



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Maestría

Procesamiento de datos fisiológicos para
detectar estados emocionales en el proceso de
evaluación de la experiencia de usuario

presentada por

Ing. Gabriel Alejandro García Pinzón

como requisito para la obtención del grado
de

Maestro en Ciencias de la Computación

Director de tesis

Dr. Juan Gabriel González Serna

Co-director de tesis

Dr. Nimrod González Franco

Cuernavaca, Morelos, México. Febrero de 2020.



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



Centro Nacional de Investigación y Desarrollo Tecnológico
Departamento de Ciencias Computacionales

"2020, Año de Leona Vicario, Benemérita Madre de la Patria"

Cuernavaca, Mor., 27/enero/2020


OFICIO No. DCC/021/2020
Asunto: Aceptación de documento de tesis
CENIDET-AC-004-M14-OFCIO

C. DR. GERARDO VICENTE GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO
PRESENTE

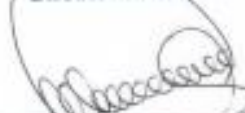
Por este conducto, los integrantes de Comité Tutorial del **C. Ing. Gabriel Alejandro García Pinzón**, con número de control MT7CE090, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis de grado titulado **"Procesamiento de datos fisiológicos para detectar estados emocionales en el proceso de evaluación de la experiencia de usuario"** 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.



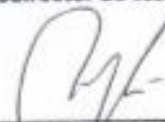
Dr. Juan Gabriel González Serna
Doctor en Ciencias de la Computación
7820329
Director de tesis



Dr. Nimrod González Franco
Doctor en Ciencias de la Computación
11088913
Codirector de tesis



Dr. Máximo López Sánchez
Doctor en Ciencias de la Computación
7498547
Revisor 1



Dra. Andrea Magadán Salazar
Doctora en Ciencias Computacionales
10654097
Revisor 2

C.c.p. Depto. Servicios Escolares
Expediente / Expediente
JGCS/mz



Carretera México-Pedernales, C. P. Cuernavaca, C. P. 62490 Cuernavaca, Morelos.
E-mail: doc@cenidet.edu.mx
www.tecnm.mx | www.cenidet.tecnm.mx





EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



Centro Nacional de Investigación y Desarrollo Tecnológico
Subdirección Académica

"2020, Año de Leona Vicario, Benemérita Madre de la Patria"

Cuernavaca, Morelos, **50 Enero / 2020**

OFICIO No. SAC/099/2020
Asunto: Autorización de impresión de tesis

LIC. GABRIEL ALEXANDRO GARCÍA PINZÓN
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 *"Procesamiento de datos fisiológicos para detectar estados emocionales en el proceso de evaluación de la experiencia de usuario"*, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

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

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

DR. GERARDO VICENTE GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO



SEP TecNM
CENTRO NACIONAL
DE INVESTIGACIÓN
Y DESARROLLO
TECNOLÓGICO
SUBDIRECCIÓN
ACADÉMICA

C.p. M.E. Guadalupe Carrido Rivers. Jefa del Departamento de Servicios Escolares.
Expediente.

CVCR/CHC



Interior Internado Palmira S/N, Col. Palmira, C. P. 62490, Cuernavaca, Morelos.
Tel. (01) 777 3 62 77 70, ext. 4106, e-mail: dir_cenidet@tecnm.mx
www.tecnm.mx | www.cenidet.edu.mx



Dedicatoria

A mi madre Gloria Olivia, por todo su apoyo brindado durante mis estudios de posgrado. Hubo muchos momentos difíciles que viví, pero siempre fui capaz de afrontarlos gracias a ella.

A mi tía Elia, quien siempre ha estado al pendiente de mí y de lo que decido hacer con mi vida. Gran parte de mis logros han sido gracias a sus consejos, sabiduría y enseñanzas.

A mis tíos Maru, Luis, Rosa y Carlos y primos Abraham, Roberto, y Nidia, así como su esposo Alex. Quienes han estado de forma incondicional para desde siempre. No puedo imaginar cómo sería mi vida sin todos ellos.

A mí primo Sergio y su padre Gregorio, quien falleció mientras yo realizaba mis estudios y su pérdida fue bastante fuerte para la familia. Por ellos porque, aunque estaban un poco lejos, siempre han sido importantes para mí

A mis amigos de la infancia, Edgar, Alexander, Javier, Héctor, Jordan y Samara, porque a pesar del paso de los años siempre encontramos un momento para compartir juntos y cada que pudieron me dieron palabras de aliento.

A mis compañeros de la maestría Eddy y Santiago, quienes hicieron mi estancia en la escuela bastante agradable y con ellos realice bastantes proyectos que nos costaron desvelos.

Agradecimientos

Al Consejo Nacional de Ciencia y Tecnología (CONACYT), por proporcionarme a mí y a muchos otros estudiantes el apoyo necesario para potencializar nuestros sueños y habilidades.

Al Tecnológico Nacional de México / Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET), por su gran servicio como Institución Académica, empeñada en formar e impulsar el conocimiento científico.

Al Dr. Juan Gabriel González Serna, por darme la confianza plena en el desarrollo de investigación, así también, por haberme brindando las herramientas necesarias para desarrollar mi trabajo y agradecer su apoyo durante mi estancia en CENIDET.

A mis revisores, Dr. Máximo López Sánchez y Dra. Andrea Magadán Salazar, por haberme brindado sus observaciones y apoyo durante la investigación y el desarrollo de la tesis de maestría.

A mis compañeros de la maestría Eddy y Santiago, quienes hicieron mi estancia en la escuela bastante agradable y con ellos realice bastantes proyectos que nos costaron desvelos.

Resumen

En los últimos años el cómputo afectivo ha ido tomando mayor relevancia en la implementación de diferentes sistemas computacionales. La obtención de datos fisiológicos de los usuarios permite el análisis de estados emocionales, dando lugar a que la interacción con la tecnología sea más amigable y natural.

Hoy en día existen diferentes sensores que permiten registrar y procesar información fisiológica; sin embargo, los algoritmos requeridos para el procesamiento aún se encuentran en etapas tempranas, en particular en el análisis de estados emocionales. A pesar de que existen programas cuya función es precisamente realizar el procesamiento de dichos estados, estos mantienen ocultos sus algoritmos y metodologías.

La información fisiológica que se puede obtener de los usuarios es amplia y heterogénea. Por ejemplo, se pueden registrar datos del ritmo cardiaco, de conductividad eléctrica en la piel, la actividad eléctrica del cerebro, la actividad eléctrica en músculos, la respiración, el movimiento ocular, entre otras.

Se tienen registros de que en el año 2017 en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) dentro del Departamento de Ciencias Computacionales, se desarrollaron proyectos de investigación relacionados con la detección e inducción de estados cognitivos y emocionales. También se desarrolló un sistema (UXLab) que permite realizar evaluaciones de la experiencia del usuario mediante el procesamiento de señales EEG.

En el presente trabajo de tesis se buscó tener un acercamiento con diferentes sensores fisiológicos de bajo costo, algoritmos que son usados en la clasificación de estados emocionales y de las técnicas usadas en el procesamiento de señales. Lo que se hizo fue desarrollar módulos para el sistema UXLab que permiten grabar la información fisiológica de sensores de electrocardiograma, electroencefalograma y respuesta galvánica de la piel, así como de otros dispositivos tales como micrófono, cámara y la pantalla de la computadora. Luego, la información de los sensores biométricos puede ser procesada aplicando filtros y extrayendo diferentes características de sus señales, para finalmente probar la clasificación emocional con los algoritmos de Naive Bayes, Máquinas de vector soporte y Vecinos más cercanos. Adicional a esto también se pueden realizar análisis emocionales de la información mediante otra versión del sistema que realiza la reproducción de dicha información.

Para probar el sistema se utilizó la metodología para caracterizar e inducir estados mentales a través de realidad virtual inmersiva e interfaz cerebro computadora (Soriano, 2017). Se lograron inducir los estados de alegría, tristeza y un estado neutro a diferentes personas. Durante

la aplicación de la metodología se tuvo una habitación controlada para minimizar el ruido, tener una iluminación constante y evitar distracciones en los usuarios. Antes de comenzar a inducir los estados emocionales se colocaban los sensores a los usuarios y se posicionaban en un lugar en específico para poder grabar también los demás dispositivos.

Después de la realización de varias pruebas se obtuvo que la plataforma más estable fue la de Arduino UNO con el kit de sensores Grove. Y el clasificador con el que se obtuvieron los mejores resultados fue el de Vecinos más cercanos. Sin embargo, también se deja abierta la posibilidad de seguir experimentando con otros algoritmos de clasificación, de incluir más sensores en las grabaciones o incluso de utilizar otros diferentes a Grove.

Abstract

In recent years, affective computing has been becoming more relevant in the implementation of different computer systems. Obtaining biometric data from users allows the analysis of emotional states, resulting in a friendlier and natural interaction with technology.

Today there are different sensors that allow you to record and process biometric information; however, the algorithms required for processing and extracting features of these data are still in early stages, particularly in the analysis of emotional states. Although there are programs whose function is precisely to process these states, they keep their algorithms and methodologies hidden.

The biometric information that can be obtained from users is broad and heterogeneous. For example, data on heart rate, electrical conductivity in the skin, electrical activity of the brain, electrical activity in muscles, breathing, eye movement, among others, can be recorded.

In this thesis work, we sought to have an approach with different low-cost biometric sensors, algorithms that are used in the classification of emotional states and the techniques used in signal processing. What was done was to develop modules for the UXLab system that allow recording the biometric information of electrocardiogram sensors, electroencephalogram and galvanic response of the skin, as well as other devices such as microphone, camera and computer screen. Then, the information of the biometric sensors can be processed by applying filters and extracting different characteristics of their signals, to finally test the emotional classification with the algorithms of Naive Bayes, Support vector machines and nearest Neighbors. In addition to this, emotional analysis of the information can also be performed through another version of the system that performs the reproduction of said information.

To test the system, the methodology was used to characterize and induce mental states through immersive virtual reality and brain computer interface' (Soriano, 2017). They were able to induce the states of joy, sadness and a neutral state to different people. During the application of the methodology there was a controlled room to minimize noise, have constant lighting and avoid distractions in users. Before starting to induce the emotional states, the sensors were placed on the users and they were positioned in a specific place so that the other devices could also be recorded.

After several tests, the most stable platform was that of Arduino UNO with the Grove sensor kit. And the classifier with which the best results were obtained was that of Nearest Neighbors. However, the possibility of continuing experimenting with other classification algorithms, including more sensors in the recordings or even using others other than Grove is also left open.

Índice general

Lista de figuras	III
Lista de tablas	VI
Acrónimos	VII
Glosario de términos	VIII
Capítulo 1. Introducción	1
1.1 Antecedentes	2
1.2 Descripción del problema	2
1.3 Objetivos	3
1.3.1 Objetivo General	3
1.3.2 Objetivos Específicos.....	3
1.4 Justificación.....	3
1.5 Alcances y Limitaciones	3
1.5.1 Alcances	4
1.5.2 Limitaciones.....	4
Capítulo 2. Marco teórico	5
2.1 Biofeedback.....	6
2.2 Neurofeedback	6
2.3 Electroencefalograma.....	6
2.4 Estados afectivos.....	6
2.4.1 Estado afectivo positivo	7
2.4.2 Estado afectivo negativo	8
2.5 Respuesta galvánica de la piel.....	8
2.6 Electrocardiograma	8
Valencia y Excitación	9
2.7 9	
2.8 Placas Arduino	10
2.8.1 Arduino UNO.....	10
2.8.2 Arduino Linkit One.....	11

2.9	Plataforma Grove	12
2.10	Plataforma MySignals ehealth v2.0.....	12
2.11	Sensor Xbee de radiofrecuencia	12
2.12	Reconocimiento de patrones.....	13
Capítulo 3. Estado del arte		14
3.1	Measuring Affective, Physiological and Behavioral Differences in Solo, Competitive and Collaborative Games (2016)	15
3.2	Computational Analysis of Valence and Arousal in Virtual Reality Gaming using Lower Arm Electromyograms (2017).....	15
3.3	Non-intrusive Wearable Health Monitoring Systems for Emotion Detection (2017) 15	
3.4	Discrimination between different emotional states based on the chaotic behavior of galvanic skin responses (2017)	15
3.5	Physiological Signal-based Emotion Recognition System (2017)	16
3.6	EMG and GSR signals for evaluating user’s perception of different types of ceramic flooring (2008).....	16
3.7	Affect Detection in Normal Groups with the Help of Biological Markers (2015)	16
3.8	Emotion Recognition employing ECG and GSR Signals as Markers of ANS (2016) 16	
3.9	Emotion Detection using non-invasive low cost sensors (2017)	17
3.10	Modeling the Affective Space of 360 Virtual Reality Videos Based on Arousal and Valence for Wearable EEG-Based VR Emotion Classification (2018).....	17
Capítulo 4. Metodología de solución.....		20
4.1	Metodología de solución.....	21
4.2	Elección de sensores fisiológicos.....	21
4.2.1	Arquitectura	21
4.2.2	Diademas de electroencefalograma (EEG).....	22
4.2.3	Arduino UNO.....	24
4.2.4	MySignals	29
4.2.5	Arduino Linkit One.....	32
4.2.6	Sensores Xbee	33
4.3	Definición de pasos para el análisis emocional.....	35
4.4	Desarrollo de sistema prototipo	37
4.4.1	Sistema de grabación de UXLab.....	37

4.4.2 Sistema de reproducción de UXLab	38
4.5 Definición del plan de pruebas.....	39
4.6 Realización de pruebas del sistema.....	40
4.7 Definición y corrección de errores	41
4.8 Análisis de resultados.....	44
Capítulo 5. Pruebas finales y análisis de resultados.....	45
5.1 Descripción de las pruebas finales	46
5.2 Extracción de características	46
5.3 Pruebas con clasificadores	47
5.3.1 Pruebas de los clasificadores sin aplicar filtro.	48
5.3.2 Pruebas de los clasificadores aplicando filtro de paso banda.	49
5.4 Comparación de los resultados de los clasificadores	51
5.4.1 Análisis de resultados	51
5.5 Selección de variables/características	51
Capítulo 6. Conclusiones y trabajos futuros	54
6.1 Conclusiones	55
6.2 Aportaciones	55
6.3 Trabajos futuros	55
Referencias	57
Anexos.....	59

Lista de figuras

Figura 1. Clasificación de estados afectivos (Soriano 2018).....	7
Figura 2. Sensor de respuesta galvánica en la piel (TESLABEM, 2018).	8
Figura 3. Sensor de electrocardiograma (Seed, 2018).....	9
Figura 4. Modelo Valencia – Excitación (Ayata, Yaslan y Kamaşak 2016).....	9
Figura 5. Arduino UNO (Arduino, 2018).....	10
Figura 6. Placa de desarrollo Linkit One (Seed, 2018).....	11
Figura 7. Placa de la plataforma Grove (Seed, 2018).....	12

Figura 8. MySignals e-health v2.0 (e-health, 2018).....	12
Figura 9. Módulo Xbee versión Pro S1	13
Figura 10. Metodología de solución de la investigación	21
Figura 11. Primer prototipo de adquisición de datos.....	22
Figura 12. Arquitectura de adquisición de datos con diferentes sensores y envío de información.....	22
Figura 13. Diademas Emotive Insight y Emotive Epoc (Emotive, 2019)	23
Figura 14. Usuario portando diadema Emotiv epoc y visor de realidad virtual	24
Figura 15. Usuario portando diadema Emotiv insight y visor de realidad virtual.....	24
Figura 16. Arduino con grove y sensores GSR y ECG	25
Figura 17. Conexión GSR directo a Arduino UNO	25
Figura 18. Ajuste de sensibilidad del sensor GSR	26
Figura 19. Comunicación I2C	26
Figura 20. Sensor ECG conectado directo al Arduino UNOO.....	27
Figura 21. ECG conectado Grove y Arduino UNO.....	28
Figura 22. Usuario usando sensores de GSR y ECG.....	28
Figura 23. Sensor ECG (e-health, 2019)	29
Figura 24. Conexión de electrodos de ECG en e-health (e-health, 2019).....	29
Figura 25. Posicionamiento de electrodos de ECG	30
Figura 26. Sensor GSR (e-health, 2019).....	30
Figura 27. Posicionamiento de electro de GSR en e-health (e-health, 2019).....	31
Figura 28. Señal de GSR grabada con e-health	31
Figura 29. Señal de ECG grabada con e-heatlh.....	31
Figura 30. Sensor ECG conectado a placa Linkit One	32
Figura 31. Mapeo de valores en Linkit One	32
Figura 32. Prueba de conexión mediante Wifi de Linkit One	33
Figura 33. Guardado de archivos en Linkit One y switch de memoria sd	33
Figura 34. Comunicación de sensores Xbee y sensor ECG	34

