulo de dispositivos se encarga de controlar los diferentes componentes de monitoreo, permitiendo activar, visualizar y desactivar el flujo de datos de cada uno (figura 19).



Figura 19: Módulo de dispositivos / UXLab

La ilustración es extraída de Fouilloux, 2018. Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario.

Al iniciar una grabación UXLab comenzará a monitorear los sensores que estén activos, este proceso puede ser controlado de mejor forma con la ayuda de la función visualizar la cual permite observar el flujo actual de los datos de cada sensor (figura 20) de forma que será posible detectar pronto los errores de grabación.



Figura 20: Visualización de sensores / UXLab
 La ilustración es extraída de Fouilloux, 2018. Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario.

3.1.8.3 Integrador de grabación

El integrador de grabación como el nombre indica es el encargado de controlar las grabaciones, en esta interfaz se puede hacer el registro de usuarios y la selección del directorio de guardado. Para iniciar una grabación solamente se necesita presionar el botón iniciar grabación y al hacer esto UXLab comenzara a almacenar la información adquirida de los sensores activos. Al finalizar una grabación iniciará un proceso donde se guardarán los resultados de la grabación. En la figura 21 se puede ver la interfaz del integrador de grabación.



*Figura 21: Integrador de grabación / UXLab
La ilustración es extraída de Fouilloux, 2018. Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario.*

3.1.8.4 Sistema de reproducción

El sistema de reproducción consta de una aplicación encargada de mostrar los resultados y grabaciones obtenidos después de una sesión con UXLab. Una vez abierta la herramienta se debe seleccionar la ruta donde se encuentren los archivos, esta es la misma que se estableció en el integrador de grabación y esperar a que estos sean procesados.

Como se puede observar en la figura 22, en la parte superior del reproductor se muestran las grabaciones del rostro del usuario y la actividad que realiza, en este caso observar un estímulo visual, mientras en la parte inferior se muestra el flujo de datos de los sensores capturados.



Figura 22: Reproductor de UXLab

La ilustración es extraída de Fouilloux, 2018. Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario.

4. Metodología de solución

Capítulo 4. Metodología de solución

Después de analizar los antecedentes en el área del reconocimiento emocional y considerar los recursos con los que cuenta esta investigación se desarrolló una metodología que combina el uso de repositorios, algoritmos de aprendizaje automático y la herramienta para evaluación de la experiencia de usuario UXLab para generar un proceso robusto de predicción emocional por medio de las propiedades de valencia y excitación. En la figura 23 se muestra la arquitectura de esta metodología.

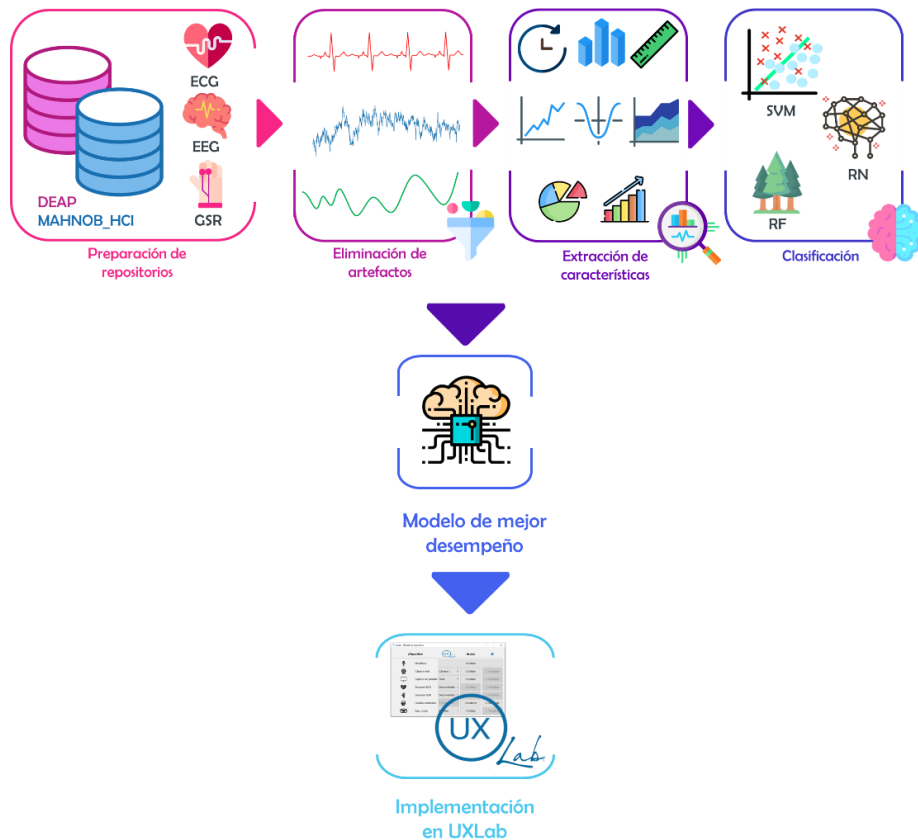


Figura 23: Arquitectura de la propuesta de solución

Esta metodología se apega a los procesos y métodos definidos en otras investigaciones como se mencionó en el capítulo anterior. En la primera etapa de esta investigación se analizaron los repositorios DEAP (Koelstra et al., 2012) y Manhob (Soleymani et al., 2012), identificados en el estado del arte. Posteriormente cada repositorio fue procesado con las mismas técnicas de filtrado

y extracción de características para asegurar imparcialidad en el proceso. Finalmente se construyó un par de datasets por cada repositorio, uno para predicción de valencia y otro para excitación. Se realizó una comparación entre diferentes algoritmos de aprendizaje automático para seleccionar el modelo de mejor desempeño. Dicho modelo posteriormente fue implementado en la plataforma UXLab para realizar las pruebas y validación de los resultados de forma que permita predecir emociones en pruebas reales. A continuación, se describe el trabajo realizado en cada etapa.

4.1 Preparación de repositorios

El objetivo de utilizar repositorios en lugar de desarrollar uno propio es ahorrar tiempo para invertirlo en etapas más cruciales, sin embargo, esto generó desafíos como la selección de un repositorio ideal y compatible con los alcances del proyecto, además de generar la necesidad de un proceso de normalización.

Como se explicó anteriormente, existen muchos repositorios que pueden ser utilizados para el reconocimiento de emociones, abarcando una gran cantidad de señales y estímulos. Los repositorios seleccionados para esta investigación fueron DEAP (Koelstra et al., 2012) y Manhob (Soleymani et al., 2012), ambos con señales fisiológicas de tipo EEG, GSR y ritmo cardiaco (ECG, BVP).

4.1.1 DEAP - Base de datos para análisis emocionales con señales fisiológicas

Es un conjunto de datos multimodal para el análisis de estados afectivos. Incluye señales de electroencefalograma (EEG) registrados con una Interfaz Cerebro Computadora (BCI por sus siglas en inglés) de 32 canales basado en el sistema 10-20 (Jasper, 1958), así como datos de un sensor de respuesta galvánica de la piel (GSR), y de ritmo cardiaco (BVP) además de otras señales como temperatura, respiración y electromiografía adquiridas usando un sistema Biosemi ActiveTwo System (figura 24), en un equipo de cómputo Pentium 4, 3,2 GHz.



Figura 24: Proceso de grabación del repositorio DEAP

La ilustración es extraída de Koelstra et al., 2012. A dataset for emotion analysis using eeg, physiological and video signals.

Las pruebas contaron con la participación de 32 sujetos (mitad hombres y mujeres de 19 a 32 años) realizando 40 pruebas emocionales de diferente duración, sin embargo, estos fueron resumidos por el equipo desarrollador a un minuto con ayuda de un algoritmo. Los experimentos se llevaron a cabo en 2 ambientes controlados de laboratorio con iluminación constante, utilizando como material de estímulo emocional videos musicales. Al final de cada prueba los usuarios valoraron su experiencia en términos de activación, valencia y dominancia mediante el instrumento de maniquíes de autovaloración (SAM) (Bradley y Lang, 1994). El repositorio DEAP está disponible para descargar en dos formatos .mat (formato de almacenamiento de datos binarios exclusivo del programa MATLAB) y .dat (formato de almacenamiento de datos planos compatible con windows) cada uno corresponde a un usuario y almacena las señales de cada prueba, debido a que se utilizara Python como lenguaje de programación, se utilizaron los archivos .dat, los cuales fueron exportados más adelante a archivos de valores separados por comas (CSV) para un mejor manejo de las pruebas e individualidad entre sensores.

En la tabla 6 se describen las características principales del repositorio DEAP.

Tabla 6: Características del repositorio DEAP

Repositorio DEAP	
Número de participantes	32
Numero de pruebas	40
Tipo de estímulos	Música, Video
Duración de pruebas	1 minuto
Variables/Etiquetas	Valencia, Activación
Forma de valuación	Mediante encuesta después de cada prueba
Escala de evaluación	1 - 9
Sensores utilizados	Fotopletismografía (BVP) - 128Hz GSR – 128Hz EEG de 32 canales – 128Hz Respiración Temperatura EMG
Monitoreo	Grabaciones de rostro

4.1.2 MAHNOB-HCI Base de datos multimodal para reconocimiento de afectos y etiquetado implícito

Es un repositorio muy utilizado, se caracteriza por ser una de las primeras y más completas bases de datos afectivas, proporciona grabaciones de rostro en distintos ángulos utilizando 6 cámaras para registrar las expresiones faciales y la pose de la cabeza además de señales de sensores como electroencefalograma de 32 canales, ECG, GSR, temperatura, respiración y seguimiento ocular. Para la captura de estas señales se utilizó de nuevo el sistema Biosemi active II (figura 25).



Figura 25: Proceso de grabación del repositorio MAHNOB.

La ilustración es extraída de Soleymani et al., 2012. A Multimodal Database for Affect Recognition and Implicit Tagging.

La muestra es de 30 participantes por 20 pruebas, con una distribución de 17 mujeres y 13 hombres con edades que van desde los 19 a los 40 años. Se utilizaron estímulos variados que consisten en fragmentos de películas. En la tabla 7 se describen las señales y estímulos del repositorio MAHNOB-HCI. De la misma forma que con DEAP, se realizó una encuesta en términos del nivel de activación, valencia y dominancia al final de cada prueba. MAHNOB se distribuye en archivos de tipo Biosemi “bdf” el cual es una versión de 24 bits del formato EDF (Formato de datos europeo) de 16 bits que almacenan las señales únicamente de una prueba, por lo que es necesario transformarlos en archivos de texto comunes como csv. En la tabla 7 se describen las características principales del repositorio MAHNOB.

Capítulo 4. Metodología de solución

Tabla 7: Características del repositorio MAHNOB-HC

Repositorio MAHNOB-HC	
Número de participantes	30
Número de pruebas	20
Tipo de estímulos	Video
Duración de pruebas	Duración variable
Variables/Etiquetas	Valencia, Activación
Forma de valuación	Mediante encuesta después de cada prueba
Escala de evaluación	1 - 9
Sensores utilizados	ECG - 128Hz GSR - 128Hz EEG de 32 canales - 128Hz Temperatura Respiración
Monitoreo	Grabaciones de rostro Micrófono

Ambos repositorios fueron solicitados bajo el acuerdo de licencia de uso académico.

4.2 Eliminación de artefactos

Los desarrolladores de los repositorios emocionales suelen aplicar una capa de preprocesado a las señales antes de ponerlas a disposición. Sin embargo, al analizar los repositorios de MAHNOB y DEAP se nota que todavía contienen artefactos, información completamente errónea, además de tener un problema con la tendencia la cual es inestable. Debido a esto, las señales fueron sometidas a otro proceso de filtrado. En el caso de MAHNOB se descartaron las pruebas de 3 usuarios debido a problemas irreparables en las señales, no obstante, esto se advierte desde un principio en su mismo reporte. Para tener una configuración similar en todos los sensores se decidió que las señales fueran ajustadas a una

Capítulo 4. Metodología de solución

frecuencia de 128hz ya que es la frecuencia de trabajo de los dispositivos de UXLab, en el caso de DEAP no hay problema ya que ésta es la misma frecuencia que poseen. El proceso de filtrado general para todas las señales, incluyendo a las obtenidas en UXLab fue aplicar un filtro de paso banda cuyo rango dependía del sensor. En la tabla 8 se especifican los rangos de frecuencia para cada una de las señales.

Tabla 8: Características del repositorio MAHNOB-HC

Rangos de frecuencia recomendados	
EEG	4 – 45 Hz
ECG	2 – 20 Hz
GSR	0.01 – 0.2 Hz
BVP	1 – 3 Hz

4.3 Extracción de características

Para esta investigación se seleccionaron las características que pertenecen a trabajos relevantes del estado del arte y que probaron su eficacia mediante pruebas de aprendizaje automático. Algunos ejemplos son las propuestas en (Miranda et al., 2017) y (Kim y Andre, 2009) así como en repositorios como DEAP (Koelstra et al., 2012), Manhob (Soleymani et al., 2012), y AMIGOS (Correa et al., 2018). En la tabla 9 se muestran las características mencionadas.

Capítulo 4. Metodología de solución

Tabla 9: Conjunto de características multimodales

Señal	Cantidad	Características
EEG	184	<ul style="list-style-type: none"> • Potencia Espectral de las ondas: <i>theta</i> (4 - 8 hz), <i>alpha</i> (8 - 12 hz), <i>beta</i> (12 – 30hz) y <i>gamma</i> (30 – 45 hz). Con un total de 128. • Asimetría entre los 14 pares de electrodos en las cuatro bandas de theta, alpha, beta, y gamma). Con un total de 56.
ECG/BVP	71	<ul style="list-style-type: none"> • Promedio y desviación estándar de la frecuencia cardiaca. Con un total de 2. <ul style="list-style-type: none"> • HRV <ul style="list-style-type: none"> • Media cuadrática de diferencias sucesivas (RMSSD). • Desviación estándar de NNI sucesivos (SDNN). • 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. • Potencias espectrales en las bandas de 0-6 HZ. Con un total de 60. <ul style="list-style-type: none"> • Espectro poicare. Con un total de 3.
GSR	16	<ul style="list-style-type: none"> • Promedio de resistencia en piel • Promedio de la primera derivada <ul style="list-style-type: none"> • Promedio de la primera derivada para valores negativos • Proporción de los valores negativos con respecto a todas las muestras <ul style="list-style-type: none"> • Número de mínimos locales • Tiempo promedio de subida de la señal • Densidad espectral de potencia en las bandas [0 – 2,4]Hz. Con un total de 10.

4.4 Clasificación

Finalmente, la selección de los algoritmos de aprendizaje automático concluyó con tres candidatos, todos de gran relevancia y con historial de eficiencia. Estos son: máquinas de soporte vectorial, bosques aleatorios y redes neuronales. La implementación de estos algoritmos se logró mediante las librerías de Python como son Scikit learn (Pedregosa et al., 2011) y Keras (Chollet et al., 2015). La proporción para entrenamiento y predicción se estableció en 80/20, ambos repositorios DEAP y MAHNOB se sujetaron a dos pruebas, cálculo de valencia y

cálculo de activación. La valencia se dividió en dos clases negativa y positiva de la misma forma la activación con alta y baja. Para minimizar las diferencias entre las características y favorecer la velocidad de los algoritmos se aplicó un proceso de normalizado, en el que se estableció el valor de cada característica entre [0, 1]. Tomando esto en cuenta, se llevaron a cabo las pruebas de predicción utilizando métricas como *Precision*, *Recall*, *F1-score* y *Accuracy*.

A continuación, se muestran los resultados de cada clasificador incluyendo pruebas alternativas implementando el análisis de componentes principales (descrito a continuación) para convertir el conjunto de información en uno más pequeño, más fácil de explorar y de analizar.

4.4.1 Análisis de componentes principales (PCA)

El análisis de componentes principales es una técnica de reducción de características, basado en la transformación de un gran conjunto de información en uno más pequeño en términos de nuevas variables y sin perder la mayor parte de la información del conjunto grande (Pai et al., 2013). Es conocido por ser el enfoque más eficiente, rápido y fácil de implementar en el aprendizaje automático. La reducción de la cantidad de variables de un conjunto de datos suele afectar métricas como la precisión, sin embargo, PCA se enfoca en la conservación de la mayor cantidad de información resumida en la menor cantidad de nuevas variables. El algoritmo 1 (Sriram et al., 2013) muestra el pseudocódigo correspondiente a esta técnica.