Figura 35. Arquitectura de adquisición de datos con Xbee	34
Figura 36. Diagrama para obtener muestras y hacer la clasificación	35
Figura 37. Metodología para caracterizar e inducir estados mentales a través de realidad virtual inmersiva e interfaz cerebro computadora. (Jeovanny Soriano, 2018).	36
Figura 38. Plataforma de grabación con Grove y Emotive Insight	37
Figura 39. Interfaz gráfica del módulo de dispositivos	38
Figura 40. Interfaz del módulo de integración	38
Figura 41. Interfaz del reproductor de UXLab	39
Figura 42. Ejemplo de grabación con UXLab	42
Figura 43. Selección de carpeta para reproducción	43
Figura 44. Visualización de información de señales GSR, ECG y de video	43
Figura 45. Visualización de información de señales EEG	44
Figura 46. Desempeño de los clasificadores	51
Figura 47. Selección de variables con CfsSubsetEval + Bestfirst	52
Figura 48. Selección de variables con CfsSubsetEval + GreedyStepwise	53
Figura 49. Naive Bayes sin estimación K con 20 muestras de aprendizaje y 10 de prueba. 59	
Figura 50. Figura 15. SVM con $c=1.0$, PolyKernel, 20 muestras de aprendizaje y 10 de prueba.	60
Figura 51. KNN con $K=4$, 20 muestras de aprendizaje y 10 de prueba.	60
Figura 52. Naive Bayes sin estimación K con 30 muestras de aprendizaje y las mismas de prueba.	61
Figura 53. SVM con $c=1.0$, PolyKernel, 30 muestras de aprendizaje y las mismas de prueba.	61
Figura 54. KNN con $K=4$, 30 muestras de aprendizaje y las mismas de prueba.	62
Figura 55. Naive Bayes sin estimación K con 20 muestras de aprendizaje y 10 de prueba. 62	
Figura 56. SVM con $c=2.0$, PolyKernel, 20 muestras de aprendizaje y 10 de prueba	63
Figura 57. KNN con $K=4$, 20 muestras de aprendizaje y 10 de prueba	63
Figura 58. Naive Bayes sin estimación K con 30 muestras de aprendizaje y las mismas de prueba	64

Figura 59. SVM con $c=2.0$, PolyKernel, 30 muestras de aprendizaje y las mismas de prueba	64
Figura 60. KNN con $K=4$, 30 muestras de aprendizaje y las mismas de prueba	65
Figura 61. Lectura de sensores Grove Usuario 1-P1	65
Figura 62. Lectura de sensores Grove Usuario 2-P1	66

Lista de tablas

Tabla 1. Clasificación de los estados afectivos (Mas, 2016).....	7
Tabla 2. Comparación de trabajos relacionados	18
Tabla 3. Descripción de las columnas de la tabla de plan de pruebas	39
Tabla 4. Comparativa de Arduino Grove vs MySignals	40
Tabla 5. Características extraídas de cada señal.....	46
Tabla 6. Pruebas sin filtros con conjunto_Aprendizaje= 20 y conjunto_Prueba=10	49
Tabla 7. Pruebas sin filtros con conjunto_Aprendizaje= 30 y conjunto_Prueba=30	49
Tabla 8. Pruebas con filtros con conjunto_Aprendizaje= 20 y conjunto_Prueba=10	50
Tabla 9. Pruebas con filtros y con conjunto_Aprendizaje = 30 y conjunto_Prueba =30	50

Acrónimos

CENIDET: Centro Nacional de Investigación y Desarrollo Tecnológico.

ECG: *Electrocardiogram* (Electrocardiograma).

EEG: *Electroencephalogram* (Electroencefalograma).

GSR: *Galvanic Skin Response* (Respuesta galvánica de la piel).

KNN: *K-Nearest Neighbor* (K-Vecino más cercano).

SVM: *Supporting Vector Machine* (Máquinas de vector soporte).

UX: *User Experience* (Experiencia del usuario).

Glosario de términos

Búsqueda lineal: Es un método para encontrar un valor objetivo dentro de una lista. Ésta comprueba secuencialmente cada elemento de la lista para el valor objetivo hasta que es encontrado o hasta que todos los elementos hayan sido comparados

Exactitud: La exactitud es una métrica para evaluar modelos de clasificación. Informalmente, la exactitud es la fracción de predicciones que el modelo realizó correctamente. La exactitud tiene formalmente la siguiente definición:

$$Exactitud = \frac{VP + VN}{VP + VN + FP + FN} \quad (\text{Fórmula 1})$$

Dónde: VP = Verdaderos Positivos, VN= Verdaderos Negativos, FP = Falsos Positivos y FN= Falsos Negativos

Experiencia del usuario: Son las percepciones y respuestas de una persona que resultan del uso anticipado de un producto, sistema o servicio (ISO FDIS 9241-210).

Función Kernel: Proyecta la información de un conjunto de objetos a un espacio de características de mayor dimensión el cual aumenta la exactitud de un algoritmo de clasificación.

Filtro Paso Banda: Es un filtro que deja pasar un determinado rango de frecuencias de una señal y atenúa las que están fuera del rango.

Máquinas de vector soporte: Una Máquina de Soporte Vectorial (SVM) aprende la superficie decisión de dos clases distintas de los puntos de entrada. Como un clasificador de una sola clase, la descripción dada por los datos de los vectores de soporte es capaz de formar una frontera de decisión alrededor del dominio de los datos de aprendizaje con muy poco o ningún conocimiento de los datos fuera de esta frontera. Los datos son mapeados por medio de un kernel Gaussiano u otro tipo de kernel a un espacio de características en un espacio dimensional más alto, donde se busca la máxima separación entre clases (Betancourt, 2005).

Naive bayes: Naive Bayes es uno de los algoritmos de aprendizaje inductivo más eficientes y efectivos para el aprendizaje automático y la minería de datos. Su desempeño competitivo en la clasificación es sorprendente (Zhang, 2014).

Polykernel: Es una función kernel utilizada en los clasificadores de Máquinas de vector soporte (SVM), que representa la similitud entre vectores en un espacio de características polinomiales de las variables originales.

Precisión: La precisión hace referencia a la porción de identificadores positivos que es clasificado de forma correcta en un modelo. La definición formal de la precisión es la siguiente:

$$\text{Precisión} = \frac{VP}{VP + FP} \quad (\text{Fórmula 2})$$

Dónde: VP = Verdaderos Positivos, FP = Falsos Positivos

Realidad virtual inmersiva: La realidad virtual inmersiva también definida como "inmersión multimedia" tiene la capacidad de recrear experiencias sensoriales como el gusto, el olor, el sonido y el tacto, ya que brinda una inmersión virtual total mediante periféricos (cascos de realidad virtual, gafas y posicionadores), hasta el punto de pensar que está en otra dimensión (Rodríguez, Rey, Clemente, Wrzesien, & Alcañiz, 2014).

Recuperación:

La recuperación se refiere a la porción de positivos reales que se identifican correctamente en una clasificación de objetos. Su definición formal es la siguiente:

$$\text{Recuperación} = \frac{VP}{VP + FN} \quad (\text{Fórmula 3})$$

Dónde: VP = Verdaderos Positivos, FN = Falsos Negativos

Sensores fisiológicos: Proveen una medida objetiva de señales fisiológicas. La mayoría de estas señales suelen ser involuntarias y no se pueden fingir. La mayoría de estas señales se basan en grabaciones de la actividad eléctrica producida por el cerebro, corazón, músculos y la piel (Feidakis, 2016).

UXLab: Software de grabación y reproducción de señales de diferentes dispositivos biométricos, fisiológicos, de audio, cámaras y pantallas de computadora (Fouilloux, 2017).

Vecinos más cercanos: El algoritmo de clasificación del vecino K más cercano (KNN) intenta encontrar los K vecinos más cercanos de un objeto (x0) y utiliza un voto mayoritario para determinar la etiqueta de clase del objeto x0 (Song, Huang, Zhou, Zha and Giles, 2007).

WEKA: Es una colección de algoritmos de aprendizaje automático para tareas de minería de datos. Contiene herramientas para la preparación de datos, clasificación, regresión, agrupamiento, minería de reglas de asociación y visualización. (Frank, Hall, & Witten, 2016).

ZigBee: Es una tecnología de comunicación de corto alcance y bajo consumo desarrollada por la IEEE 802.15 .

Capítulo 1.

Introducción

En el contenido de este capítulo se muestran los antecedentes de esta investigación, la problemática a resolver, el objetivo general, objetivos específicos, la justificación, los alcances y limitaciones del proyecto.

1.1 Antecedentes

Se tienen registros de que en el año 2017 en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) dentro del Departamento de Ciencias Computacionales, se desarrollaron proyectos de investigación relacionados con la detección e inducción de estados cognitivos y emocionales. También se desarrolló un sistema UXLab (Fouilloux, 2017) que permite realizar evaluaciones de la experiencia del usuario mediante el procesamiento de señales EEG y dispositivos de audio y video.

En el trabajo de tesis ‘Metodología UXEEg para la evaluación de la Experiencia del Usuario en personas con discapacidad a partir de Interfaces Cerebro Computadora’ (Nimrod, 2017) se toman en consideración varios factores cognitivos y afectivos. En la experimentación se hace uso de un sensor de electroencefalograma para analizar las señales del cerebro en los usuarios. El resultado fue una metodología con actividades y distintos escenarios para evaluar tecnologías de asistencia y rehabilitación en personas con discapacidad.

La tesis de maestría ‘Metodología para caracterizar e inducir estados mentales a través de realidad virtual inmersiva e interfaz cerebro computadora’ (Soriano, 2017) proporciona material (imágenes, audio, video, etc.) para la inducción de estados mentales. Este material ha sido probado usando EEG, posibilitando entonces la realización de pruebas con otros sensores fisiológicos. Su relevancia en el presente trabajo de investigación se relaciona también en la propuesta de una metodología que puede funcionar como guía en la evaluación de la experiencia del usuario, ya que proporciona información de cómo interactuar con el usuario durante la evaluación y distintos cuestionarios que sirven para analizar los resultados obtenidos.

1.2 Descripción del problema

El análisis de estados afectivos ha ido tomando mayor importancia en los últimos años, esto debido a que la información fisiológica sirve para retroalimentar sistemas computacionales y evaluar productos o servicios, por ejemplo, para evaluar tecnologías de interacción humano-computadora, desarrollar software para el cómputo afectivo, monitorear terapias psicológicas, realizar estudios mercadológicos, etc. Hoy en día existen herramientas de software que ofrecen servicios para realizar esta actividad de análisis en los estados emocionales, pero sus procesos son cajas negras que ocultan como se hace el procesamiento de la información.

Por lo que se puede definir que el problema que se atacará con este proyecto de tesis es conocer los detalles relacionados con las distintas combinaciones de señales fisiológicas, los sensores y placas de desarrollo que permitan el análisis de estados afectivos asociados a un proceso de evaluación de la experiencia del usuario. Esto con el fin de desarrollar una

plataforma que sea flexible para probar a futuro otros sensores, técnicas de procesamiento y algoritmos de clasificación.

1.3 Objetivos

1.3.1 Objetivo General

Desarrollar un sistema que permita el análisis y detección de estados emocionales mediante el procesamiento de datos fisiológicos heterogéneos.

1.3.2 Objetivos Específicos

1. Investigar el estado del arte sobre el análisis y detección de estados emocionales
2. Desarrollar un algoritmo que permita analizar y detectar el estado emocional de un usuario mediante señales EEG, ECG y GSR
3. Realizar pruebas para visualizar en tiempo real los valores de las señales de los sensores fisiológicos obtenidas de los usuarios
4. Analizar los datos obtenidos con la experimentación usando la herramienta Weka
5. Guardar la información fisiológica de los sensores en archivos de texto
6. Agregar un módulo para la visualización de las grabaciones en el sistema UXLab

1.4 Justificación

Durante la realización de estudios que se han llevado a cabo en el transcurso de los años relacionados con el análisis de emociones, estos siempre incluyen el uso de diferentes sensores fisiológicos y de algoritmos para clasificar las señales. Sin embargo, no se ha encontrado alguna combinación en concreto de cuales valores obtenidos de los sensores son capaces de identificar una emoción. La mayoría de las veces los sensores tienen ruido en sus señales o son difíciles de colocar en todos los usuarios. Además, todas las personas reaccionan de forma diferente ante las situaciones que viven diariamente.

Es por esto que con el presente trabajo se buscó tener un mayor acercamiento con diferentes kits de sensores de bajo costo, el procesamiento de las señales y los clasificadores con mejores resultados en trabajos pasados, esto con el fin de brindar alternativas de estudio que involucren análisis de estados afectivos.

1.5 Alcances y Limitaciones

En este apartado se presentan los alcances y limitaciones del presente trabajo de investigación.

1.5.1 Alcances

1. Construcción de un sistema prototipo para la adquisición de datos fisiológicos
2. Desarrollo de un módulo para agregar la sincronización de señales de audio, video y EEG con las señales fisiológicas GSR y ECG en UXLab
3. Aplicación de algoritmos de reconocimiento de patrones (SVM, KNN y Naive Bayes) que permiten realizar el análisis de estados emocionales usando las señales fisiológicas.
4. El análisis de los resultados de la sincronización se puede realizar en el sistema UXLab
5. Se realiza la extracción de características sobre las diferentes señales fisiológicas.

1.5.2 Limitaciones

1. Se evaluaron los algoritmos de clasificación de Vecinos más cercanos, Máquinas de vector soporte y Naive Bayes.
2. No se analizarán todos los estados afectivos. Sólo se probaron los estados afectivos de: alegría, tristeza y un estado neutro.
3. Solo se ejecutaron pruebas de clasificación de emociones aplicando el filtro de paso banda.
4. El sistema UXLab solo funciona con la plataforma Arduino Uno con Grove y Arduino Uno con MySygnals en su versión de e-health 2.0.
5. El sistema de adquisidor de datos fisiológicos no es portable, por lo que los sensores deben de estar conectados directamente a una computadora.

Capítulo 2.

Marco teórico

Este capítulo aborda los conceptos teóricos principales que se involucran en el presente trabajo de tesis, esto con el objetivo de que el lector comprenda mejor el tema que aborda la investigación.

2.1 Biofeedback

Se refiere al uso de distintos aparatos (mecánicos, eléctricos) que posibilitan tomar conciencia de una respuesta biológica, de forma que una persona pueda aprender, mediante un proceso de ensayo-error, a mejorar el control de una respuesta. Consiste en regular aquellos procesos fisiológicos controlados por el sistema nervioso autónomo, que normalmente son inconscientes, para que pasen a ser conscientes en la persona. De esta forma se logra una mayor conciencia sobre el propio organismo y un mayor control sobre él (Saz y Ortíz, 2005).

2.2 Neurofeedback

Trata sobre la enseñanza del autocontrol de funciones cerebrales a las personas a través de medir la actividad de ondas cerebrales y proveer una señal de retroalimentación. En el Neurofeedback se utiliza de forma muy común la retroalimentación a través de sonidos y videos. La actividad eléctrica o EEG (por sus siglas en inglés) puede ser grabada al poner electrodos en el cuero cabelludo. Esta actividad eléctrica es generada en áreas específicas de la piel por las neuronas, posibilitando así ser grabadas por los electrodos (Marzbani, Reza y Mansourian, 2016).

2.3 Electroencefalograma

El electroencefalograma o EEG, consiste en el registro de la actividad eléctrica del cerebro mediante un equipo especial denominado electroencefalógrafo. La actividad cerebral genera señales eléctricas que pueden ser captadas mediante electrodos situados sobre el cuero cabelludo. Estas señales son amplificadas y se pueden representar en una pantalla o registrar en una gráfica (Giménez, 2011).

2.4 Estados afectivos.

Se entiende por estados afectivos a la condición neuropsicológica que presenta un sujeto. Los estados afectivos se clasifican en emociones y sentimientos. Los estados afectivos se diferencian principalmente por el tiempo de duración, los sentimientos tienen una duración mayor que las emociones. En la Tabla 1 se presenta la clasificación de los estados afectivos y algunos ejemplos que permiten diferenciarlos.

Tabla 1. Clasificación de los estados afectivos (Mas, 2016).

Emociones	Sentimientos
Miedo	Vergüenza
Ira	Resentimiento
Tristeza	Amor
Alegría	Simpatía
Sorpresa	Orgullo
Asco	Celos

Los estados emocionales se clasifican en dos tipologías: estados emocionales positivos y estados emocionales negativos. En la figura 1 se muestra una categorización de estados afectivos según la neurociencia.