Algoritmo 1: PCA

Input: p = número de patrones, \mathbf{x} = matriz de características, $\mathbf{x}_{k=1}$ a \mathbf{x}_p

Output: componentes principales

1: Calcular el vector de características principales

$$\mu = \frac{1}{p} \sum_{k=1}^p x_k.$$

2: Calcular la matriz de covarianza, \mathbf{T} representa la transposición de la matriz

$$C = \frac{1}{p} \sum_{k=1}^p \{x_k - \mu\} \{x_k - \mu\}^T$$

3: Calcular valores característicos λ_i y vectores característicos v_i de la matriz de covarianza

$$Cv_i = \lambda_i v_i \quad (i = 1, 2, 3, \dots, q). \quad q = \text{numero de caracteristicas}$$

4: Estimar los vectores característicos de alto valor

- i) Organizar todos los valores característicos (λ_i) en orden descendente
- ii) Elegir un valor de umbral, Θ
- iii) Elegir un número de alto valor (λ_i) para satisfacer la relación

$$\left(\sum_{i=1}^s \lambda_i \right) \left(\sum_{i=1}^q \lambda_i \right)^{-1} \geq \theta \quad s = \text{número de elegidos de alto valor } \lambda_i$$

- iv) Seleccionar los vectores característicos correspondientes al valor alto seleccionado λ_i

5: Extraer los vectores de características de baja dimensión (componentes principales) de la matriz de características en bruto.

$$P = V^T X$$

V = matriz de componentes principales, X = matriz de características

4.4.2 Máquinas de soporte vectorial

En ingles *Support vector machine* o máquinas de soporte vectorial (SVM) es una técnica de clasificación y regresión de aprendizaje supervisado con algoritmos asociados que analizan los datos y reconocen patrones. SVM funciona correlacionando datos a un espacio de características de grandes dimensiones de forma que los puntos de datos se puedan categorizar, incluso si los datos no se puedan separar linealmente de otro modo. Se detecta un separador entre las categorías y los datos se transforman de forma que el separador se puede extraer como un hiperplano. Tras ello, las características de los nuevos datos se pueden utilizar para predecir el grupo al que pertenece el nuevo registro («Modelos de máquina de vectores de soporte», 2019). Este algoritmo ha sido ampliamente utilizado en investigaciones de reconocimiento emocional, y en los proyectos donde se compara su desempeño ha demostrado además ser de los mejor

evaluados. El algoritmo 2 (Pedersen y Schoeberl, 2006) detalla el pseudocódigo para entrenar un modelo SVM.

Algoritmo 2: Entrando un modelo SVM

Input: $X = \text{muestras}$, $y = \text{clases}$, $\alpha \leftarrow 0$

Output: Modelo entrenado

1: $C \leftarrow 10$

2: repeat

3: for all $\{x_i, y_i\}, \{x_j, y_j\}$ do

4: Optimizar α_i y α_j

Retener solo los vectores de soporte ($\alpha_i > 0$)

5: end for

6: until no haya cambios en α u otros criterios de restricción de recursos

En la tabla 10 y 11 se muestran los resultados de la predicción de excitación y valencia respectivamente para los repositorios DEAP y MAHNOB en dos escenarios: sin aplicar PCA y con PCA además se resaltan los mejores resultados por cada métrica.

Tabla 10: Tabla de resultados para activación con SVM

EXCITACIÓN				
DEAP				
Algoritmo	Precision	Recall	F1-score	Accuracy
SVM	0.656	0.663	0.970	0.788
SVM + PCA	0.683	0.689	0.977	0.808
MAHNOB-HCI				
SVM	0.654	0.673	0.600	0.634
SVM + PCA	0.645	0.560	0.787	0.654

Como se puede observar en la tabla 10 los resultados para excitación, SVM + PCA obtuvo los mejores resultados con todas las métricas junto al repositorio

Capítulo 4. Metodología de solución

DEAP. Por el contrario, aplicar PCA con MAHNOB fue contraproducente pues obtuvo resultados inferiores, lo cual es un caso inusual. Al comparar los resultados entre repositorios se puede notar un desempeño similar al desistir de las técnicas de selección de características (PCA), aunque resalta de forma ligera DEAP. En cualquier escenario todos los resultados se pueden considerar satisfactorios.

Tabla 11: Tabla de resultados para valencia con SVM

VALENCIA				
DEAP				
Algoritmo	Precision	Recall	F1-score	Accuracy
SVM	0.664	0.663	0.969	0.788
SVM + PCA	0.660	0.666	0.970	0.790
MAHNOB-HCI				
SVM	0.627	0.592	0.818	0.687
SVM + PCA	0.627	0.635	0.797	0.707

Los resultados mostrados en la tabla 11 muestran la predicción de valencia es muy similares a los obtenidos para excitación. El mejor escenario se obtuvo al aplicar PCA con el repositorio DEAP, salvo por el valor de precisión, donde gana DEAP sin selección de características, aunque por una diferencia mínima. En el caso de MAHNOB los resultados fueron similares utilizando o no PCA. Se puede considerar que todos los escenarios son satisfactorios sin embargo son inferiores a los obtenidos para excitación, lo que es comprensible pues la valencia y excitación son variables diferentes e incomparables.

Entre la comparación de los repositorios, DEAP presentó mejor rendimiento que MAHNOB por una pequeña diferencia para ambas características.

4.4.3 Bosques aleatorios

Bosques aleatorios (*Random Forest* / RF) es un algoritmo de aprendizaje supervisado por conjuntos. La idea general consiste en la construcción de muchos árboles de decisión débiles y de pocas características para generar un proceso

computacionalmente económico, sin embargo, al combinar estos pequeños arboles se puede conseguir un modelo robusto por medio de promedios de decisión o por voto mayoritario. Este algoritmo es popular en investigaciones relacionadas a la predicción emocional y suele conseguir resultados satisfactorios. En el algoritmo 3 (Matthew N., 2019) se puede consultar el pseudocódigo correspondiente a esta técnica.

Algoritmo 3: RF

Input: $S =$ conjunto de entrenamiento $(x_1, y_1), \dots, (x_n, y_n)$,

$F =$ características, $B =$ número de árboles para el bosque

Output: árbol de decisión

1: function RandomForest(S, F)

2: $H \leftarrow \emptyset$

3: for $i \in 1, \dots, B$ **do**

4: $S(i)$

\leftarrow muestra Bootstrap (bagging) del conjunto de entrenamiento S

5: $h_i \leftarrow$ ArbolDeAprendizajeAleatorio($S(i), F$)

6: $H \leftarrow H \cup \{h_i\}$

7: end for

8: return H

9: end function

10: function ArbolDeAprendizajeAleatorio(S, F)

11: Por cada nodo:

12: $f \leftarrow$ subconjunto de F

13: Dividir entre la mejor característica en f

14: return árboldecision

15: end function

Utilizando los repositorios DEAP y MAHNOB se desarrollaron dos escenarios, uno con todas las características y otro aplicando técnicas de reducción de características (PCA). En las tablas 12 y 13 se pueden ver los resultados de la predicción de excitación y valencia respectivamente, donde se resaltan los mejores resultados.

Capítulo 4. Metodología de solución

Tabla 12: Tabla de resultados para excitación con RF

EXCITACIÓN				
DEAP				
Algoritmo	Precision	Recall	F1-score	Accuracy
RF	0.660	0.721	0.823	0.769
RF + PCA	0.640	0.693	0.779	0.734
MAHNOB-HCI				
RF	0.681	0.692	0.654	0.672
RF + PCA	0.690	0.687	0.758	0.721

Los resultados de excitación para los escenarios con DEAP fueron positivos utilizando o no PCA, como se muestra en la tabla 12. En este caso ocupar la selección de características no mejoró los resultados como se esperaba, ya que fueron inferiores al aplicarse. Así mismo, las métricas *recall*, *f1*, y *accuracy* obtuvieron los valores más altos en todo el experimento con bosques aleatorios al utilizar el repositorio DEAP e ignorar PCA. Los resultados de MAHNOB por otra parte obtuvieron mejor precisión, la cual es la métrica de evaluación más importante en este estudio, y al utilizar PCA si se mejoró el rendimiento general. El mejor escenario fue quizá el construido con DEAP sin PCA.

Tabla 13: Tabla de resultados para valencia con RF

VALENCIA				
DEAP				
Algoritmo	Precision	Recall	F1-score	Accuracy
RF	0.617	0.663	0.809	0.729
RF + PCA	0.652	0.687	0.856	0.762
MAHNOB-HCI				
RF	0.681	0.695	0.774	0.732
RF + PCA	0.681	0.705	0.761	0.732

Capítulo 4. Metodología de solución

Los resultados de la predicción de valencia, tabla 13, fueron lo que se esperaba, positivos y con mejor rendimiento al utilizar PCA. En el caso de DEAP las métricas de *f1* y *accuracy* obtuvieron valores superiores a los resultados de MAHNOB, caso contrario con las métricas de *precision* y *recall* donde este supero a DEAP con o sin PCA. El mejor escenario en general lo obtuvo MAHNOB al emplear selección de características.

Al comparar el desempeño entre repositorios, MAHNOB obtuvo un mejor rendimiento pues sus resultados fueron balanceados en todos los escenarios y obtuvo siempre el valor de precisión más alto en el experimento.

4.4.4 Redes neuronales

Una red neuronal es un modelo computacional utilizado para el reconocimiento de patrones a través de procesos simples interconectados. Toma la idea del cerebro humano para construir un modelo basado en el concepto de neuronas. La mayoría de las redes neuronales están organizadas en capas de nodos. Un nodo individual puede estar conectado a varios otros nodos en la capa debajo de él, desde donde recibe datos, y a varios nodos en la capa superior, a los que envía datos. A cada una de sus conexiones entrantes, un nodo asignará un número conocido como "peso". Cuando la red está activa, el nodo recibe diferentes valores sobre cada una de sus conexiones y lo multiplica por el peso asociado. Luego suma los productos resultantes, dando un solo número. Si ese número está por debajo de un valor umbral, el nodo no pasa datos a la siguiente capa. Si el número excede el valor de umbral, el nodo "dispara", lo que en las redes neuronales actuales generalmente significa enviar el número, la suma de las entradas ponderadas, a lo largo de todas sus conexiones salientes. Cuando se entrena una red neuronal, todos sus pesos y umbrales se establecen inicialmente en valores aleatorios. Los datos de entrenamiento se envían a la capa inferior, la capa de entrada, y pasan a través de las capas siguientes, multiplicándose y sumando de formas complejas, hasta que finalmente llegan, radicalmente transformados, a la capa de salida. Durante el entrenamiento, los pesos y los umbrales se ajustan continuamente hasta que los datos de entrenamiento con las mismas etiquetas

arrojan resultados similares de manera consistente (Hardesty, 2017). En el algoritmo 4 se describe el pseudocódigo perteneciente a una pequeña red neuronal.

Algoritmo 3: RF

Input: m = matriz de datos

Output: modelo de red

```

1: for all  $m$ -th vectores de datos do
2:   for  $j = 1$ ; hasta numero de neuronas de la primer capa do
3:      $y_{1,j} = g(w_{1,j,0} + \sum_{k=1}^n w_{1,j,k}x_{k,m})$ 
4:   end for
5:   for  $i = 2$  hasta numero de capas de la red do
6:     for  $j = 1$  hasta numero de neuronas de la capa  $i$  do
7:        $y_{i,j} = g(w_{i,j,0} + \sum_{k=1}^{size(i-1)} w_{i,j,k}y_{i-1,k})$ 
8:     end for
9:   end for
10:  for  $j = 1$  hasta numero de neuronas de la ultima capa do
11:     $i =$  valor de la última capa
12:     $z_{j,m}$ 
= resultado  $\delta_{i,j} = (1 - y_{i,j}^2)(z_{j,m} - y_{i,j})$   $j$  salida del  $m$  vector del conjunto de da
13:
14:  end for
15:  for  $i =$  numero de capas de la red - 1 downto 1 do
16:    for  $j = 1$  hasta numero de neuronas de la capa  $i$  do
17:       $\delta_{i,j} = (1 - y_{i,j}^2) \sum_{k=1}^{size(i+1)} (\delta_{i+1,k} w_{i+1,k,j})$ 
18:    end for
19:  end for
20:  for  $i = 1$  hasta numero de capas de la red do
21:    for  $j = 1$  hasta numero de neuronas de la capa  $i$  do
22:      for  $k = 0$  hasta numero de neuronas de la capa  $i - 1$  do
23:         $\tilde{w}_{i,j,k} = w_{i,j,k} + \eta \delta_{i,j} y_{i-1,k}$ 
24:      end for
25:    end for

```

26: *end for*

27: *end for*

Para las pruebas con la red neuronal se utilizaron los mismos procedimientos que en los dos casos anteriores. En la tabla 14 se pueden consultar los resultados para excitación y en la tabla 15 los resultados para valencia donde se resaltaron los valores más altos.

Tabla 14: Tabla de resultados para excitación con RN

EXCITACIÓN				
DEAP				
Algoritmo	Precision	Recall	F1-score	Accuracy
RN	0.684	0.708	0.880	0.785
RN + PCA	0.695	0.697	0.971	0.811
MAHNOB-HCI				
RN	0.709	0.673	0.673	0.673
RN + PCA	0.781	0.758	0.814	0.785

Los resultados de la red neuronal para excitación fueron los más altos en comparación a los obtenidos con SVM y RF aplicando o no PCA para ambos repositorios. Esto establece a la red neuronal como el modelo más óptimo y señala que ambos repositorios son funcionales pues obtuvieron valores bastante similares.

Al analizar de forma detallada estas diferencias se podría decir que el repositorio Mahnob es más adecuado pues obtuvo un mejor rendimiento con las métricas *precision* y *recall*, ambas de crucial importancia para un clasificador.

Tabla 15: Tabla de resultados para valencia con RN

VALENCIA				
DEAP				
Algoritmo	Precision	Recall	F1-score	Accuracy
RN	0.703	0.691	0.936	0.795
RN + PCA	0.672	0.665	0.962	0.786
MAHNOB-HCI				
RN	0.700	0.689	0.836	0.755
RN + PCA	0.727	0.710	0.870	0.782

De la misma manera los resultados de la predicción de valencia fueron los más altos en comparación a los modelos de SVM y RF, con y sin PCA, para los dos repositorios. Esto termina de definir a la red neuronal como un modelo robusto pues obtuvo un rendimiento aceptable con los dos repositorios lo que indica un alto grado de compatibilidad. Analizando detalladamente las diferencias entre repositorios MAHNOB posee un mejor desempeño con las métricas *precision* y *recall* que como se mencionó anteriormente tienen mayor peso.

4.4.5 Discusión

Analizando los resultados obtenidos en las pruebas de rendimiento, se puede llegar a varias conclusiones, en primer lugar, los tres algoritmos funcionan de forma decente para ambos repositorios, pero destaca el desempeño de la red neuronal por un pequeño margen. De la misma forma los dos repositorios funcionan para entrenar y predecir ambas características (valencia y excitación). Además, el utilizar técnicas como PCA altera los resultados regularmente de forma positiva. UXLab no puede realizar de forma automática estas técnicas de reducción de características, sin embargo, abre la posibilidad de que en futuras mejoras se implementen estas funciones.

Capítulo 4. Metodología de solución

En la tabla 16 se muestran los resultados para la predicción de excitación en todos los escenarios anteriormente descritos. La figura 26 sirve para visualizar de forma sencilla las diferencias entre los distintos modelos y como estos son influenciados por el repositorio con el que fueron entrenados. De forma similar la figura 27 refleja este aspecto, pero al aplicarse la reducción de características.

Tabla 16: Resultados de la predicción de excitación

EXCITACIÓN				
DEAP				
Algoritmo	Precision	Recall	F1-score	Accuracy
SVM	0.656	0.663	0.970	0.788
SVM + PCA	0.684	0.689	0.977	0.808
RF	0.660	0.721	0.823	0.769
RF + PCA	0.640	0.693	0.779	0.734
RN	0.683	0.708	0.880	0.785
RN + PCA	0.695	0.697	0.971	0.811
MAHNOB-HCI				
SVM	0.654	0.673	0.600	0.634
SVM + PCA	0.645	0.560	0.787	0.654
RF	0.681	0.682	0.654	0.672
RF + PCA	0.690	0.687	0.758	0.721
RN	0.709	0.683	0.673	0.673
RN + PCA	0.781	0.758	0.814	0.785

Como se había mencionado anteriormente los resultados de la red neuronal fueron los más altos para predecir excitación, inclusive sin necesitar de la técnica PCA. En el caso del repositorio MAHNOB esto es bastante notable ya que conserva los resultados más altos para todas las métricas, resaltando la precisión que alcanzó el 78% y aun sin PCA el 71%. Por parte del repositorio DEAP también se le considera el modelo más óptimo sin embargo obtuvo un menor rendimiento en comparación a MAHNOB con una precisión del 69% y sin PCA de 68%.

Resultados de EXCITACIÓN

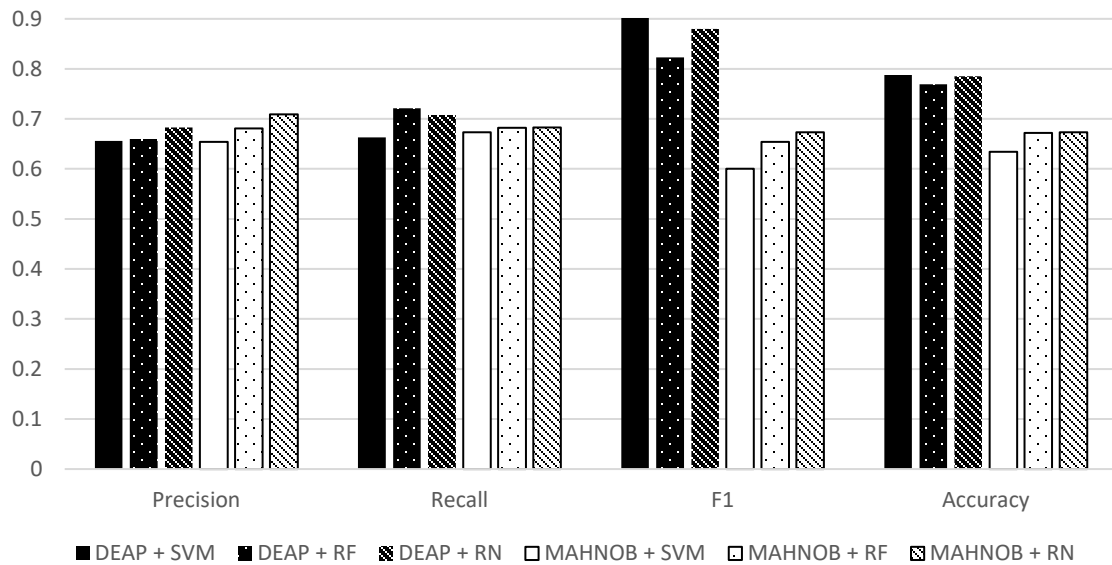


Figura 26: Resultados de excitación entre repositorios

Resultados de EXCITACIÓN + PCA




Figura 27: Resultados de excitación entre repositorios + PCA

La representación de los resultados en la figura 26 ayuda a observar de forma sencilla la diferencia entre el desempeño de los repositorios, así como los detalles importantes que no eran tan evidentes. Por ejemplo, se puede notar que salvo por la precisión, DEAP resalta más para predecir las otras métricas: También refuerza

Capítulo 4. Metodología de solución

la idea de la red neuronal como el modelo más adecuado pues la precisión consiguió el valor más alto de la mano del repositorio MAHNOB, las métricas *f1* y *accuracy* obtuvieron los valores más destacables con SVM y RN de la mano con DEAP y la métrica *recall* con RF entrenado con DEAP. Similar al caso anterior la figura 27 explora las diferencias en el rendimiento de los repositorios aplicando PCA, en este caso, el modelo de red neuronal con MAHNOB resalta con las métricas de *precision* y *recall*, por otra parte, SVM y RN obtuvieron resultados virtualmente iguales y superiores de la mano de DEAP para las métricas *f1* y *accuracy*.

En la tabla 17 se muestran los resultados para la predicción de valencia en todos los escenarios descritos anteriormente. La figura 28 sirve para visualizar de forma sencilla las diferencias entre los distintos modelos y como estos son influenciados por el repositorio con el que fueron entrenados. De forma similar la figura 29 refleja este aspecto, pero al aplicarse la reducción de características.

Tabla 17: Resultados de la predicción de valencia

VALENCIA				
DEAP				
Algoritmo	Precision	Recall	F1-score	Accuracy
SVM	0.664	0.663	0.969	0.788
SVM + PCA	0.660	0.666	0.970	0.790
RF	0.617	0.663	0.809	0.729
RF + PCA	0.652	0.687	0.856	0.762
RN	0.703	0.691	0.936	0.795
RN + PCA	0.672	0.665	0.962	0.786
MAHNOB-HCI				
SVM	0.627	0.592	0.818	0.687
SVM + PCA	0.627	0.635	0.797	0.707
RF	0.681	0.695	0.774	0.732
RF + PCA	0.681	0.705	0.761	0.732
RN	0.700	0.689	0.836	0.755
RN + PCA	0.727	0.710	0.870	0.782

Los resultados de la predicción de valencia fueron levemente inferiores a los obtenidos con excitación, sin embargo, las observaciones son similares. La red neuronal fue el modelo más marcado, inclusive sin la aplicación de PCA. Esto se nota especialmente con DEAP pues el modelo de RN clásico supero a su contraparte con PCA, en el caso de MAHNOB, los resultados de RN + PCA fueron los más altos en todo el experimento, y su contraparte sin PCA los segundos más altos seguidos.




Figura 28: Resultados de valencia entre repositorios

Si bien los resultados de la predicción de valencia son inferiores a los alcanzados para excitación (lo cual es normal debido a que son temas diferentes) es notable que son resultados demasiado similares. Por ejemplo, la red neuronal sobresale para el valor de precisión junto al repositorio Mahnob, sin embargo, el modelo RN con DEAP obtuvo un resultado igual. De la misma forma la métrica *recall* alcanzó su valor más alto junto a la RN de DEAP, no obstante, de nuevo la RN con DEAP, obtuvo un desempeño idéntico. Las métricas *f1* y *accuracy*

obtuvieron sus valores más altos pero iguales con los modelos SVM y RN entrenados con DEAP, sin embargo, les siguió la red neuronal con MAHNOB.

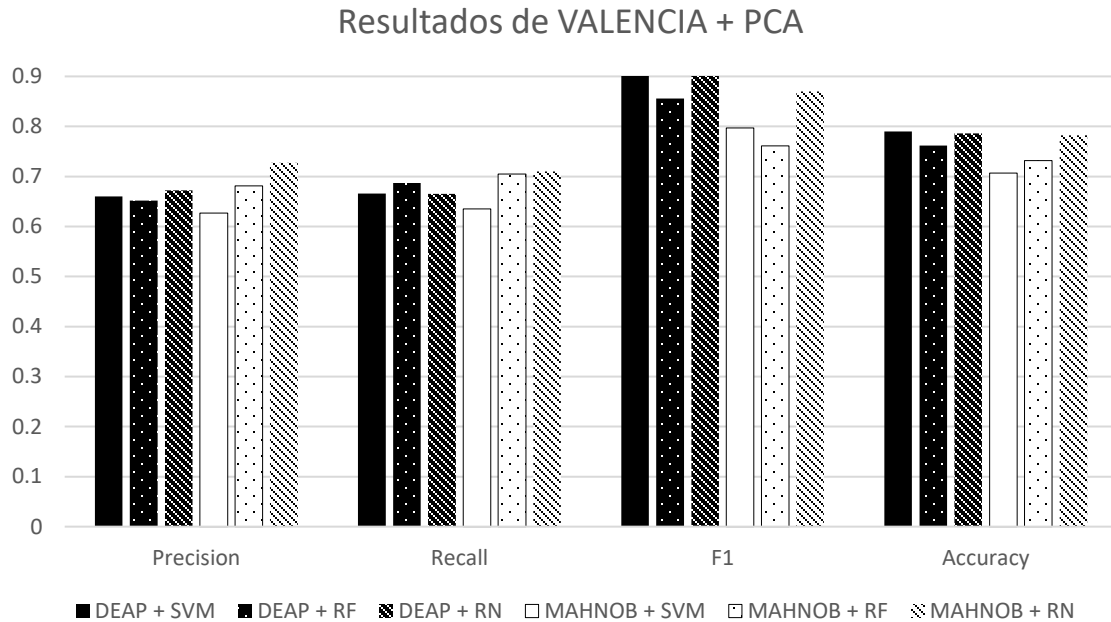


Figura 29: Resultados de valencia entre repositorios + PCA

Los resultados con valencia al implementar técnicas de reducción de características fueron levemente superiores a su contraparte sin aplicar esta técnica. Para la métrica *precision* y *recall* resalto el modelo de red neuronal con MAHNOB mientras que para las métricas *f1* y *accuracy* resaltaron los modelos SVM y RN entrenados con DEAP. Como se puede ver son escenarios similares a los vistos anteriormente incluyendo los de excitación.

Finalmente, se decidió implementar el modelo de red neuronal en la plataforma de grabación de UXLab. En la siguiente sección se mostrará el rendimiento de esta mejora mediante otras pruebas emocionales en escenarios reales.

4.5 Implementación en UXLab

Como se mencionó en la presentación de UXLab, esta plataforma tiene la capacidad de sincronizar las salidas de diferentes tipos de dispositivos, incluyendo sensores fisiológicos. Esto la convierte en la herramienta perfecta para probar el desempeño del modelo de conocimiento emocional, no obstante, es necesario pulir sus atributos. En un principio UXLab funcionaba por medio de sensores muy básicos y limitados, en el caso del sensor GSR y ritmo cardiaco se utilizaba la placa Grove que se conecta a una placa Arduino, el principal inconveniente fue que no se puede trabajar con un sensor de ritmo cardiaco como si fuera un electrocardiograma puesto que son conceptos muy diferentes, un sensor de ritmo cardiaco solo proporciona esta métrica mientras que un ECG permite la adquisición de información adicional e inclusive más valiosa como la variabilidad del ritmo cardiaco. En el caso del sensor de electroencefalografía se podía hacer la conexión con dos dispositivos de la marca EMOTIV, los modelos insight y epoc+ de 5 y 14 electrodos respectivamente.

Afortunadamente se dio la posibilidad de aumentar la calidad de los sensores gracias a la adquisición de la placa MySignals y del gorro EMOTIVE FLEX de 32 electrodos.

4.5.1 MySignals

MySignals es una plataforma de desarrollo para dispositivos médicos y aplicaciones de salud electrónica. Permite medir más de 20 señales biométricas, como pulso, frecuencia respiratoria, oxígeno en sangre, señales de electrocardiograma, señales de electromiografía muscular, respuesta galvánica de la piel, etc. Posee diferentes versiones, la versión software es un dispositivo profesional que guarda la información en la nube, sin embargo, es muy restrictiva. La versión hardware (figura 30), y actualmente en uso es una placa que necesita conectarse a Arduino y posteriormente a la computadora por medio del puerto USB, las señales no se pueden guardar por medio de la placa, sino que es responsabilidad del usuario.




Figura 30: Placa MySignals

La ilustración es extraída de Libellium, 2019. MySignals SW eHealth and Medical IoT Development Platform Technical Guide.

4.5.2 EMOTIV FLEX

EMOTIV EPOC Flex (figura 31) es el más reciente y avanzado gorro de electroencefalografía de la marca EMOTIV, proporciona una mayor cobertura de electrodos (hasta 32 canales) en comparación con otros productos de la marca. Además, la matriz de canales es configurable por el usuario de acuerdo con el sistema internacional 10-20, lo que permite a los investigadores optimizar la recopilación de datos y en este caso permite imitar la configuración de electrodos de los repositorios DEAP/MAHNOB. Este dispositivo cuenta con una resolución de 14 bits lo que ayuda a evitar el ruido eléctrico.



Figura 31: Gorro EMOTIV EPOC FLEX

La ilustración es extraída del sitio. Emotiv Epoc Flex <https://www.emotiv.com/epoc-flex/>.

Capítulo 4. Metodología de solución

Ambos dispositivos fueron implementados en UXLab de forma que se integren en su rutina de sincronización. En la tabla 18 se puede consultar el catálogo de sensores y sus variantes soportadas actualmente en el software UXLab.

Tabla 18: Tabla de resultados para valencia con RN

Sensor	Marca	Modelo	Descripción
EEG	EMOTIV	INSIGHT	Electrodos: AF3, AF4, T7, T8, Pz Frecuencia: 128 Hz Ancho de banda: 0.5-45 Hz
		EPOC+	Electrodos: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 Frecuencia: 128 - 256 Hz Ancho de banda: 0.5-45 Hz
		FLEX	Electrodos: 32 canales configurables de un total de 72 ubicaciones según el estándar de ubicación 10-20. Frecuencia: 128 - 256 Hz Ancho de banda: 0.5-45 Hz
ECG	Grove	GSR_Sensor V1.2	Sensor de frecuencia cardíaca con clip para el dedo Frecuencia: 128 Hz
	MySignals	HW v2	Electrocardiograma, sistema de tres electrodos Frecuencia: 128 - 256 Hz
GSR	Grove	HEART RATE sensor	Salidas: Voltaje Frecuencia: 128 Hz
	MySignals	HW v2	Salidas: Voltaje, Conductancia, Resistencia Frecuencia: 128 - 256 Hz

Adicionalmente se hicieron los cambios necesarios para adoptar los nuevos procesos relacionados a la clasificación emocional como es la implementación de los métodos de filtrado, extracción de características y el propio modelo de aprendizaje automático entrenado. Paralelamente a este trabajo se realizó otra mejora en UXLab relacionada al seguimiento ocular para el reconocimiento de estados cognitivos por lo que se realizó una colaboración con el objetivo de mejorar los aspectos visuales y de usabilidad de la plataforma incluyendo sus dos componentes, el grabador y reproductor.

4.5.3 Mejoras generales a UXLab

Además de integrar nuevas funcionalidades en el software de UXLab, se trabajó en mejoras dentro del código de la interfaz gráfica, con el fin de mejorar su usabilidad. Las mejoras fueron las siguientes:

- Visuales
- Iconos
- Tooltips
- Botones consistentes
- Menús de ayuda
- Validación de campos
- Tamaños, posición y consistencia de ventanas
- Funcionales
- Arreglo de bugs en los módulos relacionados a la adquisición de las señales fisiológicas
- Desarrollo de un proceso completo de instalación y distribución

4.5.4 Modificaciones en el proceso de grabación

Mientras se realizaba la integración de los módulos de predicción emocional a UXLab se hicieron algunos cambios en la forma de almacenar los archivos de las señales fisiológicas y se estableció una frecuencia base para todos los sensores, así como se añadieron algunas mejoras al proceso general. No se realizaron cambios críticos en los métodos de conexión y sincronización de los sensores más allá de la incorporación de los nuevos dispositivos por lo que se garantizó la integridad de las funcionalidades anteriores a este trabajo.

Cómo se puede ver en la figura 32, visualmente se realizó la separación de los sensores en el módulo administrador de dispositivos añadiendo una fila de opciones por cada sensor. La opción selección permite acceder a un menú donde se puede elegir el modelo del sensor con el que se desea realizar la conexión y ésta iniciará al presionar el botón activar.




Figura 32: Nueva interfaz del módulo de dispositivos.

La ilustración es adaptada de Fouilloux, 2018. Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario.

La opción visualizar continúa funcionando de la misma forma sin embargo se mejoró la manera en la que se muestra el flujo de datos para dar una mejor perspectiva de la información, la figura 33 muestra el flujo de datos del sensor ECG y GSR.




Figura 33: Visualización del flujo de datos de los sensores ecg/gsr
a) electrocardiograma, b) respuesta galvánica en piel

Por otra parte, los cambios realizados en el integrador de grabación se limitan a su funcionalidad interna salvo por los pequeños detalles visuales que se pueden notar en la figura 34.