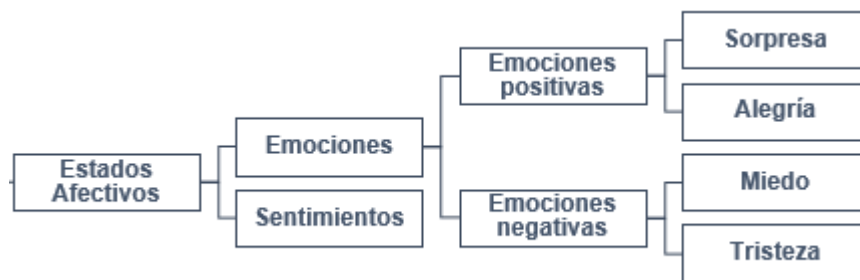


Figura 1. Clasificación de estados afectivos (Soriano 2018)

2.4.1 Estado afectivo positivo

Está compuesto por sentimiento y emociones positivas, como la alegría, el buen humor, el optimismo, el entusiasmo y el amor, este estado emocional conlleva a una situación placentera (Fredrickson, 2003), por lo que se puede considerar que las emociones son tendencias de respuesta con un gran valor adaptativo, que tienen evidentes manifestaciones a nivel fisiológico, en la expresión facial, la experiencia subjetiva, el procesamiento de la información, etc., que son intensas pero breves en el tiempo y que surgen ante la evaluación de algún acontecimiento antecedente.

2.4.2 Estado afectivo negativo

Estado emocional compuesto por sentimientos y emociones negativas, como el miedo, la culpa, la ira y el disgusto que conlleva una situación no placentera, las emociones negativas solucionan problemas de supervivencia inmediata porque tienen asociadas tendencias de respuesta específicas, por ejemplo, la ira prepara para el ataque; el asco provoca rechazo; el miedo prepara para la huida (Malatesta y Wilson, 1988).

2.5 Respuesta galvánica de la piel

La respuesta galvánica en la piel (GSR por sus siglas en inglés) se refiere al cambio en el calor y la electricidad que transmiten los nervios y el sudor a través de la piel. La respuesta galvánica de la piel suele variar en los distintos estados emocionales. También se llama conductividad de la piel y respuesta electrodérmica (NCI, 2016). La siguiente figura 2 muestra un sensor de respuesta galvánica de la piel.



Figura 2. Sensor de respuesta galvánica en la piel (TESLABEM, 2018).

2.6 Electrocardiograma

El electrocardiograma permite la grabación de la actividad eléctrica del corazón en diferentes puntos sobre la superficie del cuerpo. Con lo cual se puede realizar un análisis de dicha actividad. (Goldman y Schafer, 2016). Actualmente también se puede adquirir la información usando componentes electrónicos que permiten la transferencia y estudio de datos en una computadora u otros dispositivos. A continuación, en la figura 3 se muestra un ejemplo de sensor de electrocardiograma.




Figura 3. Sensor de electrocardiograma (Seeed, 2018)

El sistema nervioso autónomo controla la función del corazón. Los humanos no pueden controlar el músculo del corazón de forma subconsciente, entonces la condición del corazón naturalmente representa cambios emocionales (Dimas, Septiana, Dharmas y Hery 2017).

2.7 Valencia y Excitación

Ayata, Yaslan y Kamaşak (2016) comentan que el modelo dimensional valencia-excitación de las emociones es usado en una gran cantidad de estudios de investigación. La figura 4 muestra el modelo antes mencionado.



Figura 4. Modelo Valencia – Excitación (Ayata, Yaslan y Kamaşak 2016)

La valencia para Frijda (1986) especialmente en el debate sobre las emociones, se entiende como el atractivo intrínseco (valencia positiva) o la aversión (valencia negativa) de un evento, objeto o situación.

Guerri (2017) define la excitación como un estado de mayor actividad, tanto en nuestra mente como de nuestro cuerpo, que nos hace más alerta. La excitación actúa a lo largo de un espectro que va de bajo a alto. Podemos sentirnos un poco excitados o extremadamente excitados.

2.8 Placas Arduino

Arduino es una plataforma de prototipos de electrónica de código abierto basada en hardware y software fáciles de usar (Arduino, 2018). Permite el control de distintos sensores, motores y otros artefactos. Existen diferentes placas que se pueden adecuar a diferentes necesidades.

2.8.1 Arduino UNO

Este arduino utiliza el microcontrolador ATmega328 y el ATmega16U2, lo cual permite que la transferencia de información con una computadora sea más rápida y también brinda mayor espacio de memoria interna (Arduino, 2018). En la figura 5 se muestra una placa de Arduino UNO.



Figura 5. Arduino UNO (Arduino, 2018)

Estas son las características de la placa Arduino UNO:

- Microcontrolador: ATmega328.
- Voltaje Operativo: 5v.
- Voltaje de Entrada (Recomendado): 7 – 12 v.
- Pines de Entradas/Salidas Digital: 14 (De las cuales 6 son salidas PWM)
- Pines de Entradas Análogas: 6.
- Memoria Flash: 32 KB (ATmega328) de los cuales 0,5 KB es usado por Bootloader.
- SRAM: 2 KB (ATmega328)

2.8.2 Arduino Linkit One

De acuerdo con (Seeed, 2018), la placa Arduino Linkit One es de código abierto y permite el desarrollo de prototipos de electrónica que pueden ser portables e interactúen con el internet de las cosas. Permite la conexión mediante Wi-Fi, Bluetooth y SMS, además de que también cuenta con tecnología GPS para la localización global. Esta placa integra todas las funciones básicas que tiene un Arduino, solo que se le agregan cualidades para que su comunicación inalámbrica sea más fácil y rápida. En la figura 6 se observa una placa Linkit One.



Figura 6. Placa de desarrollo Linkit One (Seeed, 2018)

Dentro de las características de esta placa se destacan las siguientes:

- Chipset del procesador: MT2502A (Aster); Núcleo: ARM7 EJ-S 260MHz (velocidad de reloj).
- Almacenamiento masivo 16MB FLASH; Tarjeta Micro SD: Hasta 32 GB (Clase 10).
- Memoria RAM 4MB.
- Sistema operativo RTOS.
- Pines de E / S digitales Número de Pines: 16 (D0 ~ D13, SDA, SCL); Voltaje: 3.3V.
- Entradas analógicas, numero de pines: 4 (A0, A1, A2); Voltaje: 0 ~ 5V.
- Conexión en red Wi-Fi 802.11b / g / n, GSM / GPRS, GPS, Bluetooth 2.1 y 4.0.15
- Otras interfaces 2x señales PWM; 1x I 2 C interfaz; 1x interfaz SPI; Interfaz Grove 2x (1xUART / 1x I 2 C).
- Fuente de alimentación Jack de batería: 3.7 ~ 4.2V Li-batería; Corriente continua por perno de E / S: 0.3 ~ 3mA.
- Jack para auriculares de audio (con micrófono).
- USB: 1 Micro USB.

2.9 Plataforma Grove

Grove es un sistema de prototipos de conectores estandarizados y modulares. Grove adopta un enfoque de bloques de construcción para ensamblar productos electrónicos. En comparación con el sistema basado en puentes o soldaduras, es más fácil conectar, experimentar y construir, y simplifica el sistema de aprendizaje. La figura 7 muestra la placa de esta plataforma.




Figura 7. Placa de la plataforma Grove (Seeed, 2018)

2.10 Plataforma MySignals ehealth v2.0

MySignals se refiere a varios productos de salud y desarrollo médico específicamente orientados a investigadores, desarrolladores y fabricantes. Los sensores fisiológicos de la versión 2.0 de e-health que se pueden utilizar con esta plataforma son varios como el electrocardiograma, la respuesta galvánica en la piel, sensor de respiración, nivel de azúcar en la sangre, entre otros. La figura 8 muestra la placa correspondiente a esta plataforma.



Figura 8. MySignals e-health v2.0 (e-health, 2018)

2.11 Sensor Xbee de radiofrecuencia

De acuerdo a Digi (2019), los módulos XBee son soluciones integradas que brindan un medio inalámbrico para la interconexión y comunicación entre dispositivos. Estos módulos utilizan el protocolo de red llamado IEEE 802.15.4 para crear redes FAST POINT-TO- MULTIPOINT (punto a multipunto); o para redes PEER-TO-PEER (punto a punto). Fueron diseñados para aplicaciones que requieren de un alto tráfico de datos, baja latencia y una sincronización de

comunicación predecible. Por lo que básicamente XBee es propiedad de Digi basado en el protocolo Zigbee. En términos simples, los XBee son módulos inalámbricos fáciles de usar, (MCI electronics, s.f.). Los módulos de radio XBee pueden ser usados con un número mínimo de conexiones: Power (3.3V), GND y TX/RX de la UART, junto con otras funciones recomendables como reset y sleep. Un ejemplo de estos módulos es la versión Pro S1 que se visualiza en la figura 9.



Figura 9. Módulo Xbee versión Pro S1

2.12 Reconocimiento de patrones

Según (Pavlidis, 1977) la palabra patrón significa ‘algo que se configura como un ejemplo perfecto para ser imitado’. Así, el reconocimiento de patrones significa la identificación del ideal con el que se hizo un objeto dado después. Para (González ,1978) el reconocimiento de patrones se define como la clasificación de una señal de entrada al extraer características importantes de ella.

Capítulo 3.

Estado del arte

En este capítulo se presentan los trabajos más importantes y recientes relacionados con este trabajo de tesis. Se describen los fundamentos y métodos usados en cada estudio de las emociones y de los sensores fisiológicos. También se agregan algunas investigaciones más antiguas que aportan conceptos para el procesamiento de señales fisiológicas y la clasificación de emociones..

3.1 Measuring Affective, Physiological and Behavioral Differences in Solo, Competitive and Collaborative Games (2016)

Descripción: Estudio realizado con el propósito de medir estados afectivos y de comportamiento en jugadores de videojuegos. Esto para comprender sus sentimientos en diferentes modos de juego y revisar como los juegos pueden ser mejorados para ofrecer una mayor experiencia al usuario de inmersión e interés. La experimentación fue realizada con sensores de respuesta galvánica en la piel y de ritmo cardiaco.

3.2 Computational Analysis of Valence and Arousal in Virtual Reality Gaming using Lower Arm Electromyograms (2017)

Descripción: Trabajo de investigación desarrollado para determinar si es posible detectar estados afectivos en una persona usando sensores de electromiograma localizados en los antebrazos, mientras interactúa en un ambiente de realidad virtual. Además, se analizó la posibilidad de detectar el estado afectivo con la información de un solo antebrazo.

3.3 Non-intrusive Wearable Health Monitoring Systems for Emotion Detection (2017)

Descripción: Sistema desarrollado para la detección de estados emocionales en pacientes de hospitales a personal médico. La finalidad de conocer cómo se encuentra emocionalmente el paciente permite ayudarlo a sentirse mejor. En la mayoría de los casos entre niños y adultos se detecta ansiedad, estrés o miedo al estar en el hospital. El sistema detecta cambios en la temperatura del cuerpo el ritmo cardiaco y la posición del paciente, que además de cumplir con la detección de las emociones, tiene la posibilidad de poderse monitorear de forma remota.

3.4 Discrimination between different emotional states based on the chaotic behavior of galvanic skin responses (2017)

Descripción: El objetivo de este estudio fue examinar la efectividad de usar la respuesta galvánica de la piel en el reconocimiento de estados emocionales. La experimentación se llevó a cabo al grabar y procesar la información de personas que escucharon y vieron distintos videos musicales que provocaban emociones. Compara los resultados obtenidos al procesar la respuesta galvánica de la piel contra otros estudios que se han realizado con propósitos similares, pero usando sensores de electroencefalograma y electrocardiograma. Se concluye que la respuesta galvánica de la piel es un gran indicador de distintos estados emocionales cuando se usa la música como estímulo.

3.5 Physiological Signal-based Emotion Recognition System (2017)

Descripción: Es un sistema que se propone para reconocer tres estados emocionales: ira, alegría y neutro. Implementa la medición de señales de varios sensores fisiológicos como el electrocardiograma, el electromiograma, la respuesta galvánica de la piel, la respiración, saturación del oxígeno en la sangre y la presión de la sangre. Aborda el tema de que es muy complicado elegir que sensores utilizar para el estudio del reconocimiento de emociones, ya que algunos sensores aportan más información relevante que otros, y también en algunas ocasiones un sensor puede determinar la diferencia entre una emoción y otra. Se propone también una tabla que relaciona las emociones con la actividad detectada de los sensores.

3.6 EMG and GSR signals for evaluating user's perception of different types of ceramic flooring (2008)

Descripción: Es un trabajo de investigación que utiliza la evaluación de la experiencia del usuario con sensores de electromiograma y la respuesta galvánica de la piel. Básicamente el estudio consistió en someter a los usuarios a una prueba en donde veían imágenes de pisos de cerámica en una pantalla, al mismo tiempo se grababa la señal fisiológica y sus rostros. Se realizó una comparación de las expresiones de los rostros (sonriendo, neutral, asco) y las señales fisiológicas, concluyendo que se puede detectar el agrado o desagrado de los pisos para el usuario simplemente al ver la actividad del electromiograma o la respuesta galvánica.

3.7 Affect Detection in Normal Groups with the Help of Biological Markers (2015)

Descripción: En este estudio se usaron como estímulos imágenes del Sistema internacional de imágenes afectivas (IAPS por sus siglas en inglés), que son imágenes comprobadas que inducen emociones. Se presenta el reconocimiento de emociones al analizar distintas señales fisiológicas que incluyen la respiración, ritmo cardiaco, respuesta galvánica de la piel electromiograma y la temperatura de la piel. El diseño del experimento también usa la música como estímulo para regresar al usuario a un estado de relajación.

3.8 Emotion Recognition employing ECG and GSR Signals as Markers of ANS (2016)

Descripción: Es un estudio realizado para la evaluación de la efectividad de los sensores de respuesta galvánica de la piel (GSR) y electrocardiograma (ECG) en el reconocimiento de estados emocionales. Se toman como referencia los estados de felicidad, tristeza y neutral. De forma general en el trabajo se realizan pruebas de la detección de los estados emocionales con los sensores fisiológicos y algunos algoritmos de clasificación. Los algoritmos utilizados

son las máquinas de vector-soporte, el vecino más cercano y Naive Bayes. Se analizó cual es la mejor combinación entre los sensores y los clasificadores, en algunos casos los resultados son mejores usando la respuesta galvánica, pero en otros con otro clasificador y combinando ambas señales de GSR y ECG el resultado de la detección es mejor.

3.9 Emotion Detection using non-invasive low cost sensors (2017)

Descripción: Este estudio fue desarrollado principalmente para comprobar que sensores fisiológicos no invasivos son igual de confiables en la detección de cambios emocionales que otros sensores que sí son invasivos. El estudio está basado en otro anteriormente llamado “DEAP A Database for Emotion Analysis using Physiological Signals”, con la variante de que se aplicaron algoritmos de extracción de características y se cambió el enfoque de la clasificación de las emociones. En el estudio original un clasificador fue entrenado y probado para cada sujeto usando validación cruzada. Por otro lado, en el estudio reciente se usó un enfoque de sujeto-cruzado usando la técnica de ‘dejar uno fuera’. Al final los resultados mostraron que los sensores no invasivos son confiables para detectar cambios emocionales.

3.10 Modeling the Affective Space of 360 Virtual Reality Videos Based on Arousal and Valence for Wearable EEG-Based VR Emotion Classification (2018)

Descripción: El experimento realizado en este artículo consistió en estimular a varios usuarios con videos en 360 y realidad virtual. Al combinar estas dos técnicas se buscó que los usuarios expresaran en tiempo real como se sentían al ver el video, y al final se les realizaron también cuestionarios para que indicaran en un esquema emocional de valencia y excitación que les había parecido la prueba. Una vez que se terminaron las pruebas se buscó relacionar los datos obtenidos con los videos que fueron mostrados, es decir, buscar la relación de las emociones con el contenido del video. Lo que pretenden a futuro es usar este repositorio de emociones y de videos para capturar información eléctrica del cerebro (EEG) y buscar ahora la relación de las emociones con las ondas cerebrales.

En las siguientes páginas se muestra la Tabla 2, en donde se observa la comparación de los distintos trabajos relacionados. En la última columna se muestra el porcentaje de clasificación obtenido en cada trabajo, aunque en algunos se pone un valor de Na (No aplica), ya que algunos trabajos se basan en etapas más tempranas y no usan todavía algún algoritmo de clasificación.