Figura 34: Nueva interfaz del Integrador de grabación.

La ilustración es adaptada de Fouilloux, 2018. Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario.

4.5.4.1 Integración del módulo de reconocimiento emocional

El proceso de reconocimiento emocional se integró de la siguiente forma, en primer lugar, se estableció que éste iniciará hasta después de que se generaren los archivos de los sensores fisiológicos. Estos archivos posteriormente son analizados y sometidos a una capa de filtrado similar a la utilizada para los repositorios. En la práctica UXLab será utilizado para evaluaciones de la experiencia de usuario, estas pruebas suelen ser extensas y podrían durar entre 10 y 20 minutos lo que hace impráctico utilizar toda la información de los sensores para una sola predicción emocional, además las emociones como se analizó en su momento son de corta duración. Debido a esto se programó la segmentación del flujo de los sensores en periodos de 15 segundos, como se muestra en la figura 35. Más adelante se realiza la extracción de características para cada periodo y finalmente se compone un pequeño repositorio el cual será utilizado por los modelos entrenados en valencia y excitación para obtener las predicciones emocionales.




Figura 35: Representación de la segmentación de pruebas

Adicional y únicamente con propósitos visuales se realizó otro análisis para medir de forma más precisa el nivel de la valencia (figura 36 a) y excitación (figura 36 b), pero en este caso por medio de una escala, utilizando las evaluaciones individuales de los usuarios al final de cada prueba, como se muestra en la figura 36.

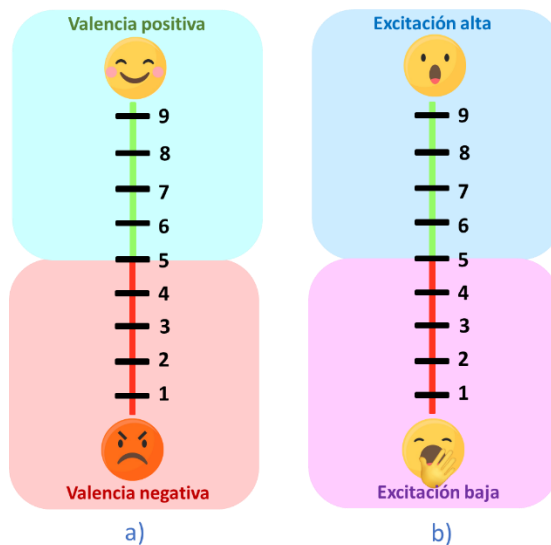


Figura 36: Escalas emocionales

Capítulo 4. Metodología de solución

Como se mencionó anteriormente ambos repositorios DEAP/MAHNOB utilizaron la escala SAM para evaluar la experiencia del usuario en términos de la valencia, excitación y dominancia, esto por medio de una escala que va desde el 1 a 9, los resultados de dichas encuestas se utilizaron para etiquetar las pruebas sin embargo las etiquetas utilizadas se hicieron por medio de las clases positiva/negativa para valencia y alta/baja para excitación, perdiendo así el valor específico de su experiencia. Se propuso implementar en UXLab el uso del valor específico de estas encuestas para calcular de forma más atractiva el nivel de valencia y excitación durante las evaluaciones por medio de técnicas de regresión. Gracias a esto se implementó el algoritmo Support Vector Regression (Regresión de Soporte Vectorial) la cual es una variante del modelo SVM, pero su uso se centra en predecir valores por medio de regresión.

Por obvias razones los resultados de un modelo de regresión no se pueden comparar con la precisión de la red neuronal desarrollada debido a su menor capacidad de análisis y los problemas de extrapolación que surgen. Los resultados de estas evaluaciones solo serán utilizados por el reproductor de UXLab para representar de forma más gráfica el recorrido de las emociones y no se tomarán en cuenta para la evaluar su precisión. Los resultados del algoritmo de regresión se sujetan a los resultados de la red neuronal, por ejemplo, si se asignó a un periodo con valencia negativa el valor de regresión debería estar entre 1 y 5, en caso de valencia positiva entre 6 y 9, de la misma forma esto aplica para la excitación. Los resultados se almacenan en un archivo separado por comas (csv) en la carpeta establecida en UXLab.

En la figura 37 se puede ver el esquema conceptual del proceso de grabación de UXLab.

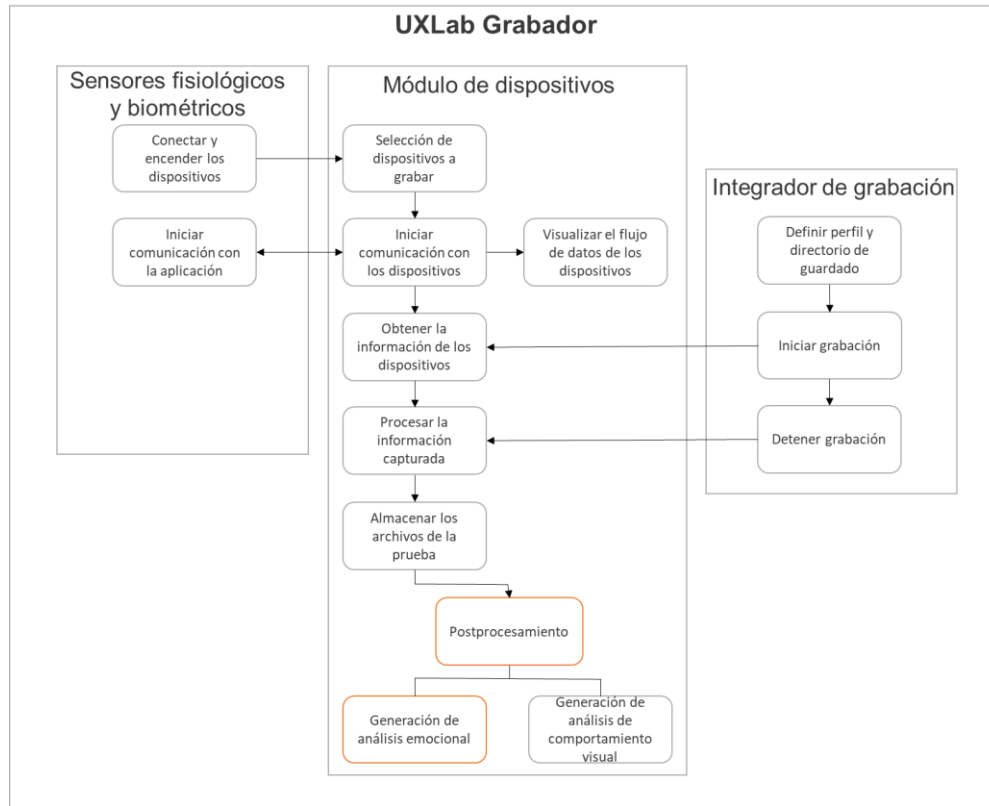


Figura 37: esquema conceptual del proceso de grabación de UXLab.

4.5.5 Modificaciones en el proceso de reproducción

El reproductor de UXLab también fue modificado para integrar el módulo de reconocimiento emocional, añadiendo elementos que ayuden a interpretar correctamente los resultados (figura 38). En la parte superior de la interfaz se encuentra la sección de menús, el menú principal (1) permite seleccionar la ruta de almacenamiento de la prueba que será visualizada, mientras que los menús de métricas oculares (2) permiten la selección del tipo de video de análisis visual que se reproducirá, cabe destacar que esta opción es ajena al módulo de reconocimiento emocional. Debajo de la sección de menús se encuentra la sección de video, esta se divide en dos grabaciones, la primera muestra la actividad que realizó el usuario durante la prueba (3) y la segunda la grabación de la cámara web de su rostro (4). Entre ambas grabaciones se encuentran los indicadores emocionales (5), su función es la de interpretar los resultados de la predicción de valencia y excitación. El primer modelo representa los cuadrantes emocionales,

Capítulo 4. Metodología de solución

cuando se inicia la reproducción, estos cambiarán dependiendo del nivel de valencia y excitación, mostrando el cuadrante al que se vinculan. El segundo modelo muestra emojis, estos elementos son expresivos y se utilizan actualmente para la comunicación en redes sociales, por lo que son muy familiares y agradables para las personas. Los emojis que se muestran también dependen de la predicción de la valencia y excitación y representan las emociones relacionadas al cuadrante emocional mostrado. En la parte inferior de la interfaz se encuentran las representaciones gráficas de la predicción de valencia/excitación y el flujo de los sensores capturados (6). Este componente posee un cursor, al ir descendiendo por éste se mostrará en primer lugar el recorrido emocional de excitación, debajo el recorrido emocional de la valencia y el flujo de los sensores fisiológicos EEG, ECG y GSR. Para visualizar el tiempo transcurrido y el momento actual de la prueba existe la línea de tiempo (7) y para poder pausar, adelantar y retrasar se encuentran los botones de control (8).

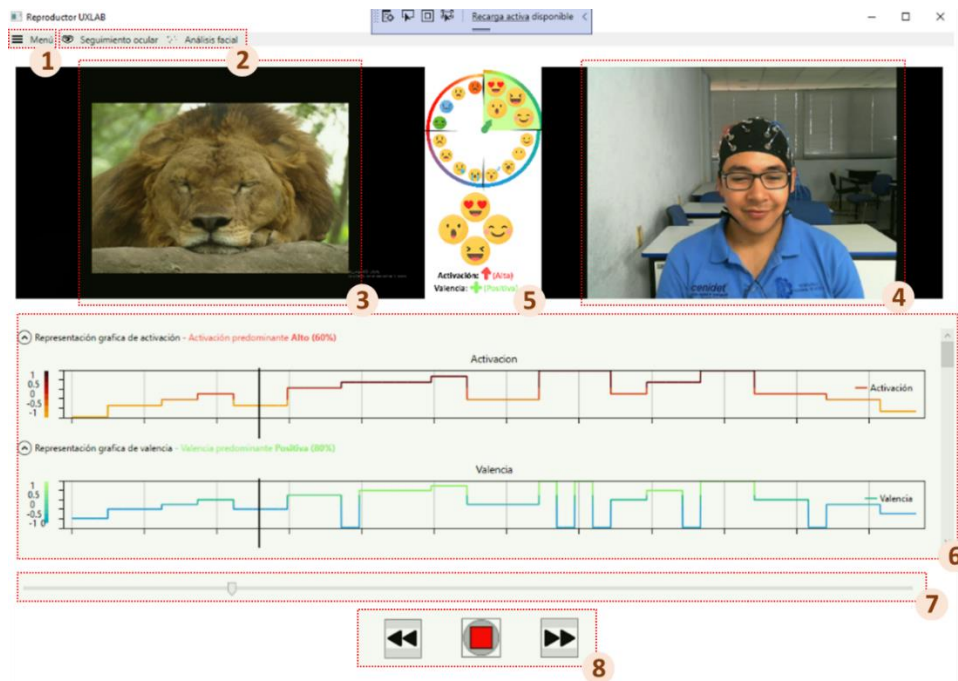


Figura 38: Elementos de la Interfaz del Reproductor UXLab. 1) Menú principal (abrir grabación), 2) Menú de métricas oculares, 3) Memoria de video del usuario durante su experiencia, 4) Video del rostro del participante de la prueba, 5) Indicadores emocionales, 6) Representación gráfica de resultados y sensores capturados, 7) Línea de tiempo, 8) Botones de control, reproducir, adelantar, regresar.

La ilustración es adaptada de Fouilloux, 2018. Método para integrar y sincronizar datos EEG y multimedia para su aplicación en el proceso de evaluación de la experiencia del usuario.

En la figura 39 se ilustra el diagrama conceptual del proceso de reproducción.

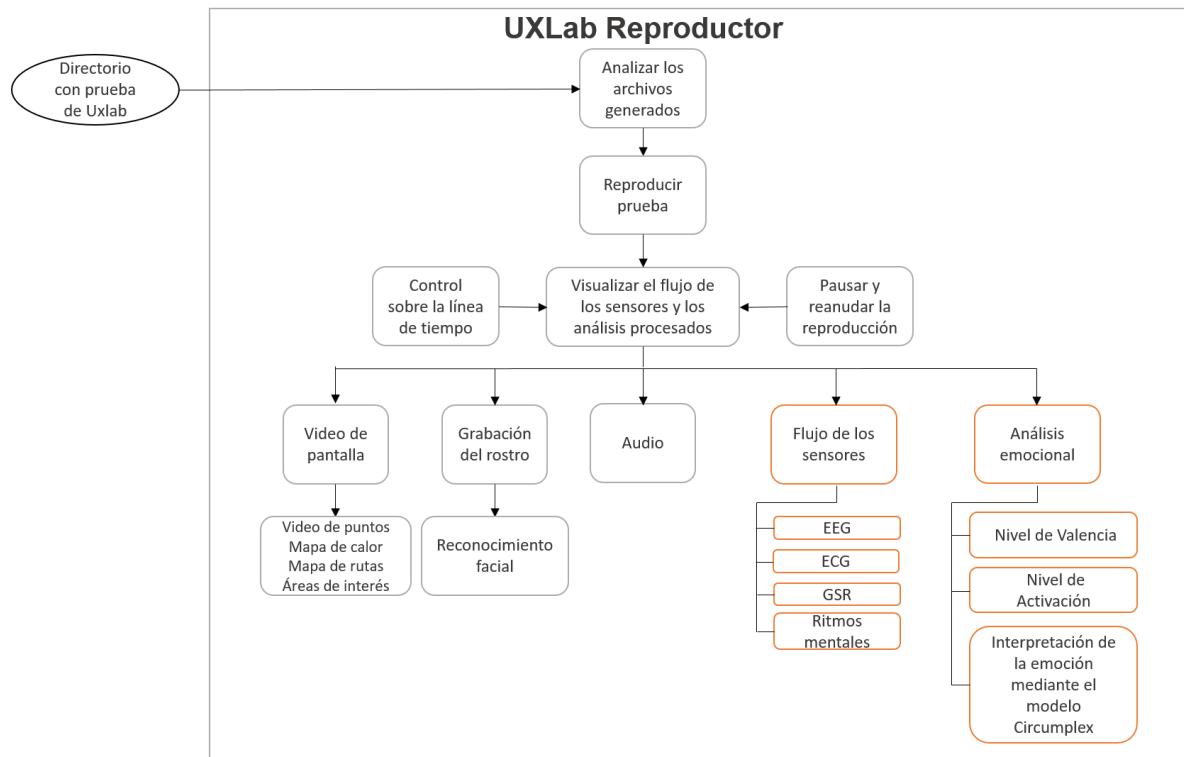


Figura 39: Esquema conceptual del proceso de grabación de UXLab.

4.6 EMOLEARN

Al tratar con los repositorios de DEAP y MAHNOB-HCI fue necesario implementar un sistema para automatizar la generación de datasets. Cada señal fisiológica posee diferentes formas de filtrado y características que varían desde el cálculo de la frecuencia, el tiempo o incluso análisis más profundos. Crear un dataset de este tipo conlleva muchos parámetros y es común explorar diferentes opciones. Por esta razón se desarrolló una herramienta de software que toma como entrada señales fisiológicas ya sea de repositorios como DEAP, MAHNOB-HCI o incluso del propio UXLab, los procesa y permite personalizar el proceso de filtrado y extracción de características para generar los datasets correspondientes de valencia y excitación. Estos datasets pueden ser utilizados más adelante en la misma aplicación para entrenar un clasificador. Los algoritmos implementados en el sistema son máquinas de soporte vectorial (SVM), Bosques aleatorios (RF) y el

Capítulo 4. Metodología de solución

modelo de red neuronal. También se puede aplicar funciones de reducción de características como el análisis de componentes principales. En la Figura 34 se muestra la arquitectura del sistema EmoLearn.




Figura 40: Esquema conceptual del funcionamiento de EMOLEARN

4.6.1 Funcionamiento

El funcionamiento de EmoLearn se divide en sus dos principales características, construir un dataset y clasificar. En la figura 41 se puede observar el menú principal de la aplicación.