Tabla 2. Comparación de trabajos relacionados

Proyecto/Investigación	Electroencefalograma	Electrocardiograma	Electromiograma	Conductividad en piel	Usa realidad virtual	Clasificación	Emociones	Porcentaje de clasificación obtenido
[Gunes 2016]	-	x	-	x	-	Algoritmos de extracción de ruido, análisis matemático con la clasificación de excitación y valencia.	Felicidad, neutral e ira	58%
[Gunes 2017]	-	-	x	-	-	Máquinas de soporte vectorial y vecinos más cercanos	Felicidad, ira, aburrimiento, tranquilidad, nervioso, calmado, triste, enojado y excitado.	85% - 91%
[Norhafizah 2017]	-	x	-	-	-	Análisis matemático y estadístico.	Estrés, felicidad, miedo y ansiedad	55% - 92%
[Atefeh Goshvarpour 2017]	-	-	-	x	-	Selección de búsqueda secuencial, Random forest, Máquinas de vector soporte	Felicidad, miedo, tristeza y neutral	75% - 95%

[Ibrahim Bafade 2017]	-	-	x	x	-	Análisis estadístico y predictivo de modelos de datos	Felicidad, neutral y enojo	NA
[Laparra-Hernández 2008]	-	-	-	x	-	Normalización de datos con ecuaciones matemáticas	Estrés, relajación y felicidad	20%
[Arnab bag 2015]	-	x	x	x	-	Vecino más cercano y máquinas de vector soporte	Ira, alegría, amor y odio	55%- 75%
[Priyanka Das 2016]	-	x	-	x	-	Máquinas de vector soporte, Naive bayes y Vecino más cercano	Felicidad, tristeza y neutral	32% - 100%
[Daniela Girardi 2017]	x	x	-	x	-	Naive Bayes, Máquinas de vector soporte y Algoritmo J48	Alegría, Tristeza, Miedo, sueño e ira	53% - 60%
[Nazmi Sofian Suhaimi 2018]	x	-	-	-	x	Clasificación por etiquetado	Felicidad, miedo, ansiedad, disgusto, sorpresa, interés, aburrimiento y satisfacción	NA
Presente trabajo de tesis	x	x	-	x	x	Máquinas de vector soporte, Naive Bayes y vecinos más cercanos.	Alegría, neutro y tristeza	30% - 100%

Capítulo 4.

Metodología de solución

En este capítulo se describen y explican los pasos que se realizaron en la metodología de solución del presente trabajo de investigación.

4.1 Metodología de solución

En esta sección se muestra la metodología de solución que se llevó a cabo en la investigación y el proceso para realizar las pruebas. Así como también se explica brevemente cada una de las secciones de la metodología. La metodología de solución es la que se muestra en la figura 10:




Figura 10. Metodología de solución de la investigación

4.2 Elección de sensores fisiológicos

El desarrollo de esta actividad consistió principalmente en probar distintos sensores fisiológicos y placas de desarrollo Arduino que sirvieran para la obtención de los valores de los sensores. Además, el objetivo fue tener una plataforma estable que generara un archivo de texto para aplicarle un procesamiento a los valores obtenidos.

4.2.1 Arquitectura

Al inicio se modeló una arquitectura pequeña de cómo podría ser el sistema de adquisición de datos. Se tomó en cuenta un sensor que recolectará datos para enviarlos a una placa Arduino. Así mismo se consideró la tecnología Grove para realizar la conexión, debido a que es más fácil que usar conexión con cables independientes. La información se procesaría en el Arduino para luego visualizarse en una pantalla LCD como se muestra en la siguiente figura 11.

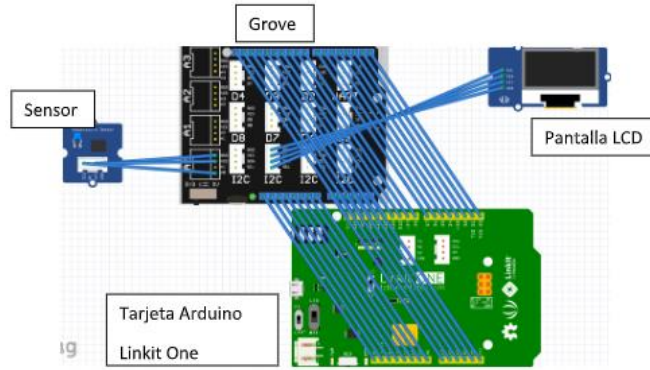


Figura 11. Primer prototipo de adquisición de datos

Se tuvieron varias ideas de cómo se debía hacer el envío de la información fisiológica del usuario y la grabación de los datos obtenidos en una computadora. La figura 12 muestra un primer diseño que se hizo con la identificación de los elementos del prototipo, como la placa de arduino, los sensores fisiológicos, el usuario, el software a evaluar y el sistema de grabación.

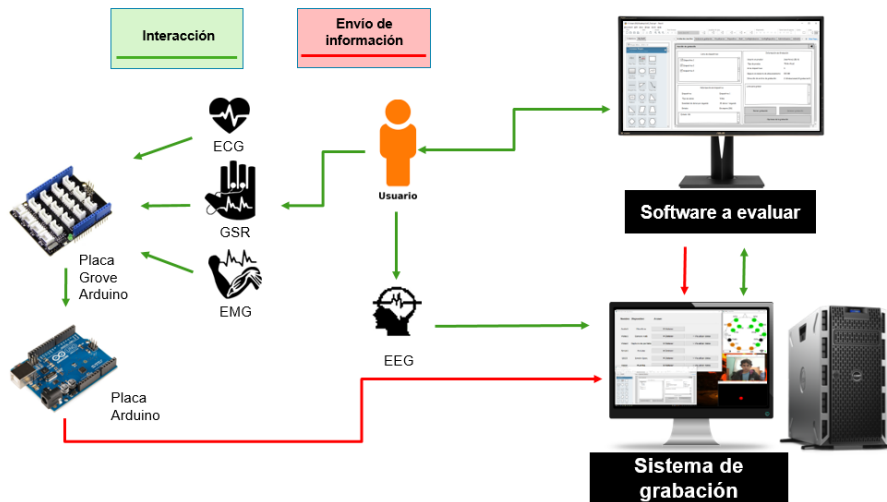


Figura 12. Arquitectura de adquisición de datos con diferentes sensores y envío de información

4.2.2 Diademas de electroencefalograma (EEG)

Para elegir una diadema de electroencefalograma (EEG) fueron realizadas pruebas con dos modelos de diademas. En la figura 13 se puede ver del lado derecho el modelo Eloc y del izquierdo la Insight.



Figura 13. Diademas Emotive Insight y Emotive EPOC (Emotive, 2019)

Características de Emotive EPOC:

- 14 electrodos
- Envío de información en tiempo real
- Conexión inalámbrica mediante un dongle

Características de Emotive Insight:

- 5 electrodos
- Envío de información en tiempo real
- Conexión mediante dongle y Bluetooth

En general, si no se tiene experiencia con diademas EEG el proceso de ajuste de la posición de los electrodos puede ser tardado y estresante para la persona que hará el estudio al usuario. De 15 pruebas realizadas con la Emotive EPOC, algunos usuarios tenían el cabello largo y se tardó demasiado en ajustarse la diadema, en comparación en este aspecto la Emotive Insight es más fácil colocar ya que logra contacto con el cuero cabelludo sin enredarse con el cabello y el tiempo es menor. Además, la Emotive EPOC al tener más electrodos, toma más tiempo tratar de colocarlos.

Otro aspecto que se consideró en las pruebas fue el uso de las diademas en conjunto con visores de realidad virtual, para esta prueba de nueva cuenta la Emotive Insight era más ergonómica en los usuarios y no se perdía la señal de los electrodos, en cambio con la EPOC a veces la señal se perdió y no era correcta. Por los motivos antes explicados, se decidió usar el modelo de Emotive Insight. La información obtenida del sensor es guardada en un archivo de texto de forma separada.

La figura 14 muestra a un usuario usando un visor de realidad virtual y la diadema Emotiv Epoc, de esta forma el contacto de los electrodos no es óptima ya que las correas del visor llegar a bloquear la señal de algunos y no se hace contacto directo con el cuero cabelludo del usuario.



Figura 14. Usuario portando diadema Emotiv epoc y visor de realidad virtual

La figura 15 muestra a un usuario usando la diadema Emotiv Insight con el visor de realidad virtual, en este caso los electrodos no pierden tanto el contacto con el cuero cabello del usuario y la señal se obtiene sin tanto ruido.



Figura 15. Usuario portando diadema Emotiv insight y visor de realidad virtual

4.2.3 Arduino UNO

Dentro de las placas Arduino que se probaron fueron la de Arduino Link it One y Arduino UNO, ambas placas se probaron con Grove y con MySignals. Las figuras 11 y 12 muestran la placa de MySignals en su versión de e-health 2.0, esta placa ya incluye los sensores de ECG y GSR, además de que se conecta directamente al Arduino UNO. La figura 16 muestra la placa Grove con los sensores de ECG y GSR que también se conectan a la placa Arduino UNO.




Figura 16. Arduino con grove y sensores GSR y ECG

Pruebas con GSR directo al Arduino UNO

La figura 17 muestra la conexión de un GSR conectado de forma directa a la placa Arduino UNO, la desventaja de hacerlo así, es que el sensor se puede desconectar fácilmente de la placa ya que los cables son muy sensibles y no están soldados ni fijados de alguna manera.



Figura 17. Conexión GSR directo a Arduino UNO

Lo que mide este sensor es la resistencia del cuerpo al aplicarle un voltaje. También al seguir revisando la documentación se encontró que se debe ajustar una resistencia que ayuda a disminuir el ruido en la señal. El fabricante recomienda obtener en pantalla un valor de 512 sin tener las almohadillas del sensor en los dedos. El valor de 512 viene de aplicarle un mapeo al voltaje que devuelve el sensor. A continuación, se muestra en la figura 18 el ajuste del sensor GSR.




Figura 18. Ajuste de sensibilidad del sensor GSR

Pruebas con ECG directo a Arduino UNO

Las pruebas con este dispositivo fueron relativamente fáciles al principio, ya que el proveedor proporciona información de ejemplo para su uso, sin embargo, se debe de tener en cuenta de que la transmisión de este sensor se hace mediante un estándar llamado I2C, el cual usa un cable para la transmisión de datos (SDA) y otro para indicar la frecuencia del reloj (SCL) con la que se debe de transmitir información. La siguiente figura 19 es una representación de la comunicación I2C.




Figura 19. Comunicación I2C

Es por este estándar I2C que se complicó un poco la experimentación, ya que al inicio se probó el sensor conectándolo a una placa Arduino Linkit One, la cual tiene una conexión especial para I2C, pero después al probar el sensor ECG en el Arduino UNO no se sabía cómo se debía conectar, ya que, este Arduino no tiene una entrada especial para I2C y se debía hacer la conexión de cables de forma individual. Al realizar la prueba el resultado en pantalla no era el esperado. El resultado del sensor debe de indicar un valor del ritmo cardíaco, según la (American Heart Association, 2018) no mayor a 100 pulsaciones por minuto en estado de reposo, y lo que se mostraba eran valores entre 400 y 600, a los cuales no se les podía dar una interpretación. En la siguiente figura 20 se muestra la conexión directa del sensor ECG y el valor que se obtenía.




Figura 20. Sensor ECG conectado directo al Arduino UNOO

Por lo regular un sensor solo envía información al Arduino, pero este sensor ECG funcionaba con otro estándar que tiene comunicación bidireccional, es decir, necesitaba definirse un puerto de envío de información y otro de recepción desde el Arduino, cosa que en GSR no era necesario, ya que el GSR solo envía la información.

Pruebas con Grove

Una vez que se incorporó la placa Grove al Arduino, se logró que los usuarios tengan más movilidad en su mano, ya que los cables Grove son más largos y resistentes. Además, la conexión con la placa Grove es más estable porque los cables no se desconectan tan fácil debido a que en sus puntas tiene un pequeño seguro que encaja con los sensores y la placa Grove. La figura 21 muestra el sensor ECG conectado al Arduino UNO mediante Grove, de esta manera el sensor no se desconecta ni pierde la lectura de la información tan fácilmente.




Figura 21. ECG conectado Grove y Arduino UNO

En las pruebas realizadas con el Arduino UNO siempre se mantuvo una conexión Serial con una computadora en el puerto USB. Las pruebas se realizaron primero sin usar la placa Grove, es decir, conectando los sensores directamente al Arduino. Luego se probó conectado la placa Grove al Arduino y los sensores al Grove.

Al usar los sensores solo con el Arduino los usuarios no tienen que estar tan lejos de la computadora en la cual se conecta el Arduino. Es por esto que los usuarios tenían dificultades para realizar ciertas actividades, por ejemplo, tomar lectura de algunas hojas, manipular el mouse, teclado u otros objetos como los visores de realidad virtual. También los sensores de ECG y GSR les llegaban a limitar sus movimientos, ya que el alcance de los cables es corto y los sensores abarcan casi todos los dedos de una mano al ser colocados. La desventaja de usar cables independientes con los sensores es que son frágiles y no tienen una conexión estable, casi con cualquier movimiento que mueva demasiado el cable se pierde la conexión. La figura 22 muestra a un usuario realizando algunas actividades como leer instrucciones en papel, manipular su celular, el mouse de la computadora, etc., todo mientras porta los sensores de ECG y GSR.



Figura 22. Usuario usando sensores de GSR y ECG

Debido a la ergonomía y la estabilidad de la información que se obtenía con el Grove, se decidió usarlo como complemento a la placa de Arduino UNO.

4.2.4 MySignals

MySignals es un conjunto de productos orientados a la investigación y desarrollo de aplicaciones médicas. En este trabajo de investigación se probó el producto conocido como e-health v2, el cual cuenta con distintos sensores fisiológicos. Los que se utilizaron fueron el ECG y GSR que ya tiene incluido. Para usar esta placa se tuvieron que leer las configuraciones e indicaciones del fabricante, puesto que se debía conocer la posición de los electrodos tanto del sensor ECG como del sensor GSR. La siguiente figura 23 muestra la conexión de los electrodos a la placa de e-health para usar el sensor de ECG.




Figura 23. Sensor ECG (e-health, 2019)




Figura 24. Conexión de electrodos de ECG en e-health (e-health, 2019)

La siguiente figura 25 muestra el posicionamiento de los electrodos en el pecho de una persona, de acuerdo al estado del arte el electrodo negativo debe ir debajo del corazón, es decir, del lado izquierdo.




Figura 25. Posicionamiento de electrodos de ECG

La siguiente figura 26 muestra la conexión de los electrodos con la placa:




Figura 26. Sensor GSR (e-health, 2019)

La siguiente figura 27 muestra el posicionamiento de los electrodos del sensor GSR en los dedos de la mano.




Figura 27. Posicionamiento de electrodo de GSR en e-health (e-health, 2019)

En esta plataforma a pesar de que las conexiones de los electrodos se hacen también con cable, la ventaja es que se fijan mediante unos pequeños tornillos (véase la figura 24), es por esto los cables están fijos a la placa y la información se graba de forma confiable y constante. En las siguientes figuras 28 y 29 se muestran señales grabadas con este sensor y se observa que en ningún momento el valor se vuelve 0




Figura 28. Señal de GSR grabada con e-health




Figura 29. Señal de ECG grabada con e-health

Debido a que esta plataforma en las primeras pruebas era constante en los valores que reflejaba, se optó por experimentar con ella y compararla con la del arduino UNO, esta actividad se realizó más adelante en las pruebas ya del sistema completo, incluyéndolos en UXLab.

4.2.5 Arduino Linkit One

De acuerdo con las pruebas realizadas con esta placa, los resultados que se obtuvieron con las lecturas de los sensores fueron bastante similares a los del Arduino. Se probó conectando los sensores directamente a la placa. La siguiente figura muestra la conexión del sensor ECG directamente a la placa de Link it One.



Figura 30. Sensor ECG conectado a placa Linkit One

En el caso del sensor GSR se debe de hacer un ajuste en sus valores. Lo que pasa es que en la programación de la lectura de la señal del sensor GSR, se tiene que hacer un mapeo del voltaje obtenido, este mapeo de valores la placa Arduino UNO ya lo hace en un procesamiento interno, pero la Linkit One no. En la siguiente imagen se muestra el mapeo que se hizo para ajustar los valores.

```
valor = map(valor, 0, 59, 0, 1023);
```

Figura 31. Mapeo de valores en Linkit One

De la operación anterior básicamente se hace una transformación a los datos de 0 al máximo valor que se obtenía de la señal a un espacio de 0 a 1023, esto para poder realizar un mejor análisis de la señal del sensor.