Figura 41: Menú principal de EMOLEARN

4.6.1.1 Generar Dataset

Al seleccionar esta opción se mostrará la primera sección del proceso de generación de datasets, llamada preprocesamiento. En ésta se debe elegir la carpeta donde se almacenan las señales fisiológicas en formato csv. En esta sección también se deben establecer las señales que conformaran el dataset y el rango de frecuencia a utilizar para el filtrado de cada una. En la figura 42 se puede ver la interfaz de la sección uno: preprocesamiento.



Figura 42: Sección 1: preprocesamiento (EMOLEARN)

Capítulo 4. Metodología de solución

Después de llenar los requisitos de la sección uno y presionar el botón guardar, se mostrará la siguiente sección. Esta sección se conoce como extracción de características y como su nombre indica en esta se seleccionan las características que más adelante serán extraídas de los repositorios. Las características de electrocardiografía y respuesta galvánica se seleccionan por medio de un menú desplegable mientras que las de electroencefalografía por medio de un diagrama que representa los electrodos de un dispositivo EEG. En la figura número 43 se puede ver la interfaz de la sección dos.



Figura 43: Sección dos: extracción de características (EMOLEARN)

Tras seleccionar las características necesarias y presionar el botón guardar se mostrará la sección tres y última llamada visualizar configuración. Esta sección permite visualizar las pruebas y usuarios encontradas del repositorio, así como las características que fueron seleccionadas anteriormente. En esta se debe seleccionar la ruta de almacenamiento de los datasets y presionar el botón iniciar procesamiento para que se generen los datasets. Este es un proceso bastante tardado por lo que se mostrara una barra de progreso para poder visualizar el tiempo aproximado que requiere. También es posible cancelarlo en cualquier momento. Al finalizar el proceso se mostrará la leyenda “terminado” sobre la barra

Capítulo 4. Metodología de solución

de carga y en la carpeta seleccionada se encontrarán dos dataset, uno para valencia y otro para excitación. En la figura número 44 se muestra el diseño de la sección tres.




Figura 44: Sección tres: visualizar configuración (EMOLEARN)

4.6.1.2 Clasificador

Esta opción permite probar de forma sencilla y con la configuración adecuada al proyecto, diferentes algoritmos de aprendizaje automático. Estos son máquinas de soporte vectorial (SVM), Bosques aleatorios (RF) y la red neuronal. Permite usar dos proporciones de muestras: 70/30 y 80/20. También se puede aplicar análisis de componentes principales (PCA) para obtener un resumen de las características más apropiadas. Los resultados se muestran en base a las propiedades valencia y excitación por medio de las métricas *precisión*, *recall*, *f1-score* y *accuracy*. En la figura 45 se puede visualizar la pantalla perteneciente a esta función.

EmoLearn

Clasificador

Seleccionar directorio:

Algoritmo: SVM Prueba: 80/20 Aplicar PCA

Kernel: Lineal No. Características:

Clasificar

Finalizado

Matriz de confusión
Activación

Predicción	Positivos	Negativos
Positivos	31	15
Negativos	31	33

Resultados
Activación

Precisión	0.69
Recall	0.52
F1-score	0.59
Accuracy	0.58

Matriz de confusión
Valencia

Predicción	Positivos	Negativos
Positivos	16	28
Negativos	13	53

Resultados
Valencia

Precisión	0.65
Recall	0.8
F1-score	0.72
Accuracy	0.63

Volver atrás
Guardar resultados

Figura 45: Interfaz del clasificador (EMOLEARN)

5. Pruebas y resultados

En este capítulo se reportan los resultados de las pruebas realizadas para validar la metodología de solución planteada en esta tesis, así como los resultados obtenidos y los hallazgos relevantes.

5.1 Plan de pruebas

El plan de pruebas se dividió en dos bloques: 1) Pruebas funcionales con los softwares involucrados: UXLab, Emolearn y 2) pruebas de reconocimiento emocional enfocadas a medir la precisión del algoritmo desarrollado. En el 1er caso, pruebas funcionales, se anexó el reporte de las mismas en un documento separado que fue entregado en la presentación de resultados. Para la validación del proceso de reconocimiento de emociones en este capítulo se reportan los resultados de las pruebas utilizando la red anteriormente entrenada e instalada dentro de la plataforma UXLab.

5.2 Reporte de resultados

A continuación, se presentan los detalles sobre la ejecución del plan de pruebas, los resultados obtenidos y los hallazgos relevantes encontrados durante este proceso.

5.2.1 Pruebas funcionales con el software UXLab

Las pruebas con el software UXLab se enfocaron en ejecutar y comprobar el correcto funcionamiento de las funcionalidades asociadas al módulo de adquisición de señales fisiológicas y reconocimiento emocional implementado en este software, en el sistema de grabación y el sistema reproductor. Estas funcionalidades abarcan la adquisición y almacenamiento de las señales fisiológicas, los procesos de filtrado para cada sensor, la extracción de características y la clasificación emocional, además del almacenamiento de la información y la visualización de los resultados. En la figura 46 se muestra el conjunto de funcionalidades que involucró este proceso, tanto para la herramienta de grabación (a) como la herramienta de reproducción (b). Estas verificaciones se realizaron en forma de casos de prueba

donde se analizó el correcto comportamiento de la aplicación mientras se realizaba el proceso de reconocimiento emocional en la aplicación UXLab y posteriormente se visualizaban los resultados. Al final de las pruebas se puede concluir que la plataforma UXLab tiene la capacidad de adquirir la información de un conjunto de sensores fisiológicos y en base a las señales obtenidas predecir emociones de acuerdo con el modelo valencia-excitación.

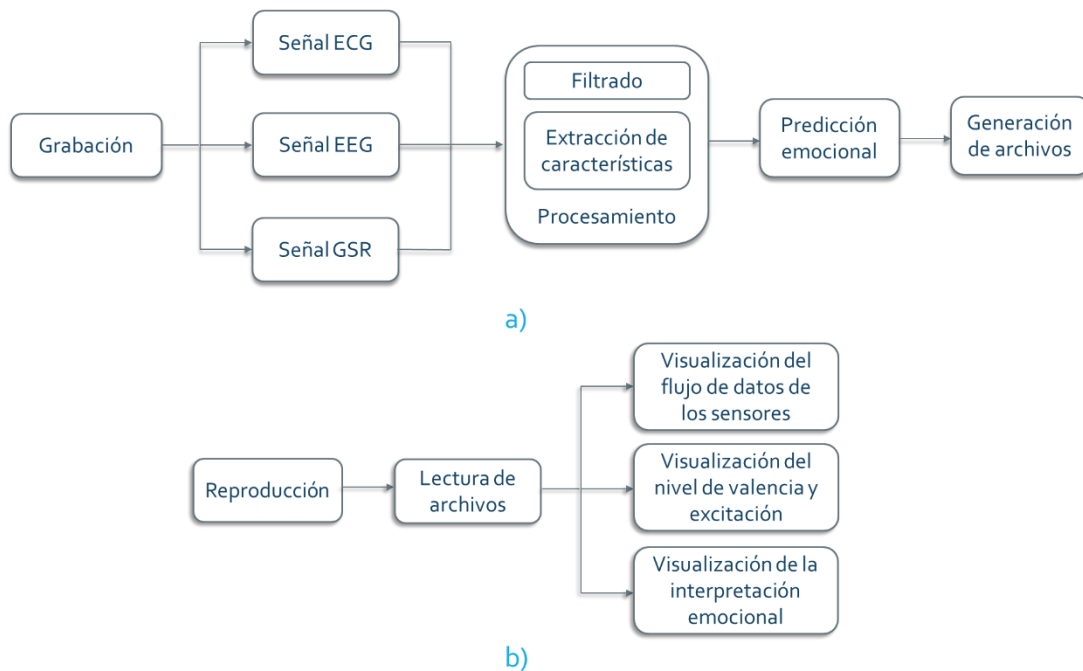


Figura 46: Esquemas de funcionalidades de la plataforma UXLab, grabador a) y reproductor b)

5.2.2 Pruebas funcionales con EMOLEARN

Las pruebas con la plataforma EMOLEARN se centraron en demostrar su capacidad para generar datasets de datos fisiológicos. De igual manera se realizaron en forma de casos de prueba donde se validó la configuración de todos los parámetros mientras se realizaba el proceso de desarrollo de un dataset. En conclusión, se puede confirmar que el software EMOLEARN tiene la capacidad de construir y evaluar datasets para predicción emocional por medio de repositorios de señales fisiológicas.

5.2.3 Pruebas de reconocimiento emocional

Para realizar las pruebas de reconocimiento emocional se contó con la participación de 8 usuarios, cuatro hombres y cuatro mujeres con una edad media de 28 años. A cada uno se le aplicó la metodología de inducción emocional (PIE) desarrollada en (Soriano, 2018) utilizando los estímulos visuales del repositorio IAPS presentados en la figura 47. Cada estímulo se mostró durante 30 segundos, uno detrás del otro. Al final de cada prueba se realizó la predicción emocional con el software UXLab (cada predicción toma 15 segundos) y se visualizaron los resultados en el módulo reproductor junto con los videos de actividad y rostro, de forma que la predicción de UXLab coincidiera con la clasificación del estímulo mostrado, si esto era así entonces se contaba como acierto, de otra forma se contaba como error. Los resultados obtenidos se agruparon en orden de estímulo y se especificaron los hallazgos relacionados a estos, también se analizaron y correlacionaron los resultados obtenidos con el cuestionario SAM que se aplicó al final de cada bloque.




Figura 47: Estímulos utilizados para las pruebas emocionales. Las ilustraciones fueron extraídas de Kurdi, Lozano, y Banaji, 2016. Introducing the Open Affective Standardized Image Set (OASIS). Behavior Research Methods.

5.2.3.1 Estímulos de Alegría

En general los estímulos de alegría, que se interpretan como valencia positiva y excitación alta, fueron reconocidos de manera aceptable. Los cuatro estímulos mostrados en la tabla 19 demostraron tener un impacto positivo en los usuarios, principalmente las dos primeras imágenes, ya que consiguieron ser acertadas en la mayoría de las ocasiones, sin embargo, el tercer y cuarto estímulo sólo consiguieron ser acertados en la mitad de los casos. Analizando la reacción de los usuarios se puede notar cierto grado de desinterés con el paso del tiempo, esto quizá se deba a que las imágenes no son tan llamativas o que su duración es demasiada para una imagen estática (15 segundos).

Tabla 19: Imágenes IAPS utilizadas en el pie alegría



En la tabla 20 se muestran los resultados obtenidos con el clasificador en términos de valencia y excitación donde se resaltan los aciertos. Como se mencionó en anteriormente las pruebas resultaron aceptables ya que la mayoría de las imágenes fueron acertadas en al menos una característica. Sin embargo, para que se tome como una predicción exitosa ambas características deben ser acertadas. Aun con esto el clasificador logró un desempeño aceptable con los estímulos de alegría.

Capítulo 5. Pruebas y resultados

Tabla 20: Resultados obtenidos con el clasificador, estímulos de alegría

Usuario	Imagen 1		Imagen 2		Imagen 3		Imagen 4	
	Valencia	Excitación	Valencia	Excitación	Valencia	Excitación	Valencia	Excitación
1	Positiva	Alta	Positiva	Baja	Positiva	Baja	Positiva	Baja
2	Positiva	Alta	Positiva	Alta	Negativa	Baja	Negativa	Baja
3	Positiva	Alta	Positiva	Alta	Positiva	Baja	Positiva	Alta
4	Positiva	Alta	Negativa	Baja	Positiva	Alta	Positiva	Alta
5	Positiva	Alta	Positiva	Alta	Positiva	Baja	Negativa	Baja
6	Positiva	Alta	Positiva	Alta	Positiva	Alta	Positiva	Alta
7	Positiva	Alta	Positiva	Alta	Positiva	Alta	Positiva	Alta
8	Positiva	Alta	Positiva	Alta	Positiva	Alta	Positiva	Alta

De acuerdo con los resultados de la evaluación SAM, presentados en la tabla 21, el nivel de excitación que reportaron los usuarios corresponde en promedio a un nivel de excitación baja, lo que se interpreta como un estímulo de poco interés. Sin embargo, los resultados si corresponden con valencia positiva ya que el 100% de los casos coincidió que son estímulos agradables. Tomando en cuenta los resultados del dominio los usuarios reportaron sentirse serenos y tranquilos. En la figura 48 se puede consultar el promedio de estas encuestas, recordando que los valores deseables deberían superar el nivel 5 para ambas características pues éstas se traducirían en una valencia positiva y excitación alta. Los resultados muestran que se alcanzó una valencia positiva pero las respuestas de los usuarios parecen inclinarse por una excitación baja.

Tabla 21: Evaluación SAM, estímulos de alegría

Alegría			
Usuario	Valencia	Excitación	Dominio
1	7	3	5
2	5	3	5
3	7	5	5
4	7	7	5
5	7	5	5
6	7	3	7
7	7	3	5
8	5	1	8

VALORES PROMEDIO DE LA ENCUESTA SAM




Figura 48: Valores promedio de la encuesta SAM para los estímulos de alegría

En la figura 49 se presentan imágenes de usuarios que realizaron las pruebas de inducción con los estímulos de alegría.



Figura 49: Usuario reaccionando a estímulos de alegría

5.2.3.2 Estímulos de Ansiedad

Los estímulos de ansiedad traducidos como valencia negativa, excitación alta fueron los menos acertados durante las pruebas, siendo mal clasificadas en la mayoría de las ocasiones lo cual puede deberse a varios factores. El propósito de este tipo de estímulos era causar mucha incomodidad, casi siempre se acertaba con la valencia lo que certifica que son imágenes muy desagradables pero la excitación tuvo muchos problemas para ser clasificada, la razón podría ser que los estímulos mostrados en la tabla 22 simplemente son poco impactantes o confunden demasiado a los usuarios ya que no son explícitas en lo absoluto.

Tabla 22: Imágenes IAPS utilizadas en el pie de ansiedad



En la tabla 23 se muestran los resultados obtenidos con el clasificador en términos de valencia y excitación donde se resaltan los aciertos. Si bien es notable que al menos en la mitad de las predicciones el clasificador acertó en una característica, para estas pruebas es necesario que tanto la valencia como la excitación realicen la predicción correctamente. Por lo que el clasificador no está entrenado de la mejor manera para predecir la emoción de ansiedad.

Capítulo 5. Pruebas y resultados

Tabla 23: Resultados obtenidos con el clasificador, estímulos de ansiedad

Usuario	Imagen 1		Imagen 2		Imagen 3		Imagen 4	
	Valencia	Excitación	Valencia	Excitación	Valencia	Excitación	Valencia	Excitación
1	Negativa	Alta	Negativa	Baja	Positiva	Alta	Positiva	Baja
2	Positiva	Alta	Negativa	Baja	Positiva	Baja	Negativa	Baja
3	Negativa	Alta	Positiva	Baja	Negativa	Baja	Positiva	Baja
4	Positiva	Alta	Negativa	Alta	Positiva	Alta	Negativa	Alta
5	Negativa	Alta	Positiva	Baja	Negativa	Alta	Positiva	Baja
6	Negativa	Baja	Negativa	Alta	Negativa	Alta	Negativa	Alta
7	Negativa	Alta	Positiva	Baja	Positiva	Alta	Negativa	Alta
8	Positiva	Alta	Negativa	Alta	Positiva	Baja	Negativa	Alta

Los resultados de las evaluaciones SAM se pueden consultar en la tabla 24. Analizar estas respuestas ayuda a entender mejor el comportamiento del clasificador, pues ambas partes concuerdan con la idea de que las imágenes si causaron cierta influencia negativa. Sin embargo, una sola respuesta relacionó los estímulos presentados con excitación alta, lo que concuerda con las predicciones del clasificador y sugiere que los estímulos no funcionaron como se esperaba. En el caso del dominio en promedio se alcanzó un valor medio lo que indica un completo control de los usuarios. En la figura 50 se puede consultar el promedio de estas encuestas, recordando que los valores deseables deberían superar el nivel 5 en excitación para interpretarse como alta, lo cual no sucedió y ser inferiores a 5 en valencia para considerarse como negativa, lo que si ocurrió.