Si bien en cuanto al resultado de los archivos generados las lecturas son semejantes del Linkit One con el Arduino UNO, las grandes ventajas de usar la Linkit One incluyen que tiene otros medios de conexión con una computadora, se le puede agregar una memoria micro sd para almacenamiento interno y cuenta con su propia batería para no estar conectado a una computadora. Dentro de las pruebas que se hicieron, se hizo el envío de información mediante WiFi y el almacenamiento de lecturas de los sensores en un archivo dentro de una memoria micro Sd. En la siguiente figura se muestra la obtención de datos recuperados de la Linkit One mediante Wi-Fi.



Figura 32. Prueba de conexión mediante Wifi de Linkit One

Para ver u obtener el archivo que se generó, es necesario conectar la placa Link it One a una computadora y habilitar un switch en la placa para que se reconozca la memoria sd. A continuación, en la siguiente figura 33 se puede observar cómo queda almacenado un archivo de grabación en una memoria micro sd que se conecta a la placa Link it One y a la derecha el switch que se debe habilitar en el modo (MS) para que se reconozca la memoria sd de la placa.




Figura 33. Guardado de archivos en Linkit One y switch de memoria sd

A pesar de que la Link it One brinda otras opciones de comunicación y sus resultados son similares a los de Arduino UNO, una de las desventajas que se encontró fue la incompatibilidad de Link it One con Grove, por lo que se tenía el problema de estar ajustando los valores de los sensores mediante código y de nuevo la alta sensibilidad de conectar los sensores solo con cables. Quizá si se pueda adaptar en un futuro el desarrollo de esta placa con más sensores, pero debido al tiempo del desarrollo de la investigación, se optó por no realizar más pruebas con esta placa.

4.2.6 Sensores Xbee

Esta alternativa usa sensores de radiofrecuencia para transmitir la información de diferentes dispositivos.

Se probó el sensor ECG con Xbee, pero a pesar de que si se logra la comunicación de forma inalámbrica, los valores que se obtienen no corresponden con un valor que indique el ritmo cardiaco o pulso de una persona, esto debido a que los sensores Xbee no están adaptados para manejar el estándar I2C.



Figura 34. Comunicación de sensores Xbee y sensor ECG

Los valores del sensor deberían de ir entre 50-180, pero lo que mostraba solamente era un 1023 o un 0. Y esto se debe. A que el sensor Xbee sin alguna placa Arduino es incapaz de procesar bien la información de los sensores. Con esta alternativa valdría la pena investigar más a fondo como hacer la compatibilidad de usar esta tecnología con alguna placa como Arduino o Link it One.

A pesar de que al final no se usó esta alternativa de comunicación, se diseñó una variante del prototipo se muestra en la siguiente figura 35, la cual consiste en sustituir la conexión de la placa Grove y el Arduino por dos sensores Xbee y dos placas Grove Xbee.

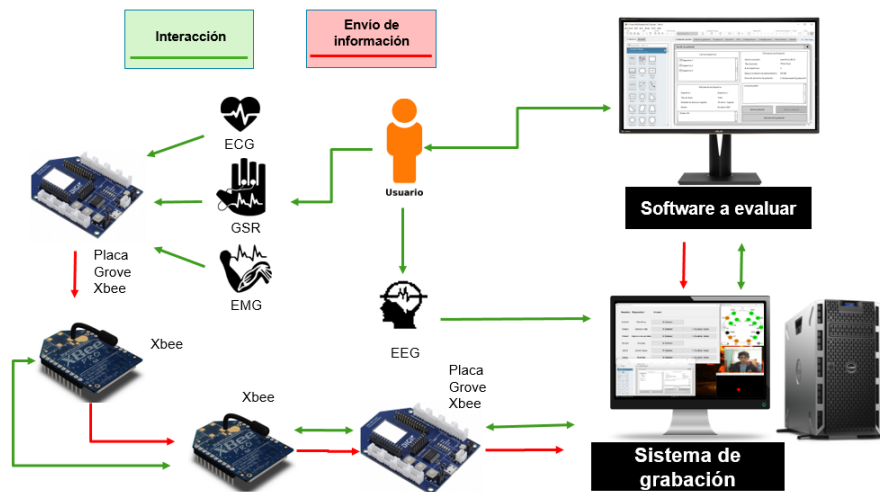


Figura 35. Arquitectura de adquisición de datos con Xbee

4.3 Definición de pasos para el análisis emocional

Los pasos se definieron conforme la investigación fue avanzando, ya que, al inicio lo único que se tenía claro era que se necesitaba grabar la información de los sensores y procesarla. Sin embargo, los pasos para realizar un análisis emocional no se tenían definidos, tampoco se sabía la forma en que la información se procesa. Lo que se hizo fue tomar de referencia otros estudios relacionales del estado del arte, donde lo que hacían era precisamente inducir alguna emoción y grabar la información de algún sensor fisiológico mientras se realizaba alguna prueba, para luego aplicar un procesamiento a las señales obtenidas.

A partir de la comprensión del estado del arte se definieron los pasos mostrados en la figura 36 para realizar un análisis emocional:

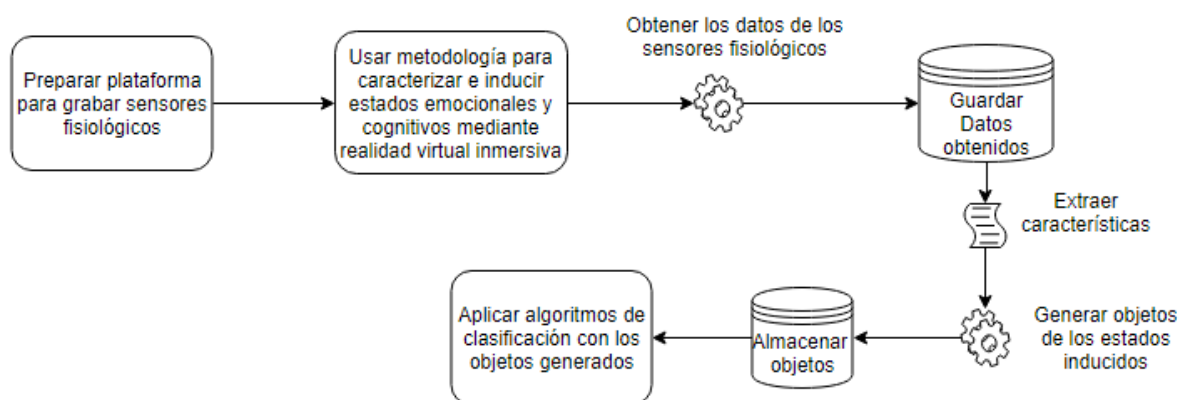


Figura 36. Diagrama para obtener muestras y hacer la clasificación

Para realizar las pruebas fue necesario contar con una metodología de inducción de emociones, con la cual se experimentó usando imágenes de un estado **neutro, alegría y tristeza** a través de realidad virtual inmersiva.

La prueba consistía básicamente en grabar la información fisiológica del usuario a través de los sensores mientras experimentaba una inducción con alguna de las emociones antes mencionadas.

En la siguiente figura 37 se pueden ver los pasos en los que consiste la metodología:

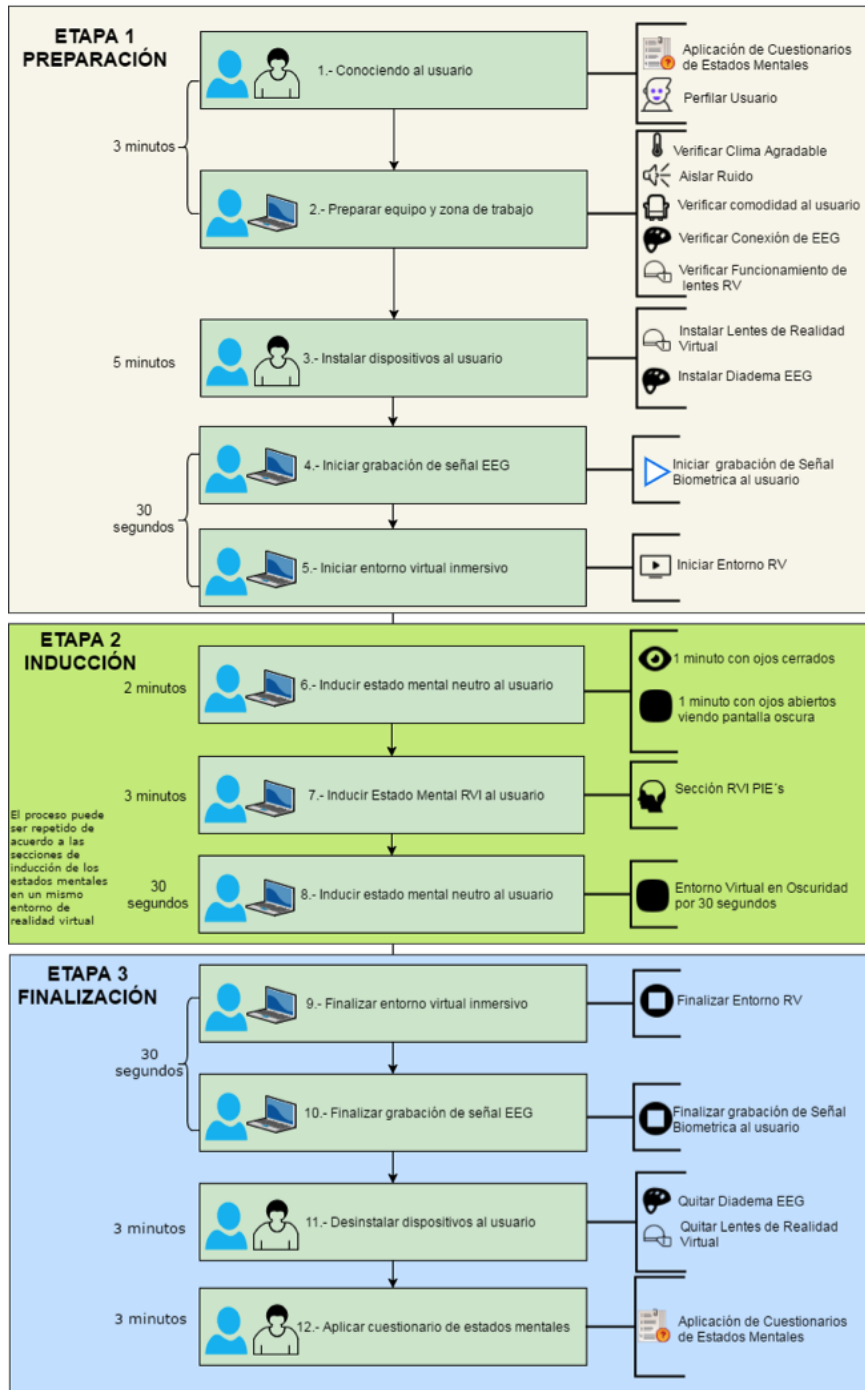


Figura 37. Metodología para caracterizar e inducir estados mentales a través de realidad virtual inmersiva e interfaz cerebro computadora. (Jeovanny Soriano, 2018).

4.4 Desarrollo de sistema prototipo

Esta actividad consistió en desarrollar módulos de grabación y reproducción de los sensores fisiológicos en el sistema UXLab.

4.4.1 Sistema de grabación de UXLab

Para el desarrollo del grabador de UXLab se tomó en cuenta la integración de diferentes módulos que permitieran adquirir y grabar la información de audio, video y de los sensores fisiológicos que se utilizan durante una evaluación. Ya se contaba con una versión que grababa y sincronizaba audio y video de un trabajo de maestría anterior (Fouilloux, 2017). Lo que se hizo fue agregar los módulos para grabar y sincronizar la información de sensores de electrocardiograma, electroencefalograma y de respuesta galvánica de la piel. La figura 38 muestra la arquitectura y los componentes de la plataforma de grabación.

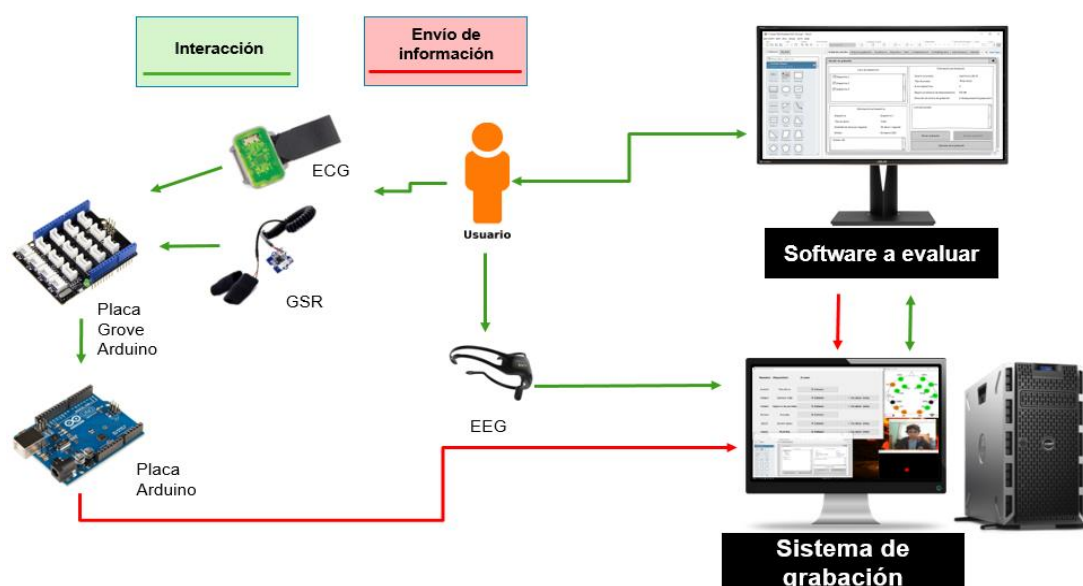


Figura 38. Plataforma de grabación con Grove y Emotive Insight

Las figuras 39 y 40 muestran la interfaz de usuario del grabador de UXLab. A través de esta interfaz es que se logra manipular los flujos de los diferentes dispositivos y sensores, además de que el programa se encarga de procesar y sincronizar las señales.



Figura 39. Interfaz gráfica del módulo de dispositivos

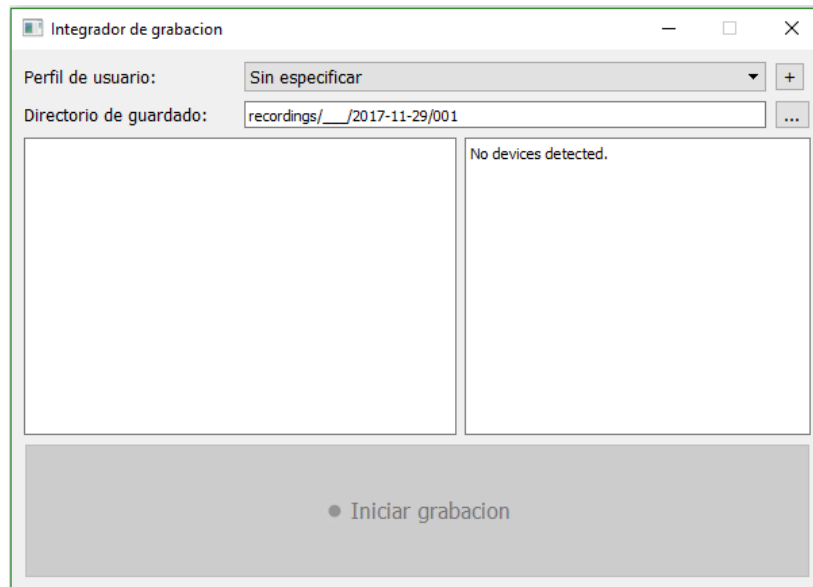


Figura 40. Interfaz del módulo de integración

4.4.2 Sistema de reproducción de UXLab

Para el desarrollo del reproductor UXLab, se revisaron varias grabaciones para definir la forma en cómo se podía analizar la información. En este módulo se implementaron varias mejoras a un programa de reproducción hecho anteriormente también en el trabajo de

maestría donde se hizo el grabador de UXLab (Fouilloux, 2017). Esto para el que el usuario que lo utilice sea capaz de ver las diferentes señales en pantalla, así como las grabaciones de video realizadas en la evaluación. La figura 41 muestra la interfaz del reproductor UXLab.