Tabla 24: Evaluación SAM, estímulos de ansiedad

Usuario	Ansiedad		
	Valencia	Excitación	Dominio
1	5	2	5
2	5	3	7
3	3	3	3
4	3	5	7
5	3	5	6
6	5	3	7
7	3	6	4
8	6	1	8

VALORES PROMEDIO DE LA ENCUESTA SAM




Figura 50: Valores promedio de la encuesta SAM para los estímulos de Ansiedad

En la figura 51 se muestran imágenes de usuarios que realizaron las pruebas de inducción con los estímulos de ansiedad.




Figura 51: Usuario reaccionando a estímulos de ansiedad

5.2.3.3 Estímulos Neutros

Los estímulos neutros (tabla 25) fueron utilizados para conocer la reacción de los usuarios ante imágenes poco impactantes y sin un contexto claro, por lo que no están etiquetados bajo ningún nivel de valencia. No obstante, lo esperado es que fuesen clasificados con niveles bajos de excitación. En la práctica esto sucedió como se esperaba, en casi el 100% de los casos el clasificador realizó las predicciones con excitación baja, aunque en cuestión de valencia los valores variaron inclinándose por positiva.

Tabla 25: Imágenes IAPS utilizadas en el pie para neutralidad



En la tabla 26 se muestran los resultados obtenidos con el clasificador en términos de excitación y se resaltan los aciertos. Al tratarse de pruebas de predicción de una sola característica, el clasificador pudo acertar en la gran mayoría de las predicciones lo que denota que los estímulos son verdaderamente simples y no causan mayor impacto en los usuarios.

Capítulo 5. Pruebas y resultados

Tabla 26: Resultados obtenidos con el clasificador, estímulos neutros

Usuario	Imagen 1	Imagen 2	Imagen 3	Imagen 4
	Excitación	Excitación	Excitación	Excitación
1	Baja	Baja	Baja	Baja
2	Baja	Baja	Baja	Baja
3	Baja	Baja	Baja	Baja
4	Baja	Baja	Baja	Baja
5	Baja	Baja	Alta	Baja
6	Baja	Baja	Alta	Baja
7	Baja	Baja	Baja	Baja
8	Alta	Alta	Baja	Baja

Los resultados de las evaluaciones SAM se pueden consultar en la tabla 27. Según estas encuestas los usuarios encontraron los estímulos poco atractivos y levemente positivos o al menos no desagradables. En la figura 52 se puede consultar el promedio de estas encuestas, recordando que el valor deseable para excitación debería ser inferior a 5 para interpretarse como excitación baja.

Tabla 27: Evaluación SAM, estímulos neutros

Neutro			
Usuario	Valencia	Excitación	Dominio
1	5	2	5
2	7	1	7
3	4	3	3
4	5	1	5
5	5	3	5
6	7	5	7
7	5	3	7
8	9	1	9

VALORES PROMEDIO DE LA ENCUESTA SAM





Figura 52: Valores promedio de la encuesta SAM para los estímulos neutros

5.2.3.4 Estímulos de Tristeza

Los estímulos de tristeza se clasifican bajo las etiquetas de valencia negativa y excitación baja, los estímulos pueden consultarse en la tabla 28. Cada una de las imágenes fue clasificada correctamente en la mayoría de las pruebas, el tema principal de este conjunto de estímulos fueron los paisajes, los cuales demostraron ser lo suficientemente melancólicos o deprimentes. Las imágenes de mayor impacto para las pruebas fueron los estímulos 2 y 3, ambos representan escenarios relacionados al abandono, lo cual podría ser la razón de su desempeño, ya que esta es una sensación común en las personas. Por otra parte, los estímulos 1 y 4 son imágenes un poco más abstractas pues se necesita que el usuario se identifique con la soledad y violencia que estas pretenden representar.

Capítulo 5. Pruebas y resultados

Tabla 28: Imágenes IAPS utilizadas en el pie para tristeza



En la tabla 29 se muestran los resultados obtenidos con el clasificador, de acuerdo con el nivel de valencia y excitación y se resaltan los resultados acertados. La respuesta del clasificador a estos estímulos fue positiva pues se acertó en la mayoría de las ocasiones en al menos una de las características, lo que indica que las imágenes objetivamente son un buen material de estímulo. Los resultados de estas pruebas son quizá los más positivos, junto a los de alegría.

Tabla 29: Resultados obtenidos con el clasificador, estímulos de tristeza

Usuario	Imagen 1		Imagen 2		Imagen 3		Imagen 4	
	Valencia	Excitación	Valencia	Excitación	Valencia	Excitación	Valencia	Excitación
1	Positiva	Baja	Positiva	Baja	Positiva	Baja	Positiva	Baja
2	Negativa	Baja	Negativa	Baja	Negativa	Baja	Negativa	Baja
3	Positiva	Baja	Negativa	Baja	Negativa	Baja	Positiva	Baja
4	Negativa	Baja	Negativa	Baja	Negativa	Baja	Negativa	Baja
5	Negativa	Baja	Negativa	Baja	Negativa	Baja	Negativa	Baja
6	Positiva	Alta	Negativa	Baja	Negativa	Baja	Negativa	Baja
7	Negativa	Baja	Negativa	Baja	Positiva	Baja	Positiva	Alta
8	Negativa	Baja	Positiva	Alta	Negativa	Baja	Negativa	Baja

Al analizar los cuestionarios SAM (tabla 30) se puede observar correlación entre los resultados del clasificador y las evaluaciones subjetivas de los usuarios. Pues ambas revelan la misma información, en este caso las respuestas de las encuestas

SAM sugieren que las imágenes tienen una valencia negativa para la mayoría de los usuarios y en cuestiones de excitación todos concordaron con un nivel bajo. En conclusión, el escenario de tristeza fue completamente exitoso. En la figura 53 se puede consultar el promedio de estas encuestas, recordando que los valores deseables deberían ser inferiores a 5 para ambas características pues estas se interpretan como excitación baja y valencia negativa. En este caso ambas expectativas fueron correctamente resultas.

Tabla 30: Evaluación SAM, estímulos de tristeza

Tristeza			
Usuario	Valencia	Excitación	Dominio
1	4	2	5
2	4	1	7
3	4	3	3
4	3	2	5
5	5	3	5
6	6	4	7
7	5	2	7
8	2	1	9

VALORES PROMEDIO DE LA ENCUESTA SAM




Figura 53: Valores promedio de la encuesta SAM para los estímulos de tristeza

En la figura 54 se muestran imágenes de usuarios que realizaron las pruebas de inducción con los estímulos de tristeza.



Figura 54: Usuario reaccionando a estímulos de tristeza

5.2.3.5 Estímulos de Relajación

Los estímulos de relajación (tabla 31) se clasifican bajo las etiquetas de valencia positiva y excitación baja, en las pruebas alcanzaron una precisión satisfactoria. Cada estímulo contribuyó de la misma forma pues fue clasificado correctamente en al menos la mitad de las ocasiones sobresaliendo la segunda imagen pues fue correctamente clasificada por todos los usuarios. El tema principal de las imágenes eran las personas, esto se decidió en cierta forma para crear la sensación de empatía, los estímulos que sobresalieron fueron el primero y segundo, probablemente debido a que son ambientes interesantes siendo un laboratorio y una reunión de amigos respectivamente, aun así, no hay mucha diferencia entre el desempeño individual de cada estímulo.

Capítulo 5. Pruebas y resultados

Tabla 31: Imágenes IAPS utilizadas en el pie para relajación



En la tabla 32 se muestran los resultados obtenidos con el clasificador, de acuerdo con el nivel de valencia y excitación y se resaltan los resultados acertados. En este caso la precisión del clasificador se podría considerar decente sin embargo no fue tan positiva como con las emociones de alegría y tristeza. Aun con esto se consiguió acertar la mayoría de las pruebas de forma correcta.

Tabla 32: Resultados obtenidos con el clasificador, estímulos de relajación

Usuario	Imagen 1		Imagen 2		Imagen 3		Imagen 4	
	Valencia	Excitación	Valencia	Excitación	Valencia	Excitación	Valencia	Excitación
1	Positiva	Baja	Positiva	Baja	Positiva	Baja	Positiva	Baja
2	Negativa	Baja	Positiva	Baja	Negativa	Baja	Negativa	Baja
3	Positiva	Baja	Positiva	Baja	Positiva	Alta	Positiva	Baja
4	Positiva	Baja	Positiva	Baja	Negativa	Baja	Negativa	Baja
5	Positiva	Baja	Positiva	Baja	Positiva	Baja	Positiva	Alta
6	Negativa	Baja	Positiva	Baja	Negativa	Baja	Positiva	Baja
7	Positiva	Alta	Positiva	Baja	Positiva	Baja	Negativa	Baja
8	Positiva	Alta	Positiva	Baja	Positiva	Baja	Negativa	Baja

Los resultados de las encuestas SAM (tabla 33) dejan claro que la mayoría de los usuarios se sintieron cómodos durante la prueba. La mayoría de las encuestas concuerdan con la idea de que los estímulos causaron una impresión positiva, pero a la vez tranquila. El dominio se mantuvo en un valor neutro para la mayoría de los

usuarios lo que indica una reacción controlada. En la figura 55 se puede consultar el valor promedio de estas encuestas, recordando que el resultado deseable debería ser mayor a 5 para valencia (nivel positivo) y menor a 5 para excitación (nivel bajo). En este caso ambos valores concuerdan con lo esperado.

Tabla 33: Evaluación SAM, estímulos de relajación

Relajación			
Usuario	Valencia	Excitación	Dominio
1	5	2	5
2	7	1	7
3	4	3	4
4	5	1	5
5	5	3	4
6	7	5	7
7	5	3	7
8	9	1	9

VALORES PROMEDIO DE LA ENCUESTA SAM




Figura 55: Valores promedio de la encuesta SAM para los estímulos de relajación

En la figura 56 se muestran imágenes de usuarios que realizaron las pruebas de inducción con los estímulos de relajación.




Figura 56: Usuarios reaccionando a estímulos de relajación

5.2.3.6. Análisis de encuestas SAM

Para validar los resultados de las encuestas con SAM se usó la herramienta Alfa de Cronbach, este coeficiente es utilizado para validar los resultados de una prueba. En la fórmula 9 se expresa su función matemática.

$$\alpha = \frac{k}{k-1} \left[1 - \frac{\sum V_i}{V_t} \right] \quad (9)$$

Donde:

k=Número de ítems

Vi=Varianza del item i

Vt=Varianza de la suma de los ítems

De acuerdo con el resultado de la fórmula 9 se puede evaluar el test. En la tabla 34 se puede consultar los rangos de clasificación y su significado.

Tabla 34: Clasificación de resultados según el alfa de Cronbach

Muy Baja	Baja	Moderada	Alta	Muy Buena
0 - 0.2	0.21 - 0.4	0.41 - 0.6	0.61 - 0.8	0.81 - 1

Valencia

La tabla 35 expresa los valores obtenidos mediante las encuestas SAM para todas las pruebas al evaluar la valencia, del lado derecho se calcula el total de los valores por usuario y en la parte inferior se muestran los valores de varianza por cada emoción y para el total.

Tabla 35: Alfa de Cronbach correspondiente a la valencia

Usuarios	Valencia					Total
	Alegría	Ansiedad	Neutro	Tristeza	Relajación	
Usuario 1	7	5	5	3	5	25.00
Usuario 2	5	5	7	7	8	32.00
Usuario 3	7	3	4	3	6	23.00
Usuario 4	7	3	5	5	5	25.00
Usuario 5	7	3	5	5	4	24.00
Usuario 6	7	5	7	7	7	33.00
Usuario 7	7	3	5	7	8	30.00
Usuario 8	5	6	9	9	9	38.00
Varianza	0.75	1.36	2.36	3.94	2.75	11.16 24.94

En este caso, aplicando la fórmula 9 las variables toman los siguientes valores:

$$k= 5$$

$$Vi= 11.16$$

$$Vt= 24.94$$

Donde el valor del Alfa de Cronbach es de **0.69** correspondiente a un valor **Alto** de acuerdo con la tabla 34.

Excitación

En la tabla 36 se expresan los valores obtenidos mediante las encuestas SAM para todas las pruebas al evaluar la excitación, del lado derecho se calcula el total de los valores por usuario y en la parte inferior se muestran los valores de varianza por cada emoción y para el total.

Capítulo 5. Pruebas y resultados

Tabla 36: Alfa de Cronbach correspondiente a la valencia

Usuarios	Excitación					Total
	Alegría	Ansiedad	Neutro	Tristeza	Relajación	
Usuario 1	3	2	2	3	2	12.00
Usuario 2	3	3	1	1	3	11.00
Usuario 3	5	3	3	2	5	18.00
Usuario 4	7	5	1	1	2	16.00
Usuario 5	5	5	3	6	3	22.00
Usuario 6	3	3	5	1	1	13.00
Usuario 7	3	6	3	2	2	16.00
Usuario 8	1	1	1	1	1	5.00
	2.94	2.50	1.73	2.61	1.48	11.27 22.86

En este caso las variables toman los siguientes valores:

$$k= 5$$

$$V_i= 11.27$$

$$V_t= 22.89$$

Donde el valor del Alfa de Cronbach es de **0.63** correspondiente a un valor **Alto** de acuerdo con la tabla 34.

Dominio

La tabla 37 se expresan los valores obtenidos mediante las encuestas SAM para todas las pruebas al evaluar la excitación, del lado derecho se calcula el total de los valores por usuario y en la parte inferior se muestran los valores de varianza por cada emoción y para el total.

Capítulo 5. Pruebas y resultados

Tabla 37: Alfa de Cronbach correspondiente al dominio

Usuarios	Dominio					Total
	Alegría	Ansiedad	Neutro	Tristeza	Relajación	
Usuario 1	5	5	5	5	5	25.00
Usuario 2	5	7	7	7	7	33.00
Usuario 3	5	3	3	3	4	18.00
Usuario 4	5	7	5	5	5	27.00
Usuario 5	5	6	5	5	4	25.00
Usuario 6	7	7	7	7	7	35.00
Usuario 7	5	4	7	7	7	30.00
Usuario 8	8	8	9	9	9	43.00
	1.23	2.61	3.00	3.00	2.75	12.59 50.50

En este caso las variables toman los siguientes valores:

$$k= 5$$

$$V_i= 12.59$$

$$V_t= 50.50$$

Donde el valor del Alfa de Cronbach es de **0.94** igual a un valor **Muy alto** de acuerdo con la tabla 34.

Finalmente se puede concluir que los resultados de las encuestas SAM son congruentes y sirven como testigo de las pruebas realizadas.

5.2.3.7. Análisis de predicción

Los resultados obtenidos se presentarán de la siguiente manera, en la tabla 38 se presentan los porcentajes de precisión de acuerdo con los estímulos o emociones, basándose únicamente en el acierto del nivel de valencia-excitación correspondiente a cada emoción. En la tabla 39 se presentan las métricas de *precision*, *recall*, *f1* y *accuracy* de toda la muestra de pruebas tomando los resultados de todas las emociones para ambas características: valencia y excitación. Finalmente, la tabla 40 divide las pruebas de acuerdo con las clases, es

Capítulo 5. Pruebas y resultados

decir se mide el porcentaje de aciertos que obtuvo cierto grado de valencia-excitación, en el caso de valencia si es negativa o positiva, y de excitación si es alta o baja.

En la tabla 38 se puede observar que las emociones de alegría y tristeza fueron las emociones mejor clasificadas, por otro lado, la ansiedad fue la de peor rendimiento, y la relajación con un desempeño aceptable. La posible razón de estos resultados podría deberse a los estímulos, en el caso de la ansiedad no se reportaron los valores esperados ni siquiera por medio de las encuestas SAM, lo que indica que los usuarios no fueron correctamente inducidos. De forma similar los estímulos para relajación tampoco fueron valorados de la forma esperada, salvo por alguna imagen las demás parecían ser muy poco atractivas. En el caso de la tristeza tanto las evaluaciones como el clasificador fueron en su mayoría correctas, y del mismo modo la felicidad.

Tabla 38: Resultados de la predicción emocional

Emoción	% Acierto
Alegría	71%
Ansiedad	40%
Tristeza	71%
Relajación	60%

La tabla 39 tiene el objetivo de presentar los resultados generales de las pruebas de clasificación. Estos resultados evalúan el rendimiento del clasificador separando las características emocionales valencia y excitación y centrándose individualmente en estas variables. Los resultados alcanzados son satisfactorios y en el caso de la excitación muy resaltables. En cambio, la valencia obtuvo valores aceptables, pero no destacables.