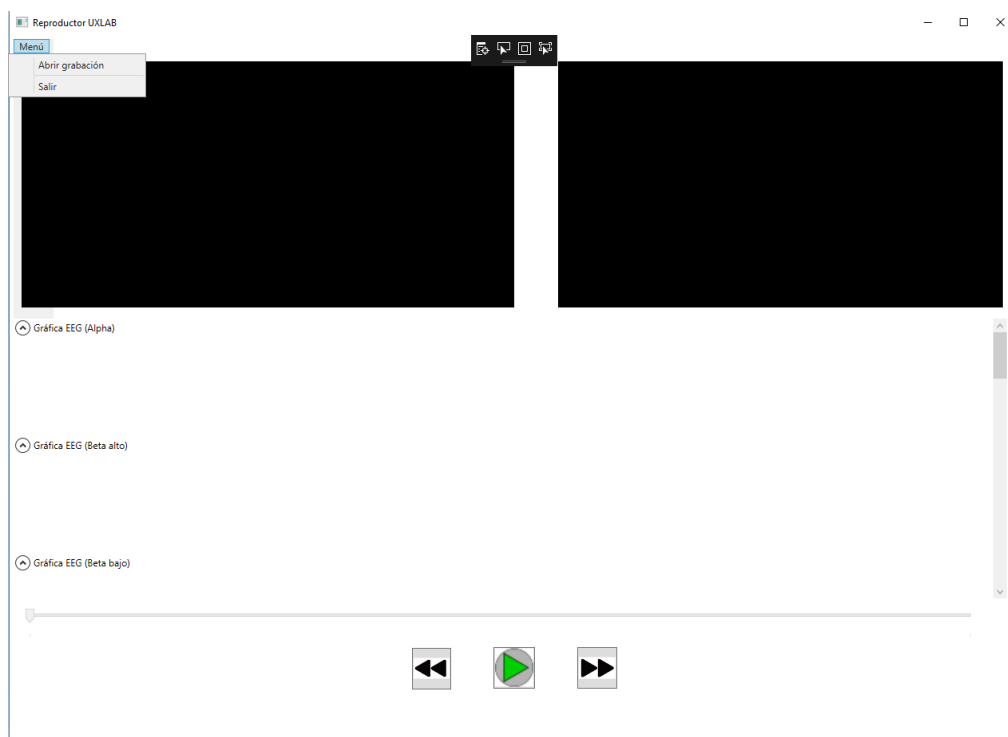


Figura 41. Interfaz del reproductor de UXLab

4.5 Definición del plan de pruebas

Para el plan de pruebas se decidió utilizar un formato de tabla para poder analizar los resultados de la clasificación de los algoritmos utilizados. La tabla muestra el porcentaje de clasificación correcta de forma total y también lo resultados obtenidos por clase o emoción. El formato de tabla es el siguiente:

Tabla 3. Descripción de las columnas de la tabla de plan de pruebas

Columna	Descripción
Algoritmo de clasificación	En esta columna se coloca el algoritmo de clasificación utilizado.
Porcentaje de clasificación	Indica el porcentaje de clasificación correcto obtenido del clasificador.
Alegría	En esta columna se colocan los valores de recuperación, precisión y exactitud de esta emoción obtenidos con el clasificador correspondiente.

Neutro	En esta columna se colocan los valores de recuperación, precisión y exactitud de esta emoción obtenidos con el clasificador correspondiente.
Tristeza	En esta columna se colocan los valores de recuperación, precisión y exactitud de esta emoción obtenidos con el clasificador correspondiente.

Con las muestras que se obtuvieron de las grabaciones se decidió clasificarlas de cuatro maneras diferentes. A continuación, se describe cada una de ellas:

- Clasificación aplicando filtro de paso banda a las señales y usando el 100% de muestras como conjunto de aprendizaje y como conjunto de prueba.
- Clasificación sin filtros en las señales y usando el 100% de muestras como conjunto de aprendizaje y como conjunto de prueba.
- Clasificación aplicando filtro de paso banda a las señales usando el 66.67% del total de muestras como conjunto de aprendizaje y el 33.33% como conjunto de prueba.
- Clasificación sin filtros en las señales usando el 66.67% del total de muestras como conjunto de aprendizaje y el 33.33% conjunto de prueba.

Al final se comparan todas las clasificaciones para poder determinar que algoritmos clasifican mejor y bajo qué condiciones.

4.6 Realización de pruebas del sistema

Esta versión del sistema fue probada varias veces antes de las pruebas finales, a continuación, se muestra una tabla con pruebas preliminares que muestran el comportamiento del sistema. En estas pruebas se tomaron en cuenta las plataformas de Arduino Grove y MySignals (Ambos fueron integrados a UXLab). La razón de realizar estas pruebas fue para encontrar la plataforma de sensores más estable para las pruebas finales. Cada prueba tomaba alrededor de una hora en realizarse, y algunas veces las pruebas se tenían que desechar porque se contaminaban con ruido o el sistema dejaba de funcionar y la información no se guardaba de forma correcta.

La tabla 4 muestra los resultados que se obtuvieron al comparar la plataforma de Arduino Grove contra la de MySignals. Esta prueba fue realizada dos veces a cinco personas con las dos plataformas.

Tabla 4. Comparativa de Arduino Grove vs MySignals

Prueba Sensor	/	GSR Grove	GSR MySignals	ECG Grove	ECG MySignals
Usuario 1 - P1		Sí grabó	Sí grabó	Sí grabó	Sí grabó

Usuario 1 - P2	Sí grabó	Sí grabó	Sí grabó	Sí grabó
Usuario 2 - P1	Sí grabó	No grabó	Sí grabó	Sí grabó
Usuario 2 - P2	Sí grabó	No grabó	Sí grabó	No grabó
Usuario 3 - P1	Sí grabó	Sí grabó	Sí grabó	Sí grabó
Usuario 3 - P2	Sí grabó	Sí grabó	Sí grabó	Sí grabó
Usuario 4 - P1	Sí grabó	Sí grabó	Sí grabó	Sí grabó
Usuario 4 - P2	Sí grabó	No grabó	Sí grabó	Sí grabó
Usuario 5 - P1	Sí grabó	No grabó	Sí grabó	No grabó
Usuario 5 - P2	Sí grabó	Sí grabó	Sí grabó	Sí grabó

Como se puede apreciar en la tabla 4, la plataforma MySignals fue más inestable que la plataforma de Grove, por eso es que se tomó la decisión de usar la opción que ocasionara menos errores al momento de grabar. Con la plataforma de Arduino la información siempre se guardó de forma correcta y el sistema UXLab funcionó de forma estable. Debido a que el tiempo de cada prueba tomaba una hora, para minimizar el porcentaje de pruebas erróneas se decidió no utilizar la plataforma de MySignals para las pruebas finales.

4.7 Definición y corrección de errores

Cuando se está realizando una grabación, es posible ver la información de los sensores fisiológicos y los otros dispositivos. Esto sirve para verificar que todos los valores se estén recibiendo de forma correcta, así como también para monitorear el estado del usuario que está realizando alguna prueba. En esta parte, se corrigieron las gráficas porque a veces no se mostraba la información correcta de los sensores. La figura 42 muestra una pantalla con las gráficas, animaciones y las capturas de videos que se pueden ver con la información de los sensores.

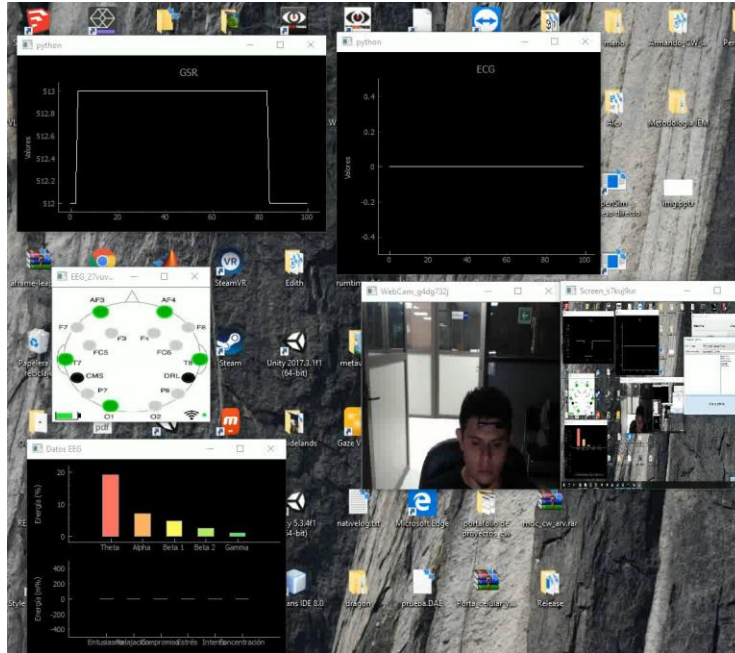


Figura 42. Ejemplo de grabación con UXLab

Dentro de las correcciones que se le hicieron al reproductor, se incluyeron controles para poder avanzar o retroceder en la reproducción, la sincronización de todas las señales grabadas y un menú para poder abrir nuevas reproducciones o salir del programa. Esto porque la interfaz no era muy amigable y no se tenía mucho control en la reproducción. A continuación, se muestran en las figuras de la 43 a la 45 la forma en que se visualiza una reproducción con el programa.

La acción que se está realizando en esta figura es la de seleccionar una carpeta que contiene la información de diferentes señales previamente grabadas con UXLab.

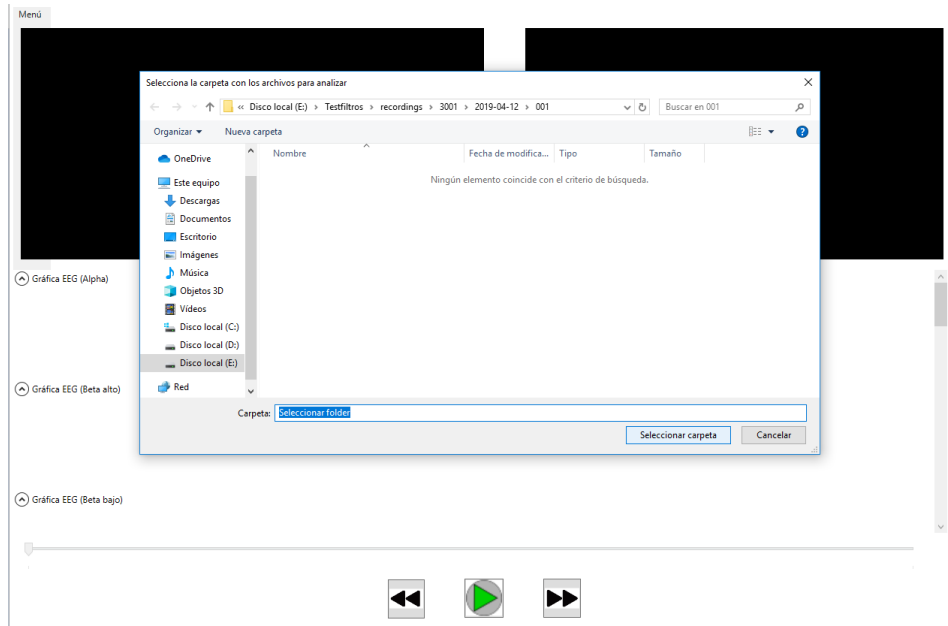


Figura 43. Selección de carpeta para reproducción

En la figura 24 se muestra que en las gráficas de las señales hay una línea negra en todas, la cual indica el tiempo de reproducción y refleja la sincronización de las señales.

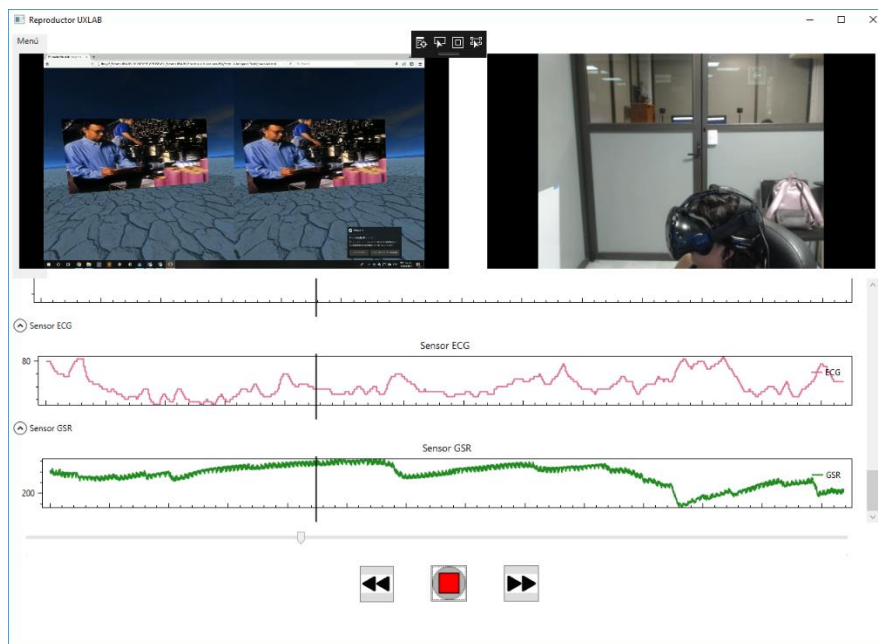


Figura 44. Visualización de información de señales GSR, ECG y de video

Finalmente, en la figura 45, las gráficas que se ven son de información electroencefalografía, dando a entender que en el sistema se pueden ver tanto las gráficas de GSR y ECG como también las de EEG.

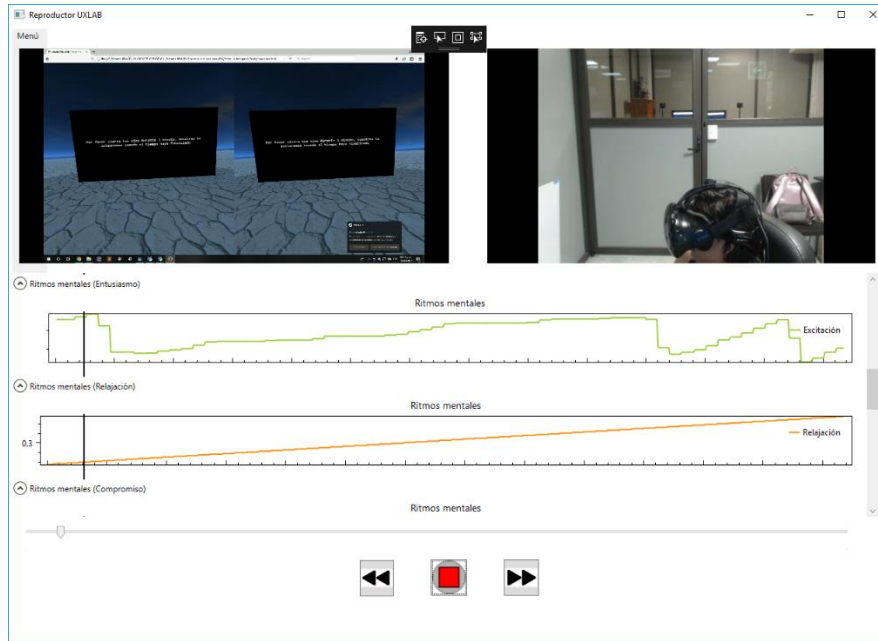


Figura 45. Visualización de información de señales EEG

4.8 Análisis de resultados

En el análisis de resultados se procesan los datos obtenidos de las inducciones emocionales, extrayendo características de las señales, aplicando filtros y algoritmos de clasificación para identificar el estado emocional. Se muestran diferentes tablas con las diferentes pruebas que se hicieron, así como los porcentajes de clasificación correcta en cada clasificador. En el capítulo 6 se detalla toda esta etapa de la metodología.

Capítulo 5.

Pruebas finales

y análisis de

resultados

Este capítulo trata del análisis de los resultados obtenidos en las pruebas finales de las clasificaciones realizadas a las inducciones de los estados emocionales de alegría, tristeza y un estado neutro. Los algoritmos que se utilizaron fueron el de Vecinos más cercanos, Maquinas de vector soporte y Naive Bayes.

5.1 Descripción de las pruebas finales

Para las pruebas finales se realizaron treinta inducciones emocionales usando estímulos de alegría, tristeza y un estado neutro. Se grabó la información de las señales EEG, GSR y ECG a una frecuencia de 33 muestras por segundo. En el estado del arte los sensores se suelen grabar a una frecuencia superior a las 100 muestras por segundo, sin embargo, si se usaba esta configuración en UXLab a veces el programa no guardaba la información de forma correcta y los archivos se corrompían, la cantidad más estable para grabar varios sensores al mismo tiempo es la de 33 y fue por eso que se grabó con esta frecuencia. La plataforma que se usó fue la de Arduino Grove y la diadema Emotive Insight. Para la clasificación se usaron los algoritmos de Vecinos más cercanos (KNN), Máquinas de vector soporte (SVM) y Naive Bayes. Los clasificadores se ejecutaron cuatro veces, dos aplicando el filtro de paso banda a las muestras y dos sin aplicar el filtro a las muestras. Dentro de cada prueba se hizo un entrenamiento al algoritmo con 20 muestras y 10 se usaron de prueba y en otra ocasión se entrenó con las 30 muestras y luego se probaron de nuevo las mismas 30. De acuerdo a otros estudios por lo regular se usa un 70% de muestras como aprendizaje y un 30% como muestras de prueba, por lo que se trató de usar un porcentaje similar, en este caso fue un 66.67% de muestras de aprendizaje y un 33.33% de pruebas.

5.2 Extracción de características

Las características que se extrajeron se muestran en la tabla 5.

Tabla 5. Características extraídas de cada señal

Sensor	Características
Respuesta galvánica de la piel	(8) Media, Mediana, Desviación estándar, Varianza, Correlación, Covarianza, Curtosis Sesgo.
Electrocardiograma	(8) Media, Mediana, Desviación estándar, Varianza, Correlación, Covarianza, Curtosis Sesgo.
Electroencefalograma	(40) Media, Mediana, Desviación estándar, Varianza, Correlación, Covarianza, Curtosis Sesgo de las ondas Alfa, Beta alto, Beta Bajo, Gamma y Theta.

5.3 Pruebas con clasificadores

A continuación, se muestran los mejores resultados de precisión, recuperación y exactitud obtenidos con cada clasificador usando las características mencionadas, así como la configuración del clasificador.

Fórmulas.

El valor de exactitud (E) se calcula con la siguiente fórmula:

$$Exactitud = \frac{VP + VN}{VP + VN + FP + FN} \quad (\text{Fórmula 1})$$

El valor de precisión (P) se representa con la siguiente fórmula:

$$Precisión = \frac{VP}{VP + FP} \quad (\text{Fórmula 2})$$

El valor de recuperación (R) se representa con la siguiente fórmula:

$$Recuperación = \frac{VP}{VP + FN} \quad (\text{Fórmula 3})$$

Configuración de los clasificadores

Para realizar la clasificación de las muestras se usó el programa WEKA, en el cual se probaron diferentes configuraciones de los clasificadores, sin embargo, en este documento de tesis solo se muestran las combinaciones en las que se obtuvo un mayor porcentaje de éxito en la clasificación. En los siguientes párrafos se muestra la configuración que se usó en cada clasificador.

Naive Bayes sin kernel de estimación: El kernel es una función de ponderación que se usa en técnicas de estimación no paramétricas, en este caso no se hace uso de estas funciones.

SVM usando polyKernel, con $c=1.0$: El polyKernel se refiere a una función que usa las características y combinaciones de las mismas características para realizar la comparación entre la similitud de los objetos. La variable 'c' es un parámetro que indica que tanto se quiere evitar una mala clasificación usando el algoritmo SVM. Entre más pequeño sea el valor, más se forzaría el clasificador a equivocarse.

KNN con búsqueda lineal y una variable $K=4$: La búsqueda lineal es un método para encontrar un valor dentro de una lista, esto lo realiza comparando los valores de forma secuencial hasta que el valor es encontrado o todos los elementos de la lista son comparados. La variable K que se usa en el algoritmo KNN se usa para definir con cuantos objetos cercanos se quiere realizar la comparación del objeto actual.

En si lo único que cambia entre clasificar aplicando un filtro o no, es que en las SVM se varió un poco el valor de la variable 'c' y en el KNN fue el valor de 'K'.

Configuración de filtro de paso banda

Para la aplicación del filtro de paso banda se usó una librería de Python, en estas pruebas se aplicó la configuración por defecto que se encontró en la documentación del filtro. Básicamente la función que ejecuta el filtro necesita de algunos parámetros y es la siguiente: butter (order, [low, high], btype='band'). A continuación, se detalla que significa cada uno de los parámetros.

Order: Define el grado de aceptación o rechazo de una frecuencia con respecto a la frecuencia de corte. Para la aplicación en las pruebas se dejó un valor de orden=2.

[low,high]: Este parámetro define cual es el rango de valores que debe dejar pasar el filtro de los valores de las frecuencias de la señal. Para el procesamiento en las pruebas se optó por dejar la configuración por defecto de la función los cuales son 0.2 en low y 5 en high. Por lo regular estos dos números de low y high se calculan a partir de la frecuencia original a la que se encuentra la señal. Generalmente su valor se calcula de la siguiente forma:

$$low = \frac{1}{\text{Raíz cuadrada de } F_n} \quad (\text{Fórmula 4})$$

$$high = low * N \quad (\text{Fórmula 5})$$

dónde: F_n = la mitad de la frecuencia original y N = un número escalar aleatorio.

Lo que se busca con estos valores es definir precisamente un rango. Si bien los valores se pueden cambiar, aunque no se usen de forma forzosa las fórmulas, hay una regla que se debe de respetar para obtener valores confiables y esa es que el valor de high siempre debe ser mayor que low.

Btype: Indica que tipo de filtro se va a usar en el procesamiento, esto debido a que con esta función en python se pueden usar otros aparte del de paso banda que funcionan diferente.

5.3.1 Pruebas de los clasificadores sin aplicar filtro.

Naive Bayes sin kernel de estimación.

SVM usando polyKernel, con $c=1.0$.

KNN con búsqueda lineal y una variable $K=4$.

Tabla 6. Pruebas sin filtros con conjunto_Aprendizaje= 20 y conjunto_Prueba=10

Algoritmo/Clase y resultados	Porcentaje de clasificación correcta	Alegría	Neutro	Tristeza
Naive Bayes	30%	P=0.333	P=0.333	P=0
		R=0.667	R=0.25	R=0
		E=0.5	E=0.5	E=0.6
SVM	40%	P=0.4	P=0.3333	P=0.5
		R=0.6666	R=0.25	R=0.3333
		E=0.6	E=0.5	E=0.7
KNN	50%	P=0.4	P=0.75	P=0
		R=0.667	R=0.75	R=0
		E=0.6	E=0.8	E=0.6

Tabla 7. Pruebas sin filtros con conjunto_Aprendizaje= 30 y conjunto_Prueba=30

Algoritmo/Clase y resultados	Porcentaje de clasificación correcta	Alegría	Neutro	Tristeza
Naive Bayes	53.3333%	P=0.5	P=0.6	P=0.571
		R=0.9	R=0.2733	R=0.4444
		E=0.6	E=0.6666	E=0.7333
SVM	80%	P=0.6923	P=1	P=0.8
		R=0.9	R=0.6363	R=0.8889
		E=0.8333	E=0.8667	E=0.9
KNN	100%	P=1	P=1	P=1
		R=1	R=1	R=1
		E=1	E=1	E=1

5.3.2 Pruebas de los clasificadores aplicando filtro de paso banda.

Naive Bayes sin kernel de estimación: El kernel es una función de ponderación que se usa en técnicas de estimación no paramétricas, en este caso no se hace uso de estas funciones.

SVM usando polyKernel con $c=2.0$:

KNN con búsqueda lineal y una variable $K=4$:

Tabla 8. Pruebas con filtros con conjunto_Aprendizaje= 20 y conjunto_Prueba=10

Algoritmo/Clase y resultados	Porcentaje de clasificación correcta	Alegría	Neutro	Tristeza
Naive Bayes	30%	P=0.25	P=1	P=0
		R=0.6667	R=0.25	R=0
		E=0.3	E=0.7	E=0.6
SVM	40%	P=0.3333	P=0.429	P=Na
		R=0.333	R=0.750	R=0
		E=0.6	E=0.5	E=0.7
KNN	30%	P=0.286	P=0.3333	P=Na
		R=0.6667	R=0.3333	R=0
		E=0.4	E=0.5	E=0.7

Tabla 9. Pruebas con filtros y con conjunto_Aprendizaje = 30 y conjunto_Prueba =30

Algoritmo/Clase y resultados	Porcentaje de clasificación correcta	Alegría	Neutro	Tristeza
Naive Bayes	70%	P=0.526	P=1	P=1
		R=1	R=0.636	R=0.444
		E=0.7	E=0.8666	E=0.8333
SVM	60%	P=0.455	P=1	P=1
		R=1	R=0.364	R=0.444
		E=0.6	E=0.7666	E=0.8333
KNN	100%	P=1	P=1	P=1
		R=1	R=1	R=1
		E=1	E=1	E=1

5.4 Comparación de los resultados de los clasificadores

En la figura 26 se muestra una comparativa del desempeño de los clasificadores con sus mejores resultados con las diferentes muestras procesadas.




Figura 46. Desempeño de los clasificadores

5.4.1 Análisis de resultados

- Se puede observar que los algoritmos mejoran el porcentaje de clasificación cuando se entrenan y prueban con un mayor número de muestras.
- También se puede notar que el algoritmo de Naive Bayes mejoró su clasificación al aplicar filtros (Véase la figura 17 en la columna Naive Bayes_30_SF contra la de Naive Bayes_30_F).
- Por otro lado, la clasificación realizada por SVM al aplicar los filtros se redujo de un 80% a un 60%.
- El clasificador KNN pareciera obtener un 100% siempre que se usen todas las muestras en la clasificación, pero al obtener porcentajes bajos al dividir las muestras en la clasificación (es decir, tomar 20 de aprendizaje y 10 de prueba), hace que no sea tan confiable y estable.

5.5 Selección de variables/características

Adicional a la clasificación también se había realizado la selección de variables con varios métodos, pero en los resultados quedaban muy pocas variables para procesar y analizar un cambio significativo. Por eso se decidió usar en la clasificación a todo el conjunto de características extraídas de las señales. Este proceso puede ser llamado de ambas formas

selección de variables o características, y consiste en seleccionar un subconjunto de características que mejor describan a las clases o tipos de diferentes objetos.

A continuación, se muestran los resultados obtenidos de dos pruebas que se hicieron usando métodos de selección de variables. Estas pruebas fueron realizadas en Weka y los dos métodos que se probaron coincidieron en que las mejores variables que mejor describen a los objetos son las características de: Desviación estándar GSR, Desviación estándar ECG y la Varianza ECG.

El método CfsSubsetEval + Bestfirst, busca en el espacio de los subconjuntos de variables mediante una escalada codiciosa y aumentada con una función de retroceso. Prefiere los subconjuntos de características que están altamente correlacionados con un objeto. Controla el número de nodos consecutivos no mejorados permitidos y el nivel de retroceso realizado. Este método puede comenzar con el conjunto vacío de variables y buscar hacia adelante, o comenzar con el conjunto completo de variables y buscar hacia atrás, o comenzar en cualquier punto y buscar en ambas direcciones (considerando todas las posibles adiciones y eliminaciones de variables individuales en un punto dado). (Weka, 2019)

La única diferencia de este método con el greedy stepwise es la función de retroceso en bestfirst. La figura 27 muestra la selección de variables usando el método de CfsSubsetEval combinado con el Bestfirst.

```
Evaluation mode:    evaluate on all training data

=== Attribute Selection on all input data ===

Search Method:
  Best first.
  Start set: no attributes
  Search direction: forward
  Stale search after 5 node expansions
  Total number of subsets evaluated: 430
  Merit of best subset found:    0.462

Attribute Subset Evaluator (supervised, Class (nominal): 57 Clase):
  CFS Subset Evaluator
  Including locally predictive attributes

Selected attributes: 3,11,12 : 3
                    DesviacionGSR
                    DesviacionECG
                    VarianzaECG
```

Figura 47. Selección de variables con CfsSubsetEval + Bestfirst

El método CfsSubsetEval + GreedyStepwise realiza una búsqueda codiciosa hacia adelante o hacia atrás a través del espacio de subconjuntos de atributos. Puede comenzar con ningún o todos los atributos o desde un punto arbitrario en el espacio. Se detiene cuando la

adición o eliminación de cualquier atributo restante da como resultado una disminución en la evaluación. También puede generar una lista ordenada de atributos al recorrer el espacio de un lado a otro y registrar el orden en que se seleccionan los atributos.

La figura 28 muestra muestra la selección de variables usando el método de CfsSubsetEval combinado con el GreedyStepwise.

```
=== Attribute Selection on all input data ===  
  
Search Method:  
  Greedy Stepwise (forwards).  
  Start set: no attributes  
  Merit of best subset found: 0.462  
  
Attribute Subset Evaluator (supervised, Class (nominal): 57 Clase):  
  CFS Subset Evaluator  
  Including locally predictive attributes  
  
Selected attributes: 3,11,12 : 3  
  DesviacionGSR  
  DesviacionECG  
  VarianzaECG
```

Figura 48. Selección de variables con CfsSubsetEval + GreedyStepwise

Capítulo 6.

Conclusiones y trabajos futuros

En este capítulo se presentan las conclusiones a las que se llegaron y las aportaciones obtenidas como resultado de esta investigación, además, se sugieren algunos trabajos futuros para dar continuidad a la investigación.

6.1 Conclusiones

Existen muchos factores que influyen y se pueden mejorar durante el análisis emocional de una persona. El sistema UXLab prueba tener buenos y satisfactorios resultados con los sensores que usa y los algoritmos probados.

Se pueden diseñar muchos otros escenarios para seguir probando el sistema y crear comparativas con los resultados sobre la correcta clasificación de las emociones. Por ejemplo, agregar más emociones en la inducción, probar otros filtros de señales en el procesamiento de la información, incluir otras plataformas de sensores fisiológicos o probar otros algoritmos de clasificación.

Este tema de investigación se puede relacionar fácilmente con otras áreas como la psicología, el marketing, computo afectivo y el internet de las cosas. Por lo que se puede utilizar para diseñar experimentos en esas áreas.

6.2 Aportaciones

Las principales aportaciones de este trabajo de tesis son:

1. Módulos dentro del sistema UXLab que permiten la grabación y sincronización de señales EEG, ECG y GSR. Se permite la conexión de las versiones Emotiv epoc y Emotiv insight de las diademas EEG. También la conexión de dos diferentes kits de sensores fisiológicos, uno que es el conformado por Arduino con un sistema Grove y de Arduino con el kit de MySignals e-health v2.0.
2. Mejoras en el sistema UXLab en la versión de reproducción. Con la versión que se obtuvo es posible analizar grabaciones de distintos dispositivos de forma sincronizada. De esta forma se pueden encontrar relaciones entre las distintas señales de acuerdo al transcurso del tiempo.
3. Un script que permite la extracción de características de las señales EEG, ECG y GSR. Este script también es flexible para probar la aplicación de distintos filtros a las señales, como puede ser de paso banda, paso bajo, paso alto o incluso agregar otros.

6.3 Trabajos futuros

Para trabajos futuros se propone:

1. Incrementar las características extraídas de cada sensor fisiológico y ejecutar pruebas con algoritmos de selección de variables. Esto serviría para ver si algunos de los datos clasifican mejor una emoción. Además de que no todos los trabajos relacionados con el análisis emocional lo incluyen.

2. Realizar más pruebas incrementando el número de usuarios e incluir otros clasificadores como Árboles de decisión, AdaBoost, etcétera.
3. Probar con otros kits de sensores fisiológicos como los SHIMMER u otros kits de MySignals. Con estos kits algunas veces ya se cuenta con la aplicación de filtros en la señal y esto ayudaría a explorar más aspectos e el análisis de emociones.
4. El trabajo de investigación se puede comparar contra más investigaciones relacionadas al tema que sean nuevas e incluyan aspectos nuevos o diferentes. Esto con la finalidad de tomar otros puntos de referencia y también así poder seguir ampliando las experimentaciones que se pueden realizar con que ya se ha obtenido.