Capítulo 5. Pruebas y resultados

Tabla 39: Resultados de la predicción general Valencia-Excitación

Valencia			
Precisión	Recall	F1-score	Accuracy
0.68	0.79	0.73	0.71
Excitación			
0.85	0.65	0.74	0.77

La tabla 40 sirve para analizar de mejor manera los resultados generales, pues en ésta, las pruebas se dividen en las clases correspondientes. Es notable que el clasificador tuvo más problemas al predecir la valencia positiva y la excitación baja, estos dos valores conforman la emoción de relajación la cual apenas alcanzó resultados aceptables. Por otra parte, la clase positiva para valencia y alta para excitación alcanzaron los mejores porcentajes de precisión, ambas clases conforman la emoción de ansiedad la cual fue la de peor rendimiento, sin embargo, estos resultados tan altos son producto del buen rendimiento de las emociones tristeza (valencia negativa) y felicidad (excitación alta) compuesta por ambas clases.

Tabla 40: Resultados de la predicción para las clases Valencia-Excitación

Valencia	
Nivel	% Acierto
Positivo	65%
Negativo	89%
Excitación	
Alto	79%
Bajo	62%

Clasificador vs SAM

Con el objetivo de estudiar mejor los resultados obtenidos, se optó por comparar las evaluaciones con SAM vs. valores obtenidos mediante el clasificador. La red neuronal sólo tiene la capacidad de clasificar en dos clases, por lo que se volverán a tomar en cuenta los valores obtenidos mediante la regresión, como se había

Capítulo 5. Pruebas y resultados

mencionado este aspecto es más ilustrativo que objetivo, sin embargo, se apega a los resultados del clasificador por lo que tampoco se descarta como material. Los valores de regresión se tomaron de las evaluaciones a las imágenes/estímulos, por lo que se promedió el valor obtenido de cada evaluación y se prometió por emoción. En la tabla 41 se puede ver la comparación de los valores relacionados a la valencia y en la tabla 42 los de excitación.

Tabla 41: Resultados de la predicción de emociones, clasificador vs SAM para VALENCIA

	Alegría		Ansiedad		Tristeza		Relajación	
	SAM	UXLab	SAM	UXLab	SAM	UXLab	SAM	UXLab
Usuario 1	7	8	5	6	4	9	5	9
Usuario 2	5	4.7	5	4.7	4	1	7	3
Usuario 3	7	7.5	3	4.7	4	4.7	4	6.2
Usuario 4	7	7.5	3	5.7	3	3	5	5
Usuario 5	7	6.7	3	5	5	3	5	8
Usuario 6	7	9	5	2.5	6	4.2	7	7
Usuario 7	7	9	3	4.2	5	4	5	4.2
Usuario 8	5	9	6	7	2	4.5	9	4.5
	6.5	7.6	4.1	4.9	4.1	4.1	6	5.8

Los resultados obtenidos para valencia demuestran estar demasiado apegados a los obtenidos mediante SAM, aunque se pueden encontrar valores bastante contrarios que al promediarse se equilibran. Los resultados de tristeza y relajación son los más parecidos y con menor rango de desigualdad.

Capítulo 5. Pruebas y resultados

Tabla 42: Resultados de la predicción de emociones, clasificador vs SAM para EXCITACIÓN

	Alegría		Ansiedad		Tristeza		Relajación	
	SAM	UXLab	SAM	UXLab	SAM	UXLab	SAM	UXLab
Usuario 1	3	4.5	2	5.5	2	3.2	2	3.5
Usuario 2	3	5.5	3	3.2	1	1	1	3
Usuario 3	5	6	3	3.2	3	2	3	4
Usuario 4	7	5.2	5	6.5	2	2.5	1	2.5
Usuario 5	5	4	5	4.5	3	2.2	3	4.2
Usuario 6	3	7	3	5	4	2.2	5	3.7
Usuario 7	3	7.7	6	4.7	2	3.5	3	3.2
Usuario 8	1	6	1	6	1	3.5	1	4.5
	3.7	5.7	3.5	4.8	2.2	2.5	2.7	3.5

En el caso de la excitación también se encuentran valores iguales para ambas fuentes como es el caso de la tristeza y en menor grado la relajación sin embargo aquí se nota más la disparidad entre los valores, aunque no de forma extrema. Finalmente, los resultados arrojados para ambas características muestran la calidad y el desempeño del algoritmo de regresión y certifican su veracidad. También sirven para ilustrar de forma práctica los resultados obtenidos mediante encuestas.

6. Conclusiones

Capítulo 6. Conclusiones

Durante el transcurso de esta investigación se concluyó exitosamente con cada uno de los puntos establecidos, incluyendo los objetivos, los alcances y las limitaciones. El objetivo principal fue desarrollar un modelo de reconocimiento emocional mediante aprendizaje automático implementando señales fisiológicas. Esto involucró el uso de repositorios afectivos de señales fisiológicas y el desarrollo de una metodología para dar seguimiento al proceso de creación de datasets. Para definir el modelo que se utilizaría se realizó una comparativa entre diferentes algoritmos de aprendizaje automático: SVM, RF Y RN, donde resaltó el desempeño de una red neuronal, esta fue entrenada con el repositorio MAHNOB y DEAP, obteniendo resultados de predicción cercanos al 75%. Sin embargo, se decidió utilizar un modelo basado en MAHNOB debido a resultados levemente superiores. El modelo obtenido fue implementado posteriormente en la herramienta UXLab para la evaluación de la experiencia de usuario y se realizaron pruebas para verificar el nivel de precisión que podría adquirir este modelo con usuarios reales. Las pruebas consistían en la estimulación de los usuarios por medio de imágenes, las cuales estaban etiquetadas bajo una sola emoción, mientras los usuarios las observaban se tomaron señales de EEG, ECG y GSR. Por medio del módulo de reconocimiento emocional implementado en UXLab se realizó el proceso de predicción. Los resultados fueron aceptables para predecir felicidad, tristeza y relajación sin embargo bajos para predecir ansiedad, las razones de esto podrían deberse a la selección de los estímulos utilizados y a que no se indujo el nivel de emoción requerido. Sin embargo, las predicciones por usuario acertaron en la mayoría de pruebas, lo que indica que el algoritmo trabaja tanto con hombres y mujeres de edades entre 20-30 años, lo cual es una característica positiva. La red neuronal fue entrenada con un repositorio ajeno a la institución y algo provecho, aun así, permitió predecir emociones de forma satisfactoria por lo que su potencial podría expandirse si se entrenase con un repositorio similar a las características de la captura de UXLab. Estos resultados son alentadores pues con una mejora en el desarrollo del modelo clasificador, enfocado a predecir de forma más específica el nivel emocional y una mejor etapa de estimulación en los usuarios. Podrían conseguir resultados muy superiores a los alcanzados en esta investigación.

6.1 Aportaciones

A continuación, se listan las aportaciones de esta investigación:

6.1.1 Metodología de reconocimiento emocional

Durante esta investigación se establecieron procesos que conformaron posteriormente la propuesta de solución. Dichos procesos describen las etapas que se deben seguir para cumplir el objetivo de predecir emociones. Esto incluye la adquisición de señales fisiológicas, su correspondiente etapa de filtrado y extracción de características. Asimismo, incluye el entrenamiento de una máquina de aprendizaje automático. Además, se construyeron datasets específicos a partir de los repositorios DEAP y MAHNOB los cuales ayudaran más a delante a los investigadores a desarrollar sus propias aplicaciones.

6.1.2 Desarrollo de la herramienta EMOLEARN

Esta herramienta es fácil de instalar y de usar, permitirá a los investigadores desarrollar datasets a partir de cualquier conjunto de señales fisiológicas, ya sea de repositorios o de la interacción con UXLab. Esto resulta en un gran ahorro de tiempo, pues la herramienta se encarga de procesar, filtrar y construir los datasets automáticamente. También permite la evaluación de los datasets por medio de algoritmos ya establecidos en la herramienta.

6.1.3 Integración del módulo de reconocimiento emocional dentro de la plataforma UXLab.

El módulo de reconocimiento emocional implementado en UXLab es una de las mejoras más importantes en la herramienta. Permite utilizar los sensores fisiológicos para predecir emociones bajo las características de valencia excitación. Los resultados son fáciles de interpretar gracias a las mejoras del reproductor, que permiten visualizar de manera sencilla la reacción del usuario junto con la predicción emocional. UXLab posee una red neuronal entrenada con el repositorio MAHNOB lo cual garantiza un grado de seguridad en las predicciones de la aplicación.

6.1.4 Publicaciones

Se realizó una publicación de artículo en el volumen 1 del Congreso Estudiantil de Inteligencia Artificial Aplicada a la Ingeniería y Tecnología. Bajo el nombre El proyecto XEEGnal: sistema para la identificación de Estados Mentales a partir de Señales Bioeléctricas (Morales, González, González, Magadan y López, 2019). Este artículo describía una versión temprana de la ahora llamada herramienta EMOLEARN.

6.2 Trabajos a futuro

Para ampliar los horizontes de esta investigación y mejorar el proceso de reconocimiento emocional y sus resultados se propone trabajar en los siguientes componentes.

- Implementar análisis de respiración: en muchos trabajos el sensor de respiración obtuvo mucha relevancia y es una de las señales biométricas más empleadas después de los sensores adoptados en esta investigación.
- Entrar completamente en el área del deep learning: la mayoría de los trabajos actuales están dejando los algoritmos de aprendizaje automático normales para centrarse únicamente en el aprendizaje profundo. Uno de los algoritmos que ha sobresalido por sus resultados son las redes neuronales convolucionales.
- Selección de estímulos: es importante adoptar material que aproveche las ventajas de la realidad virtual además de utilizar material relevante para las nuevas generaciones, pues como se notó en este trabajo las imágenes estáticas no tienen el mismo efecto que quizá en otros tiempos.
- Características relacionadas al análisis del rostro: En muchos trabajos se optó por este tipo de estudio, pues es la forma más fácil de reconocer emociones, aunque tiene sus claras desventajas principalmente la habilidad de las personas a esconder sus verdaderas emociones. Aun así, implementar este tipo de estudio puede ayudar a mejorar el reconocimiento si sólo se le da poca relevancia.

7. Referencias

Capítulo 7. Referencias

Thanyathorn Thanapattheerakul, Katherine Mao, Jacqueline Amoranto, and Jonathan H. Chan. 2018. Emotion in a Century: A Review of Emotion Recognition. In Proceedings of the 10th International Conference on Advances in Information Technology (IAIT 2018). Association for Computing Machinery, New York, NY, USA, Article 17, 1–8. DOI: 10.1145/3291280.3291788

Dzedzickis, A., Kaklauskas, A., & Bucinskas, V. (2020). Human Emotion Recognition: Review of Sensors and Methods. *Sensors (Basel, Switzerland)*, 20(3), 592. <https://doi.org/10.3390/s20030592>

Shu L, Xie J, Yang M, Li Z, Li Z, Liao D, Xu X, Yang X. A Review of Emotion Recognition Using Physiological Signals. *Sensors (Basel)*. 2018 Jun 28;18(7):2074. doi: 10.3390/s18072074

Chen J, Hu B, Wang Y, Moore P, Dai Y, Feng L, Ding Z. Subject-independent emotion recognition based on physiological signals: a three-stage decision method. *BMC Med Inform Decis Mak*. 2017 Dec 20;17(Suppl 3):167. doi: 10.1186/s12911-017-0562-x.

Ali M, Machot FA, Mosa AH, Jdeed M, Machot EA, Kyamakya K. A Globally Generalized Emotion Recognition System Involving Different Physiological Signals. *Sensors (Basel)*. 2018 Jun 11;18(6):1905. doi: 10.3390/s18061905.

Wei W, Jia Q, Feng Y, Chen G. Emotion Recognition Based on Weighted Fusion Strategy of Multichannel Physiological Signals. *Comput Intell Neurosci*. 2018 Jul 5;2018:5296523. doi: 10.1155/2018/5296523.

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 (Tesis de maestría, TecNM/Cenidet).

Capítulo 7. Referencias

Ortiz Carreón Félix (2016). Metodología de Comunicación Aumentativa y Alternativa para Personas con Parálisis Cerebral Mediante Mecanismos Heterogéneos de Interacción Humano Computadora (Tesis de maestría, TecNM/Cenidet).

González Franco Nimrod (2017). Metodología UXEEg para la evaluación de la Experiencia del Usuario en personas con discapacidad a partir de Interfaces Cerebro Computadora (Tesis de doctorado, TecNM/Cenidet).

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 (Tesis de maestría, TecNM/Cenidet).

Soriano Terrazas Jeovanny (2018). Metodología para caracterizar a inducir estados cognitivos y emocionales mediante realidad virtual inmersiva (Tesis de maestría, TecNM/Cenidet).

García Pinzón G. A. (2019). Sistema embebido para analizar datos biométricos e identificar estados cognitivos y emocionales en procesos de evaluación de la experiencia del usuario (Tesis de maestría, TecNM/Cenidet).

Rosalind W. Picard. 1997. Affective computing. MIT Press, Cambridge, MA, USA.

Afectiva. (2018). <https://www.affectiva.com/>. Obtenido de <https://www.affectiva.com/>: <https://www.affectiva.com/>

imotios. (2016). <https://imotions.com/>. Obtenido de <https://imotions.com/>: <https://imotions.com/>

Capítulo 7. Referencias

Colomer Adrián, Naranjo Valery, Guixeres Jaime, Alcañiz Mariano. Adquisición, Acondicionamiento y Análisis de Señales Fisiológicas para la Evaluación de Contenidos Audiovisuales. 2018.

Rangayyan, Rangaraj M. Biomedical Signal Analysis: A Case-Study Approach. (2001).

Jianhua Zhang, Zhong Yin, Peng Chen, Stefano Nichele. Emotion recognition using multi-modal data and machine learning techniques: A tutorial and review. 2020. Information Fusion. Volume 59. Pages 103-126. ISSN 1566-2535. Doi: 10.1016/j.inffus.2020.01.011

Jirayucharoensak Suwicha, Pan-ngum Seta, Israsena Pasin. 2014. EEG-Based Emotion Recognition Using Deep Learning Network with Principal Component Based Covariate Shift Adaptation. The Scientific World Journal. Doi: 10.1155/2014/627892.

R. Khosrowabadi, A. Wahab, K. K. Ang and M. H. Baniasad, "Affective computation on EEG correlates of emotion from musical and vocal stimuli," 2009 International Joint Conference on Neural Networks, Atlanta, GA, 2009, pp. 1590-1594, doi: 10.1109/IJCNN.2009.5178748.

Yan, J., Chen, S., & Deng, S. (2019). A EEG-based emotion recognition model with rhythm and time characteristics. Brain informatics, 6(1), 7. Doi: 10.1186/s40708-019-0100-y.

Demerdzieva, A., & Pop-Jordanova, N. (2015). Relation Between Frontal Alpha Asymmetry and Anxiety in Young Patients with Generalized Anxiety Disorder. Prilozi, 36(2), 157–177. Doi: 10.1515/prilozi-2015-0064.

Torres P, E. P., Torres, E. A., Hernández-Álvarez, M., & Yoo, S. G. (2020). EEG-Based BCI Emotion Recognition: A Survey. *Sensors (Basel, Switzerland)*, 20(18), 5083. Doi: 10.3390/s20185083.

Nazmi Sofian Suhaimi, James Mountstephens, Jason Teo, "EEG-Based Emotion Recognition: A State-of-the-Art Review of Current Trends and Opportunities", *Computational Intelligence and Neuroscience*, vol. 2020, Article ID 8875426, 19 pages, 2020. <https://doi.org/10.1155/2020/8875426>

Bos, D.O. (2007). EEG-based Emotion Recognition The Influence of Visual and Auditory Stimuli.

Jasper, H.H. (1958) The Ten-Twenty Electrode System of the International Federation. *Electroencephalography and Clinical Neurophysiology*, 10, 371-375.