Referencias

- Daniela Girardi, Filippo Lanubile, Nicole Novielli (2017). Emotion Detection Using Noninvasive Low Cost Sensors. *ResearchGate*. Recuperado de: <https://www.researchgate.net/publication/319235469> (31 de agosto de 2018).
- David Eduardo Fouilloux Quiroz (2018). *Método para integrar y sincronización de datos EEG y multimedia para su aplicación en un ambiente de evaluación para la experiencia del usuario* (Tesis de maestría). CENIDET, Morelos, México.
- Değer Ayata, Yusuf Yaslan, Mustafa Kamaşak (2016). Emotion Recognition via Random Forest and Galvanic Skin Response: Comparison of Time Based Feature Sets Window Sizes and Wavelet Approaches.). *IEEE*. doi: 10.1109/TIPTEKNO.2016.7863130 Recuperado de: <https://ieeexplore.ieee.org/document/7863130/> (31 de agosto de 2018)
- Ekman, P., Levenson, R. W., and Friesen, W. V. (1983). Autonomic nervous system activity distinguishes among emotions. *Science*, 221 (4616)
- Gustavo Betancourt (2005). Las máquinas de soporte vectorial (SVM's). Recuperado de: https://link.springer.com/chapter/10.1007/978-3-540-74976-9_25 (20 de noviembre de 2019)
- HaiYan Xu, Konstantins N (2015). Subject Independent Affective States Clasiffication Using EEG Signals.*IEEE*. Recuperado de: <https://ieeexplore.ieee.org/document/7418411> (20 de Noviembre de 2019)
- Harry Zang (2004). The Optimality of Naive Bayes. Recuperado de: <https://www.aaai.org/Papers/FLAIRS/2004/Flairs04-097.pdf> (20 de noviembre de 2019)
- IliaShumailov, Hatie Gunes (2017). Computational Analysis of Valence in Virtual Reality Gaming using Lower Arm Electromyograms. *ResearchGate*. Recuperado de: https://www.researchgate.net/publication/320065042_Computational_Analysis_of_Valence_and_Arousal_in_Virtual_Reality_Gaming_using_Lower_Arm_Electromyograms (31 de agosto de 2018)
- Jeovanny Soriano Terrazas (2018). *Metodología para caracterizar e inducir estados mentales a través de realidad virtual inmersiva e interfaz cerebro computadora* (Tesis de maestría). (mayo, 15, 2018). CENIDET, Morelos, México.
- José Laparra Hernández (2008). EMG and GSR signals for evaluating user's perception of different types of ceramic flooring. *ResearchGate*. Recuperado de: https://www.researchgate.net/publication/245095584_EMG_and_GSR_signals_for_ev

- aluating_user's_perception_of_different_types_of_ceramic_flooring (31 de agosto de 2018).
- Mohammad Soleymani, Jeroen Lichtenauer, Thierry Pun, Maya Pantic (2012). A multimodal database for affect recognition and implicit tagging. *IEEE*. Recuperado de: <https://ibug.doc.ic.ac.uk/media/uploads/documents/taffcsi-2010-11-0112-2.pdf> / (18 de diciembre de 2018)
- Nico H. Frijda (1986). The emotions. *Wikipedia*. Recuperado de: [https://es.wikipedia.org/wiki/Valencia_\(psicolog%C3%ADa\)](https://es.wikipedia.org/wiki/Valencia_(psicolog%C3%ADa)) (15 de mayo de 2018)
- Rodríguez, A., Rey, B., Clemente, M., Wrzesien, M., & Alcañiz, M. (2014). Assessing brain activations associated with emotional regulation during virtual reality mood induction procedures. *Elsevier*.
- Stamos Katsigiannis, NaeemRamzan (2018). Dreamer a database for emotion recognition through eeg and ecg signals from Wireless low-cost off the shelf devices. *IEEE*. Recuperado de: <https://ieeexplore.ieee.org/document/7863130/> (18 de diciembre de 2018).
- HYang Song, Jian Huang, Ding Zhou, Hongyuan Zha and C. Lee Giles (2007). The Optimality of Naive Bayes. Recuperado de: <http://revistas.utp.edu.co/index.php/revistaciencia/article/view/6895/4139>(20 de noviembre de 2019)

Anexos

Anexo A) Ejecuciones de clasificadores en Weka

Este anexo se muestra evidencia de las diferentes ejecuciones de Weka con los diferentes archivos y clasificadores. Las figuras de la 49 a la 54 son las ejecuciones sin filtro y las figuras de la 55 a la 60 son las que si tenían los filtros.

Pruebas sin filtros

```

=== Summary ===

Correctly Classified Instances      3          30    %
Incorrectly Classified Instances    7          70    %
Kappa statistic                    -0.0448
Mean absolute error                 0.4667
Root mean squared error             0.6831
Relative absolute error             105.2286 %
Root relative squared error         145.0905 %
Total Number of Instances          10

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
          0,667   0,571   0,333     0,667   0,444     0,089   0,548    0,433    Alegria
          0,000   0,143   0,000     0,000   0,000    -0,218   0,571    0,425    Tristeza
          0,250   0,333   0,333     0,250   0,286    -0,089   0,479    0,450    Neutro
Weighted Avg.   0,300   0,348   0,233     0,300   0,248    -0,074   0,527    0,438

=== Confusion Matrix ===

 a b c  <-- Classified as
 2 0 1 | a = Alegria
 2 0 1 | b = Tristeza
 2 1 1 | c = Neutro

```

Figura 49. Naive Bayes sin estimación K con 20 muestras de aprendizaje y 10 de prueba

```

=== Summary ===

Correctly Classified Instances      4          40   %
Incorrectly Classified Instances    6          60   %
Kappa statistic                    0.1045
Mean absolute error                0.4
Root mean squared error            0.4944
Relative absolute error            90.1961 %
Root relative squared error        105.01 %
Total Number of Instances         10

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
          0,667   0,429   0,400     0,667   0,500     0,218   0,667    0,433    Alegria
          0,333   0,143   0,500     0,333   0,400     0,218   0,595    0,367    Tristeza
          0,250   0,333   0,333     0,250   0,286     -0,089  0,563    0,433    Neutro
Weighted Avg.   0,400   0,305   0,403     0,400   0,384     0,095   0,604    0,413

=== Confusion Matrix ===

a b c  <-- classified as
2 0 1 | a = Alegria
1 1 1 | b = Tristeza
2 1 1 | c = Neutro

```

Figura 50. Figura 15. SVM con $c=1.0$, PolyKernel, 20 muestras de aprendizaje y 10 de prueba.

```

=== Summary ===

Correctly Classified Instances      5          50   %
Incorrectly Classified Instances    5          50   %
Kappa statistic                    0.2424
Mean absolute error                0.4096
Root mean squared error            0.5085
Relative absolute error            92.3607 %
Root relative squared error        108.0105 %
Total Number of Instances         10

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
          0,667   0,429   0,400     0,667   0,500     0,218   0,619    0,592    Alegria
          0,000   0,143   0,000     0,000   0,000     -0,218  0,190    0,257    Tristeza
          0,750   0,167   0,750     0,750   0,750     0,583   0,792    0,813    Neutro
Weighted Avg.   0,500   0,238   0,420     0,500   0,450     0,233   0,560    0,580

=== Confusion Matrix ===

a b c  <-- classified as
2 1 0 | a = Alegria
2 0 1 | b = Tristeza
1 0 3 | c = Neutro

```

Figura 51. KNN con $K=4$, 20 muestras de aprendizaje y 10 de prueba.

```

=== Summary ===

Correctly Classified Instances      16          53.3333 %
Incorrectly Classified Instances    14          46.6667 %
Kappa statistic                    0.3023
Mean absolute error                0.302
Root mean squared error            0.5426
Relative absolute error            68.1543 %
Root relative squared error        115.2977 %
Total Number of Instances          30

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
0,900  0,450  0,500  0,900  0,643  0,433  0,820  0,624  Alegria
0,444  0,143  0,571  0,444  0,500  0,327  0,889  0,789  Tristeza
0,273  0,105  0,600  0,273  0,375  0,217  0,703  0,662  Neutro
Weighted Avg.  0,533  0,231  0,558  0,533  0,502  0,322  0,798  0,687

=== Confusion Matrix ===

a b c  <-- classified as
9 1 0 | a = Alegria
3 4 2 | b = Tristeza
6 2 3 | c = Neutro

```

Figura 52. Naive Bayes sin estimación K con 30 muestras de aprendizaje y las mismas de prueba.

```

=== Summary ===

Correctly Classified Instances      24          80 %
Incorrectly Classified Instances     6          20 %
Kappa statistic                    0.7015
Mean absolute error                0.2815
Root mean squared error            0.3651
Relative absolute error            63.5258 %
Root relative squared error        77.588 %
Total Number of Instances          30

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
0,900  0,200  0,692  0,900  0,783  0,666  0,830  0,656  Alegria
0,889  0,095  0,800  0,889  0,842  0,772  0,884  0,744  Tristeza
0,636  0,000  1,000  0,636  0,778  0,725  0,876  0,803  Neutro
Weighted Avg.  0,800  0,095  0,837  0,800  0,799  0,719  0,863  0,737

=== Confusion Matrix ===

a b c  <-- classified as
9 1 0 | a = Alegria
1 8 0 | b = Tristeza
3 1 7 | c = Neutro

```

Figura 53. SVM con $c=1.0$, PolyKernel, 30 muestras de aprendizaje y las mismas de prueba.

```

=== Summary ===

Correctly Classified Instances      30          100   %
Incorrectly Classified Instances    0           0   %
Kappa statistic                     1
Mean absolute error                 0.0079
Root mean squared error             0.0105
Relative absolute error             1.7799 %
Root relative squared error         2.2229 %
Total Number of Instances          30

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
                1,000   0,000   1,000     1,000   1,000     1,000   1,000    1,000    Alegria
                1,000   0,000   1,000     1,000   1,000     1,000   1,000    1,000    Tristeza
                1,000   0,000   1,000     1,000   1,000     1,000   1,000    1,000    Neutro
Weighted Avg.   1,000   0,000   1,000     1,000   1,000     1,000   1,000    1,000

=== Confusion Matrix ===

 a b c  <-- classified as
10 0 0 | a = Alegria
 0 9 0 | b = Tristeza
 0 0 11| c = Neutro

```

Figura 54. KNN con K=4, 30 muestras de aprendizaje y las mismas de prueba.

Pruebas con filtros

```

=== Summary ===

Correctly Classified Instances      3           30   %
Incorrectly Classified Instances    7           70   %
Kappa statistic                   -0.0145
Mean absolute error                0.4667
Root mean squared error            0.6829
Relative absolute error            105.2288 %
Root relative squared error        145.0394 %
Total Number of Instances          10

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
                0,667   0,857   0,250     0,667   0,364     -0,218   0,452    0,306    Alegria
                0,000   0,143   0,000     0,000   0,000     -0,218   0,619    0,411    Tristeza
                0,250   0,000   1,000     0,250   0,400     0,408    0,542    0,622    Neutro
Weighted Avg.   0,300   0,300   0,475     0,300   0,269     0,032    0,538    0,464

=== Confusion Matrix ===

 a b c  <-- classified as
 2 1 0 | a = Alegria
 3 0 0 | b = Tristeza
 3 0 1 | c = Neutro

```

Figura 55. Naive Bayes sin estimación K con 20 muestras de aprendizaje y 10 de prueba

```

=== Summary ===

Correctly Classified Instances      4          40  %
Incorrectly Classified Instances    6          60  %
Kappa statistic                    0.0476
Mean absolute error                 0.4222
Root mean squared error             0.5235
Relative absolute error             95.207  %
Root relative squared error        111.1923 %
Total Number of Instances          10

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
0,333  0,286  0,333  0,333  0,333  0,048  0,571  0,333  Alegria
0,000  0,000  ?      0,000  ?      ?      0,452  0,283  Tristeza
0,750  0,667  0,429  0,750  0,545  0,089  0,542  0,421  Neutro
Weighted Avg.  0,400  0,352  ?      0,400  ?      ?      0,524  0,354

=== Confusion Matrix ===

a b c  <-- classified as
1 0 2 | a = Alegria
1 0 2 | b = Tristeza
1 0 3 | c = Neutro

```

Figura 56. SVM con $c=2.0$, PolyKernel, 20 muestras de aprendizaje y 10 de prueba

```

=== Summary ===

Correctly Classified Instances      3          30  %
Incorrectly Classified Instances    7          70  %
Kappa statistic                   -0.0448
Mean absolute error                 0.4921
Root mean squared error             0.5594
Relative absolute error             110.9698 %
Root relative squared error        118.8173 %
Total Number of Instances          10

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
0,667  0,714  0,286  0,667  0,400  -0,048  0,286  0,279  Alegria
0,000  0,000  ?      0,000  ?      ?      0,095  0,230  Tristeza
0,250  0,333  0,333  0,250  0,286  -0,089  0,292  0,360  Neutro
Weighted Avg.  0,300  0,348  ?      0,300  ?      ?      0,231  0,296

=== Confusion Matrix ===

a b c  <-- classified as
2 0 1 | a = Alegria
2 0 1 | b = Tristeza
3 0 1 | c = Neutro

```

Figura 57. KNN con $K=4$, 20 muestras de aprendizaje y 10 de prueba


```

=== Summary ===

Correctly Classified Instances      21          70    %
Incorrectly Classified Instances    9           30    %
Kappa statistic                    0.5477
Mean absolute error                 0.1998
Root mean squared error             0.4466
Relative absolute error             45.0814 %
Root relative squared error        94.9048 %
Total Number of Instances          30

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
1,000  0,450  0,526  1,000  0,690  0,538  0,940  0,901  Alegria
0,444  0,000  1,000  0,444  0,615  0,599  0,942  0,899  Tristeza
0,636  0,000  1,000  0,636  0,778  0,725  0,785  0,809  Neutro
Weighted Avg.  0,700  0,150  0,842  0,700  0,700  0,625  0,884  0,867

=== Confusion Matrix ===

 a  b  c  <-- classified as
10  0  0 | a = Alegria
 5  4  0 | b = Tristeza
 4  0  7 | c = Neutro

```

Figura 58. Naive Bayes sin estimación K con 30 muestras de aprendizaje y las mismas de prueba

```

=== Summary ===

Correctly Classified Instances      18          60    %
Incorrectly Classified Instances    12          40    %
Kappa statistic                    0.4
Mean absolute error                 0.3407
Root mean squared error             0.4389
Relative absolute error             76.8997 %
Root relative squared error        93.2492 %
Total Number of Instances          30

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
1,000  0,600  0,455  1,000  0,625  0,426  0,700  0,455  Alegria
0,444  0,000  1,000  0,444  0,615  0,599  0,796  0,678  Tristeza
0,364  0,000  1,000  0,364  0,533  0,515  0,742  0,646  Neutro
Weighted Avg.  0,600  0,200  0,818  0,600  0,589  0,511  0,744  0,592

=== Confusion Matrix ===

 a  b  c  <-- classified as
10  0  0 | a = Alegria
 5  4  0 | b = Tristeza
 7  0  4 | c = Neutro

```

Figura 59. SVM con $c=2.0$, PolyKernel, 30 muestras de aprendizaje y las mismas de prueba

```

=== Summary ===

Correctly Classified Instances      30          100    %
Incorrectly Classified Instances    0           0    %
Kappa statistic                    1
Mean absolute error                0.0176
Root mean squared error            0.0244
Relative absolute error            3.9629 %
Root relative squared error        5.1914 %
Total Number of Instances          30

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
1,000    0,000    1,000     1,000    1,000     1,000    1,000    1,000    Alegria
1,000    0,000    1,000     1,000    1,000     1,000    1,000    1,000    Tristeza
1,000    0,000    1,000     1,000    1,000     1,000    1,000    1,000    Neutro
Weighted Avg.  1,000    0,000    1,000     1,000    1,000     1,000    1,000    1,000

=== Confusion Matrix ===

  a  b  c  <-- classified as
10  0  0 | a = Alegria
 0  9  0 | b = Tristeza
 0  0 11 | c = Neutro

```

Figura 60. KNN con K=4, 30 muestras de aprendizaje y las mismas de prueba

Anexo B

En la figura 26 se puede ver que los valores de GSR y ECG de la plataforma Grove se encuentran en los rangos esperados del sensor. $512 > \text{GSR} > 0$ y $130 > \text{ECG} > 0$.

0.0277949001	01,GSR:373,ECG:79
0.0307751999935	GSR:373,ECG:79
0.0338621999981	GSR:373,ECG:79
0.0368316999957	GSR:373,ECG:79
0.0397861999954	GSR:373,ECG:79
0.0427729999938	GSR:373,ECG:79
0.045778700005	GSR:373,ECG:79
0.0487352000055	GSR:373,ECG:79
0.0517618000013	GSR:373,ECG:79
0.0548151999974	GSR:373,ECG:79
0.0577630000043	GSR:373,ECG:79
0.0608754999994	GSR:373,ECG:79

Figura 61. Lectura de sensores Grove Usuario 1-P1

En la figura 27 que corresponde al sensor de Mysignals, los valores en -1 indican que el Arduino no está recibiendo información del sensor. Este error ocurrió varias veces en las pruebas.

0.0448810999515,GSR:-1.00,ECG:2.91
0.0738252999727,GSR:-1.00,ECG:2.91
0.102835899976,GSR:-1.00,ECG:2.91
0.13187099999,GSR:-1.00,ECG:2.91
0.160935499996,GSR:-1.00,ECG:2.91
0.189856699959,GSR:-1.00,ECG:2.91
0.21883779997,GSR:-1.00,ECG:2.91

Figura 62. Lectura de sensores Grove Usuario 2-P1