Jurcak, V., Tsuzuki, D., & Dan, I. (2007). 10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems. *NeuroImage*, 34, 1600-1611.

Jiang, X., Bian, G. B., & Tian, Z. (2019). Removal of Artifacts from EEG Signals: A Review. *Sensors (Basel, Switzerland)*, 19(5), 987. Doi: 10.3390/s19050987

Frederick, B. Aaron, Weng, G., Mountstephens, J., Teo J. (2020). A review of recent approaches for emotion classification using electrocardiography and electrodermography signals. *Informatics in Medicine Unlocked*. Volume 20. ISSN 2352-9148. Doi: 10.1016/j.imu.2020.100363.

Sarkar, P., & Etemad, A. (2020). Self-supervised ECG Representation Learning for Emotion Recognition. *ArXiv, abs/2002.03898*.

Capítulo 7. Referencias

Dissanayake, T., Rajapaksha, Y., Ragel, R., & Nawinne, I. (2019). An Ensemble Learning Approach for Electrocardiogram Sensor Based Human Emotion Recognition. *Sensors (Basel, Switzerland)*, 19(20), 4495. Doi: 10.3390/s19204495

Malik, Marek. Heart rate variability: standards of measurement, physiological interpretation and clinical use. Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology. (1996). *Circulation*, 93(5), 1043–1065.

Quintana, D. S., Guastella, A. J., Outhred, T., Hickie, I. B., & Kemp, A. H. (2012). Heart rate variability is associated with emotion recognition: direct evidence for a relationship between the autonomic nervous system and social cognition. *International journal of psychophysiology : official journal of the International Organization of Psychophysiology*, 86(2), 168–172. <https://doi.org/10.1016/j.ijpsycho.2012.08.012>.

Shu, L., Yu, Y., Chen, W., Hua, H., Li, Q., Jin, J., & Xu, X. (2020). Wearable Emotion Recognition Using Heart Rate Data from a Smart Bracelet. *Sensors (Basel, Switzerland)*, 20(3), 718. <https://doi.org/10.3390/s20030718>

Ferdinando, H., Seppänen, T., Alasaarela y E. (2016). Comparing Features from ECG Pattern and HRV Analysis for Emotion Recognition System*. 10.1109/CIBCB.2016.7758108.

Rahul Kher (2019) Signal Processing Techniques for Removing Noise from ECG Signals. *J Biomed Eng* 1: 1-9.

Greco, A., Marzi, C., Lanata, A., Scilingo, E. P., & Vanello, N. (2019). Combining Electrodermal Activity and Speech Analysis towards a more Accurate Emotion Recognition System. Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society.

Annual International Conference, 2019, 229–232.
<https://doi.org/10.1109/EMBC.2019.8857745>

Liu, M., Fan, D., Zhang, X., & Gong, X. (2016). Human Emotion Recognition Based on Galvanic Skin Response Signal Feature Selection and SVM. 2016 International Conference on Smart City and Systems Engineering (ICSCSE), 157-160.

Goshvarpour, A., Abbasi, A., & Goshvarpour, A. (2017). An accurate emotion recognition system using ECG and GSR signals and matching pursuit method. *Biomedical journal*, 40(6), 355–368. <https://doi.org/10.1016/j.bj.2017.11.001>

Udovicic, G., Derek, J., Russo, M., & Sikora, M. (2017). Wearable Emotion Recognition System based on GSR and PPG Signals. *MMHealth '17*.

J. Shukla, M. Barreda-Angeles, J. Oliver, G. C. Nandi and D. Puig, "Feature Extraction and Selection for Emotion Recognition from Electrodermal Activity," in *IEEE Transactions on Affective Computing*, doi: 10.1109/TAFFC.2019.2901673.

Ayata, D., Yaslan, Y., & Kamasak, M. (2017). Emotion Recognition via Galvanic Skin Response: Comparison of Machine Learning Algorithms and Feature Extraction Methods. *Istanbul University - Journal of Electrical and Electronics Engineering*, 17, 3147-3156.

Tobiipro. 2019. GSR Artifacts. [ONLINE] Available at: <https://www.tobiipro.com/learn-and-support/learn/GSR-essentials/gsr-artifacts/>. [Accessed 18 Enero 2020].

Cannon, W. B. (1927). The James-Lange theory of emotions: a critical examination and an alternative theory. *The American Journal of Psychology*, 39, 106–124. <https://doi.org/10.2307/1415404>

Capítulo 7. Referencias

Dror, O. E. (2014). The cannon–bard thalamic theory of emotions: A brief genealogy and reappraisal. *Emotion Review*, 6(1), 13–20. <https://doi.org/10.1177/1754073913494898>

Ekman, P., Friesen, W. V., & Ellsworth, P. (1972). *Emotion in the human face: Guidelines for research and an integration of findings*. Pergamon Press.

Plutchik, R. (1984). *Emotions: A general psychoevolutionary theory*. *Approaches to emotion*, 1984, 197-219.

Russell James “A Circumplex Model of Affect,” *Journal of Personality and Social Psychology*, pp. 1161-1178, 1980.

Lang, P.J., Bradley, M.M., y Cuthbert, B.N. (2008). *International affective picture system (IAPS): Affective ratings of pictures and instruction manual*. Technical Report A-8. University of Florida, Gainesville, FL.

Kurdi, B., Lozano, S., y Banaji, M. (2016). Introducing the Open Affective Standardized Image Set (OASIS). *Behavior Research Methods*, 49. <https://doi.org/10.3758/s13428-016-0715-3>

Kim, J., & André, E. (2008). Emotion recognition based on physiological changes in music listening. *IEEE transactions on pattern analysis and machine intelligence*, 30(12), 2067–2083. <https://doi.org/10.1109/TPAMI.2008.26>

Becerra, M., Londoño-Delgado, E., Pelaez-Becerra, S.M., Serna-Guarín, L., Castro-Ospina, A.E., Marín-Castrillón, D., & Peluffo-Ordóñez, D.H. (2018). Odor Pleasantness Classification from Electroencephalographic Signals and Emotional States. https://doi.org/10.1007/978-3-319-98998-3_10.

Capítulo 7. Referencias

Al-Galal, S.A., Al-Shaikhli, I., & Rahman, A. (2016). Automatic Emotion Recognition Based on EEG and ECG Signals While Listening to Quranic Recitation Compared with Listening to Music. *2016 6th International Conference on Information and Communication Technology for The Muslim World (ICT4M)*, 269-274.

Banaei, M., Hatami, J., Yazdanfar, A., & Gramann, K. (2017). Walking through Architectural Spaces: The Impact of Interior Forms on Human Brain Dynamics. *Frontiers in human neuroscience*, 11, 477. <https://doi.org/10.3389/fnhum.2017.00477>.

Marín-Morales, J., Higuera-Trujillo, J. L., Greco, A., Guixeres, J., Llinares, C., Scilingo, E. P., Alcañiz, M., & Valenza, G. (2018). Affective computing in virtual reality: emotion recognition from brain and heartbeat dynamics using wearable sensors. *Scientific reports*, 8(1), 13657. <https://doi.org/10.1038/s41598-018-32063-4>.

Correa, J.A., Abadi, M.K., Sebe, N., & Patras, I. (2017). AMIGOS: A dataset for Mood, personality and affect research on Individuals and GrOupS. ArXiv, abs/1702.02510.

Subramanian, R., Wache, J., Abadi, M.K., Vieriu, R.L., Winkler, S., & Sebe, N. (2018). ASCERTAIN: Emotion and Personality Recognition Using Commercial Sensors. *IEEE Transactions on Affective Computing*, 9, 147-160.

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>

Capítulo 7. Referencias

Abadi, M.K., Ramanathan, S., Kia, S.M., Avesani, P., Patras, I., & Sebe, N. (2015). DECAF: MEG-Based Multimodal Database for Decoding Affective Physiological Responses. *IEEE Transactions on Affective Computing*, 6, 209-222.

Verma, G. K., & Tiwary, U. S. (2014). Multimodal fusion framework: a multiresolution approach for emotion classification and recognition from physiological signals. *NeuroImage*, 102 Pt 1, 162–172. <https://doi.org/10.1016/j.neuroimage.2013.11.007>

Jang, E. H., Park, B. J., Park, M. S., Kim, S. H., & Sohn, J. H. (2015). Analysis of physiological signals for recognition of boredom, pain, and surprise emotions. *Journal of physiological anthropology*, 34(1), 25. <https://doi.org/10.1186/s40101-015-0063-5>

Ranganathan, H., Chakraborty, S., & Panchanathan, S. (2016). Multimodal emotion recognition using deep learning architectures. In 2016 IEEE Winter Conference on Applications of Computer Vision, WACV 2016 [7477679] Institute of Electrical and Electronics Engineers Inc.. <https://doi.org/10.1109/WACV.2016.7477679>

Guendil, Z., Lachiri, Z., Maaoui, C., & Pruski, A. (2016). Multiresolution framework for emotion sensing in physiological signals. 2016 2nd International Conference on Advanced Technologies for Signal and Image Processing (ATSIP), 793-797.

Thammasan, N., Hagad, J.L., Fukui, K., & Numao, M. (2017). Multimodal stability-sensitive emotion recognition based on brainwave and physiological signals. *2017 Seventh International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW)*, 44-49.

Lin, W., Li, C., & Sun, S. (2017). Deep Convolutional Neural Network for Emotion Recognition Using EEG and Peripheral Physiological Signal. *ICIG*.

Capítulo 7. Referencias

Girardi, D., Lanubile, F., & Novielli, N. (2017). Emotion detection using noninvasive low cost sensors. *2017 Seventh International Conference on Affective Computing and Intelligent Interaction (ACII)*, 125-130.

Ali, M., Machot, F. A., Mosa, A. H., Jdeed, M., Machot, E. A., & Kyamakya, K. (2018). A Globally Generalized Emotion Recognition System Involving Different Physiological Signals. *Sensors (Basel, Switzerland)*, 18(6), 1905. <https://doi.org/10.3390/s18061905>

Zhang, X., Xu, C., Xue, W., Hu, J., He, Y., & Gao, M. (2018). Emotion Recognition Based on Multichannel Physiological Signals with Comprehensive Nonlinear Processing. *Sensors (Basel, Switzerland)*, 18(11), 3886. <https://doi.org/10.3390/s18113886> Sdf

Lee, J., & Yoo, S. K. (2018). Design of User-Customized Negative Emotion Classifier Based on Feature Selection Using Physiological Signal Sensors. *Sensors (Basel, Switzerland)*, 18(12), 4253. <https://doi.org/10.3390/s18124253>

Kwon, Y. H., Shin, S. B., & Kim, S. D. (2018). Electroencephalography Based Fusion Two-Dimensional (2D)-Convolution Neural Networks (CNN) Model for Emotion Recognition System. *Sensors (Basel, Switzerland)*, 18(5), 1383. <https://doi.org/10.3390/s18051383>

Akalin, N., & Kose, H. (2018). Emotion recognition in valence-arousal scale by using physiological signals. *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 1-4.

Degirmenci, M., Ozdemir, M.A., Sadighzadeh, R., & Akan, A. (2018). Emotion Recognition from EEG Signals by Using Empirical Mode Decomposition. *2018 Medical Technologies National Congress (TIPTEKNO)*, 1-4.

Capítulo 7. Referencias

Fabiano, D., & Canavan, S.J. (2019). Emotion Recognition Using Fused Physiological Signals. *2019 8th International Conference on Affective Computing and Intelligent Interaction (ACII)*, 42-48.

Siddharth, Jung, T., & Sejnowski, T. (2019). Utilizing Deep Learning Towards Multi-modal Bio-sensing and Vision-based Affective Computing. ArXiv, abs/1905.07039.

Ross, K., Sarkar, P., Rodenburg, D., Ruberto, A., Hungler, P., Szulewski, A., Howes, D., & Etemad, A. (2019). Toward Dynamically Adaptive Simulation: Multimodal Classification of User Expertise Using Wearable Devices. *Sensors (Basel, Switzerland)*, 19(19), 4270. <https://doi.org/10.3390/s19194270>.

Oh, S., Lee, J. Y., & Kim, D. K. (2020). The Design of CNN Architectures for Optimal Six Basic Emotion Classification Using Multiple Physiological Signals. *Sensors (Basel, Switzerland)*, 20(3), 866. <https://doi.org/10.3390/s20030866>

Tan, C., Ceballos, G., Kasabov, N., & Puthanmadam Subramaniam, N. (2020). FusionSense: Emotion Classification Using Feature Fusion of Multimodal Data and Deep Learning in a Brain-Inspired Spiking Neural Network. *Sensors (Basel, Switzerland)*, 20(18), 5328. <https://doi.org/10.3390/s20185328>

Ayata, D., Yaslan, Y., & Kamasak, M. (2020). Emotion Recognition from Multimodal Physiological Signals for Emotion Aware Healthcare Systems. *Journal of Medical and Biological Engineering*, 40, 149-157.

Dar, M. N., Akram, M. U., Khawaja, S. G., & Pujari, A. N. (2020). CNN and LSTM-Based Emotion Charting Using Physiological Signals. *Sensors (Basel, Switzerland)*, 20(16), 4551. <https://doi.org/10.3390/s20164551>.

Capítulo 7. Referencias

Bradley, M. M., & Lang, P. J. (1994). Measuring emotion: the Self-Assessment Manikin and the Semantic Differential. *Journal of behavior therapy and experimental psychiatry*, 25(1), 49–59. [https://doi.org/10.1016/0005-7916\(94\)90063-9](https://doi.org/10.1016/0005-7916(94)90063-9).

Pedregosa, F., Varoquaux, Ga"el, Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12(Oct), 2825–2830.

Chollet, F., & others. (2015). Keras. GitHub. Retrieved from <https://github.com/fchollet/keras>

Taran, S., & Bajaj, V. (2019). Emotion recognition from single-channel EEG signals using a two-stage correlation and instantaneous frequency-based filtering method. *Computer methods and programs in biomedicine*, 173, 157–165. <https://doi.org/10.1016/j.cmpb.2019.03.015>

Liu, W., Qiu, J., Zheng, W., & Lu, B. (2019). Multimodal Emotion Recognition Using Deep Canonical Correlation Analysis. *ArXiv, abs/1908.05349*.

Murugappan, M., & Murugappan, S. (2013). Human emotion recognition through short time Electroencephalogram (EEG) signals using Fast Fourier Transform (FFT). *2013 IEEE 9th International Colloquium on Signal Processing and its Applications*, 289-294.

Hasan, M. J., Shon, D., Im, K., Choi, H.-K., Yoo, D.-S., & Kim, J.-M. (2020). Sleep State Classification Using Power Spectral Density and Residual Neural Network with Multichannel EEG Signals. *Applied Sciences*, 10(21), 7639. [doi:10.3390/app10217639](https://doi.org/10.3390/app10217639)

Capítulo 7. Referencias

Goshvarpour, A., Abbasi, A., & Goshvarpour, A. (2017). Indices from lagged poincare plots of heart rate variability: an efficient nonlinear tool for emotion discrimination. *Australasian physical & engineering sciences in medicine*, 40(2), 277–287. <https://doi.org/10.1007/s13246-017-0530-x>.

Cheveigné, A., & Nelken, I. (2019). Filters: When, Why, and How (Not) to Use Them. *Neuron*, 102(2), 280–293. <https://doi.org/10.1016/j.neuron.2019.02.039>.

GS, V., Pai, S. P., Sriram, N., & Rao, R. B. (2013). Radial basis function neural network based comparison of dimensionality reduction techniques for effective bearing diagnostics. *Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology*, 227(6), 640–653. <https://doi.org/10.1177/1350650112464927>.

Modelos de máquina de vectores de soporte. (2019)., de IBM® IBM Knowledge Center website: <https://www.ibm.com/>

Pedersen, R., & Schoeberl, M. (2006). An Embedded Support Vector Machine. 2006 International Workshop on Intelligent Solutions in Embedded Systems, 1-11.

Matthew N., B. (2019). Random Forests, de Machine Learning website: <https://mbernste.github.io/>

Hardesty , L. (2017). Explained: Neural networks, de Massachusetts Institute of Technology website: <https://news.mit.edu/2017/explained-neural-networks-deep-learning-0414>.